



Journal of Data Mining and Information Systems

<https://journal.yp3a.org/index.php/JDMIS>

DOI Prefix: 10.54259/jdmis.v3i2

Vol. 3, No. 2, August 2025

e-ISSN: 2986-3473
p-ISSN: 2986-5271



Diterbitkan Oleh:

Yayasan Pendidikan Penelitian Pengabdian Algero

Jl. Glugur Rimbun, Perum. Medan Hills, Cluster Eboni, Blok J No. 3. Indonesia

Website: <https://journal.yp3a.org/index.php/jdmis>

Email: jurnal.jdmis@gmail.com



Journal of Data Mining and Information Systems

<https://journal.yp3a.org/index.php/JDMIS>

DOI Prefix: 10.54259/jdmis.v3i2

Vol. 3, No. 2, August 2025

e-ISSN: 2986-3473
p-ISSN: 2986-5271

Volume 3 Nomor 2 (Agustus 2025)

Evaluasi Kinerja Bisnis Berbasis Business Intelligence Dashboard pada UD. Sentral

Daniel Lexandrosth Halim, Nicholas Calim, Audrey Tamalate, Winnie Felicia

Analisis Sentimen Ulasan Perbedaan Aplikasi BCA Mobile dengan MyBCA di Playstore Menggunakan Metode Lexicon

Jesslyn Patricia Yoman, Cherry Cok, Kerstyn Laigusten, Geovani Zovintho

Analisis Sentimen Churn Pelanggan dalam Layanan Streaming NETFLIX di X Menggunakan Metode IndoBERT

Farencia Levis, Cindy Chuwardi, Yoshe Wuvanka, Eveleen Huandra

Penerapan Algoritma K-Nearest Neighbors untuk Klasifikasi Kualitas Air Minum

Jansen, Cariven Tanova, Dariel, Marciano, Ade Maulana

Penilaian Kualitas Layanan WiFi Oxygen dan Kolerasinya terhadap Kepuasan Pengguna

Chaca Ananda Putri, Afifah Kurnia Fadillah

Implementasi Market Basket Analysis dengan Algoritma Frequent Pattern Growth pada Data Transaksional di Electronic Commerce

Athaya Fairuzindah, Istiqomah Rabithah Alam Islami, Nafa Rexa, Silvia Anggraini, Etis Sunandi

Deteksi Sentimen Komentar Aplikasi Gobis Suroboyo dengan Metode Naive Bayes dan Metode Regresi Logistik

Shifa Elmaliyasari, Muhammad Arsyad Alzam, Nanda Aulia Pratiwi, Shindi Sheila May Wara, Kartika Maulida Hindrayani



Diterbitkan Oleh:

Yayasan Pendidikan Penelitian Pengabdian Algero

Jl. Glugur Rimbun, Perum. Medan Hills, Cluster Eboni, Blok J No. 3. Indonesia

Website: <https://journal.yp3a.org/index.php/jdmis>

Email: jurnal.jdmis@gmail.com

JDIMS (Journal of Data Mining and Information Systems)

Vol. 3 No. 2 (Agustus 2025)

EDITOR IN CHIEF

Jefri Junifer Pangaribuan (Scopus ID: 57213221087, Universitas Pelita Harapan, Jakarta, Indonesia)

EDITORIAL BOARD

1. Mirza Ilhami (Scopus ID: 56703365400, Universitas Mikroskil, Medan, Indonesia)
2. Eddy Kurniawan (Scopus ID: 57215113944, Universitas Pesantren Tinggi Darul Ulum, Jombang, Indonesia)
3. Ali Akbar Lubis (Scopus ID: 57214068544, Universitas Negeri Medan, Indonesia)
4. Faisal Nadjar (Scopus ID: 57988165100, Universitas Pelita Harapan, Jakarta, Indonesia)
5. Erlangga (Google Scholar: nyaoWYgAAAAJ, Universitas Bandar Lampung, Indonesia)
6. Jusin (Scopus ID: 57211317974, Universitas Pelita Harapan, Jakarta, Indonesia)
7. Raissa Amanda Putri (Scopus ID: 57207730940, Universitas Islam Negeri Sumatera Utara, Medan, Indonesia)
8. Muhamad Fahmi Nugraha (Google Scholar: UBy3dMwAAAAJ, Universitas Ma'soem, Sumedang, Indonesia)
9. Segar Napitupulu (Google Scholar: 0kVXTn4AAAAJ, Universitas Mikroskil, Medan, Indonesia)

REVIEWER BOARD

1. Prof. Dr. Dahlan Abdullah, ST, M.Kom, IPU, ASEAN Eng. (Scopus ID: 57205132023, Universitas Malikussaleh, Aceh, Indonesia)
2. Dr. Ronsen Purba, M.Sc. (Scopus ID: 57215525192, Universitas Mikroskil, Medan, Indonesia)
3. Romindo, S.Kom., M.Kom. (Scopus ID: 57222623835, Universitas Pelita Harapan, Medan, Indonesia)

4. Kelik Sussolaikah, S.Kom., M.Kom. (Scopus ID: 57209271915, Universitas PGRI, Madiun, Indonesia)
5. Ade Maulana, S.Kom., M.T.I. (Scopus ID: 57211039635, Universitas Pelita Harapan, Medan, Indonesia)
6. Darsono Nababan, S.Kom., M.Kom. (Scopus ID: 57203861998, Universitas Timor, Kefamenanu, Indonesia)
7. Yudhistira Adhitya Pratama, S.Kom., M.Kom. (Scopus ID: 57987583100, Universitas Sumatera Utara, Medan, Indonesia)
8. I Made Ardwi Pradnyana, S.T., M.T. (Scopus ID: 57202607891, Universitas Pendidikan Ganesha, Bali, Indonesia)
9. Dr. Adli Abdillah Nababan, S.Kom., M.Kom. (Scopus ID: 57202310083, Universitas Prima Indonesia, Medan, Indonesia)
10. Oman Somantri, S.Kom., M.Kom. (Scopus ID: 57208898676, Politeknik Negeri Cilacap, Indonesia)
11. Frans Mikael Sinaga, S.Kom., M.Kom. (Scopus ID: 57215527202, Universitas Mikroskil, Medan, Indonesia)

JDIMS (Journal of Data Mining and Information Systems)

Vol. 3 No. 2 (Agustus 2025)

Daftar Isi

Evaluasi Kinerja Bisnis Berbasis Business Intelligence Dashboard pada UD. Sentral

Daniel Lexandrosth Halim, Nicholas Calim, Audrey Tamalate, Winnie Felicia54-63

Analisis Sentimen Ulasan Perbedaan Aplikasi BCA Mobile dengan MyBCA di Playstore
Menggunakan Metode Lexicon

Jesslyn Patricia Yoman, Cherry Cok, Kerstyn Laigusten, Geovani Zovintho64-76

Analisis Sentimen Churn Pelanggan dalam Layanan Streaming NETFLIX di X Menggunakan
Metode IndoBERT

Farencia Levis, Cindy Chuwardi, Yoshe Wuvanka, Eveleen Huandra.....77-85

Penerapan Algoritma K-Nearest Neighbors untuk Klasifikasi Kualitas Air Minum

Jansen, Cariven Tanova, Dariel, Marciano, Ade Maulana.....86-93

Penilaian Kualitas Layanan WiFi Oxygen dan Kolerasinya terhadap Kepuasan Pengguna

Chaca Ananda Putri, Afifah Kurnia Fadillah.....94-100

Implementasi Market Basket Analysis dengan Algoritma Frequent Pattern Growth pada Data
Transaksional di Electronic Commerce

***Athaya Fairuzindah, Istiqomah Rabithah Alam Islami, Nafa Rexa, Silvia Anggraini,
Etis Sunandi.....101-107***

Deteksi Sentimen Komentar Aplikasi Gobis Suroboyo dengan Metode Naive Bayes dan
Metode Regresi Logistik

***Shifa Elmaliyasari, Muhammad Arsyad Alzam, Nanda Aulia Pratiwi, Shindi Sheila
May Wara, Kartika Maulida Hindrayani.....108-116***

Evaluasi Kinerja Bisnis Berbasis *Business Intelligence Dashboard* pada UD. Sentral

Daniel Lexandrosth Halim¹, Nicholas Calim², Audrey Tamalate³, Winnie Felicia⁴

^{1,2,3,4} Sistem Informasi (Kampus kota Medan), Universitas Pelita Harapan, Medan, Indonesia

Email: ¹03081220025@student.uph.edu, ²03081220021@student.uph.edu, ³03081220017@student.uph.edu,

⁴03081220002@student.uph.edu

ABSTRAK

Penelitian ini bertujuan untuk mengevaluasi efektivitas implementasi *Business Intelligence (BI) Dashboard* dalam mendukung proses evaluasi kinerja bisnis pada UD. Sentral, sebuah usaha dagang yang bergerak di bidang distribusi kartu data dan voucher pulsa. Permasalahan utama yang dihadapi adalah proses pencatatan dan pelaporan data secara manual yang memakan waktu, rawan kesalahan, serta kurangnya visualisasi data yang informatif bagi manajemen. Penelitian ini menggunakan pendekatan kualitatif melalui wawancara dan observasi terhadap pemilik serta staf operasional untuk mengidentifikasi kebutuhan pengguna dan permasalahan yang ada. Data operasional kemudian diolah dan divisualisasikan menggunakan *Power BI* dalam bentuk *dashboard* yang menyajikan indikator kinerja utama (KPI), seperti total penjualan, pergerakan stok, jumlah pelanggan, hingga tren penjualan bulanan. Hasil implementasi menunjukkan bahwa *dashboard BI* mampu meningkatkan efisiensi pemantauan bisnis, mempercepat proses evaluasi, serta mendukung pengambilan keputusan strategis berbasis data. Selain itu, *dashboard* juga mendorong budaya kerja berbasis data dan memungkinkan identifikasi dini terhadap penurunan performa bisnis. Temuan ini memberikan kontribusi dalam pengembangan sistem informasi berbasis data bagi UMKM di Indonesia.

Kata Kunci: *Business Intelligence, Dashboard, Evaluasi Kinerja, UMKM, Power BI*

ABSTRACT

This study aims to evaluate the effectiveness of implementing a *Business Intelligence (BI) Dashboard* in supporting the business performance evaluation process at UD. Sentral, a trading company engaged in the distribution of data cards and voucher products. The main issues identified include manual data recording and reporting processes that are time-consuming, prone to errors, and lack informative visualizations for management. A qualitative approach was used through interviews and direct observation with the business owner and operational staff to identify user needs and challenges. Operational data were then processed and visualized using *Power BI* in the form of a dashboard displaying Key Performance Indicators (KPIs), such as total sales, stock movement, customer count, and monthly sales trends. The implementation results showed that the BI dashboard improved business monitoring efficiency, accelerated evaluation processes, and supported strategic data-driven decision-making. Furthermore, the dashboard encouraged a data-driven culture and enabled early identification of declining business performance. These findings contribute to the development of data-based information systems for MSMEs in Indonesia.

Keywords: *Business Intelligence, Dashboard, Performance Evaluation, MSMEs, Power BI*

Penulis Korespondensi:

Daniel Lexandrosth Halim

Email: 03081220025@student.uph.edu

Article Info

Diterima: 11 April 2025

Direvisi: 15 April 2025

Disetujui: 22 April 2025

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



1. PENDAHULUAN


Di tengah persaingan bisnis yang semakin ketat dan perkembangan teknologi informasi yang pesat, perusahaan dituntut untuk mampu beradaptasi dengan cepat dalam menghadapi dinamika pasar. Pengambilan keputusan yang tepat dan berdasarkan data yang akurat menjadi salah satu kunci utama dalam menjaga keberlangsungan dan pertumbuhan bisnis [1]. Untuk itu, perusahaan perlu memiliki sistem yang dapat mengelola, menganalisis, dan menyajikan data operasional maupun strategis secara efisien dan informatif. Salah satu pendekatan yang dapat digunakan untuk menjawab tantangan tersebut adalah pemanfaatan *Business Intelligence (BI)*.

Business Intelligence merupakan sekumpulan teknologi, aplikasi, dan proses yang digunakan untuk mengumpulkan, mengintegrasikan, menganalisis, dan memvisualisasikan data bisnis. Melalui BI, perusahaan dapat memperoleh wawasan mendalam tentang kinerja operasional, tren pasar, perilaku pelanggan, serta berbagai indikator lainnya yang penting dalam mendukung proses pengambilan keputusan [2]. Salah satu komponen utama dari BI adalah *dashboard*, sebuah alat visualisasi yang menyajikan informasi dalam bentuk grafik, diagram, dan indikator kinerja secara *real-time* dan mudah dipahami oleh pengguna bisnis. Studi oleh Picozzi [3], menunjukkan bahwa penggunaan perangkat lunak BI untuk memantau *Key Performance Indicators* (KPI) dalam sistem manajemen pemeliharaan terkomputerisasi dapat meningkatkan efisiensi dan akurasi evaluasi kinerja.

UD. Sentral merupakan sebuah usaha dagang yang bergerak di bidang distribusi dan penjualan kartu data yang dibutuhkan sehari-hari. Seiring dengan bertambahnya jumlah transaksi dan semakin kompleksnya proses bisnis, UD. Sentral menghadapi tantangan dalam memantau dan mengevaluasi kinerja usahanya secara menyeluruh. Selama ini, proses pelaporan dan analisis data masih dilakukan secara konvensional, seperti menggunakan *spreadsheet* atau pencatatan manual, yang tidak hanya memakan waktu tetapi juga berisiko menimbulkan kesalahan data. Selain itu, kurangnya visualisasi data yang informatif membuat manajemen kesulitan untuk dengan cepat mengidentifikasi area bisnis yang mengalami penurunan performa atau membutuhkan perhatian lebih.

Dalam kondisi tersebut, manajemen UD. Sentral mengalami kesulitan untuk mengambil keputusan yang cepat dan tepat berbasis data yang tersedia. Hal ini berdampak langsung terhadap kemampuan perusahaan dalam merespons perubahan permintaan pasar, mengelola persediaan secara efisien, dan meningkatkan kepuasan pelanggan. Oleh karena itu, dibutuhkan suatu sistem yang mampu menyajikan informasi kinerja bisnis secara cepat, akurat, dan mudah dipahami, agar manajemen dapat melakukan evaluasi dan perbaikan proses bisnis secara berkelanjutan.

Dengan menerapkan *Business Intelligence Dashboard*, UD. Sentral dapat memantau berbagai indikator kinerja utama (*Key Performance Indicators*), seperti penjualan, persediaan, profitabilitas, dan performa cabang, dalam satu tampilan terintegrasi. *Dashboard* ini tidak hanya mempercepat proses evaluasi, tetapi juga membantu manajemen dalam merumuskan strategi yang lebih tepat sasaran [4].



Gambar 1. *Key Performance Indicator* [5]

Melalui penelitian ini, diharapkan dapat dilakukan evaluasi terhadap implementasi *Business Intelligence Dashboard* dalam konteks usaha dagang seperti UD. Sentral. Penelitian ini juga bertujuan untuk mengkaji bagaimana *dashboard* BI dapat memberikan kontribusi nyata dalam meningkatkan efisiensi, akurasi, dan kualitas evaluasi kinerja bisnis di perusahaan tersebut. Dengan demikian, hasil dari penelitian ini diharapkan dapat menjadi referensi dalam pengembangan sistem informasi berbasis data yang efektif untuk UMKM di Indonesia.

Selain meningkatkan efisiensi pengelolaan data, implementasi *Business Intelligence* juga dapat memberikan keunggulan kompetitif bagi perusahaan [6]. Dengan kemampuan untuk memantau tren pasar secara *real-time*, perusahaan dapat lebih sigap dalam menyesuaikan strategi pemasaran, menetapkan target penjualan yang realistis, serta mengantisipasi potensi risiko bisnis. Dalam konteks UD. Sentral, pemanfaatan *dashboard* BI memungkinkan identifikasi lebih awal terhadap produk-produk dengan penurunan permintaan, sehingga strategi promosi dan pengelolaan stok dapat disesuaikan secara optimal.

Lebih jauh, transformasi digital melalui BI tidak hanya berdampak pada proses pengambilan keputusan, tetapi juga mendorong budaya kerja berbasis data (*data-driven culture*) di lingkungan organisasi [7]. Dengan informasi yang tersedia secara transparan dan terpusat, setiap bagian dalam perusahaan dapat berkontribusi secara kolaboratif dalam pencapaian target bisnis. Hal ini sangat penting bagi UD. Sentral sebagai usaha dagang yang sedang berkembang, agar mampu bersaing secara lebih strategis dan adaptif terhadap perubahan yang terjadi di sektor perdagangan.

2. LANDASAN TEORI

Untuk mendukung pemahaman terhadap penelitian ini, berikut dilampirkan konsep-konsep teoritis yang mencakup pemahaman mengenai *Business Intelligence*, peran *dashboard* dalam BI, evaluasi kinerja bisnis, serta studi terdahulu yang menjadi landasan dalam merancang dan mengevaluasi sistem BI *dashboard* di UD. Sentral.

2.1. Business Intelligence

Business Intelligence adalah sekumpulan teknologi, aplikasi, dan praktik yang memakai model matematis dan metode analitis untuk mengumpulkan, mengintegrasikan, menganalisis, serta memanfaatkan data yang telah disediakan untuk menyajikan informasi bisnis guna mendukung pengambilan keputusan perusahaan yang lebih baik [8]. Dalam konteks ini, *Business Intelligence* tidak hanya membantu dalam melakukan visualisasi data, namun juga menyediakan wawasan yang dapat ditindaklanjuti melalui pengukuran *Key Performance Indicators* (KPI).

2.2. Evaluasi Kinerja Bisnis

Evaluasi kinerja bisnis adalah sebuah proses pengukuran dan penilaian atas aktivitas-aktivitas yang dilakukan perusahaan dalam mencapai tujuan strategis bisnis [9]. Dalam implementasinya, pengukuran ini dapat dilakukan menggunakan indikator seperti profitabilitas, efisiensi operasional, produktivitas, dan tingkat kepuasan pelanggan.

2.3. Dashboard Business Intelligence

Dashboard dalam *Business Intelligence* merupakan tampilan antarmuka visual yang dimana data-data dalam database perusahaan diolah kemudian menyajikan informasi penting dalam bentuk grafik visual sehingga memudahkan dalam melakukan analisis [10]. *Dashboard* juga menyediakan informasi secara cepat, tepat, jelas, dan interaktif. Selain itu, visualisasi BI juga dapat memberikan manfaat berupa monitoring performa, mendeteksi anomali data, dan mendukung keputusan berbasis fakta [11].

2.4. Penelitian Terdahulu

Berikut merupakan beberapa penelitian terdahulu yang menunjukkan bahwa penggunaan BI *dashboard* meningkatkan efisiensi dan efektivitas pengambilan keputusan bisnis.


Table 1. Studi Terdahulu Implementasi *Dashboard* BI

No	Judul	Tujuan	Metode	Hasil
1	<i>Dashboard Visualisasi Data UMK Sebagai Alat Pengambilan Keputusan Menggunakan Microsoft Power BI</i> [12]	Mengevaluasi implementasi <i>dashboard Business Intelligence</i> dalam visualisasi data UMK di Indonesia	Studi deskriptif dengan pendekatan kuantitatif, menggunakan data sekunder dari instansi terkait yang diolah dan divisualisasikan melalui <i>dashboard</i> BI.	Studi menunjukkan implementasi <i>dashboard</i> BI visualisasi data UMK per provinsi di Indonesia dapat memberikan gambaran menyeluruh terhadap sebaran usaha, jumlah pekerja, pendapatan, dan pengeluaran. Jawa Timur menjadi provinsi dengan performa UMK tertinggi dari sisi jumlah usaha, serapan tenaga kerja, hingga pendapatan, sedangkan Kalimantan Utara dan Maluku Utara tercatat memiliki kinerja terendah. <i>Dashboard</i> BI membantu pengambilan keputusan yang lebih cepat berbasis data <i>real-time</i> , serta menjadi alat strategis dalam perencanaan investasi UMK di berbagai sektor ekonomi.
2	<i>Sistem Dashboard untuk Visualisasi Data Pendapatan dan Pengeluaran Berbasis Web PT. XYZ</i> [10]	Menganalisis efektivitas pemanfaatan <i>dashboard Business Intelligence</i> dalam meningkatkan kualitas pengambilan keputusan di sektor logistik	Pendekatan kuantitatif deskriptif dengan pengumpulan data primer melalui kuesioner yang disebarakan kepada pengguna sistem <i>dashboard</i> BI di sektor logistik.	Hasil menunjukkan bahwa <i>dashboard</i> BI berperan signifikan dalam meningkatkan efisiensi pemantauan aktivitas logistik, mempercepat analisis kinerja, dan mendukung pengambilan keputusan berbasis data secara lebih tepat dan responsif terhadap dinamika operasional.
3	<i>Dashboard Business Intelligence Data Akreditasi Sekolah Pada SMP Negeri 1 Sumbawa</i> [13]	Mengembangkan <i>dashboard</i> BI untuk mendukung analisis data kepegawaian dan penggajian.	Metode prototyping dengan analisis kebutuhan, perancangan, dan evaluasi sistem.	Studi menunjukkan <i>Dashboard</i> yang diimplementasi membantu penyajian data secara visual dan <i>real-time</i> , mempermudah pengambilan keputusan manajerial.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kualitatif untuk mendapatkan pemahaman mendalam tentang Evaluasi Kinerja Bisnis Berbasis *Business Intelligence Dashboard* pada UD. Sentral. Pendekatan ini dipilih karena memungkinkan peneliti untuk

memperoleh data secara langsung dari pihak yang terlibat dalam proses bisnis, sehingga hasil yang diperoleh lebih kontekstual dan sesuai dengan kondisi nyata di lapangan [14]. Tahapan-tahapan penelitian akan dilampirkan pada gambar berikut ini.



Gambar 2. Tahapan Penelitian

Pertama, metode yang digunakan adalah metode wawancara langsung dan observasi, yaitu teknik pengumpulan data yang dilakukan secara tatap muka dengan subjek penelitian. Wawancara dilakukan dengan pemilik usaha sebagai bentuk permintaan persetujuan terhadap penelitian yang dilakukan, sekaligus untuk menggali kebutuhan dan permasalahan yang sedang dihadapi oleh perusahaan. Wawancara dilakukan secara semi-terstruktur, di mana peneliti menyiapkan beberapa pertanyaan utama namun tetap memberikan ruang untuk diskusi terbuka agar informasi yang diperoleh lebih fleksibel dan mendalam. Berikut daftar pertanyaan yang akan diberikan kepada pemilik usaha :

Table 2. Daftar Pertanyaan Pemilik Usaha

Pertanyaan untuk Pemilik Usaha	
No	Pertanyaan
1	Bisa ceritakan sedikit mengenai UD. Sentral? Usaha ini bergerak di bidang apa saja?
2	Sejak kapan usaha ini berdiri?
3	Bagaimana biasanya Bapak/Ibu melakukan evaluasi kinerja usaha? (misalnya: laporan penjualan, stok, keuangan)
4	Apakah proses evaluasi kinerja tersebut dilakukan secara berkala (mingguan/bulanan)?
5	Apakah ada kesulitan dalam melakukan evaluasi kinerja usaha secara manual?
6	Data apa saja yang biasanya dikumpulkan setiap hari? (penjualan, stok, keuangan, dsb.)
7	Siapa yang biasanya mencatat dan mengelola data tersebut?
8	Apakah data tersebut sudah pernah divisualisasikan sebelumnya (misalnya dalam bentuk grafik, tabel, atau <i>dashboard</i>)?
9	Menurut Bapak/Ibu, informasi apa saja yang penting untuk dimiliki agar dapat mengambil keputusan yang tepat?
10	Apakah Bapak/Ibu pernah mendengar atau menggunakan <i>Business Intelligence Dashboard</i> ?
11	Jika ada sistem yang dapat menyajikan informasi penjualan, stok, dan keuntungan dalam bentuk visual secara <i>real-time</i> , apakah Bapak/Ibu tertarik menggunakannya?
12	Apa harapan Bapak/Ibu jika <i>dashboard</i> ini diterapkan di UD. Sentral?

Selain itu, peneliti juga mewawancarai salah satu pekerja operasional di UD. Sentral untuk mendapatkan informasi mendalam tentang proses kerja, pengelolaan data, dan sistem pelaporan kinerja yang digunakan sebelum dan sesudah penggunaan *dashboard*. Berikut daftar pertanyaan yang akan diberikan kepada karyawan :

Table 3. Daftar Pertanyaan Karyawan Terkait

Pertanyaan untuk Pekerja (Staf Operasional)	
No	Pertanyaan
1	Apa saja tugas utama yang biasa Anda kerjakan setiap hari?
2	Apakah Anda terlibat dalam pencatatan transaksi atau pengelolaan data penjualan?
3	Bagaimana proses pencatatan penjualan dilakukan di UD. Sentral? Apakah dicatat di buku, Excel, atau aplikasi tertentu?
4	Apakah Anda pernah mengalami kendala saat mencatat atau mengelola data (misalnya kehilangan data, kesalahan input, keterlambatan rekap data, dsb.)?
5	Apakah Anda pernah melihat <i>dashboard</i> yang menampilkan grafik penjualan atau stok barang?

Selain wawancara, peneliti juga melakukan observasi langsung terhadap alur kerja dan pengelolaan data di lokasi usaha. Observasi ini bertujuan untuk memahami bagaimana data operasional (seperti penjualan, stok, dan keuangan) dicatat, diproses, dan digunakan untuk evaluasi oleh pemilik atau karyawan. Setelah proses wawancara dan observasi dilakukan, peneliti mulai

merancang *Business Intelligence Dashboard* sesuai kebutuhan yang telah diidentifikasi. Hasil wawancara dan pengamatan menjadi dasar dalam memilih indikator-indikator kinerja utama (*Key Performance Indicators/KPI*) yang akan divisualisasikan. Data yang digunakan dalam *dashboard* diambil dari laporan penjualan, laporan stok barang, dan catatan transaksi yang telah tersedia.

Data hasil wawancara dan observasi dianalisis menggunakan teknik analisis tematik (*thematic analysis*), di mana peneliti mengidentifikasi pola dan tema dari jawaban responden. Hasil analisis ini akan disintesis untuk menarik kesimpulan mengenai efektivitas *dashboard* dalam mendukung proses evaluasi kinerja di UD. Sentral. Setelah data dari wawancara dan observasi dikumpulkan, peneliti melakukan transkripsi terhadap hasil wawancara secara manual. Selanjutnya, data dianalisis menggunakan teknik analisis tematik (*thematic analysis*) untuk mengidentifikasi pola-pola, isu utama, serta kebutuhan pengguna terhadap sistem *Business Intelligence Dashboard*. Proses ini melibatkan *coding* secara induktif untuk mengelompokkan jawaban ke dalam tema-tema seperti kendala dalam pencatatan data, kebutuhan visualisasi informasi, dan harapan terhadap evaluasi kinerja yang lebih efisien [15].

Sementara itu, data operasional mentah dari UD. Sentral diperoleh dalam format Excel yang berisi informasi penjualan, stok barang, daftar produk, dan data pelanggan. Pengolahan data dilakukan menggunakan *Google Colab* dengan bahasa pemrograman *Python*. Proses pengolahan ini mencakup [16] :

1. Pembersihan data (*data cleaning*)
Seperti penghapusan data duplikat, penanganan nilai kosong (*missing values*), dan konsistensi nama produk atau kategori pelanggan.
2. Standarisasi format
Seperti penyamaan format tanggal pada data penjualan dan stok, serta penyesuaian format angka (harga jual, modal, dan total transaksi).
3. Penggabungan antar *sheet*
Menghubungkan data penjualan dengan data produk dan pelanggan berdasarkan *id_produk* dan *id_pelanggan*.
4. Pengelompokan data berdasarkan waktu
Untuk mendapatkan tren harian, mingguan, dan bulanan.
5. Perhitungan metrik penting
Seperti total penjualan per produk, margin keuntungan (*harga_jual - harga_modal*), total stok keluar/masuk per cabang, serta segmentasi penjualan berdasarkan kategori pelanggan (*Retail vs Reseller*).

Setelah data dinyatakan bersih dan terstruktur, hasilnya diekspor dan digunakan sebagai sumber data untuk membangun *Business Intelligence Dashboard*. Proses pembangunan *dashboard* dilakukan menggunakan *Power BI*, di mana data yang telah diolah divisualisasikan dalam bentuk grafik tren penjualan, laporan keuntungan, pergerakan stok, dan performa produk [17]. Visualisasi ini dibuat sesuai dengan kebutuhan informasi yang telah diidentifikasi dari hasil wawancara, sehingga *dashboard* dapat digunakan secara langsung oleh pemilik usaha untuk melakukan evaluasi kinerja secara *real-time* dan lebih efisien.

4. HASIL DAN PEMBAHASAN

Berikut hasil implementasi *Dashboard Business Intelligence* menggunakan *Power BI* yang diterapkan pada UD Sentral. Visualisasi yang ditampilkan pada *dashboard* mencerminkan kondisi dari data operasional perusahaan yang mencakup penjualan, produk, stok, pelanggan, hasil penjualan bulanan, dan lainnya. Tujuan utama dari pembuatan *dashboard* ini adalah untuk memberikan kemudahan dalam melakukan analisis dan evaluasi performa bisnis secara menyeluruh serta mendukung pengambilan keputusan berbasis data oleh pemilik.

4.1. Penggambaran *Dashboard* Kinerja Bisnis UD Sentral

Penggambaran *dashboard* interaktif akan menggunakan *Microsoft Power BI*. *Dashboard* ini diberi nama "*Business Performance Dashboard – UD Sentral*" karena dirancang untuk memberikan gambaran menyeluruh mengenai performa penjualan, pelanggan, produk, dan distribusi cabang dari perusahaan dagang UD Sentral. Selain itu, *Dashboard* ini bertujuan membantu pemilik usaha dalam mengambil keputusan strategis berbasis data dengan visualisasi yang informatif, cepat, dan mudah dipahami. Data yang dianalisis mencakup periode penjualan dari tahun 2024 hingga 2025. Penggambaran *dashboard* akan dilakukan melalui hasil data penjualan, data stok, data produk, data pelanggan yang telah melalui *proses Extract-Transform-Load (ETL)*. Berikut akan dilampirkan hasil data-data yang telah dilakukan pembersihan dan akan diolah dalam *Power BI* untuk pembuatan *dashboard* sebagai alat untuk evaluasi kinerja UD Sentral.

Data di bawah ini merupakan data produk, yang telah melalui proses pembersihan data. Data produk terdiri atas kolom *id_produk*, *nama_produk*, kategori, *harga_jual*, dan *harga_modal*. Penggambaran data disajikan pada table di bawah ini :

Table 4. Data Produk

id_produk	nama_produk	kategori	harga_jual	harga_modal
P0001	Axis Kartu Data 50000	Kartu Data	50000	44601
P0002	Telkomsel Voucher Pulsa 25000	Voucher Pulsa	25000	22113
P0003	Indosat Kartu Data 10000	Kartu Data	10000	8785

P0004	XL Kartu Data 15000	Kartu Data	15000	13400
P0005	Indosat Voucher Pulsa 10000	Voucher Pulsa	10000	8983
P0006	XL Voucher Pulsa 15000	Voucher Pulsa	15000	13546
P0007	Indosat Kartu Data 10000	Kartu Data	10000	8509
P0008	Axis Voucher Pulsa 50000	Voucher Pulsa	50000	45380
P0009	XL Kartu Data 50000	Kartu Data	50000	42691
P0010	Smartfren Voucher Pulsa 25000	Voucher Pulsa	25000	22093

Data di bawah ini merupakan data stok yang telah melalui proses pembersihan data. Data stok terdiri atas kolom id_stok, id_produk, cabang, tanggal, tipe_mutasi, dan jumlah. Penggambaran data disajikan pada tabel di bawah ini :

Table 5. Data Stok

id_stok	id_produk	cabang	tanggal	tipe_mutasi	jumlah
S0001	P0273	Medan Barat	2025-03-22	keluar	179
S0002	P0616	Medan Timur	2024-11-15	masuk	54
S0003	P0602	Medan Utara	2025-01-25	keluar	174
S0004	P0056	Medan Selatan	2025-02-15	masuk	41
S0005	P0841	Medan Utara	2024-10-22	masuk	111
S0006	P0298	Medan Barat	2025-03-07	keluar	94
S0007	P0941	Medan Kota	2025-01-23	masuk	10
S0008	P0187	Medan Utara	2024-10-22	masuk	182
S0009	P0499	Medan Timur	2025-01-31	keluar	111
S0010	P0209	Medan Utara	2024-12-30	keluar	93

Data di bawah ini merupakan data pelanggan, yang telah melalui proses pembersihan data. Data pelanggan terdiri atas kolom id_pelanggan, nama_pelanggan, dan kategori. Penggambaran data disajikan pada table di bawah ini :

Table 6. Data Pelanggan

id_pelanggan	nama_pelanggan	kategori
U0001	Iqbal ponsel	<i>Retail</i>
U0002	aff cell	<i>Reseller</i>
U0003	aff cell	<i>Reseller</i>
U0004	Arifah	<i>Reseller</i>
id_pelanggan	nama_pelanggan	kategori
U0005	gavcell	<i>Retail</i>
U0006	Laris Ponsel	<i>Reseller</i>
U0007	Iqbal ponsel	<i>Reseller</i>
U0008	Dilla	<i>Reseller</i>
U0009	ARSY PONSEL	<i>Retail</i>
U0010	Armay ponsel	<i>Reseller</i>

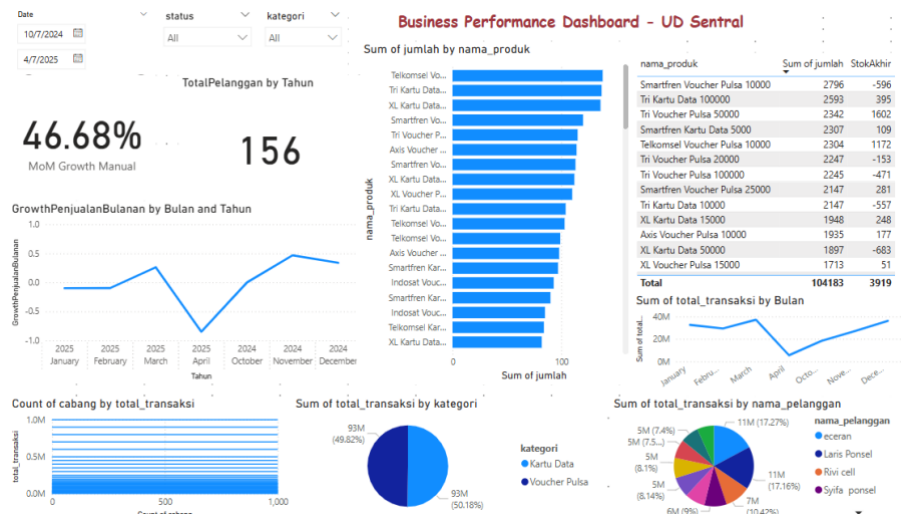
Data di bawah ini merupakan data penjualan, yang telah melalui proses pembersihan data. Data penjualan terdiri atas kolom nomor_pesanan, id_produk, id_pelanggan, tanggal_transaksi, jumlah, total_transaksi, dan status. Penggambaran data disajikan pada table di bawah ini :

Table 7. Data Penjualan

nomor_pesanan	id_produk	id_pelanggan	tanggal_transaksi	jumlah	total_transaksi	status
T00119	P0350	U0594	2025-04-07	7	70000	pending
T00705	P0600	U0792	2025-04-07	8	400000	success
T00936	P0623	U0613	2025-04-07	10	250000	success
T00026	P0568	U0046	2025-04-06	9	90000	success
T00062	P0273	U0772	2025-04-06	7	105000	success
T00600	P0160	U0395	2025-04-06	3	15000	success
T00730	P0229	U0190	2025-04-06	4	40000	success
T00832	P0989	U0805	2025-04-06	7	175000	success
T00956	P0143	U0556	2025-04-06	2	20000	pending
T00959	P0100	U0619	2025-04-06	7	105000	success

4.2. Hasil Visualisasi Dashboard

Setelah menginisiasi visual apa saja yang akan diimplementasi, selanjutnya dilakukan penggambaran langsung pada Power BI dan mendapatkan hasil dari olahan data dan visual dashboard. Berikut merupakan hasil visualisasi dashboard UD Sentral yang telah selesai digambarkan :



Gambar 3. Hasil Dashboard UD Sentral

4.2.1 Indikator Kinerja Utama (KPI) dan Tren Penjualan Bulanan

Bagian ini akan menjelaskan hasil dari bagian dashboard yang menunjukkan indikator kunci performa dan hasil analisis tren penjualan bulanan.

1. Growth Month-over-Month (MoM)
Indikator ini menunjukkan persentase perubahan penjualan dari bulan-bulan sebelumnya. Pada tampilan saat ini, nilai yang ditunjukkan adalah 46.68%. Persentase menunjukkan pertumbuhan penjualan karena adanya strategi pemasaran seperti promosi besar-besaran pada bulan sebelumnya. Dengan adanya metrik ini, manajemen dapat terus memantau tren dan merespons lebih cepat terhadap perubahan.
2. Total Pelanggan
Jumlah pelanggan yang tercatat hingga saat ini mencapai 156 pelanggan. Ini menunjukkan bahwa UD Sentral memiliki basis pelanggan yang luas, termasuk kategori grosir, Retail, dan Reseller, yang tersebar di berbagai cabang.
3. Growth Penjualan Bulanan Berdasarkan Bulan dan Tahun

Visualisasi *line chart* menampilkan pertumbuhan penjualan secara bulanan dalam dua tahun terakhir. Terlihat bahwa tren pertumbuhan cukup fluktuatif, namun secara umum menunjukkan kecenderungan positif pada akhir tahun 2024 dan awal tahun 2025, di mana bulan November dan Desember mencatatkan pertumbuhan yang stabil.

4. Total Transaksi Penjualan per Bulan

Jumlah total transaksi tertinggi terjadi pada bulan Maret, sedangkan penurunan terlihat pada bulan April. Pola seperti ini mengindikasikan adanya siklus tahunan atau pengaruh periode tertentu (seperti Ramadhan, tahun baru, atau libur sekolah) terhadap volume penjualan.

4.2.2 Analisis Produk, Penjualan, dan Pelanggan

Bagian ini akan menjelaskan hasil dari bagian *dashboard* yang menunjukkan performa produk dan hasil analisis dari penjualan produk.

1. Produk Terlaris Berdasarkan Jumlah

Grafik bar horizontal menunjukkan bahwa produk dengan penjualan tertinggi adalah Telkomsel Voucher Pulsa 10000, Tri Kartu Data 100000, dan Tri Voucher Pulsa 50000. Produk-produk ini merupakan produk dengan nominal kecil-menengah yang memang cenderung lebih cepat terjual dan lebih banyak diminati oleh konsumen ritel.

2. Jumlah Penjualan dan Stok Akhir

Tabel ini menggabungkan dua informasi penting, yaitu jumlah penjualan dan stok akhir dari masing-masing produk. Terlihat bahwa beberapa produk memiliki stok akhir negatif, yang dapat mengindikasikan adanya transaksi yang belum dikonfirmasi atau kebutuhan *restock* yang mendesak. Visualisasi ini sangat bermanfaat untuk bagian logistik dalam menentukan prioritas pengadaan barang.

3. Transaksi per Cabang

Diagram batang vertikal memperlihatkan jumlah transaksi dari masing-masing cabang. Data ini penting untuk mengetahui kontribusi setiap cabang terhadap total penjualan. Cabang-cabang dengan jumlah transaksi tinggi dapat menjadi fokus dalam strategi pengembangan bisnis, sedangkan cabang dengan volume rendah bisa menjadi perhatian untuk dilakukan evaluasi.

4. Transaksi per Kategori Produk

Diagram *pie chart* menunjukkan distribusi penjualan berdasarkan dua kategori utama, yaitu Kartu Data dan Voucher Pulsa. Masing-masing kategori memberikan kontribusi hampir seimbang, yaitu sekitar 50% masing-masing. Hal ini menunjukkan bahwa kedua kategori memiliki potensi yang sama besar dan keduanya perlu dikelola dengan strategi penjualan dan stok yang seimbang.

5. Top Pelanggan Berdasarkan Total Transaksi

Visualisasi *pie chart* menunjukkan pelanggan dengan transaksi terbanyak. Pelanggan seperti eceran, Laris Ponsel, Rivi Cell, dan Syifa Ponsel menempati urutan teratas. Pelanggan-pelanggan ini bisa dikategorikan sebagai pelanggan prioritas atau VIP, sehingga manajemen dapat memberikan perhatian khusus, seperti diskon khusus, layanan personalisasi, atau prioritas pengiriman.

4.2.3 Interpretasi Hasil Analisis

Berdasarkan hasil visualisasi dan eksplorasi data yang telah dilakukan dan dari hasil penggambaran *dashboard* pada UD Sentral, dapat disimpulkan bahwa :

1. Performa bisnis UD Sentral menunjukkan potensi pertumbuhan yang baik, dengan basis pelanggan yang stabil dan produk-produk unggulan yang konsisten mendominasi penjualan.
2. Fluktuasi penjualan bulanan merupakan hal wajar dalam siklus bisnis, dan *dashboard* ini mampu memberikan peringatan dini jika terjadi penurunan performa secara signifikan.
3. Kategori produk dan distribusi pelanggan tersebar cukup merata, yang menunjukkan bahwa bisnis ini tidak terlalu bergantung pada satu jenis produk atau satu pelanggan besar saja.
4. Adanya stok negatif perlu segera ditindaklanjuti melalui koordinasi antara divisi penjualan dan pergudangan agar tidak menimbulkan *backlog* pesanan atau ketidakpuasan pelanggan.

Untuk itu, UD Sentral memerlukan perbaikan pada sistem penjualannya, melalui cara sebagai berikut :

1. Penanganan Stok Negatif Secara Serius

Stok negatif merupakan indikator adanya ketidaksesuaian antara data penjualan dan persediaan. UD Sentral perlu segera meningkatkan koordinasi antara tim penjualan dan pergudangan serta menerapkan sistem validasi stok sebelum transaksi untuk mencegah *backlog* pesanan dan menjaga kepuasan pelanggan.

2. Optimalisasi Manajemen Inventaris

Dengan data yang tersedia, UD Sentral dapat mulai menerapkan strategi manajemen stok seperti *reorder point* dan *safety stock* untuk memastikan ketersediaan produk dan menghindari kelebihan stok yang tidak efisien.

3. Peningkatan Pelayanan kepada Pelanggan Loyal

Data pelanggan dengan pembelian tertinggi dapat dimanfaatkan untuk membuat program loyalitas atau penghargaan khusus. Ini penting untuk menjaga hubungan jangka panjang dengan pelanggan yang memberikan kontribusi besar terhadap pendapatan.

4. Evaluasi Strategi Produk Berdasarkan Kategori

Dengan mengetahui kategori produk yang paling laris dan yang kurang diminati, perusahaan dapat mengatur kembali portofolio produknya. Fokus pada produk unggulan akan meningkatkan efisiensi operasional dan potensi penjualan. Penggambaran *dashboard* juga memberikan manfaat dalam pengambilan keputusan oleh pemilik. Berikut merupakan manfaat yang didapatkan dari hasil implementasi *dashboard* :

1. Menyediakan data *real-time* dalam format visual yang mudah dipahami.
2. Membantu manajemen melakukan monitoring performa secara berkala.
3. Memberikan panduan untuk melakukan evaluasi strategi penjualan, distribusi stok, dan pelayanan pelanggan secara lebih efisien.

5. KESIMPULAN

Penelitian ini menyoroti pentingnya implementasi *Business Intelligence Dashboard* dalam meningkatkan efisiensi dan akurasi evaluasi kinerja bisnis di UD. Sentral, sebuah usaha dagang yang bergerak di bidang distribusi kartu data. Dalam menghadapi tantangan pencatatan data manual yang memakan waktu dan rawan kesalahan, serta kurangnya visualisasi informasi yang informatif, *dashboard* BI terbukti mampu menjadi solusi yang relevan dan strategis. Dengan pendekatan kualitatif melalui wawancara dan observasi langsung, penelitian ini berhasil mengidentifikasi kebutuhan pengguna terhadap sistem informasi yang mampu menyajikan data secara *real-time* dan mudah dipahami. *Dashboard* yang dikembangkan menggunakan *Power BI* mampu menampilkan berbagai indikator kinerja utama (KPI) seperti total penjualan, jumlah pelanggan, pergerakan stok, dan tren pertumbuhan penjualan bulanan secara visual dan interaktif.

Implementasi BI *Dashboard* tidak hanya mempercepat proses analisis, tetapi juga mendukung budaya kerja berbasis data (*data-driven culture*), membantu manajemen dalam membuat keputusan yang lebih tepat, cepat, dan strategis. Selain itu, *dashboard* ini juga memungkinkan identifikasi dini terhadap penurunan performa produk atau area tertentu dalam bisnis. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa penggunaan *dashboard Business Intelligence* sangat bermanfaat dalam meningkatkan efektivitas pengambilan keputusan, efisiensi pemantauan bisnis, serta memberikan keunggulan kompetitif bagi UD. Sentral. Penelitian ini juga memberikan kontribusi yang dapat dijadikan acuan dalam pengembangan sistem informasi berbasis data untuk UMKM di Indonesia.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih yang sebesar-besarnya kepada UD Sentral Data atas kesediaannya menjadi objek penelitian dalam penyusunan tugas akhir ini. Dukungan dan penerimaan yang diberikan, serta akses terhadap data dan informasi yang relevan, telah memberikan kontribusi yang sangat berarti bagi kelancaran dan keberhasilan proses penelitian. Semoga hasil penelitian ini dapat memberikan manfaat dan masukan positif bagi pengembangan dan evaluasi kinerja bisnis di UD Sentral Data.

REFERENSI

- [1] R. N. Rosyidiana and I. M. Narsa, "Micro, small, and medium-sized enterprises (MSMEs) during the post-pandemic economic recovery period: digitalization, literation, innovation, and its impact on financial performance," *Cogent Bus. Manag.*, vol. 11, no. 1, 2024, doi: 10.1080/23311975.2024.2342488.
- [2] N. Wikamulia and S. M. Isa, "Predictive business intelligence dashboard for food and beverage business," *Bull. Electr. Eng. Informatics*, vol. 12, no. 5, pp. 3016–3026, Oct. 2023, doi: 10.11591/eei.v12i5.5162.
- [3] P. Picozzi, U. Nocco, A. Pezzillo, A. De Cosmo, and V. Cimolin, "The Use of Business Intelligence Software to Monitor Key Performance Indicators (KPIs) for the Evaluation of a Computerized Maintenance Management System (CMMS)," *Electron.*, vol. 13, no. 12, Jun. 2024, doi: 10.3390/electronics13122286.
- [4] T. Kongthanasuwan, N. Sriwiboon, B. Horbanluekit, W. Laesanklang, and T. Krityakierne, "Market Analysis with Business Intelligence System for Marketing Planning," *Inf.*, vol. 14, no. 2, Feb. 2023, doi: 10.3390/info14020116.
- [5] "Funtastic Tim Building," "Key Performance Indicators (KPI): Memahami Kunci Kesuksesan Bisnis," labiruevent.com.
- [6] S. Supramono, T. W. Damayanti, and D. Adhitya, "Dynamic capabilities and financial behavior to accelerate MSME performance recovery and its impacts on business sustainability," *J. Innov. Entrep.*, vol. 14, no. 1, Dec. 2025, doi: 10.1186/s13731-024-00456-7.
- [7] N. Kawengian, V. Ilat, S. Pinatik Jurusan Akuntansi, F. Ekonomi dan Bisnis, U. Sam Ratulangi, and J. Kampus Bahu, "Analisis Pengukuran Kinerja Perusahaan Menggunakan Metode Balance Scorecard Pada PT Casa Diva Manado Analysis Of Company Performance Measurement Using The Balance Scorecard Method At PT Casa Diva Manado," 2024.
- [8] H. F. Ramadhan, A. Fauzi, N. C. Rupelu, P. D. Aprillia, D. N. Anjani, and Halimatusadiah, "PENGARUH BUSINESS INTELLIGENCE TERHADAP PERUSAHAANDALAM PENGAMBILAN KEPUTUSAN: BUSINESS INTELLIGENCE, ARSITEKTUR BI DAN DATA WAREHOUSE (KAJIAN STUDIBUSINESS INTELLIGENCE)," *JEMSI*, vol. 3, no. 6, Jul. 2022.
- [9] A. Anisah, "Evaluasi Benchmarking sebagai Strategi dalam Meningkatkan Keunggulan Bersaing dan Kinerja Bisnis," *J. Ilm. Univ. Batanghari Jambi*, vol. 24, no. 2, p. 1934, Jul. 2024, doi: 10.33087/jiubj.v24i2.5466.
- [10] D. Rio Aryanto, Q. H. Hidayah, and B. A. Sekti, "Sistem dashboard untuk visualisasi data pendapatan dan pengeluaran berbasis web PT. XYZ," 2024.
- [11] J. Khatib Sulaiman, J. Asher, and E. Putri Rachmawati, "Visualisasi Data Operasi SAR BASARNAS Di Indonesia Menggunakan Google Looker Studio," *Indones. J. Comput. Sci.*, 2024.
- [12] B. Lailatul Nafisa, Y. Novealita, W. Putri, and Q. Ayunin, "Dashboard Visualisasi Data UMK Sebagai Alat Pengambilan Keputusan Menggunakan Microsoft Power BI," vol. 17, no. 2, pp. 86–105, 2022, [Online]. Available:

- <https://akuntansi.pnp.ac.id/jam>
- [13] A. S. Wibowo and A. Andri, "Dashboard Business Intelligence Visualisasi Data Akreditasi Sekolah Pada SMP Negeri 1 Sembawa," *J. Nas. Ilmu Komput.*, vol. 2, Nov. 2021.
 - [14] Dr. H. Endang Solihin, *Pendekatan Kualitatif dalam Penelitian Pendidikan*, Cetakan Pertama. Tasikmalaya: Pustaka Ellios, 2021.
 - [15] D. C. Coker, "A THEMATIC ANALYSIS OF THE STRUCTURE OF DELIMITATIONS IN THE DISSERTATION," *Int. J. Dr. Stud.*, vol. 17, pp. 141–159, 2022, doi: 10.28945/4939.
 - [16] Y. Severianus and S. Kolo, "ANALISIS SENTIMEN TERHADAP OPINI MASYARAKAT TERKAIT PERUBAHAN CUACA DI INDONESIA MENGGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE," 2024.
 - [17] N. Susi, S. Sugiana, and B. Musty, "Analisis Data Sistem Informasi Monitoring Marketing; Tools Pengambilan Keputusan Strategic," 2023.

Analisis Sentimen Ulasan Perbedaan Aplikasi BCA Mobile dengan MyBCA di Playstore Menggunakan Metode Lexicon

Jesslyn Patricia Yoman¹, Cherry Cok², Kerstyn Laigusten³, Geovani Zovintho⁴

^{1,2,3,4} Sistem Informasi, Universitas Pelita Harapan, Medan, Indonesia

Email: ¹03081220024@student.uph.edu, ²03081220034@student.uph.edu, ³03081220044@student.uph.edu,

⁴03081220001@student.uph.edu

ABSTRAK

Penelitian ini bertujuan untuk menganalisis dan membandingkan sentimen pengguna terhadap dua aplikasi perbankan digital milik Bank Central Asia, yaitu BCA Mobile dan myBCA, berdasarkan ulasan pengguna yang diambil dari Google Playstore. Penelitian dilakukan dengan pendekatan kuantitatif berbasis teks, menggunakan metode *lexicon-based sentiment analysis* untuk mengklasifikasikan opini pengguna ke dalam kategori positif, negatif, dan netral. Data dikumpulkan melalui proses scraping dan diproses dengan teknik *preprocessing* teks seperti tokenisasi, penghapusan *stopword*, dan *stemming*. Hasil penelitian menunjukkan bahwa mayoritas ulasan tergolong netral, dengan proporsi ulasan positif pada myBCA lebih tinggi dibandingkan BCA Mobile. Analisis visual melalui grafik dan *wordcloud* berhasil menggambarkan perbedaan persepsi pengguna berdasarkan fitur aplikasi, seperti kemudahan *login*, tampilan antarmuka, serta kendala teknis. Studi ini menyimpulkan bahwa analisis sentimen merupakan alat yang efektif untuk mengevaluasi pengalaman pengguna dan memberikan masukan strategis bagi pengembangan layanan digital perbankan di masa mendatang.

Kata Kunci: Sentimen Pengguna, Aplikasi Mobile Banking, Analisis Lexicon, BCA Mobile, myBCA

ABSTRACT

This study aimed to analyze and compare user sentiment toward two digital banking applications owned by Bank Central Asia: BCA Mobile and myBCA, based on user reviews collected from the Google Playstore. The research employed a text-based quantitative approach, using a lexicon-based sentiment analysis method to classify user opinions into positive, negative, and neutral categories. Data were collected through web scraping and processed using text preprocessing techniques such as tokenization, stopword removal, and stemming. The results showed that most reviews were neutral, with myBCA receiving a higher proportion of positive reviews than BCA Mobile. Visual analyses through charts and wordclouds successfully illustrated differences in user perception related to application features such as login convenience, user interface design, and technical issues. This study concluded that sentiment analysis is an effective tool to evaluate user experience and provide strategic insights for the future development of digital banking services.

Keywords: User Sentiment, Mobile Banking Application, Lexicon Analysis, BCA Mobile, myBCA

Penulis Korespondensi:

Jesslyn Patricia Yoman

Email: 03081220024@student.uph.edu

Article Info

Diterima: 16 April 2025

Direvisi: 22 April 2025

Disetujui: 24 April 2025

This is an open access article under the [CC BY](#) license.



1. PENDAHULUAN

Transformasi digital dalam sektor perbankan telah mengalami akselerasi signifikan dalam dekade terakhir, ditandai oleh pergeseran besar dari layanan konvensional menuju platform berbasis *mobile banking*. Kemunculan teknologi finansial (*fintech*) dan digitalisasi sistem perbankan mendorong lembaga keuangan untuk mengembangkan solusi yang cepat, aman, dan responsif terhadap kebutuhan nasabah, terutama di tengah meningkatnya preferensi masyarakat terhadap transaksi berbasis aplikasi. Menurut penelitian global, *digital banking* bukan hanya menawarkan efisiensi, namun juga meningkatkan kenyamanan dan aksesibilitas layanan keuangan, terutama di negara berkembang [1]. Di Indonesia, percepatan ini tidak hanya mencerminkan perubahan gaya hidup digital masyarakat, tetapi juga dipicu oleh kompetisi layanan keuangan yang menuntut inovasi teknologi sebagai nilai tambah utama bagi pelanggan [2].

Dalam konteks tersebut, layanan *mobile banking* menjadi elemen vital dalam transformasi perbankan digital. Aplikasi perbankan berbasis seluler memberikan kemudahan dalam melakukan berbagai transaksi, mulai dari pengecekan saldo, transfer dana, pembayaran tagihan, hingga layanan pembelian digital. Tingginya penetrasi *smartphone* dan ketersediaan internet yang semakin luas menjadi pendorong utama adopsi aplikasi perbankan ini. Sejumlah studi menunjukkan bahwa kemudahan, kecepatan akses, dan personalisasi fitur menjadi faktor utama dalam membentuk loyalitas pengguna aplikasi perbankan digital [3][4]. Hal ini sejalan dengan temuan di Indonesia, yang menunjukkan bahwa pengalaman positif terhadap aplikasi *mobile banking* berdampak langsung pada kepuasan dan niat pengguna untuk terus menggunakan layanan tersebut [5][6].

Bank Central Asia (BCA), sebagai salah satu institusi perbankan terbesar di Indonesia, turut merespons perubahan ini dengan menghadirkan dua aplikasi *mobile banking* yang berbeda: BCA Mobile dan myBCA. Kedua aplikasi ini dirancang untuk memenuhi kebutuhan nasabah yang beragam, namun menawarkan pendekatan dan pengalaman pengguna yang berbeda secara signifikan. BCA Mobile dikenal sebagai aplikasi yang telah lama beroperasi dan berfokus pada transaksi dasar perbankan, dengan sistem autentikasi berbasis mPIN dan antarmuka yang sederhana. Sementara itu, myBCA hadir sebagai platform terbaru yang lebih modern dan terintegrasi, menggabungkan layanan rekening, kartu kredit, investasi, hingga *login* multi-perangkat berbasis BCA ID dan autentikasi biometrik. Studi terkait menunjukkan bahwa perbedaan dalam *user interface*, kompleksitas fitur, dan metode autentikasi dapat memengaruhi persepsi pengguna terhadap kemudahan dan keamanan layanan digital [7][8].

Berangkat dari keberagaman pengalaman pengguna tersebut, perlu dilakukan kajian mendalam mengenai bagaimana persepsi dan opini publik terhadap masing-masing aplikasi BCA ini terbentuk. Dengan menggunakan data ulasan dari Playstore sebagai representasi opini publik yang bersumber langsung dari pengguna aktif, pendekatan *sentiment analysis* menjadi metode yang relevan untuk mengevaluasi persepsi tersebut secara sistematis. Pertanyaan kunci yang mendasari penelitian ini mencakup: (1) bagaimana persepsi dan sentimen pengguna terhadap masing-masing aplikasi, dan (2) apa perbedaan dominan dalam opini pengguna berdasarkan ulasan publik yang tersedia. Dengan membandingkan dua aplikasi dari satu institusi yang sama, studi ini mampu mengeliminasi variabel kelembagaan dan fokus pada variabel pengalaman pengguna secara murni.

Tujuan utama dari penelitian ini adalah untuk mengkaji dan membandingkan opini pengguna terhadap aplikasi BCA Mobile dan myBCA dengan menggunakan pendekatan *lexicon-based sentiment analysis*. Teknik ini dipilih karena sifatnya yang ringan, tidak membutuhkan data pelatihan, serta dapat diterapkan secara cepat terhadap data teks berbahasa alami, seperti ulasan pengguna di Playstore [9][10]. Dengan mengolah ratusan ulasan secara terstruktur, penelitian ini bertujuan menyajikan gambaran objektif mengenai sejauh mana pengguna memberikan tanggapan positif, negatif, atau netral terhadap aplikasi yang mereka gunakan. Selain itu, penelitian ini juga bertujuan memetakan perbedaan persepsi pengguna terhadap aspek-aspek tertentu dari masing-masing aplikasi, seperti kecepatan akses, kenyamanan antarmuka, keakuratan fitur, dan tingkat keamanan.

Kontribusi ilmiah dari penelitian ini terletak pada pendekatan studi komparatif terhadap dua aplikasi dari satu institusi yang sama, sesuatu yang masih jarang ditemukan dalam literatur akademik, terutama dalam konteks lokal Indonesia. Studi terdahulu lebih banyak membahas satu aplikasi tertentu secara terpisah atau membandingkan aplikasi dari bank yang berbeda, yang kerap kali menghadirkan bias kelembagaan [11][12]. Pendekatan komparatif ini memberikan nilai tambah dalam memahami bagaimana desain dan fitur aplikasi memengaruhi persepsi pengguna, tanpa terganggu oleh perbedaan *brand* atau reputasi institusi. Selain itu, penggunaan Google Colab sebagai platform pemrosesan data dalam penelitian ini menunjukkan pendekatan yang efisien, transparan, dan mudah direplikasi oleh peneliti lain, sesuai dengan prinsip keterbukaan data dan *reproducibility* dalam riset sains komputer [13].

Tinjauan pustaka menunjukkan bahwa metode *sentiment analysis* telah berkembang pesat, terutama dalam menganalisis opini publik di platform digital seperti media sosial dan forum aplikasi. Pendekatan ini tidak hanya digunakan untuk memahami kepuasan pelanggan, tetapi juga untuk mengidentifikasi topik yang paling sering dibicarakan dan merumuskan strategi pengembangan produk berbasis umpan balik publik [14][15]. Beberapa penelitian telah menggunakan teknik ini untuk menilai aplikasi pemerintah, aplikasi layanan umum, hingga produk komersial [15]. Dalam studi aplikasi perbankan, pendekatan ini telah terbukti efektif untuk mengevaluasi kualitas layanan berdasarkan persepsi publik, terutama di ranah keamanan, kenyamanan penggunaan, dan kemudahan akses [10][16]. Sebuah studi terbaru oleh Rahman et al. menegaskan bahwa *sentiment analysis* mampu mengklasifikasikan respons pengguna aplikasi *mobile banking* dengan akurasi tinggi dalam kategori positif, netral, dan negatif, yang dapat dijadikan masukan strategis untuk peningkatan layanan [10].

Namun demikian, terdapat *gap* yang cukup besar dalam literatur terkait komparasi antara dua aplikasi yang

dikembangkan oleh satu institusi perbankan. Mayoritas studi sebelumnya hanya memusatkan perhatian pada satu aplikasi tertentu atau membandingkan aplikasi dari lembaga yang berbeda, yang kerap kali mengandung bias dari segi kualitas sistem, keamanan server, maupun reputasi layanan [17][18]. Oleh karena itu, penelitian ini mencoba mengisi kekosongan tersebut dengan fokus pada dua aplikasi dari institusi yang sama, yaitu BCA. Hal ini memungkinkan penelitian untuk lebih fokus pada variabel desain aplikasi, pengalaman pengguna, dan kepuasan layanan tanpa perlu mengontrol faktor eksternal seperti perbedaan *brand image* atau tingkat kepercayaan konsumen terhadap institusi.

Dengan menyasar data ulasan yang diperoleh secara organik dari pengguna aktif di Google Playstore, pendekatan ini tidak hanya memberikan gambaran yang objektif mengenai persepsi pengguna, tetapi juga bersifat *real-time* dan responsif terhadap perubahan atau pembaruan sistem dalam aplikasi. Data ini cenderung lebih jujur dan reflektif karena ditulis secara sukarela tanpa intervensi survei atau pengaruh lembaga tertentu [9][12]. Pemanfaatan pendekatan *lexicon-based* memungkinkan klasifikasi opini publik yang cepat dan efisien, khususnya untuk teks berbahasa Indonesia yang belum memiliki banyak sumber daya NLP dalam bentuk korpus pelatihan yang lengkap. Oleh karena itu, metode ini menjadi pilihan strategis dalam penelitian berbasis opini pengguna yang luas namun membutuhkan eksekusi ringan secara teknis [10].

Dengan mempertimbangkan seluruh uraian di atas, penelitian ini diharapkan dapat memberikan kontribusi empiris dan metodologis terhadap studi *user experience* dalam aplikasi perbankan digital di Indonesia. Hasil dari analisis sentimen ini tidak hanya memberikan gambaran umum mengenai persepsi pengguna terhadap masing-masing aplikasi, tetapi juga membuka ruang bagi pengembang untuk memahami aspek-aspek mana yang perlu ditingkatkan, dipertahankan, atau dirombak. Studi ini juga menunjukkan bagaimana data publik seperti ulasan aplikasi dapat dimanfaatkan secara optimal untuk keperluan evaluasi dan pengembangan sistem yang berorientasi pada pengguna. Dengan demikian, penelitian ini memberikan landasan ilmiah sekaligus panduan praktis bagi pengambil keputusan di sektor *digital banking* untuk menciptakan layanan yang lebih adaptif, inklusif, dan memuaskan bagi masyarakat pengguna aplikasi perbankan seluler di Indonesia.

2. LANDASAN TEORI

2.1. Metode Analisis Sentimen

Analisis sentimen merupakan salah satu pendekatan dalam *Natural Language Processing* (NLP) yang bertujuan untuk mengidentifikasi, mengekstraksi, dan mengategorikan opini atau emosi yang terkandung dalam teks. Dalam konteks interaksi digital, analisis sentimen menjadi metode krusial untuk menangkap persepsi publik secara sistematis melalui ulasan, komentar, atau tanggapan yang tersebar di platform daring. Dalam lingkungan bisnis digital, terutama pada sektor layanan keuangan berbasis aplikasi, pendekatan ini memungkinkan perusahaan untuk mengevaluasi kualitas layanan dari perspektif pengguna berdasarkan ekspresi linguistik yang terungkap dalam bentuk teks [14]. Penggunaan teknik ini berkembang secara signifikan seiring dengan meningkatnya volume data yang bersifat opini, khususnya dari media sosial, forum publik, maupun kolom ulasan aplikasi di toko digital seperti Google Playstore dan App Store. Pendekatan ini mampu mengklasifikasikan opini ke dalam tiga kategori utama, yaitu positif, negatif, dan netral, yang kemudian menjadi dasar bagi analisis perilaku konsumen dan pengambilan keputusan strategis oleh pengembang layanan digital [15].

Secara lebih spesifik, dalam konteks aplikasi *mobile banking*, analisis sentimen memiliki peran penting dalam menilai tingkat kepuasan dan kepercayaan pengguna terhadap fitur, antarmuka, keamanan, serta kinerja sistem aplikasi. Penelitian yang dilakukan oleh Rahman et al. menunjukkan bahwa klasifikasi sentimen dalam ulasan aplikasi perbankan dapat memberikan pemetaan yang akurat terhadap dimensi kualitas layanan, serta menunjukkan titik-titik kritis yang perlu ditangani oleh pengembang aplikasi [10]. Penerapan metode ini dalam ranah perbankan digital bukan hanya relevan, tetapi juga mendesak, mengingat pentingnya menjaga loyalitas pengguna dan menciptakan pengalaman digital yang andal dan ramah pengguna [1]. Sentimen yang muncul dari ulasan pengguna dapat mencerminkan realitas penggunaan aplikasi secara *real-time*, termasuk permasalahan teknis yang tidak selalu terdeteksi oleh tim pengembang, seperti *lag*, *error* transaksi, atau kesulitan *login* [9]. Oleh karena itu, analisis sentimen bukan sekadar alat pelengkap evaluasi, melainkan menjadi bagian integral dalam proses penyempurnaan layanan digital berbasis kebutuhan aktual pengguna.

Penerapan analisis sentimen juga relevan dengan tren disrupsi digital dalam sektor keuangan. Perbankan tidak lagi mengandalkan layanan tatap muka sebagai kanal utama, melainkan berpindah ke platform digital yang memungkinkan otomatisasi dan efisiensi pelayanan [1]. Dalam dinamika ini, persepsi pengguna menjadi indikator utama keberhasilan adopsi teknologi digital. Studi-studi kontemporer menegaskan bahwa pemahaman mendalam terhadap opini publik yang tertuang dalam ulasan pengguna dapat digunakan sebagai *feedback loop* bagi institusi finansial dalam membentuk strategi pengembangan produk yang berorientasi pada pengguna [2]. Oleh karena itu, analisis sentimen telah menjadi metode yang tidak dapat diabaikan dalam evaluasi performa aplikasi digital, terlebih dalam sektor yang sangat sensitif terhadap kepercayaan dan kepuasan nasabah seperti industri perbankan.

2.2. Metode Lexicon

Metode lexicon dalam analisis sentimen merupakan pendekatan berbasis kamus, di mana setiap kata dalam teks dibandingkan dengan daftar kata yang telah diberi label sentimen, baik positif, negatif, maupun netral. Pendekatan ini bersifat *rule-based* dan tidak membutuhkan proses pelatihan model seperti pada pendekatan pembelajaran mesin, sehingga lebih ringan secara komputasional dan mudah diterapkan, khususnya dalam analisis teks berbahasa Indonesia yang belum memiliki

banyak sumber daya anotasi data [10]. Lexicon menjadi pilihan strategis dalam situasi di mana waktu, sumber daya sistem, dan ketersediaan data latih menjadi kendala, misalnya dalam penelitian berbasis eksplorasi awal terhadap ulasan aplikasi yang volumenya besar dan bervariasi. Permana et al. menyatakan bahwa pendekatan lexicon efektif digunakan dalam analisis ulasan aplikasi perbankan, karena mampu menangkap pola umum persepsi pengguna terhadap fitur, performa, serta aspek kenyamanan aplikasi [9].

Kelebihan utama dari pendekatan lexicon terletak pada kemampuannya dalam memberikan hasil klasifikasi yang cepat dan relatif akurat pada skenario tertentu, terutama jika daftar kata yang digunakan telah dikustomisasi sesuai dengan konteks bahasa dan domain aplikasi. Dalam konteks ini, lexicon dapat dikembangkan atau disesuaikan untuk domain perbankan digital, dengan memasukkan istilah-istilah umum yang sering digunakan pengguna seperti “lemot”, “gagal”, “aman”, “praktis”, atau “mudah” [11]. Selain itu, lexicon juga dapat digabungkan dengan pendekatan berbasis aspek (*aspect-based sentiment analysis*) untuk memperdalam makna sentimen pada elemen tertentu, misalnya keamanan aplikasi atau kenyamanan *user interface* [15]. Namun, seperti disoroti oleh Rodríguez-Ibáñez et al., pendekatan lexicon memiliki kelemahan dalam menangani konteks kalimat, ironi, dan kata yang bermakna ganda, karena tidak mempertimbangkan struktur sintaksis atau semantik secara utuh [14].

Keterbatasan lain dari metode ini terletak pada ketergantungan terhadap daftar kata yang digunakan, di mana lexicon standar seperti AFINN atau SentiWordNet yang berbahasa Inggris tidak sepenuhnya relevan dengan konteks ulasan aplikasi berbahasa Indonesia. Oleh karena itu, dalam implementasi lokal, lexicon perlu dikembangkan atau dimodifikasi agar mampu merepresentasikan karakteristik bahasa sehari-hari pengguna Indonesia dalam memberikan ulasan digital [12]. Hal ini menjadi tantangan tersendiri, namun juga menjadi peluang untuk memperkuat pendekatan lexicon sebagai metode yang fleksibel dan dapat disesuaikan lintas bahasa dan domain. Di sisi lain, pendekatan lexicon tetap menjadi pilihan populer dalam penelitian aplikatif karena kesederhanaannya, transparansinya, dan hasil klasifikasinya yang mudah dipahami oleh pemangku kepentingan non-teknis, seperti manajer produk atau analis bisnis [10][8].

2.3. Text Preprocessing

Pra-pemrosesan teks (*text preprocessing*) merupakan tahap penting sebelum proses analisis sentimen dilakukan. Tahapan ini bertujuan untuk membersihkan dan menormalkan data teks agar siap untuk dianalisis secara sistematis. Proses ini biasanya meliputi beberapa tahap utama, seperti *tokenization*, *stopword removal*, *lowercasing*, serta *stemming* atau *lemmatization* [9][10]. Tokenisasi adalah proses memecah teks menjadi unit-unit kecil seperti kata atau frasa, yang memungkinkan mesin mengenali bagian-bagian dari kalimat untuk dianalisis lebih lanjut. Setelah tokenisasi, kata-kata yang tidak memiliki makna penting seperti “dan”, “yang”, atau “adalah” akan dihapus melalui proses *stopword removal* untuk menghindari gangguan dalam penghitungan bobot sentimen. Tahapan *lowercasing* kemudian mengonversi seluruh kata menjadi huruf kecil agar konsistensi data terjaga, mengingat komputer membedakan huruf kapital dan non-kapital sebagai entitas berbeda. Terakhir, proses *stemming* dan *lemmatization* bertujuan untuk mengembalikan kata ke bentuk dasar atau akar katanya, sehingga variasi kata seperti “mengirim”, “dikirim”, dan “pengiriman” dikenali sebagai satu entitas semantik yang sama.

Keberhasilan tahapan *preprocessing* akan sangat menentukan akurasi hasil analisis sentimen. Kesalahan atau ketidakkonsistenan dalam tahapan ini dapat mengakibatkan data menjadi ambigu, menyebabkan hasil klasifikasi menjadi tidak relevan. Dalam studi analisis ulasan aplikasi *mobile banking*, Rahman et al. menunjukkan bahwa hasil klasifikasi sentimen yang berbasis lexicon meningkat secara signifikan setelah tahapan *preprocessing* dilakukan secara menyeluruh [10]. Demikian pula, Marpaung et al. juga menekankan bahwa metode *Naïve Bayes* dan *SVM* yang digunakan dalam analisis ulasan aplikasi BCA Mobile menghasilkan akurasi yang optimal ketika *preprocessing* dilakukan secara konsisten [12]. Oleh karena itu, tahapan ini tidak boleh dipandang sebagai prosedur teknis semata, melainkan sebagai pondasi utama yang menentukan validitas dan reliabilitas dari seluruh proses analisis.

Implementasi *preprocessing* yang efektif juga harus mempertimbangkan karakteristik bahasa dan konteks domain aplikasi. Bahasa Indonesia, sebagai bahasa yang kaya akan imbuhan dan bentuk turunan, menuntut pendekatan *stemming* yang lebih kompleks dibandingkan dengan bahasa Inggris. Selain itu, bentuk informal dan penggunaan campuran bahasa dalam ulasan digital juga menjadi tantangan tersendiri dalam proses normalisasi data. Oleh karena itu, pengembangan *stopword list* dan *stemmer* khusus bahasa Indonesia menjadi hal yang esensial untuk mendukung efektivitas metode lexicon dalam konteks lokal [9][10][12]. Dengan demikian, dapat disimpulkan bahwa *text preprocessing* bukan hanya langkah awal yang bersifat teknis, tetapi merupakan tahapan fundamental yang memastikan bahwa data teks yang digunakan dalam analisis sentimen benar-benar mencerminkan opini pengguna dalam bentuk yang paling representatif dan dapat diolah secara akurat.

2.4. Perbedaan Aplikasi BCA Mobile dan myBCA

Aplikasi *mobile banking* telah mengalami evolusi fungsional dan desain yang signifikan seiring dengan meningkatnya ekspektasi pengguna terhadap kenyamanan dan efisiensi layanan digital. BCA sebagai institusi perbankan nasional terkemuka menghadirkan dua aplikasi berbeda yang ditujukan untuk memberikan pengalaman digital yang adaptif terhadap kebutuhan nasabah. Aplikasi BCA Mobile dikenal sebagai platform klasik yang telah digunakan secara luas dalam waktu yang cukup lama. Aplikasi ini menawarkan fitur-fitur dasar seperti pengecekan saldo, transfer antarbank, pembayaran tagihan, dan pembelian pulsa. Proses autentikasi pada BCA Mobile dilakukan melalui sistem mPIN sebanyak enam digit, yang disimpan di perangkat dan digunakan setiap kali pengguna melakukan transaksi [6]. Antarmuka pengguna pada aplikasi ini dirancang

minimalis dan lebih konservatif, dengan akses langsung ke fitur m-BCA tanpa perlu proses *login* berbasis akun tersendiri. Sifatnya yang langsung dan efisien membuat aplikasi ini tetap populer, khususnya di kalangan pengguna yang terbiasa dengan layanan BCA sejak awal digitalisasi perbankan di Indonesia [13].

Sebaliknya, aplikasi myBCA dirancang dengan pendekatan modern yang berorientasi pada personalisasi dan integrasi layanan. Aplikasi ini menuntut pengguna untuk melakukan *login* menggunakan akun BCA ID, yang berfungsi sebagai sistem identitas digital terpadu untuk seluruh layanan BCA. Dalam proses autentikasi, myBCA juga mendukung teknologi biometrik seperti sidik jari dan pengenalan wajah, yang meningkatkan aspek keamanan dan kenyamanan pengguna [3]. Selain fitur dasar seperti transfer dan pembayaran, myBCA menyediakan fitur tambahan yang memungkinkan pengguna mengakses informasi kartu kredit, deposito, investasi, hingga riwayat transaksi dalam satu aplikasi. Pendekatan ini selaras dengan tren global dalam digital *banking*, di mana integrasi layanan menjadi prioritas untuk menciptakan pengalaman digital yang menyeluruh [1]. Keberadaan fitur *multi-device login* dan personalisasi *dashboard* menandai diferensiasi utama myBCA dari pendahulunya, menunjukkan bagaimana kebutuhan akan fleksibilitas dan kontrol menjadi kunci dalam pengembangan aplikasi digital masa kini [17].

Perbedaan antara kedua aplikasi tersebut tidak hanya terletak pada tampilan antarmuka atau sistem autentikasi, tetapi juga mencakup aspek teknis dalam hal stabilitas sistem, arsitektur *backend*, dan responsivitas antarmuka. Berdasarkan kajian terhadap ulasan pengguna, aplikasi BCA Mobile cenderung lebih stabil dalam kondisi jaringan terbatas, sedangkan myBCA lebih membutuhkan koneksi internet yang kuat untuk dapat memuat konten antarmuka yang lebih kompleks dan dinamis [11]. Hal ini sesuai dengan temuan penelitian terkait *usability* aplikasi perbankan digital, yang menyatakan bahwa aplikasi dengan beban grafis dan integrasi fitur tinggi sering kali menghadapi tantangan dalam hal waktu muat dan keterandalan sistem saat trafik tinggi [7]. Meskipun demikian, desain myBCA lebih sesuai untuk generasi digital native yang mengutamakan kontrol terpusat dan fleksibilitas akses, berbeda dengan pengguna BCA Mobile yang mengedepankan kestabilan dan kepraktisan dalam menjalankan transaksi harian [4].

Dari sisi *user journey*, BCA Mobile menawarkan pengalaman langsung tanpa hambatan *login*, yang cocok untuk pengguna dengan pola transaksi cepat dan berulang. Pengguna dapat langsung mengakses menu m-BCA setelah membuka aplikasi, yang menjadikannya unggul dalam efisiensi waktu untuk transaksi dasar. Sementara itu, myBCA mengedepankan pengalaman yang lebih personal dan sistematis. Dengan fitur seperti ringkasan keuangan dan notifikasi transaksi terintegrasi, pengguna diajak untuk memiliki hubungan jangka panjang yang lebih terstruktur dengan aplikasi [16]. Pendekatan ini mencerminkan evolusi strategi layanan digital yang tidak hanya berfokus pada transaksi, tetapi juga pada keterlibatan emosional dan kontrol pengguna terhadap seluruh ekosistem keuangan mereka [18]. Dengan demikian, perbedaan antara BCA Mobile dan myBCA bukan sekadar transformasi teknologi, melainkan mencerminkan dua paradigma berbeda dalam pendekatan pengalaman pengguna dalam konteks perbankan digital.

2.5. Proses Analisis Sentimen Lexicon

Tahapan pertama dalam proses analisis sentimen berbasis lexicon dimulai dari pengumpulan data yang menjadi fondasi dari keseluruhan prosedur analitik. Data yang digunakan dalam konteks penelitian ini berasal dari ulasan pengguna aplikasi BCA Mobile dan myBCA di Google Playstore, yang dianggap representatif karena mencerminkan opini publik secara organik dan *real-time*. Pendekatan ini telah digunakan secara luas dalam penelitian berbasis opini publik digital karena sifat datanya yang terbuka, relevan, dan mampu memuat berbagai ekspresi persepsi pengguna terhadap produk digital [14]. Permana et al. menyatakan bahwa penggunaan data ulasan aplikasi sebagai basis analisis sentimen memberikan hasil yang lebih nyata dibanding survei konvensional, karena merepresentasikan opini yang muncul secara spontan tanpa tekanan atau bias lembaga survei [9]. Oleh karena itu, pengumpulan data dari platform seperti Playstore menjadi metode yang valid dan efisien dalam mengevaluasi persepsi pengguna terhadap performa dan kualitas layanan aplikasi perbankan digital.

Tahapan kedua adalah pra-pemrosesan teks yang bertujuan untuk membersihkan dan menormalkan data sebelum dilakukan proses analisis. Tahap ini meliputi proses tokenisasi, yaitu memecah teks ulasan menjadi unit-unit kata, lalu dilanjutkan dengan penghapusan kata-kata tidak bermakna atau *stopwords* seperti “dan”, “yang”, atau “di”. Setelah itu dilakukan *lowercasing*, yaitu konversi semua huruf ke dalam bentuk huruf kecil untuk menjaga konsistensi. Langkah selanjutnya adalah *stemming* atau *lemmatization*, yaitu proses mengembalikan kata ke bentuk dasar agar variasi morfologi tidak mengganggu proses pencocokan kata dengan daftar lexicon [10]. Rodríguez-Ibáñez et al. menyatakan bahwa tahapan ini sangat penting untuk meningkatkan akurasi klasifikasi sentimen karena mengurangi kebisingan linguistik yang sering muncul dalam teks ulasan [14]. Pra-pemrosesan juga harus mempertimbangkan karakteristik bahasa lokal agar mampu mengelola kata-kata slang, kesalahan ketik, dan bahasa campuran yang sering ditemukan dalam ulasan pengguna di Indonesia [12].

Tahapan ketiga adalah pencocokan kata ulasan dengan daftar lexicon yang telah diklasifikasikan ke dalam kategori sentimen positif, negatif, atau netral. Dalam pendekatan ini, setiap kata dalam teks ulasan diperiksa apakah mengandung nilai sentimen berdasarkan daftar lexicon yang telah disiapkan sebelumnya. Jika kata “bagus” atau “puas” ditemukan, maka kata tersebut dikategorikan sebagai sentimen positif, sedangkan kata “lemot” atau “gagal” diklasifikasikan sebagai negatif. Lexicon yang digunakan bisa bersifat umum atau disesuaikan untuk konteks tertentu, seperti aplikasi perbankan digital [15]. Rahman et al. menegaskan bahwa lexicon yang dikustomisasi secara lokal memiliki tingkat akurasi lebih tinggi karena lebih relevan dengan bahasa dan konteks opini publik di wilayah geografis tertentu [10]. Oleh karena itu, pembuatan lexicon berbasis data empiris yang relevan dengan domain aplikasi menjadi langkah strategis dalam menjamin validitas hasil

klasifikasi.

Setelah kata-kata dalam teks dicocokkan dengan daftar lexicon, tahapan selanjutnya adalah penentuan skor sentimen. Dalam proses ini, setiap kata diberi bobot tertentu berdasarkan kategorinya; misalnya, kata positif diberi skor +1, kata negatif diberi skor -1, dan kata netral diberi skor 0. Nilai total sentimen dari sebuah ulasan dihitung dari penjumlahan skor semua kata dalam teks tersebut. Jika skor akhir positif, maka ulasan dikategorikan sebagai opini positif; jika negatif, maka dikategorikan sebagai opini negatif; dan jika netral, maka ulasan tidak dianggap memiliki kecenderungan emosi tertentu [9]. Sistem penilaian ini memungkinkan analisis sentimen dilakukan secara sistematis dan kuantitatif, serta dapat digunakan untuk membandingkan persepsi pengguna terhadap dua aplikasi atau fitur yang berbeda [11]. Pendekatan berbasis skor ini juga dapat disesuaikan dengan bobot khusus untuk kata-kata yang memiliki intensitas tinggi atau nuansa emosional kuat.

Tahapan akhir adalah klasifikasi sentimen, yaitu proses mengelompokkan teks ulasan ke dalam kategori akhir yang telah ditentukan berdasarkan skor yang diperoleh. Kategori umum yang digunakan adalah positif, negatif, dan netral. Hasil klasifikasi ini dapat dikompilasi dan dianalisis secara agregat untuk mengidentifikasi tren umum dalam opini pengguna terhadap aplikasi tertentu. Dalam penelitian sebelumnya, pendekatan klasifikasi ini terbukti efektif dalam menganalisis ribuan ulasan aplikasi *mobile banking* secara cepat dan efisien, tanpa memerlukan pelatihan model berbasis *machine learning* yang membutuhkan waktu dan sumber daya besar [9][10]. Kelebihan dari metode ini adalah transparansi dan interpretabilitasnya yang tinggi, sehingga hasil analisis dapat langsung digunakan oleh pengambil kebijakan atau tim pengembang aplikasi untuk mengevaluasi dan menyempurnakan fitur yang tersedia [2][4]. Dengan menyelesaikan seluruh tahapan analisis sentimen berbasis lexicon, peneliti dan pengembang dapat memperoleh gambaran holistik tentang bagaimana pengguna merespons pengalaman mereka dalam menggunakan aplikasi BCA Mobile maupun myBCA secara obyektif dan sistematis.

3. METODE PENELITIAN


berbasis teks yang bertujuan untuk menganalisis opini publik terhadap dua aplikasi perbankan milik Bank Central Asia (BCA), yaitu BCA Mobile dan myBCA, dengan memanfaatkan data sekunder berupa ulasan pengguna yang tersedia secara terbuka di platform Google Playstore [9][10]. Teknik pengumpulan data dilakukan melalui proses *web scraping* menggunakan pustaka *google-play-scraper* dalam lingkungan *Google Collab*, yang memungkinkan ekstraksi data ulasan berdasarkan filter tertentu seperti rating pengguna, rentang tanggal, dan bahasa ulasan [14]. Ulasan yang ditarik difokuskan pada bahasa Indonesia untuk menjaga kesesuaian konteks linguistik dan budaya pengguna. Setelah data berhasil dikumpulkan, dilakukan tahapan pra-pemrosesan data untuk memastikan kualitas dan kebersihan teks sebelum dianalisis. Tahapan ini mencakup proses *cleaning* untuk menghilangkan simbol atau karakter non-teks, *tokenizing* untuk memecah kalimat menjadi unit kata, *stopword removal* untuk membuang kata-kata yang tidak memiliki makna analitis seperti “yang”, “dan”, “di”, serta proses *stemming* untuk mengembalikan kata ke bentuk dasarnya agar setiap kata dapat diklasifikasikan secara konsisten dalam proses analisis selanjutnya [10][12]. Setelah proses normalisasi teks selesai, dilakukan analisis sentimen menggunakan metode lexicon yang berbasis pada pencocokan kata dalam ulasan dengan daftar kata berlabel sentimen positif atau negatif. Metode ini digunakan karena kepraktisannya, tidak memerlukan pelatihan model, serta dapat digunakan secara efisien pada data teks dalam jumlah besar [9][11]. Dalam proses ini, setiap kata diberi bobot berdasarkan nilai polaritas (+1 untuk kata positif, -1 untuk kata negatif), dan skor total dari masing-masing ulasan digunakan untuk menentukan klasifikasi akhir ke dalam sentimen positif, negatif, atau netral [10][15]. Visualisasi hasil dilakukan untuk memudahkan interpretasi data melalui penyajian dalam bentuk *bar chart* dan *pie chart* yang menggambarkan distribusi sentimen dari kedua aplikasi, serta *wordcloud* untuk menampilkan kata-kata yang paling sering muncul dalam masing-masing klasifikasi sentimen, yang berguna untuk mengidentifikasi isu atau tema dominan dalam opini pengguna [14][11]. Sebagai bentuk validasi sederhana, dilakukan pula evaluasi manual terhadap sebagian sampel ulasan untuk menguji konsistensi antara hasil klasifikasi otomatis dan pemahaman kontekstual manusia, sehingga proses analisis ini dapat dianggap tidak hanya sistematis secara teknis, tetapi juga valid secara semantik dan interpretatif [10][4].

4. HASIL DAN PEMBAHASAN

4.1 Hasil


4.1.1 Statistik Ulasan Pengguna

Analisis awal dilakukan dengan menelusuri statistik dasar dari data ulasan yang diperoleh dari Google Playstore, masing-masing sebanyak 300 ulasan untuk aplikasi BCA Mobile dan 300 ulasan untuk aplikasi myBCA. Jumlah ulasan yang seimbang ini memberikan dasar yang valid untuk melakukan perbandingan sentimen secara kuantitatif. Menurut penelitian Permana et al., data ulasan yang diperoleh dari toko aplikasi merupakan representasi opini organik yang mencerminkan pengalaman nyata pengguna dalam berinteraksi dengan fitur digital perbankan [9]. Dengan pendekatan ini, penelitian mampu menggambarkan persepsi publik tanpa intervensi pihak ketiga, menjadikan data tersebut sebagai sumber valid untuk analisis lanjutan.



Gambar 1. Distribusi Ulasan per Tanggal


Distribusi ulasan berdasarkan tanggal memperlihatkan perbedaan pola aktivitas pengguna. Berdasarkan visualisasi pada Gambar 1, terlihat bahwa ulasan terhadap BCA Mobile menunjukkan lonjakan pada 11 April 2025, sementara ulasan terhadap myBCA cenderung menyebar lebih stabil pada periode awal April 2025. Perbedaan pola ini menunjukkan bahwa interaksi pengguna terhadap dua aplikasi tersebut tidak hanya dipengaruhi oleh faktor teknis, tetapi juga oleh momentum sosial tertentu yang dapat memicu peningkatan partisipasi digital. Alqaryouti et al. menegaskan bahwa distribusi temporal dalam data opini publik sering kali menunjukkan keterkaitan dengan peristiwa pembaruan aplikasi, gangguan layanan, atau promosi digital yang memengaruhi persepsi pengguna secara kolektif [15]. Oleh karena itu, pengamatan distribusi temporal ini memberikan konteks penting dalam memahami sentimen secara dinamis.



Gambar 2. Distribusi Skor BCA Mobile

Sementara itu, Gambar 2 menyajikan distribusi skor ulasan BCA Mobile yang menunjukkan dominasi skor tertinggi, yakni bintang 5, yang mencapai lebih dari setengah jumlah ulasan. Meskipun begitu, skor terendah yakni bintang 1 juga tercatat dalam jumlah yang signifikan, yaitu lebih dari 25% dari total ulasan. Distribusi skor ini menunjukkan bahwa meskipun terdapat tingkat kepuasan tinggi dari sebagian besar pengguna, terdapat pula proporsi pengguna yang mengalami ketidakpuasan signifikan. Fenomena ini menandakan polarisasi pengalaman yang lazim dalam aplikasi perbankan digital, sebagaimana dijelaskan oleh Rodríguez-Ibáñez et al. yang menyebutkan bahwa skor ulasan bukan sekadar indikator kepuasan, tetapi refleksi dari interaksi intensif dan ekspektasi tinggi terhadap layanan digital [14]. Ketika aplikasi digunakan untuk layanan keuangan yang bersifat kritis, seperti transfer dana atau otorisasi pembayaran, kegagalan kecil sekalipun dapat memicu sentimen ekstrem dalam ulasan pengguna [4].

Distribusi skor ulasan terhadap aplikasi myBCA seperti yang ditampilkan pada Gambar 3 memperlihatkan pola persebaran yang mencolok, dengan dominasi skor 1 dan 5 sebagai dua kutub utama. Skor tertinggi (5) memperoleh porsi terbesar yakni sebanyak 123 ulasan, yang menunjukkan bahwa sebagian besar pengguna merasa sangat puas terhadap performa dan fitur aplikasi tersebut. Di sisi lain, skor terendah (1) juga menempati porsi yang besar yaitu 105 ulasan, yang menandakan bahwa terdapat pula sejumlah pengguna yang mengalami pengalaman buruk atau kegagalan dalam penggunaan aplikasi. Skor menengah (2, 3, dan 4) jauh lebih sedikit jumlahnya, masing-masing hanya berkisar di angka 24–26 ulasan.



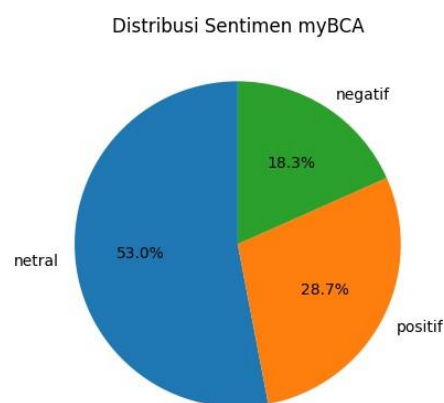
Gambar 3. Distribusi Skor myBCA

Pola distribusi seperti ini mencerminkan adanya polarisasi persepsi yang kuat terhadap aplikasi, di mana pengguna terbagi menjadi dua kelompok besar: mereka yang sangat puas dan mereka yang sangat tidak puas. Menurut Rodríguez-Ibáñez et al., distribusi ekstrem semacam ini sering kali terjadi pada aplikasi yang baru diluncurkan atau mengalami perubahan besar dalam sistem antarmuka, karena pengguna cenderung memberikan skor sangat tinggi atau sangat rendah berdasarkan ekspektasi dan pengalaman awal yang kontras [14]. Dalam konteks myBCA, hal ini dapat diasosiasikan dengan perubahan model *login*, integrasi fitur baru, atau kendala teknis yang belum stabil pasca peluncuran.


Selain itu, dominasi skor ekstrem ini juga dapat menunjukkan bahwa pengguna yang benar-benar memiliki opini kuat (baik positif maupun negatif) lebih terdorong untuk menulis ulasan, sementara pengguna yang merasa “biasa saja” atau memiliki opini netral cenderung tidak memberikan *rating*. Hal ini sejalan dengan temuan Alqaryouti et al., yang menegaskan bahwa hanya ulasan yang dipicu oleh emosi ekstrem—baik kekecewaan maupun kepuasan—yang umumnya muncul dalam sistem *rating* digital [15]. Oleh sebab itu, distribusi skor ini perlu dibaca bukan hanya sebagai cerminan kualitas aplikasi, tetapi juga sebagai indikasi tingginya emosionalitas pengguna terhadap fitur dan kinerja layanan dalam aplikasi perbankan digital seperti myBCA.

4.1.2 Hasil Klasifikasi Sentimen

Analisis sentimen terhadap seluruh ulasan dilakukan dengan metode lexicon berbasis kamus sentimen berbahasa Indonesia. Berdasarkan hasil klasifikasi, distribusi sentimen terhadap BCA Mobile menunjukkan dominasi sentimen sebanyak 28.7% ulasan positif, 18.3% ulasan negatif dan 53.0% ulasan netral. Untuk aplikasi myBCA, hasilnya tidak jauh berbeda dengan sentimen netral sebanyak 159, positif 86, dan negatif 55. Distribusi ini divisualisasikan pada Gambar 4 dalam bentuk pie chart khusus untuk myBCA, serta Gambar 5 yang menampilkan *bar chart* komparatif antara kedua aplikasi. Pola yang serupa ini mengindikasikan bahwa baik BCA Mobile maupun myBCA memiliki persepsi pengguna yang cenderung seimbang, meskipun myBCA sedikit lebih unggul dalam ulasan positif. Menurut Rahman et al., perbedaan proporsi sentimen positif pada aplikasi sejenis dari institusi yang sama dapat mengindikasikan pergeseran persepsi pengguna terhadap antarmuka, kecepatan layanan, maupun fitur tambahan yang lebih responsif terhadap kebutuhan digital masa kini [10].



Gambar 4. Distribusi Sentimen myBCA



Gambar 5. Perbandingan Sentimen BCA Mobile dan myBCA

Penting untuk dicatat bahwa tingginya jumlah sentimen netral bukan berarti pengguna tidak memiliki opini, melainkan bahwa banyak ulasan bersifat informatif, naratif, atau tidak memuat emosi eksplisit. Dalam konteks *lexicon-based classification*, ulasan semacam ini cenderung dikategorikan sebagai netral karena tidak mengandung kata berlabel polaritas tinggi. Permana et al. menyebutkan bahwa dalam kasus aplikasi *mobile banking*, ulasan netral sering muncul dalam bentuk deskripsi pengalaman teknis seperti kesulitan *login* atau permintaan bantuan, yang belum tentu bermuatan positif atau negatif secara linguistik [9]. Hal ini menunjukkan perlunya pertimbangan kontekstual dalam menginterpretasi data sentimen yang bersifat netral secara literal namun penting secara semantik.

4.1.3 Visualisasi Hasil

Untuk memahami konteks sentimen secara lebih mendalam, digunakan visualisasi *wordcloud* yang menggambarkan frekuensi kemunculan kata dalam ulasan berdasarkan kategori sentimen. Gambar 5–7 menampilkan *wordcloud* dari BCA Mobile untuk sentimen positif, negatif, dan netral. Pada *wordcloud* sentimen positif (Gambar 6), kata “sangat”, “bagus”, “baik”, dan “mantap” mendominasi, mencerminkan ekspresi kepuasan pengguna terhadap fitur dan kecepatan transaksi. Gumelar et al. menyebutkan bahwa indikator semacam ini menunjukkan keberhasilan aplikasi dalam memberikan pengalaman digital yang memuaskan secara umum [13]. Namun, pada *wordcloud* sentimen negatif (Gambar 7), kata “susah”, “verifikasi”, “masuk”, dan “gagal” muncul dominan, mengindikasikan masalah teknis seputar sistem autentikasi dan aksesibilitas layanan. Temuan ini sejalan dengan penelitian Kaur et al. yang menyatakan bahwa hambatan teknis pada tahap *login* menjadi salah satu sumber utama ketidakpuasan pengguna dalam aplikasi keuangan [2].



Gambar 6. *Wordcloud* BCA Mobile (Positif)



Gambar 7. *Wordcloud* BCA Mobile (Negatif)



Gambar 8. *Wordcloud* BCA Mobile (Netral)

Wordcloud sentimen netral (Gambar 8) menampilkan kata-kata seperti “ada”, “bisa”, “bca”, dan “masuk” yang cenderung deskriptif tanpa makna emosional eksplisit. Pola serupa terlihat pada *wordcloud* myBCA (Gambar 9–11), di mana ulasan positif didominasi kata “mudah”, “bagus”, dan “puas”, sementara ulasan negatif mengandung kata seperti “login”, “error”, “susah”, dan “ribet”. Hal ini menunjukkan bahwa kedua aplikasi menghadapi masalah teknis serupa yang menjadi perhatian utama pengguna. Namun, kata-kata positif seperti “bagus” dan “mudah” dalam *wordcloud* myBCA juga menunjukkan bahwa aplikasi tersebut memiliki fitur yang diapresiasi, kemungkinan besar berhubungan dengan antarmuka modern dan *login* biometrik. Lelasari dan Bernarto menyatakan bahwa sentimen positif yang terkait dengan kemudahan penggunaan merupakan indikator penting dalam membangun loyalitas digital pada aplikasi perbankan [6].



Gambar 9. *Wordcloud myBCA (Positif)*



Gambar 10. *Wordcloud* myBCA (Negatif)



Gambar 11. *Wordcloud* myBCA (Netral)

Melalui visualisasi ini, diperoleh gambaran yang lebih kontekstual mengenai persepsi pengguna terhadap elemen-elemen fungsional aplikasi, mulai dari pengalaman *login*, transaksi, hingga layanan bantuan. Penelitian Jamadar et al. menunjukkan bahwa pendekatan *topic modeling* yang dikombinasikan dengan analisis visual seperti *wordcloud* dapat membantu mengungkap struktur opini publik secara lebih intuitif dibandingkan hanya mengandalkan statistik klasifikasi numerik [11]. Oleh karena itu, keberadaan *wordcloud* dalam penelitian ini tidak hanya sebagai pelengkap visual, tetapi juga sebagai alat eksploratif untuk menyusun hipotesis lanjutan terhadap persepsi pengguna dan aspek layanan yang paling sering menjadi sorotan.

4.2 Pembahasan

4.2.1 Perbedaan Persepsi Publik terhadap BCA Mobile dan myBCA

Hasil analisis sentimen yang telah diperoleh menunjukkan perbedaan menarik dalam persepsi publik terhadap dua aplikasi perbankan digital dari institusi yang sama, yakni BCA Mobile dan myBCA. Meskipun keduanya memiliki proporsi sentimen netral yang tinggi, terdapat kecenderungan bahwa myBCA lebih banyak menerima opini positif dibandingkan dengan BCA Mobile. Ini mengindikasikan bahwa pengguna cenderung lebih mengapresiasi pembaruan fitur dan pendekatan desain yang ditawarkan myBCA. Sebagaimana dinyatakan oleh Jamadar et al., dalam pengembangan aplikasi keuangan digital, pengalaman pengguna yang lebih personal dan terintegrasi memainkan peran penting dalam membentuk persepsi positif pengguna terhadap inovasi teknologi [11]. Dalam konteks ini, myBCA yang mengusung fitur-fitur modern seperti *login* menggunakan BCA ID, autentikasi biometrik, serta integrasi informasi seluruh produk keuangan, memberikan nilai tambah yang nyata dibandingkan dengan BCA Mobile yang hanya mengandalkan sistem klasik mPIN dan antarmuka konvensional.

Preferensi pengguna juga terlihat dalam kata-kata kunci yang mendominasi *wordcloud*, seperti “mudah”, “bagus”, dan “terintegrasi” pada myBCA, dibandingkan dengan kata-kata seperti “cepat” atau “praktis” yang lebih banyak muncul dalam ulasan positif BCA Mobile. Ini menegaskan bahwa pengguna BCA Mobile lebih menghargai stabilitas dan kesederhanaan, sedangkan pengguna myBCA menilai fitur yang canggih dan terintegrasi sebagai keunggulan utama. Pavithra dan Geetha menggarisbawahi bahwa dalam konteks *digital banking*, persepsi terhadap *user journey* yang efisien dan menyeluruh sangat berpengaruh terhadap loyalitas pengguna terhadap suatu platform [18]. Hal ini pula yang menjelaskan mengapa meskipun keduanya memiliki volume ulasan yang seimbang, karakter dan nilai emosional dari opini yang diberikan terhadap myBCA cenderung lebih antusias dalam menggambarkan pengalaman pengguna yang modern dan komprehensif.

4.2.2 Akar Sentimen Negatif dan Apresiasi Positif

Analisis terhadap sentimen negatif pada kedua aplikasi menunjukkan bahwa sebagian besar keluhan pengguna berkaitan dengan aspek teknis, terutama terkait proses verifikasi, kegagalan *login*, serta keterbatasan respons sistem ketika terjadi kesalahan transaksi. *Wordcloud* negatif dari kedua aplikasi sama-sama menampilkan kata “susah”, “verifikasi”, dan “gagal” sebagai keluhan yang dominan. Permana et al. menyebutkan bahwa kendala teknis dalam aplikasi *mobile banking* menjadi pemicu utama lahirnya ulasan negatif karena aplikasi ini bersentuhan langsung dengan aktivitas keuangan yang sensitif dan mendesak [9]. Gangguan sekecil apapun pada proses *login* atau transaksi sering kali menimbulkan rasa frustrasi yang kemudian diekspresikan dalam bentuk sentimen negatif. Hal ini diperparah ketika aplikasi tidak memberikan notifikasi kesalahan yang jelas atau waktu pemrosesan terlalu lambat, sehingga pengalaman pengguna terganggu secara signifikan.

Sebaliknya, ulasan positif didominasi oleh ekspresi kepuasan terhadap kecepatan layanan, keakuratan saldo, kemudahan transfer, serta fitur tambahan seperti ringkasan portofolio pada myBCA. Kata “bagus”, “mantap”, dan “mudah” mendominasi *wordcloud* positif dari kedua aplikasi. Menurut Gumelar et al., aplikasi keuangan yang mampu mengelola transaksi dengan stabil, menyajikan data yang akurat, serta mudah diakses, akan mendapat apresiasi yang tinggi dari pengguna karena dianggap memberikan nilai utilitas langsung dalam kehidupan sehari-hari [13]. Dalam hal ini, myBCA berhasil menciptakan kesan positif melalui penggabungan fitur lama dan baru dalam satu antarmuka, sementara BCA Mobile tetap menjadi pilihan utama bagi pengguna yang lebih konservatif dan terbiasa dengan proses transaksi sederhana.

Kelemahan pada antarmuka juga menjadi salah satu akar sentimen negatif. Berdasarkan hasil *wordcloud*, banyak pengguna mengeluhkan desain aplikasi yang membingungkan atau tidak responsif, khususnya pada versi myBCA yang lebih padat fitur. Weichbroth menjelaskan bahwa peningkatan jumlah fitur dalam satu aplikasi perlu dibarengi dengan peningkatan *usability*, karena kerumitan antarmuka justru bisa mengurangi kenyamanan pengguna jika tidak diimbangi dengan navigasi yang intuitif [7]. Oleh karena itu, kendala teknis dan desain visual menjadi faktor yang secara langsung membentuk polarisasi opini pengguna, di mana satu sisi mengapresiasi inovasi, sementara sisi lain mengalami kebingungan dan ketidaknyamanan akibat perubahan yang drastis.

4.2.3 Dampak Sentimen terhadap Strategi Pengembangan Aplikasi

Temuan sentimen ini memiliki implikasi strategis yang penting bagi tim pengembang aplikasi perbankan digital, khususnya BCA. Dari sisi pengembangan produk, sentimen positif yang tinggi terhadap fitur integrasi dan sistem *login* berbasis identitas digital pada myBCA dapat menjadi dasar untuk memperluas pendekatan ini ke fitur lain seperti personalisasi *dashboard* atau otomatisasi transaksi. Menurut Rodríguez-Ibáñez et al., sentimen pengguna dapat menjadi indikator awal terhadap fitur yang paling dihargai dan berpotensi untuk dikembangkan lebih lanjut sebagai *unique selling point* dari aplikasi [14]. Pendekatan berbasis data sentimen ini membantu tim pengembang untuk tidak hanya merespons keluhan, tetapi juga menyusun *roadmap* pembaruan fitur berdasarkan prioritas persepsi publik.

Di sisi lain, tingginya sentimen negatif yang berkaitan dengan sistem *login* dan autentikasi harus menjadi prioritas dalam proses perbaikan. Fitur *login* yang lambat, sering gagal, atau tidak kompatibel dengan perangkat tertentu terbukti menjadi sumber frustrasi utama. Menurut Wahab et al., keberhasilan aplikasi keuangan sangat bergantung pada stabilitas fungsi-fungsi utama seperti *login* dan otorisasi karena menjadi gerbang pertama interaksi pengguna [8]. Oleh karena itu, pengembangan sistem verifikasi ganda yang lebih andal, optimasi kecepatan akses, serta peningkatan pesan kesalahan yang informatif dapat

menjadi solusi langsung atas sentimen negatif yang diungkapkan pengguna.

Sentimen netral, meskipun terlihat pasif, seharusnya tidak diabaikan. Sebagian besar ulasan netral berisi deskripsi teknis, permintaan bantuan, atau pertanyaan terkait fitur tertentu, yang mencerminkan kebutuhan akan peningkatan layanan pelanggan dalam aplikasi. Hal ini menunjukkan peluang besar bagi pengembang untuk menambahkan fitur interaktif seperti chatbot, FAQ dinamis, atau asisten digital yang dapat merespons secara langsung melalui aplikasi. Kaur et al. menunjukkan bahwa integrasi layanan bantuan langsung ke dalam aplikasi terbukti mampu menurunkan tingkat *churn* dan meningkatkan loyalitas pengguna [17]. Oleh karena itu, analisis terhadap segmen netral juga penting sebagai bagian dari strategi pengembangan aplikasi yang proaktif dan berorientasi solusi.

Lebih jauh lagi, hasil analisis ini juga memiliki implikasi terhadap strategi komunikasi dan pemasaran digital BCA. Dengan memahami bahwa pengguna mengapresiasi fitur modern tetapi tetap membutuhkan kestabilan, pendekatan komunikasi yang menekankan pada “kemudahan baru tanpa meninggalkan kenyamanan lama” dapat digunakan sebagai narasi promosi yang relevan. Menurut Susanto et al., penyelarasan antara harapan pengguna dan pesan pemasaran digital mampu meningkatkan *engagement* serta mengurangi gap ekspektasi yang sering kali menjadi pemicu sentimen negatif [5]. Oleh karena itu, pemetaan sentimen tidak hanya berguna dalam pengembangan produk, tetapi juga menjadi landasan dalam membentuk strategi komunikasi yang berbasis data dan empati terhadap pengalaman pengguna.

5. KESIMPULAN

Penelitian ini dilakukan dengan tujuan untuk mengetahui dan membandingkan persepsi pengguna terhadap dua aplikasi digital *banking* milik Bank Central Asia, yaitu BCA Mobile dan myBCA, dengan memanfaatkan metode analisis sentimen berbasis lexicon. Sebagaimana telah dijelaskan dalam Bab 1, penelitian ini dirancang untuk menjawab rumusan masalah terkait bagaimana sentimen pengguna terbentuk dan bagaimana perbedaan opini muncul dalam ulasan pengguna di Google Playstore. Harapan utama dari penelitian ini adalah menghasilkan pemetaan yang objektif dan berbasis data terhadap opini publik, sekaligus memberikan dasar argumentasi untuk strategi pengembangan aplikasi perbankan digital.

Hasil analisis yang disampaikan dalam Bab 4 menunjukkan bahwa apa yang diharapkan di awal telah tercapai secara menyeluruh. Klasifikasi sentimen memperlihatkan perbedaan distribusi antara BCA Mobile dan myBCA, di mana myBCA sedikit lebih unggul dalam jumlah ulasan positif, sementara kedua aplikasi memiliki kemiripan dalam proporsi sentimen netral dan negatif. Visualisasi data seperti distribusi per tanggal, distribusi skor, serta *wordcloud* dari tiap jenis sentimen berhasil mengungkapkan bahwa fitur-fitur seperti kemudahan *login*, tampilan antarmuka, serta kestabilan sistem sangat mempengaruhi emosi dan reaksi pengguna terhadap aplikasi yang mereka gunakan.

Keterkaitan antara pendekatan awal yang bersifat kuantitatif-tekstual dengan hasil akhir yang bersifat visual dan interpretatif menunjukkan bahwa metode analisis sentimen merupakan pendekatan yang efektif dalam menjembatani kebutuhan eksplorasi pengalaman pengguna dan pengambilan keputusan berbasis data. Temuan-temuan yang diperoleh juga mengonfirmasi pentingnya penggunaan ulasan digital sebagai sumber data yang kaya dan aktual untuk evaluasi produk berbasis pengguna. Dengan demikian, penelitian ini tidak hanya memberikan jawaban terhadap rumusan masalah, tetapi juga menghadirkan inovasi dalam hal pemrosesan data melalui platform Google Colab yang efisien dan terbuka untuk dikembangkan lebih lanjut.

Prospek pengembangan dari hasil penelitian ini terbuka luas, terutama dalam penerapan pendekatan hibrida antara metode lexicon dan pembelajaran mesin (*machine learning*) agar klasifikasi sentimen dapat mempertimbangkan konteks kalimat dan nuansa bahasa yang lebih kompleks. Selain itu, pendekatan *aspect-based sentiment analysis* juga berpotensi besar untuk diterapkan dalam menganalisis opini terhadap fitur spesifik seperti keamanan, kecepatan transaksi, atau estetika tampilan. Studi lanjutan juga dapat memperluas cakupan data dengan menyertakan platform ulasan lain atau media sosial agar hasil analisis dapat mencerminkan spektrum persepsi publik yang lebih luas. Dengan demikian, penelitian ini tidak hanya menghasilkan kontribusi teoretis dalam studi analisis sentimen, tetapi juga menyuguhkan arah strategis bagi pengembangan aplikasi berbasis data dan umpan balik pengguna secara berkelanjutan.

REFERENSI

- [1] L. Wewege, J. Lee, and M. C. Thomsett, “Disruptions and digital banking trends,” *J. Appl. Finance & Banking*, vol. 10, no. 6, pp. 15–56, 2020.
- [2] B. Kaur, S. Kiran, S. Grima, and R. Rupeika-Apoga, “Digital banking in Northern India: The risks on customer satisfaction,” *Risks*, vol. 9, no. 11, Art. no. 209, 2021, doi: 10.3390/risks9110209.
- [3] R. A. D. Kumalasari, K. I. Permanasari, M. Karismariyanti, and D. Munandar, “Mobile banking: System quality, information quality, service quality, customer satisfaction, and loyalty,” *J. Administrare*, vol. 9, no. 1, pp. 141–148, Jan.–Jun. 2022.
- [4] Y. F. Pratiwi, Yuliniar, and D. Pinem, “Influence of service quality and trust in customer satisfaction of mobile banking users,” *EBGC*, vol. 5, no. 1, pp. 47–53, Jul. 2022.
- [5] S. Susanto, F. Wahyudi, S. Bangun, T. W. Nurdiani, and H. Purnomo, “Analysis of The Influence of Service Quality on Customer Satisfaction and Its Impact on Reuse Intention of Mobile Banking Payment in E-Commerce Transactions,” *MALCOM*, vol. 3, no. 2, pp. 274–280, Oct. 2023.
- [6] N. Lelasari and I. Bernarto, “The impact of customer satisfaction on customer loyalty of BCA mobile banking,” *J. Manajemen (JM)*, vol. 27, no. 1, pp. 169–190, Feb. 2023.
- [7] P. Weichbroth, “Usability of Mobile Applications: A Systematic Literature Study,” *IEEE Access*, vol. 8, pp. 55563–55577, 2020, doi: 10.1109/ACCESS.2020.2981892.

- [8] A. Wahab, T. M. Alam, and M. M. Raza, "Usability Evaluation of FinTech Mobile Applications: A Statistical Approach," in Proc. 2021 Int. Conf. Innovative Computing (ICIC), Lahore, Pakistan, 2021, pp. 1–10, doi: 10.1109/ICIC53490.2021.9691512.
- [9] M. E. Permana, H. Ramadhan, I. Budi, A. B. Santoso, and P. K. Putra, "Sentiment analysis and topic detection of mobile banking application review," in Proc. 2020 5th Int. Conf. Informatics and Computing (ICIC), Gorontalo, Indonesia, 2020, pp. 1–6, doi: 10.1109/ICIC50835.2020.9288616.
- [10] N. A. Rahman, S. D. Idrus, and N. L. Adam, "Classification of customer feedbacks using sentiment analysis towards mobile banking applications," *IAES Int. J. Artif. Intell. (IJ-AI)*, vol. 11, no. 4, pp. 1579–1587, Dec. 2022, doi: 10.11591/ijai.v11.i4.pp1579-1587.
- [11] J. Jamadar, K. Karnik, A. Birari, and Y. Patil, "User Perception of Mobile Banking: Application of Sentiment Analysis and Topic Modelling Approaches to Online Reviews," in Proc. 2024 Int. Conf. Trends Quantum Comput. Emerging Business Technologies, Pune, India, 2024, pp. 1–6, doi: 10.1109/TQCEBT59414.2024.
- [12] J. A. Marpaung, M. Devega, and Yuhelmi, "Analisis sentimen kepuasan pengguna aplikasi BCA Mobile menggunakan metode Naïve Bayes dan Support Vector Machine (SVM)," *Semaster*, vol. 3, no. 1, pp. 249–261, Nov. 2024.
- [13] A. Gumelar, M. I. Nasution, I. F. Oesman, F. Ramadini, M. Irfan, and Nurliana, "Technology mobile banking on customer satisfaction," in J. Phys.: Conf. Ser., vol. 1477, Art. no. 072020, 2020, doi: 10.1088/1742-6596/1477/7/072020.
- [14] M. Rodríguez-Ibáñez, A. Casáñez-Ventura, F. Castejón-Mateos, and P.-M. Cuenca-Jiménez, "A review on sentiment analysis from social media platforms," *Expert Systems with Applications*, vol. 223, Art. no. 119862, Mar. 2023.
- [15] O. Alqaryouti, N. Siyam, A. A. Monem, and K. Shaalan, "Aspect-based sentiment analysis using smart government review data," *Applied Computing and Informatics*, vol. 20, no. 1/2, pp. 142–161, Jan. 2024, doi: 10.1016/j.aci.2019.11.003.
- [16] I. D. Sabukunze and A. Arakaza, "User Experience Analysis on Mobile Application Design Using User Experience Questionnaire," *Indonesian J. of Inf. Syst.*, vol. 4, no. 1, pp. 15–26, Aug. 2021.
- [17] S. J. Kaur, L. Ali, M. K. Hassan, and M. Al-Emran, "Adoption of digital banking channels in an emerging economy: Exploring the role of in-branch efforts," *J. Financial Services Marketing*, vol. 26, no. 2, pp. 107–121, Feb. 2021, doi: 10.1057/s41264-020-00082-w.
- [18] C. B. Pavithra and K. Geetha, "Factors affecting customers' perception towards digital banking services," *Turkish J. of Computer and Mathematics Education*, vol. 12, no. 11, pp. 1608–1614, 2021.

Analisis Sentimen Churn Pelanggan dalam Layanan Streaming NETFLIX di X Menggunakan Metode IndoBERT

Farencia Levis¹, Cindy Chuwardi², Yoshe Wuvanka³, Eveleen Huandra⁴

^{1,2,3,4}Sistem Informasi, Universitas Pelita Harapan, Medan, Indonesia

Email: ¹03081220029@student.uph.edu, ²03081220003@student.uph.edu, ³03081220020@student.uph.edu,

⁴03081220013@student.uph.edu

ABSTRAK

Penelitian ini bertujuan untuk menganalisis sentimen pelanggan terhadap layanan *streaming* Netflix yang diungkapkan melalui media sosial X (sebelumnya Twitter), guna mengidentifikasi potensi *churn* atau berhentinya pelanggan berlangganan. Metode yang digunakan dalam penelitian ini adalah pendekatan *Text Mining* dan *Sentiment Analysis*, dengan dukungan model *Natural Language Processing* (NLP) berbasis *IndoBERT*. Data dikumpulkan melalui proses web scraping dengan kata kunci terkait keluhan atau keputusan berhenti berlangganan Netflix, kemudian dilakukan tahap preprocessing teks berupa *case folding*, *cleaning*, *lemmatization*, dan *tokenization*. Hasil klasifikasi sentimen menunjukkan mayoritas ulasan bersentimen negatif, yang mengindikasikan risiko *churn* cukup tinggi. Faktor utama yang memicu sentimen negatif antara lain harga langganan, kebijakan login lintas perangkat, dan pembatalan konten favorit. Hasil dari penelitian ini dapat dimanfaatkan oleh tim pemasaran dan pengembangan produk Netflix dalam menyusun strategi retensi pelanggan berbasis opini pengguna. Penelitian ini juga membuktikan bahwa model *IndoBERT* efektif dalam mengklasifikasikan opini berbahasa Indonesia dari media sosial ke dalam kategori sentimen positif, netral, dan negatif.

Kata Kunci: Sentimen, Churn, IndoBERT, Netflix, Media Sosial, Text Mining

ABSTRACT

This study aims to analyze customer sentiment toward Netflix's streaming service as expressed on social media platform X (formerly Twitter), in order to identify potential churn. The research employs a combination of Text Mining and Sentiment Analysis methods, utilizing the IndoBERT-based Natural Language Processing (NLP) model. Data was collected using web scraping techniques with keywords indicating complaints or cancellation of Netflix subscriptions. The text data underwent preprocessing steps including case folding, cleaning, lemmatization, and tokenization. Sentiment classification results showed that most tweets expressed negative sentiment, suggesting a high risk of customer churn. Key factors driving negative sentiment include subscription pricing, login policy restrictions, and the cancellation of popular content. These findings can assist Netflix's marketing and product development teams in creating data-driven retention strategies. Furthermore, the study demonstrates that the IndoBERT model is effective in classifying Indonesian-language social media opinions into positive, neutral, and negative sentiment categories.

Keywords: Sentiment, Churn, IndoBERT, Netflix, Social Media, Text Mining

Penulis Korespondensi:

Farencia Levis

Email: farencialevis@gmail.com

Article Info

Diterima: 27 April 2025

Direvisi: 30 April 2025

Disetujui: 20 Mei 2025

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



1. PENDAHULUAN

Layanan *streaming* seperti Netflix telah menjadi bagian penting dalam industri hiburan digital, menawarkan berbagai konten yang dapat diakses kapan saja dan di mana saja. [1] Namun, dalam beberapa tahun terakhir, Netflix menghadapi tantangan dalam mempertahankan pelanggan akibat persaingan ketat dengan layanan *streaming* lain seperti Disney+, HBO Max, dan Amazon Prime Video. [2]

Fenomena *churn* pelanggan (berhenti berlangganan) menjadi isu yang signifikan bagi perusahaan, karena dapat berdampak langsung pada penurunan pendapatan, loyalitas pelanggan, serta pertumbuhan bisnis. [3] Beberapa faktor yang mempengaruhi *churn* pelanggan meliputi harga langganan, kualitas konten, pengalaman pengguna, serta kebijakan perusahaan seperti berbagi akun dan iklan. [4] Sejumlah studi sebelumnya telah menunjukkan bahwa faktor-faktor seperti harga langganan, kualitas konten, kemudahan penggunaan, serta kebijakan berbagi akun dan iklan dapat memengaruhi keputusan pelanggan untuk berhenti menggunakan layanan. [5] [6] Oleh karena itu, memprediksi pelanggan yang berpotensi berhenti berlangganan menjadi langkah strategis bagi Netflix untuk mengoptimalkan layanannya dan meningkatkan retensi pelanggan. [7]

Dalam penelitian ini, digunakan pendekatan NLP dengan metode *IndoBERT*, yaitu salah satu model deep learning berbasis transformer. [8] Model ini digunakan untuk melakukan analisis sentimen terhadap ulasan dan opini pelanggan terkait layanan Netflix. Hasil klasifikasi sentimen apakah positif, netral, atau negatif dapat dijadikan sebagai indikator awal untuk mendeteksi potensi *churn*.

Metode *IndoBERT* unggul dalam memahami konteks bahasa alami yang kompleks, sehingga lebih akurat dalam menilai nuansa sentimen dalam teks pelanggan. [9] [10] Penelitian ini diharapkan dapat memberikan manfaat dalam bentuk *insight* berharga tentang persepsi pelanggan terhadap layanan Netflix di media sosial, membantu perusahaan mengenali indikasi *churn* lebih awal melalui analisis opini, serta menyediakan dasar data yang dapat dimanfaatkan untuk menyusun strategi peningkatan layanan dan retensi pelanggan. Selain itu, penelitian ini juga menunjukkan efektivitas penggunaan model *IndoBERT* dalam analisis opini di media sosial X, khususnya dalam konteks isu *churn* pelanggan.

Dengan memahami pola *churn* pelanggan, Netflix dapat mengembangkan strategi pemasaran yang lebih efektif, meningkatkan pengalaman pengguna, serta mengurangi tingkat *churn*. Hasil penelitian ini diharapkan dapat memberikan wawasan berharga bagi perusahaan dalam mengelola retensi pelanggan secara lebih optimal.

2. METODE PENELITIAN

2.1. JENIS PENELITIAN

Penelitian ini merupakan penelitian kuantitatif eksperimental yang menggunakan pendekatan *data-driven*. Metode yang digunakan adalah *Text Mining* untuk menggali informasi dari teks tidak terstruktur, dan *Sentiment Analysis* untuk mengklasifikasikan opini pelanggan menjadi sentimen positif, netral, atau negatif. [11] Analisis dilakukan menggunakan Teknik *Natural Language Processing* (NLP) menggunakan model *IndoBERT* untuk klasifikasi sentimen. Fokus utama penelitian ini adalah mendeteksi opini negatif yang berpotensi menjadi indikator *churn* pelanggan. Tahapan penelitian akan meliputi:

1. Pengumpulan data dari media sosial menggunakan keyword terkait *churn* pelanggan.
2. Pra-pemrosesan data teks (*preprocessing*) untuk membersihkan dan menormalkan data.
3. Ekstraksi fitur dan tokenisasi menggunakan metode NLP.
4. Klasifikasi sentimen menggunakan model *IndoBERT*.
5. Analisis hasil untuk mengidentifikasi opini negatif sebagai indikator *churn*.

Hasil dari model dan analisis akan digunakan untuk memberikan rekomendasi strategis dalam mengurangi *churn* di layanan *streaming* seperti Netflix.

2.2. ALAT & TEKNOLOGI

1. *Google Colab* untuk mengeksekusi semua proses analisis
2. *Python libraries: pandas, nltk, spacy, transformers, matplotlib, emoji*
3. *Pretrained IndoBERT model* untuk mengklasifikasi sentimen
4. *Excel* agar menyimpan hasil *preprocessing & output* klasifikasi

2.3. TAHAPAN PENELITIAN

2.3.1. PENGUMPULAN DATA

Data pada penelitian ini dikumpulkan melalui platform media sosial X dengan menggunakan *tools* pihak ketiga (*tweet-harvest*) menggunakan *Google Colab*. Kata kunci pencarian yang digunakan disesuaikan dengan konteks *churn* pelanggan Netflix, yaitu "*netflix cancel*", "*berhenti langganan*", "*netflix not worth it*", "*unsub Netflix*", "*gak langganan Netflix lagi*"

dengan rentang waktu antara tahun 2023 hingga 2025. Dalam tahap pengumpulan data ini, dihasilkan kumpulan data mentah berupa tweet yang mengandung opini atau keluhan pelanggan terhadap layanan Netflix.

Berikut ini merupakan salah satu cuplikan kode yang digunakan dalam proses ekstraksi data sosial media untuk mengumpulkan opini dan keluhan pelanggan yang relevan terhadap *churn* layanan Netflix:

```
data = 'netflix_churn.csv'
search_keyword = 'netflix cancel OR berhenti langganan OR netflix not worth it OR unsub
netflix OR netflix mahal OR gak langganan netflix lagi since:2023-01-01 until:2025-01-01'
limit = 100

!npx --yes tweet-harvest@latest -o "{data}" -s "{search_keyword}" -l {limit} --token
"TOKEN_TWITTER"
```

Gambar 1 Kode Pengumpulan Data di Google Colab

2.3.2.EXPLORATORY DATA ANALYSIS (EDA)

Exploratory Data Analysis (EDA) adalah proses awal dalam analisis data yang bertujuan untuk memahami struktur, pola, dan karakteristik data sebelum dilakukan pemodelan lebih lanjut. [12] Pada tahap awal EDA, dilakukan proses pemuatan data dari file “*netflix_churn.csv*”. Dataset ini berisi kumpulan teks atau opini pelanggan yang diperoleh dari media sosial X terkait layanan Netflix. Dari keseluruhan kolom yang tersedia, hanya kolom *full_text* yang dipilih untuk dianalisis lebih lanjut karena berisi isi ulasan utama yang akan digunakan dalam proses klasifikasi dan prediksi *churn*. Berikut adalah tautan [Google Colab](#) untuk pre-processing dan klasifikasi dengan metode *IndoBERT* terhadap opini pelanggan terhadap layanan Netflix.

2.3.3.PRE-PROCESSING

1. Case Folding, Data Cleaning, Truncating

Pada tahap ini, dilakukan *preprocessing* awal terhadap data ulasan pelanggan yang diperoleh dari platform X untuk mendukung analisis prediksi *churn* pelanggan layanan Netflix. Langkah-langkah *preprocessing* yang diterapkan adalah sebagai berikut: [13]

a. Case Folding

Case folding adalah proses mengubah seluruh huruf dalam teks menjadi huruf kecil (*lowercase*). Tujuannya adalah untuk mengurangi keragaman kata akibat penggunaan huruf kapital. Semua huruf diubah menjadi huruf kecil menggunakan fungsi *lower()* agar kata-kata seperti “Netflix” dan “netflix” dianggap sama oleh sistem.

b. Data Cleaning

Menghapus elemen-elemen yang tidak relevan untuk analisis teks, antara lain:

- Baris baru (*n*)
- Emoji dan emotikon
- *Link* (tautan)
- *Username* (@...)
- *Hashtag* (#...)
- Angka dan simbol

Proses ini dilakukan dengan bantuan *library* dan beberapa ekspresi reguler (*regex*).

c. Truncating (Pemotongan Teks)

Untuk menjaga efisiensi pemrosesan dan konsistensi panjang input teks, dilakukan pemotongan terhadap ulasan hingga 50 karakter pertama. Semua hasil *preprocessing* disimpan dalam struktur *dictionary* bernama *churn_preprocess*, dengan kolom-kolom:

- *original* : isi tweet asli
- *lower* : hasil case folding
- *clean* : hasil pembersihan teks
- *truncate* : hasil pemotongan

2. Lemmatization

Lemmatization adalah proses dalam pemrosesan bahasa alami (NLP) yang bertujuan untuk mengubah setiap kata dalam teks menjadi bentuk dasarnya (*lemma*), tanpa mengubah makna aslinya. [14] Pada tahap ini, dilakukan proses *lemmatization* menggunakan *library spaCy* dengan model bahasa Inggris *en_core_web_sm*. *Lemmatization* bertujuan untuk mengubah setiap kata dalam teks ulasan pelanggan menjadi bentuk dasarnya (*lemma*), seperti “*running*” menjadi “*run*”. Hal ini dilakukan untuk menyederhanakan bentuk kata, sehingga proses analisis menjadi lebih efisien dan akurat.

```
import pandas as pd
import spacy

# Load model bahasa Inggris spaCy
nlp = spacy.load("en_core_web_sm")

# Load data
df = pd.read_excel("Preprocessing_Netflix.xlsx")

# Fungsi untuk lemmatization
def lemmatized_text(text):
    doc = nlp(text)
    return ' '.join([token.lemma_ for token in doc if not token.is_punct and not
token.is_space])

# Terapkan lemmatization ke kolom 'clean'
df['lemmatized'] = df['clean'].astype(str).map(lemmatized_text)

# Tampilkan hasil
print(df[['clean', 'lemmatized']].head())

# Simpan ke Excel (hasil akan disimpan sebagai file yang bisa diunduh)
df.to_excel("Preprocessing_Lemmatized_Netflix.xlsx", index=False)
```

Gambar 2 Kode Lemmatization di Google Colab

3. Tokenization

Tokenization adalah proses memecah teks menjadi satuan terkecil, yaitu token atau kata. [15] Dalam tahapan ini digunakan library NLTK (*Natural Language Toolkit*) dengan fungsi *word_tokenize*. *Input* untuk proses ini berasal dari hasil *lemmatization* sebelumnya (kolom *lemmatized*). Hasil dari tokenisasi disimpan dalam bentuk list kata di kolom '*tokenized*', lalu dikonversi menjadi *string* (dipisah dengan spasi) dan disimpan ke dalam kolom '*tokenized_str*'.

```
import pandas as pd
import numpy as np
from nltk.tokenize import word_tokenize
import nltk
nltk.download('punkt') # pastikan ini sudah diunduh

# Load hasil preprocessing + stemming
df = pd.read_excel("Preprocessing_Lemmatized_Netflix.xlsx")

# Gunakan kolom 'lemmatized' sebagai input tokenization
def tokenize_text(text):
    return word_tokenize(text)

# Terapkan tokenisasi (hasil jadi list token, bukan string lagi)
df['tokenized'] = df['lemmatized'].astype(str).map(tokenize_text)

# Bersihkan baris kosong (kalau ada)
df['tokenized'].replace('', np.nan, inplace=True)
df['tokenized'].replace(' ', np.nan, inplace=True)
```

```
df.dropna(subset=['tokenized'], inplace=True)

# Cek hasil
print(df[['lemmatized', 'tokenized']].head())

# Simpan hasil final token ke Excel
df['tokenized_str'] = df['tokenized'].apply(lambda tokens: ' '.join(tokens))
df.to_excel("Preprocessing Tokenized Netflix.xlsx", index=False)
```

Gambar 3 Kode Tokenization di Google Colab

2.3.4. PENGELOMPOKKAN DATA

Pada tahap ini dilakukan analisis sentimen menggunakan model *BERT Multilingual* yang disediakan oleh *Hugging Face*, yaitu model *nlptown/bert-base-multilingual-uncased-sentiment*. Model ini mampu mengklasifikasikan sentimen berdasarkan skala bintang dari 1 hingga 5. Setiap prediksi yang diberikan oleh model berupa label "*X stars*", kemudian dikonversi ke bentuk numerik. Setelah itu, dilakukan pemetaan untuk mengelompokkan skor bintang menjadi tiga kategori sentimen:

- 1–2 bintang: *Negative*
- 3 bintang: *Neutral*
- 4–5 bintang: *Positive*

Tujuan dari proses ini adalah untuk mengetahui persepsi atau kepuasan pelanggan berdasarkan ulasan mereka, yang kemudian bisa digunakan untuk menganalisis kemungkinan pelanggan melakukan *churn* (berhenti berlangganan).

2.3.5. VISUALISASI ANALISIS SENTIMEN

Setelah itu dilakukan analisis distribusi sentimen terhadap ulasan pelanggan dengan menggunakan visualisasi berupa grafik batang, kami dapat melihat proporsi ulasan yang positif, netral, dan negatif. Hasil dari analisis distribusi ini akan memberikan gambaran tentang apakah pelanggan umumnya merasa puas atau tidak dengan layanan yang disediakan.

3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk menganalisis sentimen pelanggan terhadap layanan *streaming* Netflix yang diekspresikan melalui media sosial X. Metode yang digunakan menggabungkan pendekatan *IndoBERT* untuk analisis sentimen. Langkah-langkah yang dilakukan meliputi:

3.1. PENGUMPULAN DATA

Hasil dari proses crawling ini menghasilkan 78 *tweets* yang mengandung potensi indikator *churn*, dan telah disimpan dalam tautan [crawl_netflix_churn.csv](#) untuk dianalisis lebih lanjut pada tahap transformasi dan klasifikasi data.

Tabel 1 Data Crawl Netflix

conversation id str	created at	favorite count	full text	id str	lang
1.71E+18	Tue Oct 03 17:00:34 +0000 2023	0	Why I cut and bailed. I basically will only renew when the last season of Stranger Things comes out and then cancel right after. Netflix is currently \$15.99 and you can bet it's going right up to \$19.99. Not worth it.	1.71E+18	en
1.62E+18	Thu Feb 02 01:48:49 +0000 2023	1084	Well folks its time to cancel your subscriptions and let Netflix suffer. Absolutely baffling they trying this and keep increasing their subscription prices. https://t.co/yGK7WhTiuX	1.62E+18	Australia
1.84E+18	Wed Oct 09 10:43:32 +0000 2024	5	I had to cancel my Netflix to budget and such - but when I canceled I did put one of the reasons as other: you guys keep canceling my favorite shows and it's not worth putting time and effort into using your app Cuz it's true - tired of getting invested and then they are gone	1.84E+18	en
1.66E+18	Sat May 13 05:04:43 +0000 2023	13	Looks like I was right. Netflix have decided to cancel #LockwoodandCo after one season. They've been doing this far too much recently & I'm starting to wonder if it's worth cancelling my subscription! https://t.co/nuWkrG9TUe	1.66E+18	Somewhere
1.62E+18	Wed Feb 01 16:22:58 +0000 2023	55	Netflix is rly about to learn how disposable it is. If you prevent me from signing in across multiple households I will simply cancel. You're not worth buying more subscriptions for.	1.62E+18	en

Tujuan dari pengumpulan data ini untuk mengetahui opini dan keluhan pengguna terkait layanan Netflix yang dapat mengindikasikan potensi *churn* pelanggan.

3.2. PRE-PROCESING TEKS

Melakukan *case folding*, *cleaning*, *truncating*, *lemmatization*, dan tokenisasi untuk mempersiapkan teks yang bersih dan siap dianalisis. *Preprocessing* bertujuan untuk membersihkan dan menormalkan teks agar lebih siap digunakan untuk tahapan analisis.

1. Case Folding, Data Cleaning, Truncate

Seluruh teks diubah menjadi huruf kecil (*lowercase*) agar tidak terjadi perbedaan interpretasi antara kata yang sama tetapi dengan format kapitalisasi berbeda, seperti “Netflix” dan “netflix”. Teks dibersihkan dari berbagai elemen yang tidak relevan dengan analisis sentiment. Teks yang telah dibersihkan kemudian dipotong (*truncate*) hingga maksimal 50 karakter pertama.

Tabel 2 Hasil *Case Folding*, *Data Cleaning*, dan *Truncate*

original	Lower	clean	truncate
Why I cut and bailed. I basically will only renew when the last season of Stranger Things comes out and then cancel right after. Netflix is currently \$15.99 and you can bet it s going right up to \$19.99. Not worth it.	why i cut and bailed. i basically will only renew when the last season of stranger things comes out and then cancel right after. netflix is currently \$15.99 and you can bet it s going right up to \$19.99. not worth it.	why i cut and bailed i basically will only renew when the last season of stranger things comes out and then cancel right after netflix is currently and you can bet it s going right up to not worth it	why i cut and bailed i basically will only renew w
Well folks its time to cancel your subscriptions and let Netflix suffer. Absolutely baffling they trying this and keep increasing their subscription prices. https://t.co/yGK7WhTiuX	well folks its time to cancel your subscriptions and let netflix suffer. absolutely baffling they trying this and keep increasing their subscription prices. https://t.co/ygk7whtiux	well folks its time to cancel your subscriptions and let netflix suffer absolutely baffling they trying this and keep increasing their subscription prices	well folks its time to cancel your subscriptions a
I had to cancel my Netflix to budget and such - but when I canceled I did put one of the reasons as other: you guys keep canceling my favorite shows and it's not worth putting time and effort into using your app Cuz it's true - tired of getting invested and then they are gone	i had to cancel my netflix to budget and such - but when i canceled i did put one of the reasons as other: you guys keep canceling my favorite shows and it's not worth putting time and effort into using your app cuz it's true - tired of getting invested and then they are gone	i had to cancel my netflix to budget and such but when i canceled i did put one of the reasons as other you guys keep canceling my favorite shows and it s not worth putting time and effort into using your app cuz it s true tired of getting invested and then they are gone	i had to cancel my netflix to budget and such but
Looks like I was right. Netflix have decided to cancel #LockwoodandCo after one season. They've been doing this far too much recently & i'm starting to wonder if it's worth cancelling my subscription! https://t.co/nuWkrG9TUE	looks like i was right. netflix have decided to cancel #lockwoodandco after one season. they've been doing this far too much recently & i'm starting to wonder if it's worth cancelling my subscription! https://t.co/nuwkrG9tue	looks like i was right netflix have decided to cancel lockwoodandco after one season they ve been doing this far too much recently amp i m starting to wonder if it s worth cancelling my subscription	looks like i was right netflix have decided to can
Netflix is rllly about to learn how disposable it is. If you prevent me from signing in across multiple households I will simply cancel. You're not worth buying more subscriptions for.	netflix is rllly about to learn how disposable it is. if you prevent me from signing in across multiple households i will simply cancel. you're not worth buying more subscriptions for.	netflix is rllly about to learn how disposable it is if you prevent me from signing in across multiple households i will simply cancel you re not worth buying more subscriptions for	netflix is rllly about to learn how disposable it i

Hasil preprocessing dikonversi ke dalam bentuk *DataFrame* dan disimpan ke file Excel [Preprocessing CDT Netflix.xlsx](#).

2. Lemmetization

Lemmatization adalah proses mengubah setiap kata ke dalam bentuk dasar (*lemma*) tanpa mengubah makna dasarnya. Misalnya, kata “watching”, “watches”, dan “watched” semuanya akan diubah menjadi bentuk dasarnya “watch”. Data yang digunakan berasal dari file *Preprocessing_Netflix.xlsx*, dan hasil *lemmatization* disimpan ke dalam kolom baru bernama *lemmatized*. File hasil *lemmatization* ini disimpan ke file baru [Preprocessing Lemmatized Netflix.xlsx](#).

Tabel 3 Hasil *Lemmetization*

truncate	lemmetized
why i cut and bailed i basically will only renew w	why I cut and bail I basically will only renew when the last season of stranger thing come out and then cancel right after netflix be currently and you can bet it s go right up to not worth it
well folks its time to cancel your subscriptions a	well folk its time to cancel your subscription and let netflix suffer absolutely baffle they try this and keep increase their subscription price
i had to cancel my netflix to budget and such but	I have to cancel my netflix to budget and such but when I cancel I do put one of the reason as other you guy keep cancel my favorite show and it s not worth put time and effort into use your app cuz it s true tired of getting invest and then they be go
looks like i was right netflix have decided to can	look like I be right netflix have decide to cancel lockwoodandco after one season they ve be do this

<i>netflix is rlly about to learn how disposable it i</i>	<i>far too much recently amp I m start to wonder if it s worth cancel my subscription netflix be rlly about to learn how disposable it be if you prevent I from sign in across multiple household I will simply cancel you re not worth buy more subscription for</i>
---	---

3. Tokenization


Tokenization adalah proses memecah kalimat atau teks menjadi unit terkecil yang disebut token, biasanya berupa kata. Tujuan dari tahap ini adalah untuk mempersiapkan data teks agar bisa digunakan pada model machine learning, khususnya untuk tahap analisis sentimen. Hasil dari *tokenization* bisa dilihat di file Excel [Preprocessing Tokenized Netflix.xlsx](#).

Tabel 4 Hasil Tokenization

<i>truncate</i>	<i>lemmetized</i>	<i>tokenized</i>	<i>tokenized str</i>
<i>why i cut and bailed i basically will only renew w</i>	<i>why I cut and bail I basically will only renew when the last season of stranger thing come out and then cancel right after netflix be currently and you can bet it s go right up to not worth it</i>	<i>['why', 'I', 'cut', 'and', 'bail', 'I', 'basically', 'will', 'only', 'renew', 'when', 'the', 'last', 'season', 'of', 'stranger', 'thing', 'come', 'out', 'and', 'then', 'cancel', 'right', 'after', 'netflix', 'be', 'currently', 'and', 'you', 'can', 'bet', 'it', 's', 'go', 'right', 'up', 'to', 'not', 'worth', 'it']</i>	<i>why I cut and bail I basically will only renew when the last season of stranger thing come out and then cancel right after netflix be currently and you can bet it s go right up to not worth it</i>
<i>well folks its time to cancel your subscriptions a</i>	<i>well folk its time to cancel your subscription and let netflix suffer absolutely baffle they try this and keep increase their subscription price</i>	<i>['well', 'folk', 'its', 'time', 'to', 'cancel', 'your', 'subscription', 'and', 'let', 'netflix', 'suffer', 'absolutely', 'baffle', 'they', 'try', 'this', 'and', 'keep', 'increase', 'their', 'subscription', 'price']</i>	<i>well folk its time to cancel your subscription and let netflix suffer absolutely baffle they try this and keep increase their subscription price</i>
<i>i had to cancel my netflix to budget and such but</i>	<i>I have to cancel my netflix to budget and such but when I cancel I do put one of the reason as other you guy keep cancel my favorite show and it s not worth put time and effort into use your app cuz it s true tired of getting invest and then they be go</i>	<i>['I', 'have', 'to', 'cancel', 'my', 'netflix', 'to', 'budget', 'and', 'such', 'but', 'when', 'I', 'cancel', 'I', 'do', 'put', 'one', 'of', 'the', 'reason', 'as', 'other', 'you', 'guy', 'keep', 'cancel', 'my', 'favorite', 'show', 'and', 'it', 's', 'not', 'worth', 'put', 'time', 'and', 'effort', 'into', 'use', 'your', 'app', 'cuz', 'it', 's', 'true', 'tired', 'of', 'getting', 'invest', 'and', 'then', 'they', 'be', 'go']</i>	<i>I have to cancel my netflix to budget and such but when I cancel I do put one of the reason as other you guy keep cancel my favorite show and it s not worth put time and effort into use your app cuz it s true tired of getting invest and then they be go</i>
<i>looks like i was right netflix have decided to can</i>	<i>look like I be right netflix have decide to cancel lockwoodandco after one season they ve be do this far too much recently amp I m start to wonder if it s worth cancel my subscription</i>	<i>['look', 'like', 'I', 'be', 'right', 'netflix', 'have', 'decide', 'to', 'cancel', 'lockwoodandco', 'after', 'one', 'season', 'they', 've', 'be', 'do', 'this', 'far', 'too', 'much', 'recently', 'amp', 'I', 'm', 'start', 'to', 'wonder', 'if', 'it', 's', 'worth', 'cancel', 'my', 'subscription']</i>	<i>look like I be right netflix have decide to cancel lockwoodandco after one season they ve be do this far too much recently amp I m start to wonder if it s worth cancel my subscription</i>
<i>netflix is rlly about to learn how disposable it i</i>	<i>netflix be rlly about to learn how disposable it be if you prevent I from sign in across multiple household I will simply cancel you re not worth buy more subscription for</i>	<i>['netflix', 'be', 'rlly', 'about', 'to', 'learn', 'how', 'disposable', 'it', 'be', 'if', 'you', 'prevent', 'I', 'from', 'sign', 'in', 'across', 'multiple', 'household', 'I', 'will', 'simply', 'cancel', 'you', 're', 'not', 'worth', 'buy', 'more', 'subscription', 'for']</i>	<i>netflix be rlly about to learn how disposable it be if you prevent I from sign in across multiple household I will simply cancel you re not worth buy more subscription for</i>

3.3. KLASIFIKASI SENTIMEN DENGAN INDOBERT

Model *IndoBERT* berhasil mengklasifikasikan tweet yang telah diproses ke dalam tiga kategori sentimen. Pemrosesan ini dilakukan sepenuhnya di *Google Colab* menggunakan pipeline dari *library Transformers*. Hasil dari tahapnya bisa dilihat dari file Excel berikut [Hasil_3Label Sentimen NetflixChurn.xlsx](#).



Gambar 4 Jumlah Sentimen Data Netflix Churn

3.4. ANALISIS DAN INTERPRETASI SENTIMEN CHURN

Setelah dilakukan *preprocessing* dan klasifikasi sentimen menggunakan model *IndoBERT*, dilakukan analisis lebih lanjut terhadap hasil klasifikasi untuk menjawab rumusan masalah dan tujuan penelitian.

3.4.1.DISTRIBUSI SENTIMEN PELANGGAN

Berdasarkan *output* dari klasifikasi sentimen, data dibagi ke dalam tiga kategori:

- Positif: mencerminkan kepuasan pelanggan
- Netral: tidak menunjukkan emosi kuat terhadap layanan
- Negatif: menunjukkan ketidakpuasan dan menjadi indikator potensi *churn*

Tabel 5 Persentase Sentimen

Sentimen	Jumlah Tweet	Persentase
Positif	10	12.8%
Netral	1	1.3%
Negatif	67	85.9%

Dari hasil persentase klasifikasi sentimen model *IndoBERT* bisa diasumsikan, mayoritas pelanggan mengungkapkan ketidakpuasan terhadap layanan Netflix, tingginya persentase tweet negatif menandakan bahwa tingkat risiko *churn* sangat tinggi dalam periode waktu pengamatan. Hasil ini memperkuat kebutuhan untuk mengevaluasi harga layanan, konten, dan kebijakan platform. Distribusi ini menjadi indikator kuat bagi perusahaan untuk segera mengambil tindakan strategis, baik dari sisi pemasaran, pelayanan pelanggan, maupun pengembangan produk.

3.4.2.INDIKATOR CHURN BERDASARKAN ANALISIS SENTIMEN

Dari hasil klasifikasi, dilakukan pemetaan kata kunci dominan yang sering muncul pada *tweet* dengan sentimen negatif. Beberapa tema utama yang muncul antara lain:

- Harga mahal: “Netflix mahal”, “*not worth*”, “*price increase*”
- Konten dikurangi atau dibatalkan: “*cancel show*”, “*favourite show gone*”
- Kebijakan login: “*multiple households*”, “*sharing password*”
- Kompetitor lebih menarik: “Disney”, “Prime”, “*cheaper option*”

Keluhan ini mengarah pada alasan konkret pelanggan berhenti berlangganan. Dengan mengidentifikasi pola ini, perusahaan bisa mengambil langkah pencegahan yang lebih tepat.

3.4.3.VALIDASI MANFAAT INDOBERT

Penggunaan *IndoBERT* terbukti efisien dalam:

- Mengklasifikasikan sentimen secara akurat.
- Menangkap konteks *churn* dari opini pendek dan informal seperti *tweet*.
- Mengurangi ambiguitas teks media sosial, berkat *pretraining* yang luas.

Model ini mendukung tujuan penelitian ke-2 dan ke-3 secara signifikan, dan memberikan dasar analitik yang kuat dalam menyusun strategi retensi pelanggan.

4. KESIMPULAN

Penelitian ini bertujuan untuk menganalisis sentimen pelanggan terhadap layanan *streaming* Netflix yang diekspresikan melalui media sosial X (sebelumnya Twitter), serta mengidentifikasi opini negatif yang berpotensi menjadi indikator *churn*. Berdasarkan hasil yang diperoleh, dapat disimpulkan bahwa tujuan penelitian sebagaimana dijabarkan dalam Bab Pendahuluan telah tercapai, dengan didukung oleh temuan dan analisis pada Bab Hasil dan Pembahasan.

Kesimpulan utama dari penelitian ini adalah sebagian besar tweet pelanggan menunjukkan sentimen negatif, yang menjadi indikator kuat adanya potensi *churn* jika tidak segera ditindaklanjuti. Sentimen negatif ini umumnya berkaitan dengan harga layanan yang meningkat, konten yang tidak memuaskan, dan kebijakan login lintas perangkat yang dianggap membatasi kenyamanan pelanggan. Metode *IndoBERT* terbukti efektif dalam memetakan opini pelanggan ke dalam tiga kategori sentimen utama: positif, netral, dan negatif. Analisis sentimen berhasil mengidentifikasi faktor-faktor utama penyebab *churn*, yang dapat dijadikan dasar untuk pengambilan keputusan bisnis secara strategis oleh pihak Netflix.

Temuan ini dapat dimanfaatkan oleh tim bisnis Netflix untuk mengembangkan strategi promosi ulang (re-marketing) kepada pelanggan yang menunjukkan potensi *churn*. Hasil klasifikasi sentimen juga dapat digunakan untuk menyesuaikan kebijakan dan fitur layanan, berdasarkan sentimen pelanggan terhadap aspek-aspek tertentu. Selain itu, perusahaan dapat meningkatkan *customer experience* melalui perbaikan yang bersifat responsif terhadap opini dan keluhan nyata dari pengguna.

Saran untuk penelitian selanjutnya adalah penggunaan dataset dengan volume yang lebih besar dan lebih bervariasi secara temporal agar hasilnya lebih general dan menggabungkan analisis sentimen dengan analisis prediktif lainnya seperti *clustering churn behavior* atau *predictive modeling* berbasis atribut pengguna.

UCAPAN TERIMA KASIH

Puji dan syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa sehingga penulis dapat menyelesaikan laporan penelitian yang berjudul "Analisis Sentimen Churn Pelanggan dalam Layanan Streaming Netflix di X Menggunakan Metode IndoBERT" dengan baik. Tim ini juga ingin menyampaikan terima kasih yang sebesar-besarnya kepada dosen pembimbing yang telah memberikan bimbingan, arahan, dan masukan yang sangat berharga selama proses penelitian ini. Laporan ini masih jauh dari sempurna. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan demi penyempurnaan laporan ini di masa yang akan datang.

REFERENSI

- [1] Y. Anjani, M. Wicaksana, and A. Kuswanti, "Penggunaan aplikasi streaming Netflix pada generasi Z," *Ikon--Jurnal Ilmiah Ilmu Komunikasi*, vol. 28, no. 1, pp. 88–96, 2023.
- [2] P. S. Sitanggang, "Strategi pemasaran global terhadap Netflix," *ULIL ALBAB: Jurnal Ilmiah Multidisiplin*, vol. 1, no. 9, pp. 3026–3035, 2022.
- [3] K. S. R. Palluvi, N. Syaada, and B. Intan, "Komparasi Metode Decision Tree dan K-Nearest Neighbor (KNN) dalam Memprediksi Costumer Churn Pada Perusahaan Telekomunikasi," *Bulletin of Information System Research*, vol. 3, no. 1, pp. 39–45, 2024.
- [4] S. T. Sjukun and M. M. SM, *Pemasaran Di Era Digital*. CV. AZKA PUSTAKA, 2024.
- [5] P. Simaniburuk *et al.*, *MEMAHAMI PERILAKU KONSUMEN: Strategi Pemasaran yang Efektif pada Era Digital*. PT. Sonpedia Publishing Indonesia, 2023.
- [6] S. E. Yoyo Sudaryo, M. MM, S. P. Nunung Ayu Sofiaty Efi, S. E. Mohamad Arfiman Yosep, S. T. Budi Nurdiansyah, and M. H. SE, *Digital Marketing dan fintech di Indonesia*. Penerbit Andi, 2020.
- [7] R. S. Y. Zebua *et al.*, *BISNIS DIGITAL: Strategi Administrasi Bisnis Digital Untuk Menghadapi Masa Depan*. PT. Sonpedia Publishing Indonesia, 2023.
- [8] D. Sebastian, H. D. Purnomo, and I. Sembiring, "Bert for natural language processing in bahasa Indonesia," in *2022 2nd International Conference on Intelligent Cybernetics Technology & Applications (ICICyTA)*, IEEE, 2022, pp. 204–209.
- [9] R. Merdiansah, S. Siska, and A. A. Ridha, "Analisis sentimen pengguna X Indonesia terkait kendaraan listrik menggunakan IndoBERT," *Jurnal Ilmu Komputer dan Sistem Informasi (JIKOMSI)*, vol. 7, no. 1, pp. 221–228, 2024.
- [10] M. P. Firdaus and D. Trisnawarman, "Analisis Sentimen Publik terhadap Program Tabungan Perumahan Rakyat Menggunakan Model IndoBERT Lite pada Komentar YouTube: Public Sentiment Analysis of the Public Housing Savings Program Using the IndoBERT Lite Model on YouTube Comments," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 1, pp. 359–368, 2025.
- [11] A. Onan, "Sentiment analysis on massive open online course evaluations: a text mining and deep learning approach," *Computer Applications in Engineering Education*, vol. 29, no. 3, pp. 572–589, 2021.
- [12] F. Elfaladonna, I. G. T. Isa, D. Sartika, and A. M. Putra, *Buku Ajar Dasar Exploratory Data Analysis (EDA)*. Penerbit NEM, 2024.
- [13] M. Kunilovskaya and A. Plum, "Text preprocessing and its implications in a digital humanities project," in *Proceedings of the Student Research Workshop Associated with RANLP 2021*, 2021, pp. 85–93.
- [14] R. Pramana, J. J. Subroto, and A. A. S. Gunawan, "Systematic literature review of stemming and lemmatization performance for sentence similarity," in *2022 IEEE 7th international conference on information technology and digital applications (ICITDA)*, IEEE, 2022, pp. 1–6.
- [15] S. U. Royan, N. Suarna, I. Ali, and D. Solihudin, "ANALISIS SENTIMEN ULASAN PRODUK SKINCARE DI SHOPEE UNTUK MENINGKATKAN KUALITAS PRODUK MENGGUNAKAN METODE SUPPORT VECTOR MACHINE," *Jurnal Informasi dan Komputer*, vol. 13, no. 01, pp. 96–105, 2025.

Penerapan Algoritma K-Nearest Neighbors untuk Klasifikasi Kualitas Air Minum

Jansen¹, Cariven Tanova², Darief³, Marciano⁴ Ade Maulana⁵

^{1,2,3,4,5}Sistem Informasi (Kampus Kota Medan), Universitas Pelita Harapan, Indonesia

Email: ¹03081230024@student.uph.edu,, ²03081230027@student.uph.edu, ³03081230013@student.uph.edu,

⁴03081230020@student.uph.edu, ⁵ade.maulana@lecturer.uph.edu

ABSTRAK

Penelitian ini bertujuan untuk mengklasifikasikan kelayakan air minum berdasarkan parameter fisik dan kimia menggunakan algoritma *K-Nearest Neighbors* (KNN). Data diambil dari platform Kaggle, terdiri dari 100.000 sampel air dengan sembilan atribut utama, termasuk pH, kekerasan, TDS, sulfat, chloramines, konduktivitas, karbon organik, trihalomethanes, dan kekeruhan. Label target adalah *potability*, yang menunjukkan apakah air layak dikonsumsi (1) atau tidak (0). Tahapan prapengolahan mencakup normalisasi dan pembagian data menjadi data latih dan uji. Model KNN dibangun dengan mengevaluasi berbagai nilai *K* untuk mendapatkan performa optimal. Hasil evaluasi menggunakan confusion matrix menunjukkan bahwa model mampu mencapai akurasi sebesar 78%. Pada kelas air layak, diperoleh precision sebesar 72%, recall 91%, dan F1-score 81%. Sementara itu, untuk air tidak layak, precision mencapai 88%, recall 65%, dan F1-score 75%. Meskipun model menunjukkan kecenderungan salah mengklasifikasikan air tidak layak sebagai layak, secara keseluruhan performanya cukup baik. Hasil ini menunjukkan bahwa KNN dapat digunakan sebagai pendekatan klasifikasi yang efektif dan berpotensi diterapkan dalam sistem pemantauan kualitas air secara otomatis.

Kata Kunci: Kualitas Air, Kelayakan Air Minum, K-Nearest Neighbors, Klasifikasi, Machine Learning

ABSTRACT

This study aims to classify drinking water potability based on physical and chemical parameters using the K-Nearest Neighbors (KNN) algorithm. The dataset, sourced from the Kaggle platform, contains 100,000 water samples with nine key attributes, including pH, hardness, total dissolved solids (TDS), sulfate, chloramines, conductivity, organic carbon, trihalomethanes, and turbidity. The target label is potability, indicating whether the water is safe (1) or unsafe (0) for consumption. The preprocessing steps included normalization and splitting the data into training and testing sets. The KNN model was trained by experimenting with various K values to achieve optimal performance. Evaluation using a confusion matrix showed that the model achieved an accuracy of 78%. For the potable class, the model reached a precision of 72%, recall of 91%, and F1-score of 81%. For the non-potable class, it achieved a precision of 88%, recall of 65%, and F1-score of 75%. Although the model tends to misclassify unsafe water as safe, overall performance is promising. These findings suggest that the KNN algorithm can serve as an effective classification approach and has potential for application in automated water quality monitoring systems.

Keywords: Water Quality, Drinking Water Potability, K-Nearest Neighbors, Classification, Machine Learning

Penulis Korespondensi:

Ade Maulana

Email: ade.maulana@lecturer.uph.edu

Article Info

Diterima: 27 Mei 2025

Direvisi: 28 Mei 2025

Disetujui: 28 Mei 2025

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



1. PENDAHULUAN

Air adalah kebutuhan utama bagi semua makhluk hidup [1]. Salah satu sumber air yang tersedia di sekitar kehidupan manusia adalah air sungai yang mengalir [2]. Ketersediaan air minum yang aman dan layak konsumsi merupakan salah satu indikator penting dalam pencapaian tujuan pembangunan berkelanjutan (SDGs), khususnya poin keenam yang menargetkan akses universal terhadap air bersih pada tahun 2030. Menurut standar air minum Indonesia yang ditetapkan oleh PP No. 82 Tahun 2001 dan KepMen No. 907 Tahun 2002, air bersih yang digunakan setiap hari harus berkualitas baik untuk dikonsumsi [3]. Namun, hingga saat ini masih terdapat sekitar dua miliar penduduk dunia yang menggunakan sumber air minum terkontaminasi [4]. Air yang tidak layak konsumsi dapat membawa berbagai risiko kesehatan serius, termasuk penyakit diare, kolera, disentri, dan infeksi parasit lainnya, yang menyumbang angka kematian cukup tinggi di berbagai negara berkembang [5]. Menurut laporan WHO, sekitar 829.000 orang meninggal setiap tahunnya akibat konsumsi air yang tercemar, sanitasi yang buruk, serta kurangnya kebersihan [6]. Di samping itu, kualitas air juga dipengaruhi oleh berbagai faktor fisik dan kimia, seperti tingkat pH, kandungan logam berat, serta parameter mikrobiologis yang tidak selalu dapat dideteksi secara visual [7]. Air disebut sebagai senyawa kompleks karena mengandung berbagai zat dan mineral. Namun, tidak semua kandungan tersebut dapat diserap oleh tubuh manusia. Air juga mudah tercemar oleh zat dan bakteri berbahaya akibat pencemaran sumber air atau lingkungan sekitarnya. Oleh karena itu, diperlukan pengawasan dan pengolahan yang ketat agar kualitas air tetap terjaga sesuai standar dan aman untuk dikonsumsi [8]. Pemantauan kualitas air secara rutin dan akurat menjadi tantangan tersendiri, terutama di wilayah dengan keterbatasan laboratorium dan teknologi pengujian [9]. Meskipun diketahui presentasi 97% air yang hadir di bumi, hanya ada sekitar 27% yang secara layak untuk dilakukan pengonsumsi atau memenuhi kebutuhan konsumsi manusia [10]. Di Indonesia sendiri, data dari Badan Pusat Statistik menunjukkan bahwa pada tahun 2022, hanya sekitar 73,9% rumah tangga yang memiliki akses terhadap air minum layak, dan angka ini lebih rendah lagi di daerah perdesaan [11]. Kondisi ini memperkuat urgensi terhadap pengembangan sistem yang mampu memprediksi kelayakan air secara cepat dan efisien sebagai bagian dari upaya preventif dalam perlindungan kesehatan masyarakat.

Pengujian kualitas air dengan metode konvensional seringkali memakan waktu dan biaya yang tinggi, sehingga dibutuhkan pendekatan yang lebih efisien dan didukung oleh pemanfaatan data [12]. Salah satu pendekatan yang semakin banyak dimanfaatkan dalam membantu proses klasifikasi data lingkungan, termasuk dalam penilaian kualitas air, adalah *machine learning*. Metode ini memungkinkan komputer untuk mengenali pola dari sejumlah data historis dan menggunakannya untuk membuat prediksi terhadap data baru. Dalam studi ini, penulis menggunakan algoritma *K-Nearest Neighbor* (KNN) sebagai teknik klasifikasi guna memprediksi kelayakan air minum berdasarkan parameter kualitas air seperti pH, kandungan logam berat, dan senyawa kimia lainnya. KNN merupakan algoritma yang sederhana namun efektif, karena bekerja dengan cara menghitung kedekatan antara data uji dan sejumlah data pelatihan yang diketahui kelasnya, lalu mengklasifikasikan data uji berdasarkan label mayoritas dari tetangganya [13][14]. Sifat algoritma ini yang fleksibel serta tidak membutuhkan asumsi distribusi data menjadikannya cocok digunakan dalam permasalahan klasifikasi kualitas air yang melibatkan banyak variabel dan kemungkinan *outlier*.

Beberapa penelitian sebelumnya menunjukkan bahwa algoritma KNN mampu memberikan performa yang baik dalam mengklasifikasikan kualitas air. Penelitian oleh Jadhav dan Channe berhasil mencapai akurasi sebesar 90,14% dalam memprediksi kelayakan air menggunakan metode KNN pada *dataset* kualitas air dari *Central Pollution Control Board* India [15]. Studi lainnya oleh Patel dan Thakkar juga menunjukkan bahwa KNN dapat digunakan secara efektif dalam sistem monitoring kualitas air berbasis sensor, dengan tingkat akurasi mencapai 85,23% [16]. Sementara itu, penelitian oleh Shukla et al. menyimpulkan bahwa KNN menjadi salah satu algoritma yang kompetitif dibanding metode lain seperti *Decision Tree* dan SVM dalam mengklasifikasikan air bersih dan tercemar, dengan akurasi 87,5% saat digunakan pada *dataset* yang diambil dari sumber sungai [17]. Penelitian-penelitian ini mengindikasikan bahwa KNN merupakan algoritma yang layak untuk digunakan dalam sistem prediksi kualitas air minum berbasis data.

Penelitian ini bertujuan untuk mengembangkan sebuah model klasifikasi kualitas air yang bersifat sederhana namun tetap akurat, dengan memanfaatkan tiga parameter utama yaitu pH, suhu, dan tingkat kekeruhan sebagai variabel masukan. Ketiga parameter ini dipilih karena dapat diperoleh dengan mudah melalui perangkat sensor dan merupakan indikator penting dalam menentukan kelayakan air. Diharapkan, hasil dari penelitian ini dapat memberikan kontribusi dalam upaya deteksi dini kualitas air, sehingga masyarakat maupun instansi terkait dapat melakukan tindakan cepat untuk mencegah dampak kesehatan dan lingkungan yang lebih luas.


2. METODE PENELITIAN

Pada penelitian ini, proses klasifikasi kualitas air dilakukan dengan pendekatan algoritma *machine learning K-Nearest Neighbor* (KNN). Secara umum, tahapan penelitian ini terdiri dari lima langkah utama, yakni identifikasi masalah, pengumpulan data, prapengolahan data, pelatihan model, serta pengujian dan evaluasi. Kelima tahapan tersebut digambarkan dalam diagram alur proses sebagai dasar metodologi yang digunakan dalam penelitian ini.

2.1. Identifikasi Masalah

Pada tahap ini, dirumuskan permasalahan terkait meningkatnya kebutuhan akan sistem pemantauan kualitas air yang efisien dan akurat, khususnya dalam kaitannya dengan lingkungan dan kesehatan masyarakat. Penilaian kualitas air secara manual memerlukan waktu, tenaga, serta sumber daya yang besar, dan cenderung rawan terhadap kesalahan subjektif. Untuk itu,

dibutuhkan suatu metode klasifikasi otomatis yang mampu mengelompokkan kualitas air berdasarkan parameter fisik dan kimia tertentu. Pendekatan berbasis *machine learning* ini diharapkan dapat meningkatkan efektivitas pemantauan serta mendukung pengambilan keputusan yang lebih tepat dalam pengelolaan sumber daya air.



Gambar 1 Metode Penelitian

2.2. Pengumpulan Data

Data yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, yang menyediakan *dataset* terkait kualitas air. *Dataset* tersebut terdiri dari 100.000 entri data yang masing-masing merepresentasikan sampel air dengan sembilan atribut utama, yaitu *pH*, *hardness*, *total dissolved solids (TDS)*, *chloramines*, *sulfate*, *conductivity*, *organic carbon*, *trihalomethanes*, dan *turbidity*. Label target dari *dataset* ini adalah *potability*, yang mengindikasikan apakah air tersebut layak untuk dikonsumsi (1) atau tidak layak konsumsi (0). *Dataset* ini dipilih karena memenuhi beberapa kriteria penting, antara lain: (1) jumlah data yang cukup untuk mendukung pelatihan dan evaluasi model secara representatif; (2) atribut-atribut yang digunakan mencerminkan parameter kimia dan fisik air yang umum dipakai dalam standar penilaian kualitas air; serta (3) format data yang telah terstruktur dan siap untuk dilakukan prapengolahan dan klasifikasi lebih lanjut.

2.3. Prapengolahan Data

Sebelum membangun model klasifikasi kualitas air, dilakukan serangkaian proses prapengolahan data untuk memastikan data yang digunakan bersih, lengkap, dan dalam format yang sesuai untuk algoritma KNN. Berikut adalah tahapan prapengolahan data yang dilakukan dalam penelitian ini:

Tabel 1 Tahap Prapengolahan Data

No	Tahapan Prapengolahan Data	Penjelasan
1	Menghapus Nilai Kosong	Menghapus baris data yang memiliki nilai <i>null</i> pada salah satu atribut.
2	Cek dan Ubah Tipe Data	Memastikan semua kolom numerik bertipe <i>float</i> untuk proses komputasi.
3	Normalisasi Nilai Atribut	Menggunakan <i>Min-Max Scaling</i> agar seluruh atribut berada pada rentang 0–1.
4	Pemisahan Fitur dan Label	Memisahkan fitur (X) dan label target <i>potability</i> (y).
5	Pembagian <i>Data Train</i> dan <i>Test</i>	Data dibagi menjadi 80% data latih dan 20% data uji menggunakan <i>train_test_split</i> .

2.4. Pelatihan Model

Setelah proses prapengolahan data selesai, langkah selanjutnya adalah melakukan pelatihan model klasifikasi untuk menilai kelayakan air berdasarkan parameter-parameter kualitasnya. Dalam penelitian ini, algoritma *K-Nearest Neighbors* (KNN) dipilih karena kesederhanaannya dan efektivitasnya dalam mengklasifikasikan data berdasarkan kedekatan nilai fitur. *Dataset* yang telah dinormalisasi dibagi menjadi dua bagian: 80% sebagai data latih dan 20% sebagai data uji, menggunakan fungsi *train_test_split()* dari pustaka *scikit-learn*. Selanjutnya, dilakukan pengujian terhadap beberapa nilai K, yaitu K = 3, 5, dan 7.

2.5. Pengujian dan Evaluasi

Pengujian dan evaluasi dilakukan untuk menilai performa model *K-Nearest Neighbors* dalam mengklasifikasikan kelayakan air berdasarkan parameter kualitas seperti pH, TDS, dan *turbidity*. Dataset dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian menggunakan fungsi *train_test_split* dari pustaka *scikit-learn*, dengan tujuan memastikan kemampuan generalisasi model terhadap data baru. Evaluasi performa dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*, yang memberikan gambaran menyeluruh mengenai efektivitas model dalam menangani data kelas seimbang. Selain itu, *confusion matrix* digunakan untuk mengilustrasikan jumlah prediksi benar dan salah pada masing-masing kelas (layak konsumsi dan tidak layak).

3. HASIL DAN PEMBAHASAN


Bagian ini menyajikan hasil dari tahapan implementasi model serta analisis terhadap performa klasifikasi yang dilakukan. Proses dimulai dari prapengolahan data, pelatihan model menggunakan algoritma *K-Nearest Neighbors*, hingga evaluasi hasil prediksi menggunakan metrik klasifikasi. Setiap tahapan dijelaskan secara sistematis untuk menunjukkan bagaimana data diolah dan bagaimana model merespons pola yang terdapat dalam *dataset* kualitas air.

3.1. Prapengolahan Data

Prapengolahan data merupakan tahap krusial dalam proses analisis data karena kualitas data sangat menentukan akurasi dan keandalan model yang dibangun. Tahapan ini dilakukan dengan beberapa langkah sebagai berikut : Langkah pertama adalah mengimpor data menggunakan pustaka *pandas* dari berkas CSV yang berisi data kualitas air. Setelah data dimuat, dilakukan eksplorasi awal untuk memahami struktur data, jenis tipe data, dan mendeteksi adanya nilai kosong pada masing-masing atribut. Berdasarkan hasil inspeksi, diketahui bahwa atribut *ph*, *tds*, *sulfate*, dan *conductivity* mengandung nilai kosong (*missing values*). Untuk menangani hal ini, nilai kosong diisi menggunakan nilai median dari masing-masing kolom. Pemilihan median dilakukan karena sifatnya lebih tahan terhadap *outlier* dibandingkan dengan rata-rata.

Selanjutnya, dilakukan pengecekan dan penghapusan terhadap duplikat data untuk mencegah bias yang tidak diinginkan. Proses dilanjutkan dengan pembatasan terhadap nilai-nilai ekstrem yang tidak logis berdasarkan referensi standar kualitas air. Sebagai contoh, nilai *ph* dibatasi dalam rentang 0–14, *hardness* maksimal 500 mg/L CaCO₃, *tds* maksimal 50.000 mg/L, *chlorine* maksimal 10 mg/L, dan batasan logis lainnya diterapkan untuk menjaga kualitas data.

Untuk mendeteksi *outlier* secara visual, digunakan *boxplot* pada atribut-atribut penting seperti *ph* dan *sulfate*. *Boxplot* ini membantu dalam memahami sebaran data dan mengidentifikasi nilai yang ekstrem atau mencurigakan.



Gambar 2 Boxplot

Distribusi kelas dari label target *potability* kemudian dianalisis. Terlihat bahwa data tidak seimbang, dengan label 0 (tidak layak minum) sebanyak 47.897 dan label 1 (layak minum) sebanyak 7.616. Ketidakseimbangan ini dapat memengaruhi performa model. Oleh karena itu, dilakukan teknik *undersampling* pada kelas mayoritas (label 0), dengan cara mengambil sampel acak sebanyak jumlah data pada kelas minoritas (label 1), yaitu 7.616 data. Kedua *subset* data kemudian digabung kembali, sehingga total data menjadi seimbang, masing-masing 7.616 untuk label 0 dan 1.

Setelah proses *undersampling*, dilakukan *shuffle* agar distribusi kelas tercampur secara acak dan tidak berpola. Label *potability* kemudian dipisahkan dari fitur untuk keperluan pelatihan model. Variabel target (*y*) adalah *potability*, sedangkan fitur (*X*) terdiri dari atribut-atribut yang relevan yaitu *ph*, *sulfate*, *trihalomethanes*, dan *turbidity*. Atribut lain seperti *temperature*, *hardness*, dan *organic_carbon* dihapus karena kontribusinya terhadap klasifikasi kualitas air tidak signifikan berdasarkan analisis awal.

Sebelum proses pelatihan dimulai, data dibagi menjadi dua *subset* yaitu data latih dan data uji dengan proporsi 80:20 menggunakan metode stratifikasi. Hasilnya, setiap *subset* memiliki distribusi kelas yang seimbang: data latih berisi 6.093 data untuk masing-masing kelas 0 dan 1, dan data uji masing-masing 1.523 data untuk kelas 0 dan 1.


Tahap terakhir dari prapengolahan adalah normalisasi data menggunakan *Min-Max Scaling*. Proses ini mengubah nilai dari setiap fitur ke rentang 0 hingga 1 agar memiliki skala yang sama dan tidak mendominasi perhitungan jarak dalam algoritma *K-Nearest Neighbors* (KNN).

3.2. Pelatihan Model

Setelah proses normalisasi dan pembagian data menjadi data latih dan data uji, langkah berikutnya adalah pelatihan model menggunakan algoritma *K-Nearest Neighbors* (KNN). Algoritma KNN bekerja dengan cara mengklasifikasikan data baru berdasarkan mayoritas kelas dari k tetangga terdekatnya dalam ruang fitur. KNN dipilih karena kesederhanaannya serta kemampuannya yang baik dalam menyelesaikan masalah klasifikasi, terutama pada data yang memiliki dimensi tidak terlalu tinggi seperti pada kasus ini.

Pelatihan model dilakukan pertama kali dengan menggunakan nilai k sebesar 5. Setelah model dilatih pada data latih, data uji digunakan untuk mengevaluasi performa prediksi model. Evaluasi dilakukan dengan menggunakan metrik akurasi, serta *classification report* yang mencakup *precision*, *recall*, dan *f1-score* untuk masing-masing kelas, yaitu kelas 0 (tidak layak minum) dan kelas 1 (layak minum). Selain evaluasi awal tersebut, dilakukan pula eksperimen lanjutan untuk mengetahui pengaruh variasi nilai k terhadap performa model.

Eksperimen dilakukan dengan mencoba berbagai nilai k , mulai dari $k = 1$ hingga $k = 20$. Untuk setiap nilai k , model dilatih ulang dan diuji pada data uji yang sama, lalu akurasinya dicatat. Hasil dari eksperimen ini divisualisasikan dalam grafik berikut:



Gambar 3 Grafik Akurasi vs Nilai K pada KNN

Berdasarkan grafik tersebut, terlihat bahwa akurasi model sangat dipengaruhi oleh pemilihan nilai k . Nilai k yang sangat kecil, seperti $k = 1$ atau $k = 2$, cenderung menghasilkan akurasi yang lebih rendah, yaitu sekitar 72,5% pada $k = 2$. Hal ini kemungkinan disebabkan karena sensitivitas model terhadap *outlier* dan *noise* saat k terlalu kecil.

Sebaliknya, nilai k yang lebih besar cenderung memberikan hasil akurasi yang lebih stabil. Grafik menunjukkan bahwa mulai dari $k = 5$ ke atas, akurasi meningkat dan cenderung stabil meskipun terdapat sedikit fluktuasi. Nilai akurasi tertinggi tercapai pada $k = 18$, yaitu sebesar 79,1%, menjadikannya sebagai nilai k optimal untuk model ini. Dengan demikian, dapat disimpulkan bahwa pemilihan nilai k merupakan faktor krusial dalam algoritma KNN dan pada penelitian ini, $k = 18$ memberikan performa terbaik dalam memprediksi kelayakan air minum berdasarkan fitur-fitur seperti pH, kekeruhan, kadar sulfate, dan trihalomethanes.

3.3. Evaluasi Model

Pada tahap ini dilakukan evaluasi performa model klasifikasi *K-Nearest Neighbors* (KNN) terhadap data kualitas air yang telah melalui tahap praproses dan pelatihan model. Evaluasi dilakukan menggunakan beberapa metrik umum klasifikasi, yaitu akurasi, *precision*, *recall*, dan *f1-score*. Metrik ini dihitung berdasarkan hasil prediksi model terhadap data uji, dan disajikan dalam bentuk laporan klasifikasi serta *confusion matrix*.

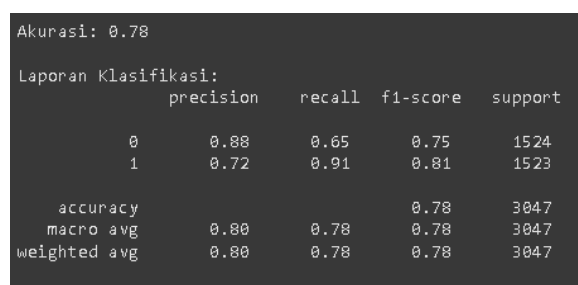
Tabel 2 Confusion Matrix

	Prediksi Positif (1)	Prediksi Negatif (0)
Kenyataan Positif (1)	True Positive (TP)	False Negative (FN)
Kenyataan Negatif (0)	False Positive (FP)	True Negative (TN)

Evaluasi model klasifikasi umumnya didasarkan pada *confusion matrix* yang ada pada tabel 2, tabel ini menggambarkan jumlah prediksi yang benar dan salah untuk setiap kelas. Empat komponen penting dari *confusion matrix* adalah:

- **True Positive (TP):** Prediksi positif dan kenyataannya positif.
- **True Negative (TN):** Prediksi negatif dan kenyataannya negatif.
- **False Positive (FP):** Prediksi positif tapi kenyataannya negatif.
- **False Negative (FN):** Prediksi negatif tapi kenyataannya positif.

Gambar 4 menunjukkan hasil laporan klasifikasi yang diperoleh dari pengujian model KNN terhadap data uji sebanyak 3.047 data, yang terdiri dari dua kelas yaitu kelas 0 (air tidak layak minum) sebanyak 1.524 data dan kelas 1 (air layak minum) sebanyak 1.523 data. Model menghasilkan nilai akurasi sebesar 0.78, yang berarti bahwa 78% prediksi yang dilakukan oleh model sesuai dengan label yang sebenarnya. Pada kelas 0, *precision* mencapai 0.88 dan *recall* sebesar 0.65, menghasilkan f1-score sebesar 0.75. Sementara itu, pada kelas 1, *precision* sebesar 0.72 dan *recall* sebesar 0.91 menghasilkan f1-score sebesar 0.81. Hasil ini menunjukkan bahwa model lebih baik dalam mengenali air yang layak minum (kelas 1), ditunjukkan oleh nilai *recall* yang tinggi, meskipun ketepatan (*precision*) dalam memprediksi kelas tersebut masih perlu ditingkatkan.



Akurasi: 0.78					
Laporan Klasifikasi:					
	precision	recall	f1-score	support	
0	0.88	0.65	0.75	1524	
1	0.72	0.91	0.81	1523	
accuracy			0.78	3047	
macro avg	0.80	0.78	0.78	3047	
weighted avg	0.80	0.78	0.78	3047	

Gambar 4 Hasil Evaluasi Model

Berdasarkan nilai-nilai tersebut, dilakukan perhitungan untuk memperoleh nilai TP, TN, FP, dan FN. Pada kelas 1 (air layak minum), *recall* sebesar 0.91 menunjukkan bahwa model berhasil mengenali sekitar 91% dari seluruh data yang memang layak, atau sekitar 1.385 data (TP). Dengan jumlah *support* sebesar 1.523 data untuk kelas 1, maka FN dapat dihitung sebesar $1.523 - 1.385 = 138$ data. Selanjutnya, *precision* sebesar 0.72 menunjukkan bahwa dari semua prediksi yang dinyatakan sebagai air layak, sekitar 72% benar. Dari nilai tersebut, FP diperkirakan sebesar 537 data. Akhirnya, dengan total data uji sebanyak 3.047, nilai TN dapat dihitung sebagai $3.047 - TP - FN - FP = 3.047 - 1.385 - 138 - 537 = 987$.

Precision merupakan ukuran yang menunjukkan seberapa akurat model dalam memprediksi kelas positif. Nilai ini dihitung dari proporsi prediksi positif yang benar (TP dibagi jumlah TP dan FP). *Recall*, di sisi lain, mengukur sensitivitas model terhadap kelas positif, yaitu seberapa besar model mampu mengenali data yang benar-benar positif (TP dibagi jumlah TP dan FN). F1-score merupakan rata-rata harmonik dari *precision* dan *recall*, yang memberikan keseimbangan antara keduanya. Nilai f1-score yang tinggi menandakan bahwa model tidak hanya akurat dalam prediksi positif, tetapi juga konsisten dalam mendeteksi seluruh data positif yang ada. Pada hasil evaluasi ini, f1-score makro dan rata-rata berbobot masing-masing sebesar 0.78, menunjukkan kinerja yang cukup stabil antara kedua kelas.


3.4. Pembahasan Hasil Evaluasi Model

Berdasarkan hasil evaluasi menggunakan *confusion matrix*, model *K-Nearest Neighbors* (KNN) yang dibangun menunjukkan performa yang baik dalam mengklasifikasikan kelayakan air minum. Seperti yang ditampilkan pada Gambar 5, model mampu memprediksi 934 data sebagai tidak layak secara benar (*True Negative*) dan 1.460 data sebagai layak secara benar (*True Positive*). Namun, terdapat 590 data tidak layak yang salah diprediksi sebagai layak (*False Positive*), serta 63 data layak yang salah diprediksi sebagai tidak layak (*False Negative*).

Model menghasilkan akurasi sebesar 78%, yang mengindikasikan bahwa sekitar 78% dari keseluruhan prediksi yang dilakukan sesuai dengan label aktual. Nilai *precision* untuk kelas layak sebesar 72% menunjukkan bahwa dari seluruh data yang diprediksi sebagai air layak minum, sekitar 72% di antaranya benar-benar layak. Sementara itu, *recall* sebesar 91% mengindikasikan bahwa model mampu mendeteksi sebagian besar data yang memang layak minum, yakni sekitar 91%. Nilai f1-score untuk kelas layak sebesar 81% memperlihatkan adanya keseimbangan yang cukup baik antara ketepatan model dalam memprediksi dan kemampuannya dalam menangkap seluruh data positif.

Performa pada kelas tidak layak juga patut diperhatikan. Meskipun *precision*-nya tinggi, yaitu sebesar 88%, *recall*-nya lebih rendah, yakni 65%. Hal ini menunjukkan bahwa model lebih sering keliru dalam mengklasifikasikan air yang tidak layak sebagai layak, yang terlihat dari cukup besarnya jumlah *false positive*. F1-score pada kelas ini sebesar 75%, yang menunjukkan bahwa performa model masih cukup baik dalam mengenali air yang tidak layak, meskipun masih ada ruang untuk perbaikan. Secara keseluruhan, hasil ini mencerminkan bahwa algoritma KNN mampu bekerja efektif dalam mengenali pola kualitas air berdasarkan fitur-fitur penting seperti pH, kekeruhan, kandungan sulfat, dan trihalomethanes. Dengan data yang telah melalui tahapan prapengolahan termasuk normalisasi dan pemilihan fitur, model menunjukkan performa yang cukup seimbang dalam

menangani kedua kelas. *Confusion matrix* yang dihasilkan menunjukkan bahwa mayoritas prediksi telah dilakukan secara tepat oleh model, menjadikan pendekatan ini menjanjikan untuk diterapkan dalam sistem pemantauan kualitas air secara otomatis dan efisien. *Confusion matrix* yang dihasilkan pada Gambar, menunjukkan bahwa prediksi untuk kedua kelas, baik layak maupun tidak layak, telah dilakukan secara tepat oleh model dalam sebagian besar kasus. Kemampuan ini memberikan potensi besar bagi penerapan model KNN dalam mendukung sistem pemantauan kualitas air secara otomatis dan cepat.



Gambar 5 Hasil Confusion Matrix

4. KESIMPULAN

Berdasarkan dari hasil penelitian ini menunjukkan bahwa model klasifikasi kualitas air menggunakan algoritma *K-Nearest Neighbors* (KNN) yang dikembangkan berhasil mencapai hasil yang andal dan akurat, sesuai dengan tujuan awal penelitian. Proses prapengolahan data, pemilihan fitur penting seperti pH, kekeruhan, sulfate, dan trihalomethanes, serta pelatihan dan evaluasi model, membuktikan bahwa KNN mampu memberikan performa yang baik dengan akurasi mencapai 78%. Evaluasi menggunakan *confusion matrix* juga mengonfirmasi kemampuan model dalam mengenali pola kualitas air secara konsisten, terutama pada kelas air layak minum dengan keseimbangan *precision* dan *recall* yang memadai.

Model ini berpotensi untuk diterapkan dalam sistem *monitoring* kualitas air secara *real-time*, khususnya jika dikombinasikan dengan teknologi sensor dan *Internet of Things* (IoT). Pengembangan di masa depan dapat difokuskan pada penerapan algoritma yang lebih kompleks seperti Random Forest atau Neural Network, serta peningkatan kualitas data dengan menambahkan parameter kimiawi dan biologis yang relevan. Dengan demikian, sistem klasifikasi ini tidak hanya berfungsi sebagai alat bantu analisis, tetapi juga dapat menjadi sistem peringatan dini untuk menjaga kesehatan dan keselamatan masyarakat.

REFERENSI

- [1] Nurmahaludin, "Klasifikasi Kualitas Air Pdam Menggunakan Algoritma Knn Dan K-means," *Klasifikasi Kualitas Air Pdam Menggunakan Algoritma Knn Dan K-means*, vol. 1, no. 1, 2019.
- [2] A. Muhtar, P. Wibawa, and M. Kallista, "Klasifikasi Kualitas Sungai Air Menggunakan Metode Pembelajaran Mesin k-Nearest Neighbour," *Klasifikasi Kualitas Sungai Air Menggunakan Metode Pembelajaran Mesin k-Nearest Neighbour*, vol. 11, no. 1, Feb. 2024.
- [3] M. Syarifuddin, "Klasifikasi Kualitas Air Pada Program Penyediaan Air Minum Dan Sanitasi Berbasis Masyarakat Desa Semenpinggir Dengan Metode Algoritma K-Nearest Neighbor," *Klasifikasi Kualitas Air Pada Program Penyediaan Air Minum Dan Sanitasi Berbasis Masyarakat Desa Semenpinggir Dengan Metode Algoritma K-Nearest Neighbor*, vol. 2, no. 1, Mar. 2024.
- [4] United States, "The Sustainable Development Goals Report," *The Sustainable Development Goals Report*, vol. 1, no. 1, 2021.
- [5] World Health Organization, "Progress on household drinking water, sanitation and hygiene, 2000-2020: Five years into the SDGs," Unicef Data. [Online]. Available: <https://data.unicef.org/resources/progress-on-household-drinking-water-sanitation-and-hygiene-2000-2020/>
- [6] World Health Organization: WHO, "Drinking-water," *World Health Organization: WHO*, Sep. 13, 2023. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/drinking-water>
- [7] P. Sawant, "Physico-chemical parameters for testing of water – A review," *Physico-chemical parameters for testing of water – A review*, vol. 3, no. 3, 2012.
- [8] S. Putri, "Penerapan Metode SVM pada Klasifikasi Kualitas Air," *Penerapan Metode SVM pada Klasifikasi Kualitas Air*, vol. 3, no. 2, 2023.
- [9] Q. Jemila, Dhanalakshmi, and Amutha, "Water Quality Prediction Using Decision Tree and KNN," *Water Quality Prediction Using Decision Tree and KNN*, vol. 9, no. 1, Jan. 2024.
- [10] M. Hasin, "Penerapan Neural Network sebagai Klasifikasi Kualitas Air Hasil Filtrasi Reverse Osmosis," *Penerapan Neural Network sebagai Klasifikasi Kualitas Air Hasil Filtrasi Reverse Osmosis*, vol. 11, no. 3, Sep. 2024.

-
- [11] Kemenkes, *Profil Kesehatan Indonesia*. Kementrian Kesehatan, 2022.
 - [12] T. Brian, "Application of K-Nearest Neighbor (KNN) Algorithm to Predict Drinking Water Quality," *Application of K-Nearest Neighbor (KNN) Algorithm to Predict Drinking Water Quality*, vol. 5, no. 1, Jan. 2025.
 - [13] S. Ulum, R. F. Alifa, P. Rizkika, and C. Rozikin, "Perbandingan Performa Algoritma KNN dan SVM dalam Klasifikasi Kelayakan Air Minum," *Generation Journal*, vol. 7, no. 2, Jul. 2023.
 - [14] Pangaribuan, J. J., Maulana, A., & Romindo, R. (2024). UNLEASHING THE POWER OF SVM AND KNN: ENHANCED EARLY DETECTION OF HEART DISEASE. *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, 10(2), 342-351.
 - [15] S. Jadhav, "Comparative Study of K-NN, Naive Bayes and Decision Tree Classification Techniques," *International Journal of Science and Research (IJSR)*, vol. 5, no. 1, 2016.
 - [16] A. Kumar, "Review on Data Mining Techniques for Prediction of Water Quality," *Review on Data Mining Techniques for Prediction of Water Quality*, vol. 6, no. 6, Jun. 2019.
 - [17] P. Padmaja, "Water Quality Prediction Using Machine Learning Algorithms," *Water Quality Prediction Using Machine Learning Algorithms*, vol. 10, no. 4, Apr. 2023.

Penilaian Kualitas Layanan *WiFi Oxygen* dan Kolerasinya terhadap Kepuasan Pengguna

Chaca Ananda Putri¹, Afifah Kurnia Fadillah²

^{1,2} Program Studi Teknologi Informasi, Universitas Bangka Belitung, Indonesia

Email: ¹chacaputripkp@gmail.com, ²fadillahafifah06@gmail.com

ABSTRAK

Penelitian ini merupakan penelitian yang dilakukan untuk mengevaluasi pengaruh kualitas layanan WiFi Oxygen terhadap tingkat kepuasan pengguna berdasarkan beberapa parameter teknis jaringan yang diuji. Data yang digunakan berasal dari log sistem *monitoring* internal dan survei kepuasan pengguna dengan jumlah responden sebanyak 198 orang. Metode yang digunakan dalam penelitian ini adalah regresi linear berganda yang digunakan untuk mengidentifikasi pengaruh variabel kualitas jaringan seperti kecepatan *download*, kecepatan *upload*, *latency*, *packet loss*, dan *jitter* terhadap kepuasan pengguna. Hasil penelitiannya menunjukkan bahwa kualitas jaringan tidak terlalu berpengaruh signifikan terhadap kepuasan berdasarkan kecepatan jaringan dengan nilai *R Square* sebesar 11.6%. Sebaliknya, model regresi untuk kepuasan pengguna berdasarkan kestabilan jaringan lebih baik dengan nilai *R Square* sebesar 36.6%, di mana variabel kecepatan *download* dan *jitter* berpengaruh positif dan signifikan. Temuan ini menunjukkan bahwa kestabilan jaringan lebih berkontribusi pada kepuasan pengguna dibandingkan kecepatan semata. Penelitian ini memberikan dasar untuk perbaikan layanan WiFi dengan fokus pada peningkatan kestabilan jaringan.

Kata Kunci: Kepuasan, Kualitas, WiFi

ABSTRACT

This research is a study conducted to evaluate the effect of Oxygen WiFi service quality on the level of user satisfaction based on several tested network technical parameters. The data used came from internal monitoring system logs and user satisfaction surveys with a total of 198 respondents. The method used in this study is multiple linear regression which is used to identify the effect of network quality variables such as download speed, upload speed, latency, packet loss, and jitter on user satisfaction. The results showed that network quality did not significantly affect satisfaction based on network speed with an *R Square* value of 11.6%. In contrast, the regression model for user satisfaction based on network stability is better with an *R Square* value of 36.6%, where the download speed and jitter variables have a positive and significant effect. This finding suggests that network stability contributes more to user satisfaction than speed alone. This research provides a basis for WiFi service improvement with a focus on improving network stability.

Keywords: Quality, Satisfaction, WiFi

Penulis Korespondensi:

Chaca Ananda Putri

Email: chacaputripkp@gmail.com

Article Info

Diterima: 27 Mei 2025

Direvisi: 4 Juni 2025

Disetujui: 9 Juni 2025

This is an open access article under the [CC BY](#) license.



1. PENDAHULUAN

Berkembangnya teknologi informasi dan komunikasi yang pesat telah berhasil mendorong kebutuhan masyarakat terhadap layanan internet yang cepat dan andal. Kelancaran koneksi WiFi telah menjadi aspek penting untuk menunjang kebutuhan pokok masyarakat modern, terkhususnya dalam menunjang aktivitas belajar, bekerja, dan juga hiburan [1]. Salah satu layanan jaringan WiFi yang banyak digunakan masyarakat adalah koneksi internet nirkabel (WiFi) yang telah disediakan oleh penyedia layanan seperti oxygen. Kualitas layanan jaringan yang diberikan menjadi faktor penting dalam memengaruhi pengalaman pengguna

secara keseluruhan. Kualitas layanan (*Quality of Service/QoS*) dari jaringan WiFi tersebut memiliki peran penting dalam memengaruhi pengalaman serta tingkat kepuasan pengguna secara keseluruhan [2].

Namun, tidak jarang pengguna mengalami berbagai kendala dalam memanfaatkan layanan WiFi seperti kecepatan yang tidak stabil, gangguan koneksi, hingga cakupan sinyal yang terbatas. Masalah yang muncul umumnya memiliki dampak langsung pada produktivitas dan kenyamanan penggunaan layanan. Kondisi ini dapat membuat penurunan terhadap tingkat kepuasan pengguna. Untuk itu, evaluasi terhadap kualitas layanan yang diberikan perlu dilakukan [3].

Beberapa penelitian terdahulu telah banyak mengkaji hubungan antara kepuasan pengguna dengan kualitas layanan internet menggunakan indikator seperti kecepatan akses, latensi, keandalan serta persepsi pengguna layanan tersebut. Penelitian yang dilakukan oleh Dimas Ardi Dwianggoro dan Rifi Wijayanti Dual Arifin pada tahun 2024 menghasilkan temuan bahwa kualitas pelayanan, kepuasan dan loyalitas berpengaruh signifikan terhadap kepercayaan pelanggan WiFi Iconnet. Berdasarkan uji statistik yang dilakukan, di dapatkan koefisien determinasi sebesar 0,585, yang berarti 58,5% perubahan pada kepercayaan pelanggan dapat dijelaskan oleh ketiga variabel tersebut, sedangkan 41,5% sisanya dipengaruhi oleh faktor lain yang tidak diteliti dalam studi ini [4]. Penelitian yang dilakukan oleh Wildan Army Abdillah, dkk pada tahun 2024 menghasilkan temuan bahwa kualitas produk dan kualitas pelayanan berpengaruh positif dan signifikan terhadap kepuasan pelanggan layanan IndiHome. Berdasarkan hasil analisis, kedua faktor tersebut mampu menjelaskan 70,3% variabilitas kepuasan pelanggan, sementara sisanya dipengaruhi oleh faktor lainnya [5]. Penelitian yang dilakukan oleh Diana Ayu Kusumaningrum dan Dian Kusumaningtyas pada tahun 2023 menghasilkan temuan berupa pelayanan, kualitas produk, dan harga berpengaruh signifikan terhadap kepuasan pelanggan PT. X di Kota dan Kabupaten Kediri. Sementara itu, promosi tidak memiliki pengaruh signifikan terhadap kepuasan pelanggan [6]. Selanjutnya penelitian yang dilakukan oleh Ridwan Alief Ramdhan Adi dan Rr. Rochmoeljadi pada tahun 2023 menghasilkan temuan berupa terdapat hubungan positif dan signifikan antara kualitas *e-service* dan kepuasan pelanggan dalam layanan WiFi. Selain itu, kepuasan pelanggan juga berpengaruh signifikan terhadap niat pembelian ulang. Pengalaman pelanggan terbukti memengaruhi kepuasan, dan kualitas *e-service* memediasi hubungan antara kepuasan pelanggan dengan niat untuk membeli ulang [2]. Penelitian terakhir dilakukan oleh Wilsen Effendy pada tahun 2024 mendapatkan temuan bahwa kualitas pelayanan dan kualitas produk terbukti berpengaruh signifikan terhadap kepuasan pelanggan pengguna WiFi Biznet di Kota Palembang. Dengan menggunakan metode kuantitatif dan analisis regresi berganda, hasil penelitian mengonfirmasi bahwa kedua variabel tersebut merupakan faktor penting dalam membentuk tingkat kepuasan pelanggan [7].

Berdasarkan beberapa sumber literatur yang didapatkan, banyak studi telah membahas pengaruh kualitas layanan terhadap kepuasan pengguna yang berfokus pada penyedia layanan seperti IndiHome, Iconnet, dan Biznet, namun belum secara khusus mengkaji layanan WiFi Oxygen. Selain itu, sebagian besar penelitian mengambil aspek persepsi umum seperti loyalitas, harga, atau promosi, sementara analisis yang lebih teknis terhadap parameter kualitas jaringan dan hubungannya dengan kepuasan pengguna berdasarkan kecepatan dan kestabilan masih jarang dibahas.

Oleh karena itu, penelitian ini berusaha untuk melihat hubungan antara parameter layanan WiFi Oxygen dengan kepuasan pengguna baik dari segi kecepatan atau kestabilan. Metode regresi linear berganda digunakan dalam penelitian ini untuk mengetahui seberapa besar pengaruh variabel-variabel kualitas layanan terhadap kepuasan pengguna WiFi Oxygen. Hasil dari penelitian yang dilakukan ini diharapkan mampu memberikan kontribusi dalam pengambilan keputusan terkait perbaikan layanan jaringan.

2. METODE PENELITIAN


Penelitian ini menggunakan metode kuantitatif objektif yang memanfaatkan data teknis dari *log* sistem *monitoring* internal penyedia layanan untuk mengevaluasi kualitas layanan WiFi Oxygen dan pengaruhnya terhadap tingkat kepuasan pengguna. Desain penelitian mengikuti tahapan sistematis yang meliputi perancangan konsep, pengumpulan data, analisis data, dan pelaporan hasil.

2.1. Desain Penelitian

Desain penelitian ini menggunakan pendekatan deskriptif kuantitatif. Data utama berupa *log* performa jaringan seperti kecepatan *download*, kecepatan *upload*, latensi, *packet loss* dan jitter. Selain itu, digunakan pula data hasil survei kepuasan pengguna yang dibagi berdasarkan kepuasan kecepatan jaringan dan kestabilan jaringan untuk mengetahui bagaimana dampak kualitas jaringan terhadap kepuasan penggunaan layanan [8].

2.2. Prosedur Penelitian

Untuk lebih memudahkan pemahaman terkait alur pelaksanaan penelitian, prosedur penelitian divisualisasikan dalam bentuk diagram alir yang secara runtut menjelaskan proses penelitian dari awal hingga akhir. Setiap langkah dirancang dengan harapan dapat memberikan gambaran yang logis dan mudah dicerna mengenai proses evaluasi kualitas layanan WiFi Oxygen. Visualisasi gambar dapat dilihat pada Gambar 1 berikut.



Gambar 1. Flowchart Penelitian

Gambar 1 merupakan diagram alir yang menggambarkan prosedur penelitian secara sistematis di dalam penerapan pelaksanaan penelitian mengenai evaluasi kualitas layanan WiFi Oxygen dan dampaknya terhadap kepuasan pengguna. Alur awal penelitian ini dimulai dari identifikasi masalah dan tujuannya, dilanjutkan dengan identifikasi penentuan variabel yang relevan, seperti parameter kualitas jaringan (kecepatan *download*, kecepatan *upload*, latensi, *packet loss* dan jitter), serta pengumpulan data yang dilakukan dengan mengambil data dari sistem *monitoring* internal dan survei kepuasan pengguna yang dilakukan oleh internal perusahaan. Data yang dikumpulkan kemudian dilakukan validasi dan dibersihkan untuk memastikan keakurasian dan kelayakannya serta menghindari dari adanya *missing value* dalam proses analisis [9].

Tahapan selanjutnya adalah analisis data menggunakan metode regresi linear berganda untuk mengidentifikasi pengaruh variabel kualitas layanan terhadap kepuasan pengguna. Hasil dari analisis yang dilakukan, kemudian diinterpretasikan untuk mendapatkan pemahaman yang mendalam mengenai hubungan antar variabel. Pada akhirnya, seluruh proses dan temuan selama penelitian dilakukan dirangkum dalam laporan akhir.

2.3. Perolehan dan Pengujian Data

Data performa jaringan diperoleh dari sistem *monitoring* jaringan internal yang digunakan oleh penyedia layanan WiFi oxygen dengan mencatat parameter-parameter kualitas jaringan selama periode waktu tertentu. Data kepuasan pengguna diperoleh melalui dokumentasi survei internal perusahaan. Pengujian dilakukan dengan menguji data kualitas jaringan dan kepuasan pengguna berdasarkan beberapa variabel seperti kepuasan kecepatan jaringan dan kepuasan kestabilan jaringan dalam jumlah yang sama, yaitu sebanyak 198 data. Data kepuasan pengguna dikumpulkan dengan menggunakan skala *likert* pada rentang nilai 1 hingga 5, di mana 1 menunjukkan indikator sangat tidak puas dan 5 menunjukkan indikator sangat puas. Validasi dan analisis dilakukan dengan menggunakan metode regresi linear berganda untuk mengetahui pengaruh masing-masing variabel kualitas jaringan terhadap kepuasan pelanggan.

Metode ini merujuk pada penggunaan metode penelitian sebelumnya yang dilakukan oleh Wilsen Effendy (2024) yang mengevaluasi pengaruh kualitas pelayanan dan produk terhadap kepuasan pelanggan pengguna WiFi Biznet di Palembang. Dalam hasil studi yang dilakukan, metode regresi linear berganda digunakan untuk menganalisis data yang dikumpulkan melalui kuesioner, hasil akhirnya menunjukkan bahwa kedua variabel tersebut memiliki pengaruh signifikan terhadap kepuasan pelanggan [7].

Selain itu, penelitian yang dilakukan oleh Diana Ayu Kusumaningrum dan Dian Kusumaningtyas (2023) di Kediri dengan menggunakan pendekatan kuantitatif bersamaan dengan penggunaan regresi linear berganda untuk menganalisis faktor-faktor yang memengaruhi kepuasan pelanggan layanan WiFi PT.X. menghasilkan hasil akhir bahwa pelayanan, kualitas produk, dan harga berpengaruh signifikan terhadap kepuasan pelanggan [6].

Penelitian lainnya juga dilakukan oleh Ankha Rhaziqien dengan menggunakan metode yang sama menghasilkan temuan bahwa peningkatan kualitas layanan dan produk yang diberikan dapat meningkatkan tingkat kepuasan pelanggan secara keseluruhan [10].

Temuan-temuan dari studi kasus yang pernah dilakukan peneliti terdahulu mendukung penggunaan metode regresi linear berganda dalam menganalisis hubungan antara kualitas layanan dan kepuasan pelanggan dalam konteks layanan internet di Indonesia. Oleh karena itu, pendekatan ini dapat dianggap relevan untuk digunakan pada penelitian ini dengan tujuan untuk mengevaluasi kualitas layanan *WiFi Oxygen* dan dampaknya terhadap kepuasan pengguna [11].

Pada penelitian ini regresi linear berganda digunakan untuk melakukan peramalan terkait nilai variabel dependen (Y) dan variabel independen (X) untuk menguji keterkaitan pengaruh antara kedua atau lebih variabel yang dimasukkan [11]. Perhitungan pada penelitian ini dilakukan dengan menggunakan *tool* bantuan berupa SPSS dengan melihat hasil *summary*, *ANOVA table* atau uji F dan *coefficients table* atau uji T. Secara sistematis, regresi linear berganda dapat dirumuskan sebagai berikut [12].

$$Y = a + b_1X_1 + b_2X_2 + e \quad (1)$$

Keterangan:

- Y = Variabel Dependen (terikat)
- a = Nilai Konstanta
- b1, b2 = koefisien regresi
- X1, X2 = variabel independen (bebas)
- e = *Error Term* (tidak dimasukkan ke dalam model)

3. HASIL DAN PEMBAHASAN

Hasil penelitian yang dilakukan disajikan dalam dua bagian utama, yaitu analisis terhadap kepuasan pengguna berdasarkan kecepatan jaringan dan analisis terhadap kepuasan pengguna berdasarkan kestabilan jaringan. Kedua analisis tersebut dilakukan secara terpisah menggunakan regresi linear berganda untuk mengidentifikasi pengaruh masing-masing parameter jaringan terhadap tingkat kepuasan pengguna. Setelah hasil dari kedua analisis dijelaskan, pembahasan disusun untuk menginterpretasikan temuan yang diperoleh secara lebih komprehensif.

3.1. Hasil Analisis Regresi Linear Berganda Terhadap Kepuasan Kecepatan Jaringan

Berdasarkan hasil analisis regresi linear berganda yang sudah dilakukan terhadap variabel-variabel kualitas jaringan seperti *download speed*, *upload speed*, *latency*, *packet loss*, dan *jitter* terhadap kepuasan pengguna berdasarkan kecepatan jaringan, diperoleh nilai *R Square* sebesar 0.116 seperti gambar di bawah ini.

Model Summary				
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.341 ^a	.116	-.085	1.269

a. Predictors: (Constant), Jitter_ms, Upload_Speed_Mbps, Packet_Loss_Percent, Download_Speed_Mbps, Latency_ms

Gambar 2. Model Summary

Nilai *R Square* tersebut menunjukkan bahwa model hanya mampu menjelaskan sebesar 11.6% variasi yang terjadi pada kepuasan pengguna terhadap kecepatan jaringan. Artinya, sekitar 88.4% variasi lainnya dipengaruhi oleh faktor-faktor di luar model ini. Hal ini mengindikasikan bahwa kelima indikator teknis jaringan yang diuji tidak cukup representatif untuk menjelaskan kepuasan pengguna terhadap kecepatan jaringan secara menyeluruh. Selain itu, faktor *non-teknis* seperti persepsi subjektif pengguna terhadap cepat atau lambat kualitas jaringan, kebutuhan aplikasi spesifik (*zoom*, *Netflix*, dll), faktor penggunaan jaringan, kondisi perangkat keras dan perangkat lunak pengguna ataupun lokasi dimana mereka berada, bisa saja menjadi variabel lain yang mempengaruhi kepuasan pengguna. Dengan kata lain aspek teknis seperti *latency* tidak cukup untuk menjelaskan seberapa cepat layanan dirasakan oleh pengguna.

Pada hasil uji *ANOVA* (uji F), diperoleh nilai F sebesar 0.577 dengan tingkat signifikansi 0.717 ($p > 0.05$), jauh di atas batas signifikansi 0.05 seperti terlihat pada Gambar 3. Hasil ini menunjukkan bahwa model regresi secara keseluruhan tidak signifikan, sehingga tidak ada bukti kuat secara statistik bahwa kombinasi kelima variabel tersebut berpengaruh secara bersama-sama terhadap kepuasan pengguna terhadap kecepatan jaringan.

Kondisi ini memperkuat dugaan temuan bahwa parameter teknis jaringan yang umum digunakan tidak dapat berdiri sendiri untuk menjelaskan persepsi pengguna.

pengguna.

ANOVA ^a						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	4.653	5	.931	.577	.717 ^b
	Residual	35.454	22	1.612		
	Total	40.107	27			

a. Dependent Variable: Kepuasan_Kecepatan

b. Predictors: (Constant), Jitter_ms, Upload_Speed_Mbps, Packet_Loss_Percent, Download_Speed_Mbps, Latency_ms

Gambar 3. Uji F

Pada uji koefisiensi (uji T), hasil analisis tidak menemukan variabel yang secara individu berpengaruh signifikan terhadap kepuasan kecepatan. Misalnya *latency* yang menunjukkan koefisien negatif terbesar -0.234, yang mengartikan bahwa semakin tinggi *latency*, maka tingkat kepuasan terhadap kecepatan jaringan cenderung menurun. Namun, nilai signifikansi dari variabel tersebut adalah 0.292, sehingga pengaruhnya secara tidak langsung tidak signifikan. Sedangkan, pada parameter jaringan lainnya tidak ditemukan hubungan yang signifikan terhadap tingkat kepuasan pengguna.

Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	
	B	Std. Error	Beta			
1	(Constant)	4.094	1.029		3.979	.001
	Download_Speed_Mbps	6.515E-18	.000	.087	.408	.687
	Upload_Speed_Mbps	8.013E-18	.000	.051	.230	.820
	Latency_ms	-2.876E-17	.000	-.234	-1.080	.292
	Packet_Loss_Percent	-3.196E-16	.000	-.161	-.754	.459
	Jitter_ms	9.443E-18	.000	.152	.710	.485

a. Dependent Variable: Kepuasan_Kecepatan

Gambar 4. Uji T

3.2. Hasil Analisis Regresi Linear Berganda Terhadap Kepuasan Kestabilan Jaringan

Berdasarkan hasil analisis regresi linear berganda yang dilakukan berdasarkan kepuasan pengguna terhadap kestabilan jaringan dengan menggunakan parameter yang sama, memperoleh nilai *R Square* sebesar 0.363 yang menunjukkan bahwa 36.3% variasi kepuasan pengguna terhadap kestabilan jaringan dapat dijelaskan oleh kombinasi kelima variabel yang dimasukkan. Sedangkan, 63.7% sisanya dipengaruhi oleh faktor lain yang tidak dimasukkan ke dalam model uji.

Nilai ini lebih tinggi dibandingkan model sebelumnya, yang menandakan bahwa pengguna lebih peka terhadap aspek kestabilan jaringan, dan kelima parameter teknis jaringan lebih relevan dalam menjelaskan persepsi kestabilan.

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.603 ^a	.363	.218	.884

a. Predictors: (Constant), Latency_ms, Jitter_ms, Packet_Loss_Percent, Download_Speed_Mbps, Upload_Speed_Mbps

Gambar 5. Model Summary

Pada hasil uji *ANOVA* (Uji F) yang dilakukan, didapatkan nilai F sebesar 2.509 dengan nilai signifikansi sebesar 0.061 yang menandakan model regresi secara keseluruhan belum signifikan berdasarkan tingkat signifikansi 0,05. Namun, nilai tersebut sudah mendekati ambang batas signifikansi, sehingga model tetap dapat memberikan indikasi bahwa terdapatnya pengaruh gabungan antar variabel terhadap kepuasan kestabilan jaringan.

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	9.791	5	1.958	2.509	.061 ^b
	Residual	17.173	22	.781		
	Total	26.964	27			

a. Dependent Variable: Kepuasan Stabilitas
b. Predictors: (Constant), Latency_ms, Jitter_ms, Packet_Loss_Percent, Download_Speed_Mbps, Upload_Speed_Mbps

Gambar 6. Uji ANOVA

Selanjutnya pada uji koefisiensi (Uji T) yang dilakukan, ditemukan nilai signifikansi *download speed* 0.012 dengan koefisien sebesar 0.495 yang memiliki arti bahwa variabel memiliki pengaruh secara positif terhadap kestabilan jaringan. Pada variabel jitter, signifikansi yang dimiliki sebesar 0.011 dengan koefisien sebesar 0.506, menunjukkan adanya pengaruh signifikan positif terhadap kepuasan kestabilan jaringan. Sedangkan pada variabel *upload speed*, *packet loss*, dan *latency*, memiliki signifikansi masing-masing bernilai 0.952, 0.894, dan 0.544, yang berarti variabel tidak terlalu berpengaruh signifikan terhadap kepuasan kestabilan jaringan dalam model uji ini.

Berdasarkan kedua variabel parameter jaringan yang mempengaruhi kepuasan pengguna terhadap kestabilan jaringan, hal ini bisa terjadi karena *download speed* seringkali diasosiasikan dengan performa saat *streaming*, mengunduh *file*, atau membuka halaman *web* secara konsisten. Sedangkan jitter mewakili fluktuasi waktu antar pengiriman paket, yang sangat krusial dalam aplikasi seperti *video conference* atau *gaming*. Sedangkan parameter lainnya, mungkin tidak dapat dirasakan langsung oleh mayoritas pengguna atau masih berada di dalam rentang yang masih dapat pengguna toleransi.

Coefficients^a

		Unstandardized Coefficients		Standardized Coefficients		
Model		B	Std. Error	Beta	t	Sig.
1	(Constant)	2.891	.716		4.037	.001
	Download_Speed_Mbps	3.055E-17	.000	.495	2.749	.012
	Upload_Speed_Mbps	1.485E-18	.000	.012	.061	.952
	Packet_Loss_Percent	-3.959E-17	.000	-.024	-.134	.894
	Jitter_ms	2.576E-17	.000	.506	2.783	.011
	Latency_ms	-1.143E-17	.000	-.114	-.617	.544

a. Dependent Variable: Kepuasan Stabilitas

Gambar 7. Uji Koefisiensi

3.3. Pembahasan

Berdasarkan hasil analisis regresi linear berganda yang telah dilakukan, terdapat perbedaan antara model yang menjelaskan kepuasan pengguna terhadap kecepatan jaringan dan model yang menjelaskan kepuasan terhadap kestabilan jaringan. Pada hasil analisis kepuasan kecepatan jaringan, nilai *R Square* yang rendah (0.116) menunjukkan bahwa kelima variabel jaringan (*download speed*, *upload speed*, *latency*, *packet loss*, dan *jitter*) hanya mampu menjelaskan 11.6% variasi kepuasan kecepatan jaringan.

Hasil uji F juga menunjukkan bahwa model ini tidak signifikan secara statistik ($p\text{-value} = 0.717$) dan tidak ada satu pun variabel yang berpengaruh signifikan secara individu terhadap kepuasan pengguna. Hal ini dapat menunjukkan bahwa pengguna tidak hanya menilai melalui pengalaman kecepatan internet hanya dari parameter teknis yang digunakan, akan tetapi juga melalui persepsi, ekspektasi layanan, atau faktor eksternal lainnya seperti jenis aplikasi yang digunakan dan waktu penggunaan internet. Seperti yang dijelaskan oleh peneliti Le Thi Mai Huong dalam penelitian yang dilakukannya pada 2023 bahwa terdapat tujuh faktor utama yang dapat memengaruhi kepuasan pengguna terhadap layanan internet seperti, kualitas layanan inti, promosi dan iklan, kemudahan bergabung dalam layanan, citra merek, harga layanan, layanan tambahan, dan layanan dukungan pelanggan [13]. Penjelasan lainnya juga pernah dijelaskan oleh peneliti Yamka Sudirman dkk (2025) dalam penelitiannya mengenai perbedaan signifikan kualitas jaringan 4G pada kawasan perkantoran dan kawasan pendidikan. Dalam penelitiannya dijelaskan bahwa Kawasan perkantoran lebih baik daripada kawasan pendidikan. Hal ini menguatkan dugaan bahwa faktor eksternal seperti lokasi geografis juga turut mempengaruhi tingkat kepuasan pengguna terhadap layanan internet [14].

Sebaliknya, pada analisis kepuasan kestabilan jaringan, model menunjukkan hasil yang lebih baik. Nilai *R Square* sebesar 0.363 menunjukkan bahwa variabel-variabel kualitas jaringan mampu menjelaskan 36.3% variasi kepuasan pengguna terhadap kestabilan jaringan, dengan uji F yang mendekati signifikan ($p\text{-value} = 0.061$). Hal ini menunjukkan bahwa stabilitas jaringan dipengaruhi oleh indikator teknis dibandingkan kecepatan. Hal ini mengindikasikan bahwa kualitas jaringan WiFi yang stabil sangat bergantung pada bagaimana jaringan tersebut dikelola secara teknis. Implementasi yang dilakukan oleh peneliti Ismail Puji Saputra dkk (2021) dengan menggunakan *Router MikroTik* dan pengimplementasian *RADIUS server* berbasis *cloud computing* terbukti dapat meningkatkan kestabilan layanan WiFi [15].

Secara individu, variabel *download speed* ($p = 0.012$) dan *jitter* ($p = 0.011$) berpengaruh positif terhadap kestabilan jaringan. Sementara itu, variabel seperti *upload speed*, *packet loss*, dan *latency* tidak berpengaruh signifikan pada penelitian ini. Hal ini menunjukkan bahwa dalam konteks penggunaan jaringan oleh pengguna *WiFi Oxygen*, stabilitas lebih dirasakan melalui kecepatan *download* dan kestabilan waktu pengiriman paket (*jitter*) daripada *upload speed* dan *latency*.

4. KESIMPULAN

Berdasarkan hasil analisis yang telah dilakukan dan dijelaskan pada bagian hasil dan pembahasan, dapat disimpulkan bahwa tujuan penelitian ini berhasil dicapai dengan diperolehnya pemahaman mendalam mengenai hubungan antara parameter kualitas jaringan dengan tingkat kepuasan pengguna.

Hasil penelitian menunjukkan bahwa kualitas jaringan tidak memberikan pengaruh signifikan terhadap kepuasan pengguna berdasarkan kecepatan jaringan. Hal ini ditunjukkan oleh nilai *R Square* yang rendah (11.6%) serta tidak adanya variabel independen yang berpengaruh signifikan secara statistik terhadap kepuasan kecepatan. Sebaliknya, pada kepuasan terhadap kestabilan jaringan, model regresi menunjukkan hasil yang lebih baik dengan nilai *R Square* sebesar 36.3%. Dua variabel, *download speed* dan *jitter*, terbukti memiliki pengaruh positif dan signifikan terhadap kepuasan kestabilan jaringan. Temuan ini menunjukkan bahwa persepsi kestabilan jaringan lebih dipengaruhi oleh performa teknis tertentu dibandingkan dengan persepsi terhadap kecepatan.

Dengan demikian, terdapat kesesuaian antara tujuan yang dinyatakan pada awal penelitian dengan hasil yang diperoleh. Penilaian kualitas layanan WiFi Oxygen dapat memberikan gambaran mengenai aspek teknis mana yang paling berkontribusi terhadap kepuasan pengguna, terutama dalam hal kestabilan jaringan.

Ke depannya, penelitian lanjutan dapat diperluas dengan mempertimbangkan cakupan variabel faktor parameter kualitas jaringan yang lebih kompleks lagi dan faktor *non-teknis* seperti persepsi layanan pelanggan, ekspektasi pengguna, atau faktor lingkungan seperti kepadatan pengguna pada jam tertentu. Selain itu, bagi pengelola dan penyedia layanan WiFi Oxygen dapat

disarankan beberapa rekomendasi diantaranya; (1) memprioritaskan stabilitas jaringan, hal ini dikarenakan jitter dan *download speed* secara signifikan mempengaruhi kepuasan kestabilan jaringan, misalnya dengan mengimplementasikan sistem *Quality of Service* untuk mengelola lalu lintas jaringan secara efisien; (2) melakukan survei kepuasan secara berkala berbasis pengalaman nyata pengguna; (3) menyesuaikan penempatan *access point* secara strategis, dan; (4) menyusun *roadmap* peningkatan jaringan berbasis hasil analisis ini untuk perbaikan kedepannya.

Untuk saran penelitian selanjutnya, peneliti dapat memperluas cakupan dan ketepatan hasil dengan menambahkan parameter kualitas jaringan lain seperti *congestion level*, *switching* antar *AP*, serta menambahkan faktor *non-teknis* seperti layanan pengguna, ekspektasi pengguna, tingkat literasi digital, dan pengaruh lingkungan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak Oxygen selaku penyedia layanan WiFi yang telah dengan lapangnya memberikan akses terhadap data sistem *monitoring* internal dan survei kepuasan pengguna sehingga memungkinkan penulis melaksanakan penelitian ini. Penelitian ini juga tidak akan terselesaikan tanpa adanya kontribusi dari studi terdahulu yang menjadi referensi dan dasar analisis yang dilakukan oleh penulis selama melakukan penelitian. Semoga penelitian ini dapat memberikan kontribusi positif bagi pengembangan layanan jaringan internet dan studi-studi selanjutnya di bidang serupa.

REFERENSI

- [1] A. Rusydi and F. N. Hasan, "Implementasi business intelligence untuk visualisasi kekuatan sinyal internet di Indonesia menggunakan platform tableau," *TEKNOSAINS J. Sains, Teknol. dan Inform.*, vol. 10, no. 1, pp. 132–141, 2023, doi: 10.37373/tekno.v10i1.378.
- [2] R. A. R. Adi and R. Rochmoeljati, "Pengaruh E-Service Quality dan Customer Experience Terhadap Keputusan Penggunaan Layanan Wifi," *INSOLOGI J. Sains dan Teknol.*, vol. 2, no. 6, pp. 1155–1165, 2023, doi: 10.55123/insologi.v2i6.2972.
- [3] A. Nurdin and R. Yusuf, "Sistem Informasi Kepuasan Layanan Hotspot Wifi Publik Dikota Metro Berbasis Web," *J. Comput. Sci. Inf. Syst. J-Cosys*, vol. 2, no. 1, pp. 32–35, 2022, doi: 10.53514/jc.v2i1.291.
- [4] D. A. Dwianggoro and R. W. D. Arifin, "Pengaruh Kualitas Pelayanan, Kepuasam, Dan Loyalitas Terhadap Kepercayaan Pelanggan Wifi Iconnet Di PT. Indonesia Comnets Plus Regional Jawa Barat," *Manag. Stud. Entrep. J.*, vol. 5, no. 1, pp. 1443–1452, 2024.
- [5] W. A. Abdillah, R. M. Pranata, and M. I. Nurfauzan, "Pengaruh Kualitas Pelayanan dan Kualitas Produk Terhadap Kepuasan Pelanggan Pengguna Wifi Indihome Kota Tasikamala penerima masyarakat terhadap perkembangan teknologi dan perubahan menuju," vol. 10, no. 01, pp. 74–87, 2024.
- [6] D. A. Kusumaningrum, "Analisis Faktor-Faktor Yang Mempengaruhi Kepuasan Pelanggan Pt. X (Persero) Pada Produk Layanan Wifi Di Kota Dan Kabupaten Kediri," *J. Ekon. Bisnis, Manaj. dan Akunt.*, vol. 2, no. 1, pp. 128–138, 2023, [Online]. Available: <https://ejournal.lapad.id/index.php/jebmak/article/view/53>
- [7] W. Effendy, "2024 Madani : Jurnal Ilmiah Multidisipline Pengaruh Kualitas Pelayanan dan Kualitas Produk Terhadap Kepuasan Pelanggan Pengguna Wifi Biznet di Kota Palembang 2024 Madani : Jurnal Ilmiah Multidisipline," vol. 2, no. 9, pp. 325–335, 2024.
- [8] E. Irfan, N. Al, and A. Prapanca, "Analisis Kualitas Layanan Jaringan Internet Menggunakan Metode Quality Of Service (QoS) Dan Reliability , Maintainability And Availability (RMA) (Studi Kasus : SMK Negeri 3 Jombang)," vol. 04, pp. 414–422, 2023.
- [9] W. Sudrajat and I. Cholid, "K-Nearest Neighbor (K-Nn) Untuk Penanganan Missing Value Pada Data Umkm," *J. Rekayasa Sist. Inf. dan Teknol.*, vol. 1, no. 2, pp. 54–63, 2023, doi: 10.59407/jrsit.v1i2.77.
- [10] A. Rhaziqien, "Pengaruh Kualitas Pelayanan dan Kualitas Produk terhadap Kepuasan Pelanggan Modem Smartfren kota Malang Oleh:," pp. 1–23, 2021.
- [11] Y. Diotiharta, A. Muktiyanto, and I. M. Muhtahid, "Pengaruh Kualitas Layanan, Citra Merek Dan Harga Terhadap Kepuasan Pengguna Layanan Internet PT. Telkomsel di Kota Bengkulu," *EKOMBIS Rev. J. Ilm. Ekon. dan Bisnis*, vol. 11, no. 1, pp. 401–414, 2023, doi: 10.37676/ekombis.v11i1.3070.
- [12] Daffa Priandi Poetra and Rohmatul Fajriyah, "Pengaruh Motivasi Kerja dan Kedisiplinan Terhadap Kinerja Pegawai Biro OSDM Kementerian Perindustrian RI dengan Menggunakan Metode Analisis Regresi Linier Berganda," *Emerg. Stat. Data Sci. J.*, vol. 2, no. 1, pp. 10–21, 2024, doi: 10.20885/esds.vol2.iss.1.art2.
- [13] N. H. Tien and L. T. M. Huong, "Factors affecting customers satisfaction on public internet service quality in Vietnam," *Int. J. Public Sect. Perform. Manag.*, vol. 1, no. 1, 2023, doi: 10.1504/ijpspm.2023.10057939.
- [14] A. Pengaruh, K. Jaringan, D. I. Kawasan, P. Dan, P. Pada, and W. Kota, "Analisis pengaruh kualitas jaringan 4g di kawasan perkantoran dan pendidikan pada wilayah kota tangerang," vol. 2, no. 1, 2025.
- [15] I. P. Saputra, R. Yusuf, and U. Saprudin, "Implementasi Cloud Computing Sebagai Radius Server Pada Jaringan Internet Router Mikrotik," *Comput. Sci. Inf. Syst.*, no. 14, pp. 63–65, 2021, doi: 10.15900/j.cnki.zylf1995.2018.02.001.

Implementasi Market Basket Analysis dengan Algoritma Frequent Pattern Growth pada Data Transaksional di Electronic Commerce

Athaya Fairuzindah¹, Istiqomah Rabithah Alam Islami², Nafa Rexa³, Silvia Anggraini⁴, Etis Sunandi⁵

^{1,2,3,4,5}Statistika, Universitas Bengkulu, Indonesia

Email: ¹athayazindah@gmail.com, ²rabithahislami2003@gmail.com, ³nafarexa9@gmail.com, ⁴silvia170404@gmail.com, ⁵esunandi@unib.ac.id

ABSTRAK

Pertumbuhan industri *e-commerce* menghasilkan jumlah data transaksi yang sangat besar, sehingga diperlukan teknik analisis data yang efektif untuk mengekstrak pola pembelian pelanggan. Algoritma Frequent Pattern Growth (FP-Growth) merupakan salah satu metode data mining yang dapat digunakan untuk menemukan pola pembelian yang sering muncul tanpa perlu membangkitkan kandidat itemset secara eksplisit. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi kinerja algoritma FP-Growth dalam menganalisis data transaksi *e-commerce* guna mengidentifikasi pola belanja yang berulang. Metode penelitian meliputi pengumpulan data transaksi, pra-pemrosesan data, penerapan algoritma FP-Growth, serta analisis hasil yang diperoleh. Penelitian ini menggunakan *dataset* transaksi *e-commerce* dari toko ritel online berbasis di Inggris dengan total 541.909 data transaksi. Dari hasil penelitian, algoritma Frequent Pattern Growth (FP-Growth) terbukti efisien dalam mengidentifikasi pola transaksi yang sering terjadi. Dengan menggunakan *support* sebesar 1% dan *confidence* sebesar 80%, ditemukan 13 aturan asosiasi yang menunjukkan hubungan antarproduk yang sering dibeli bersamaan. Analisis lebih lanjut menunjukkan bahwa hasil yang diperoleh dapat dimanfaatkan oleh pelaku bisnis *e-commerce* dalam menyusun strategi pemasaran berbasis rekomendasi produk. Kesimpulan dari penelitian ini adalah bahwa algoritma FP-Growth merupakan pendekatan yang efektif dalam mengekstrak pola pembelian dari data transaksi *e-commerce* dalam skala besar.

Kata Kunci: *Frequent Pattern Growth*, data transaksional, *e-commerce*, data mining, rekomendasi produk.

ABSTRACT

The Growth of the *e-commerce* industry has resulted in a massive volume of transaction data, necessitating effective data analysis techniques to extract customer purchasing patterns. The Frequent Pattern Growth (FP-Growth) algorithm is one of the data mining methods that can be used to identify frequently occurring purchase patterns without explicitly generating candidate itemsets. This study aims to implement and evaluate the performance of the FP-Growth algorithm in analyzing *e-commerce* transaction data to identify recurring shopping patterns. The research methodology includes transaction data collection, data preprocessing, FP-Growth algorithm implementation, and result analysis. This study utilizes an *e-commerce* transaction dataset from an online retail store based in the United Kingdom, comprising 541,909 transaction records. The research findings indicate that the FP-Growth algorithm is efficient in identifying frequently occurring transaction patterns. Using a support threshold of 1% and a confidence level of 80%, 13 association rules were discovered, demonstrating relationships between frequently co-purchased products. Further analysis shows that these findings can be leveraged by *e-commerce* businesses to develop marketing strategies based on product recommendations. In conclusion, the FP-Growth algorithm is an effective approach for extracting purchasing patterns from large-scale *e-commerce* transaction data.

Keywords: *Frequent Pattern Growth*, transactional data, *e-commerce*, data mining, product recommendation.

Penulis Korespondensi:

Etis Sunandi

Email: esunandi@unib.ac.id

Article Info

Diterima: 2 Juni 2025

Direvisi: 9 Juni 2025

Disetujui: 11 Juni 2025

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



1. PENDAHULUAN

Penyimpanan dokumen secara digital berkembang dengan pesat seiring meningkatnya penggunaan komputer[1]. Oleh karena itu, walaupun sebagian besar dokumen digital tersimpan dalam bentuk teks dan berbagai algoritma yang efisien untuk pencarian teks telah dikembangkan, teknik pencarian terhadap seluruh isi dokumen yang tersimpan bukanlah solusi yang tepat mengingat pertumbuhan ukuran data yang tersimpan umumnya[2].

Data adalah fakta kasar mengenai orang, tempat, kejadian dan sesuatu yang penting diorganisasikan[3]. Seiring dengan pesatnya perkembangan teknologi, kebutuhan akan pemanfaatan data secara lebih efektif semakin meningkat. Inilah yang melahirkan konsep data mining, sebuah proses eksplorasi dan analisis data dalam jumlah besar untuk menemukan pola, tren, dan informasi yang bermanfaat. Data mining merupakan suatu alat yang memungkinkan para pengguna untuk mengakses secara cepat data dengan jumlah yang besar. Pengertian yang lebih khusus dari data mining, yaitu suatu alat dan aplikasi menggunakan analisis statistik pada data. Data mining menggambarkan sebuah pengumpulan teknik-teknik dengan tujuan untuk menemukan pola-pola yang tidak diketahui pada data yang telah dikumpulkan. Data mining memungkinkan pemakai menemukan pengetahuan dalam data database yang tidak mungkin diketahui keberadaannya oleh pemakai[4]. Data mining merupakan suatu langkah dalam melakukan *Knowledge Discovery in Databases* (KDD). *Knowledge discovery* sebagai suatu proses terdiri atas pembersihan data (*data cleaning*), integrasi data (*data integration*), pemilihan data (*data selection*), transformasi data (*data transformation*), data mining, evaluasi pola (*pattern evaluation*) dan penyajian pengetahuan (*knowledge presentation*)[5].

Electronic Commerce atau *e-commerce* dengan kata lain perdagangan elektronik, merupakan proses jual beli produk atau layanan melalui internet. Di Indonesia baik Electronic Commerce ataupun Social Commerce menjadi terobosan baru dalam transformasi ekonomi digital untuk memberdayakan masyarakat. Namun, kedua model perdagangan ini memiliki beberapa perbedaan dan tantangan tersendiri yang mungkin dihadapi dalam perkembangannya [6]. Salah satu metode yang banyak diterapkan untuk menganalisis pola belanja pelanggan dalam *e-commerce* adalah sistem rekomendasi berbasis *data mining* dan kecerdasan buatan (*Artificial Intelligence* atau AI) [7]. Sistem ini memungkinkan personalisasi rekomendasi produk berdasarkan preferensi dan riwayat transaksi pelanggan [8].

Dalam *dataset e-commerce*, data transaksi yang dikumpulkan mencakup berbagai variabel penting yang dapat digunakan untuk analisis lebih lanjut. *Dataset* yang digunakan dalam penelitian ini yaitu variabel nomor faktur, kode produk, deskripsi produk, jumlah pembelian, harga per unit, tanggal transaksi, ID pelanggan, dan negara asal pelanggan. Dengan total 541.909 data transaksi, *dataset* ini mencerminkan aktivitas pembelian pelanggan dalam platform *e-commerce* dan dapat digunakan untuk mengidentifikasi pola perilaku pelanggan dalam berbelanja secara daring. Analisis terhadap data ini memungkinkan penyedia layanan *e-commerce* untuk mengoptimalkan strategi pemasaran, meningkatkan pengalaman pelanggan, serta menyusun rekomendasi produk yang lebih relevan [9].

Analisis data *e-commerce* menjadi tantangan tersendiri mengingat jumlah data yang terus bertambah secara eksponensial. Oleh karena itu, diperlukan metode yang efisien dan efektif untuk mengidentifikasi pola pembelian pelanggan agar perusahaan dapat mengambil keputusan bisnis yang lebih strategis. Salah satu teknik yang banyak digunakan dalam analisis pola transaksi adalah *FP-Growth*, kepanjangan dari *Frequent Pattern-Growth*, merupakan algoritma alternatif untuk menemukan himpunan item yang kerap muncul (*frequent itemset*) dalam suatu *dataset*. Algoritma ini menggunakan konsep struktur pohon yang dinamakan *FP-Tree* untuk menemukan *frequent itemset* tanpa perlu menghasilkan kandidat seperti pada algoritma *Apriori* [10]. Dengan *FP-Growth* bisa mengidentifikasi kumpulan data yang paling umum (*frequent item set*) di dalam kumpulan data [11].

FP-Growth bekerja menggunakan konsep pembangunan tree, yang biasa disebut *FP-Tree*, dalam pencarian *frequent itemset* Bukan menggunakan generate candidate seperti yang dilakukan pada algoritma *Apriori*. Dengan menggunakan konsep tersebut, algoritma *FP Growth* menjadi lebih cepat daripada algoritma *Apriori*[12]. Oleh sebab itu, algoritma *FP-Growth* sering diterapkan alat analisis yang andal untuk menggali informasi berharga dari data transaksi[13].

Dalam penelitian ini, pendekatan yang digunakan adalah *Market Basket Analysis* (MBA) untuk memungkinkan untuk mengidentifikasi hubungan dan asosiasi antara produk-produk yang dibeli oleh pelanggan secara bersamaan. Metode ini dapat membantu mengidentifikasi item apapun yang sering terjadi bersamaan dalam transaksi untuk menentukan hubungan antara apa yang dibeli oleh pelanggan. *Market Basket Analysis* (MBA) adalah teknik analisis data yang digunakan dalam industri pemasaran dan bisnis untuk menemukan pola pembelian yang mungkin dilakukan oleh pelanggan secara bersamaan [14]. Dengan menggabungkan *FP-Growth* dan *Market Basket Analysis*, penelitian ini diharapkan dapat menghasilkan informasi yang lebih akurat mengenai pola belanja pelanggan serta memberikan wawasan yang lebih luas bagi pengelola *e-commerce* dalam menyusun strategi bisnis yang lebih efektif.

Selain itu, penggunaan sistem rekomendasi berbasis algoritma *FP-Growth* dapat mencari pola yang sering muncul diantara banyak transaksi, dimana setiap transaksi terdiri dari beberapa item. Sehingga metode ini akan menemukan hubungan antar item Dalam beberapa penelitian, penerapan *FP-Growth* dalam sistem rekomendasi terbukti mampu meningkatkan tingkat konversi

dan kepuasan pelanggan di platform *e-commerce* [15]. Oleh karena itu algoritma *FP Growth* tepat digunakan untuk menangkap pola transaksi.

Implementasi algoritma *FP-Growth* pada data transaksi *e-commerce* bertujuan untuk menemukan pola transaksi yang sering terjadi, sehingga dapat mengidentifikasi hubungan antar produk yang dibeli secara bersamaan. Dengan menganalisis efektivitas algoritma *FP-Growth*, penelitian ini mengevaluasi sejauh mana algoritma tersebut mampu mengidentifikasi pola transaksi dengan efisien dibandingkan metode lainnya, terutama dalam hal kecepatan dan penggunaan memori. Hasil analisis pola transaksi yang diperoleh akan digunakan sebagai dasar dalam memberikan rekomendasi strategis guna meningkatkan efektivitas pemasaran serta pengalaman pelanggan di *platform e-commerce*. Dengan memahami pola pembelian pelanggan, perusahaan dapat mengoptimalkan strategi promosi, meningkatkan personalisasi rekomendasi produk, dan merancang kampanye pemasaran yang lebih tepat sasaran untuk meningkatkan loyalitas serta kepuasan pelanggan.

2. METODE PENELITIAN

Dalam penelitian ini menggunakan *dataset "E-commerce Data"* yang berisi catatan transaksi dari toko ritel online berbasis di Inggris antara Desember 2010 hingga Desember 2011 yang akan dianalisis menggunakan metode *FP-Growth*. *Dataset* ini mencakup variabel seperti nomor faktur, kode produk, deskripsi, jumlah pembelian, harga per satuan, tanggal transaksi, ID pelanggan, dan negara asal pelanggan, dengan total 541.909 data. *Dataset* ini merupakan *dataset open access* yang dapat diakses melalui tautan: kaggle *e-commerce* data.

Penelitian ini menggunakan aturan asosiasi dengan menggunakan penerapan *FP-Growth*. Aturan asosiasi (*Association rules*) adalah proses dalam data mining untuk menentukan semua aturan asosiatif yang memenuhi syarat minimum *support* dan minimum *confidence* pada sebuah *dataset* [16]. Metode ini digunakan untuk mencari dan menemukan hubungan antar item yang ada pada suatu *dataset* [17]. Pada aturan asosiasi terdapat beberapa ukuran yang digunakan. Ukuran pada aturan asosiasi meliputi *support* dan *confidence* [17]. *Support* merupakan persentase kombinasi item muncul di dalam keseluruhan basis data yang ada. Dengan nilai *support* ini dapat diketahui seberapa sering suatu kombinasi muncul dalam keseluruhan transaksi yang terjadi [18]. Rumus yang digunakan untuk mencari nilai *support* dari satu item adalah sebagai berikut [17]:

$$\text{Support}(A) = \frac{\text{jumlah transaksi mengandung } A}{\text{total transaksi}} \quad (1)$$

Sedangkan untuk menentukan *support* dari dua item dapat menggunakan rumus berikut [17]:

$$\text{Support}(A, B) = \frac{\text{jumlah transaksi mengandung } A \cap B}{\text{total transaksi}} \quad (2)$$

Confidence adalah ukuran yang menunjukkan seberapa besar asosiasi antar 2 produk yang diminta secara bersamaan dari seluruh permintaan yang memuat salah satu barang tersebut [17]. Berikut merupakan rumus untuk menghitung nilai *confidence* [16]:

$$\text{Confidence} = P(A|B) = \frac{\text{jumlah transaksi mengandung } A \cap B}{\text{jumlah transaksi mengandung } A} \quad (3)$$

Frequent Pattern Growth (FP-Growth) adalah salah satu alternatif algoritma yang dapat digunakan untuk menentukan himpunan data yang paling sering muncul (*frequent itemset*) dalam sebuah kumpulan data. Pada algoritma *FP-Growth* menggunakan konsep pembangunan *tree*, yang biasa disebut *FP-Tree*, dalam pencarian *frequent itemset* bukan menggunakan *generate candidate* seperti yang dilakukan pada algoritma Apriori. Dengan menggunakan konsep tersebut, algoritma *FP-Growth* menjadi lebih cepat daripada algoritma Apriori. Algoritma *FP-Growth* memiliki tahapan-tahapan yang harus dilewati agar dapat memberikan hasil yang maksimal, tahapan-tahapan tersebut yaitu [19]:

1. Tahap pembangkitan *conditional pattern base*.
2. Tahap pembangkitan *conditional FP-Tree*.
3. Tahap pencarian *frequent itemset*.

Penelitian ini dilakukan menggunakan bahasa pemrograman R di Rstudio dengan langkah-langkah analisis sebagai berikut:

1. Melakukan *pre-processing* data dengan penanganan *missing value* serta menggabungkan item yang dibeli dalam satu faktur oleh pelanggan yang sama.
2. Penggabungan data variabel “*Description*” berdasarkan faktur yang sama
3. Memastikan variabel “*Description*” unik
4. Memastikan variabel “*StockCode*” dan “*Description*” merupakan kunci primer.
5. Membentuk data transaksi dengan menerapkan metode analisis *FP-Growth* yang memiliki *support* 1% dan *confidence* sebesar 80%.
6. Lakukan identifikasi item yang memiliki keterkaitan satu sama lain berdasarkan hasil *FP-Growth* atau pencarian *frequent itemset*.
7. Interpretasikan hasil aturan asosiasi yang didapatkan.
8. Berikan rekomendasi setiap aturan asosiasi yang didapatkan.
9. Membuat kesimpulan

3. HASIL DAN PEMBAHASAN

Langkah pertama yang dapat dilakukan untuk melakukan analisis market basket pada *e-commerce* data adalah dengan melakukan *Pre-Processing* data. Dimana *Pre-Processing* data ini mencakup penanganan pada *missing value* dan menggabungkan beberapa item yang dibeli pada waktu yang sama dengan *customer* yang sama. Berikut berupa tampilan 6 data awal yang digunakan pada penelitian ini:

Tabel 1. Tampilan data

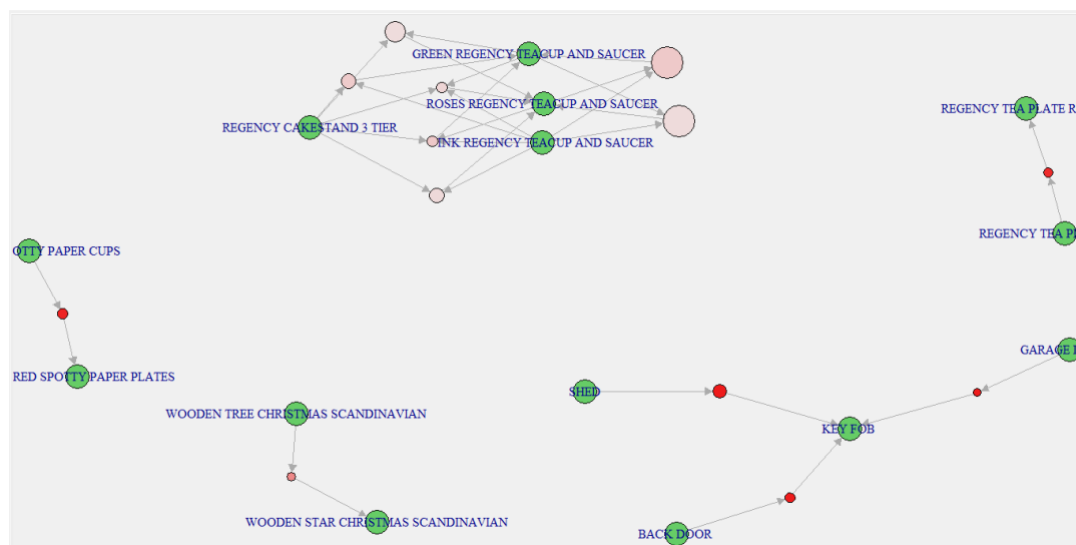
InvoiceNo	StockCode	Description	Quantity	InvoiceDate	UnitPrice	CustomerID	Country
536365	85123A	White Hanging Heart T-Light Holder	6	12/1/2010 8:26	2.55	17850	United Kingdom
536365	71053	White Metal Lantern	6	12/1/2010 8:26	3.39	17850	United Kingdom
536365	84406B	Cream Cupid Hearts Coat Hanger	8	12/1/2010 8:26	2.75	17850	United Kingdom
536365	84029G	Knitted Union Flag Hot Water Bottle	6	12/1/2010 8:26	3.39	17850	United Kingdom
536365	84029E	Red Woolly Hottie White Heart.	6	12/1/2010 8:26	3.39	17850	United Kingdom
536365	22752	Set 7 Babushka Nesting Boxes	2	12/1/2010 8:26	7.65	17850	United Kingdom

Berdasarkan tabel dapat terlihat bahwa terdapat beberapa nomor invoice yang sama, sehingga langkah selanjutnya adalah dengan menggabungkan beberapa nomor invoice yang sama menjadi satu. Langkah yang dapat dilakukan dengan penggabungan variabel “Description” berdasarkan nomor invoice. Melakukan penggabungan tersebut dapat dilakukan jika data yang digunakan sudah bersih di mana StockCode sudah tidak ada yang duplikat dan Description haruslah unique. Langkah tersebut dapat dengan melakukan join antar 2 *dataset*. *Dataset* pertama merupakan *dataset* keseluruhan di mana *dataset* ini merupakan *dataset* awal yang sudah diamputasi missing value-nya. *Dataset* kedua merupakan kunci primer yang terdiri atas StockCode dan Description yang sudah *unique*. Setelah melakukan proses penggabungan, didapatkan data berupa list sebagai berikut:

Tabel 2. Daftar data pembelian

No	Items
1	White Hanging Heart T-Light Holder
2	White Metal Lantern
3	Cream Cupid Hearts Coat Hanger
4	Knitted Union Flag Hot Water Bottle
5	Red Woolly Hottie White Heart.
6	Set 7 Babushka Nesting Boxes

Setelah mendapatkan data berupa jenis pembelanjaan, langkah selanjutnya adalah dengan membentuk data tersebut menjadi jenis transaksi. Dengan menggunakan FP-Growth dengan *support* sebesar 1% dan *confidence* sebesar 80% didapatkan hasil FP-Tree sebagai berikut:



Gambar 1. FP-Tree pembelian items

Berdasarkan FP-Tree terlihat bahwa terdapat beberapa *frequent itemset* yang memiliki keterkaitan satu sama lain, hal ini menunjukkan adanya aturan asosiasi pada data *e-commerce*. Dengan adanya FP-Tree memungkinkan untuk memperoleh *frequent itemsets* secara langsung, sehingga proses analisis menjadi lebih cepat dan dapat meminimalisir jumlah pembacaan *dataset* secara berulang-ulang dibandingkan dengan Apriori. Dengan menggunakan *support* sebesar 1% dan minimum *confidence* sebesar 80%, didapatkan aturan asosiasi sebagai berikut:

Tabel 3. Hasil aturan asosiasi

Lhs		Rhs	Support	Confidence	Count
{Set/6 Red Spotty Paper Cups}	=>	{Set/6 Red Spotty Paper Plates}	0.01063542	0.8280702	236
{Regency Tea Plate Green}	=>	{Regency Tea Plate Roses}	0.01045516	0.8436364	232
{Garage Design}	=>	{Key Fob}	0.01000451	1.0000000	222
{Back Door}	=>	{Key Fob}	0.01059036	1.0000000	235
{Wooden Tree Christmas Scandinavian}	=>	{Wooden Star Christmas Scandinavian}	0.01022983	0.8194946	227
{Shed}	=>	{Key Fob}	0.01203245	1.0000000	267
{Green Regency Teacup And Saucer, Pink Regency Teacup And Saucer}	=>	{Roses Regency Teacup And Saucer}	0.01789094	0.8428875	397
{Pink Regency Teacup And Saucer, Roses Regency Teacup And Saucer}	=>	{Green Regency Teacup And Saucer}	0.01789094	0.8802661	397
{Pink Regency Teacup And Saucer, Regency Cakestand 3 Tier}	=>	{Green Regency Teacup And Saucer}	0.01234790	0.8589342	274
{Pink Regency Teacup And Saucer, Regency Cakestand 3 Tier}	=>	{Roses Regency Teacup And Saucer}	0.01221271	0.8495298	271
{Green Regency Teacup And Saucer, Regency Cakestand 3 Tier}	=>	{Roses Regency Teacup And Saucer}	0.01424065	0.8250653	316
{Green Regency Teacup And Saucer, Pink Regency Teacup And Saucer, Regency Cakestand 3 Tier}	=>	{Roses Regency Teacup And Saucer}	0.01086075	0.8795620	241
{Pink Regency Teacup And Saucer, Regency Cakestand 3 Tier, Roses Regency Teacup And Saucer}	=>	{Green Regency Teacup And Saucer}	0.01086075	0.8892989	241

Berdasarkan tabel didapatkan hasil berupa 13 asosiasi dengan *confidence* di atas dari 80%. Pada aturan 1 didapatkan bahwa jika membeli Set/6 Red Spotty Paper Cups maka cenderung akan membeli Set/6 Red Spotty Paper Plates, sehingga pada kondisi ini *e-commerce* dapat menampilkan barang yang disarankan berupa Set/6 Red Spotty Paper Plates jika seseorang mencari Set/6 Red Spotty Paper Cups. Aturan 2 menyatakan jika membeli Regency Tea Plate Green maka cenderung akan membeli Regency Tea Plate Roses, sehingga pada kondisi ini *e-commerce* dapat menampilkan barang yang disarankan berupa Regency Tea Plate Roses jika seseorang mencari Regency Tea Plate Green.

Pada aturan 3 menyatakan jika membeli Garage Design maka cenderung akan membeli Key Fob, sehingga pada kondisi ini toko pada *e-commerce* dapat membuat paket *bundle* berupa Garage Design dengan Key Fob. Pada aturan 4 menyatakan jika membeli Back Door maka cenderung akan membeli Key Fob, sehingga pada kondisi ini toko pada *e-commerce* dapat membuat paket *bundle* berupa Back Door dengan Key Fob. Pada aturan 5 menyatakan jika membeli Wooden Tree Christmas Scandinavian maka cenderung akan membeli Wooden Star Christmas Scandinavian, sehingga pada kondisi ini toko pada *e-commerce* dapat membuat paket *bundle* Christmas Scandinavian yang terdiri atas wooden tree dan wodeen star. Pada aturan 6 menyatakan jika membeli Shed maka cenderung akan membeli Key Fob, sehingga pada kondisi ini toko pada *e-commerce* dapat membuat paket *bundle* berupa Shed dengan Key Fob.

Pada aturan 7 menyatakan jika membeli Green Regency Teacup beserta Saucer dan Pink Regency Teacup beserta Saucer maka cenderung akan membeli Roses Regency Teacup beserta Saucer, sehingga dapat dilakukan berupa penampilan notifikasi saat pelanggan menambahkan barang Green Regency Teacup beserta Saucer dan Pink Regency Teacup ke dalam keranjang, notifikasi yang diguna berupa notifikasi ajakan untuk melengkapi koleksi Regency Teacup beserta Saucer berupa varian Roses. Pada aturan 8 menyatakan jika membeli Pink Regency Teacup beserta Saucer dan Roses Regency Teacup beserta Saucer maka cenderung akan membeli Green Regency Teacup beserta Saucer, sehingga dapat dilakukan berupa penampilan notifikasi saat pelanggan menambahkan barang Pink Regency Teacup beserta Saucer dan Roses Regency Teacup ke dalam keranjang, notifikasi yang diguna berupa notifikasi ajakan untuk melengkapi koleksi Regency Teacup beserta Saucer berupa varian Green. Pada aturan 9 menyatakan jika membeli Pink Regency Teacup And Saucer dan Regency Cakestand 3 Tier maka cenderung akan membeli Green Regency Teacup beserta Saucer, sehingga langkah yang dapat dilakukan adalah dengan mengirimkan email marketing pada pelanggan yang telah membeli Pink Regency Teacup And Saucer dan Regency Cakestand 3 Tier berupa penawaran khusus atau informasi mengenai Green Regency Teacup beserta Saucer. Pada aturan 10 menyatakan jika membeli Pink Regency Teacup beserta Saucer dan Regency Cakestand 3 Tier maka cenderung akan membeli Roses Regency Teacup beserta Saucer, sehingga langkah yang dapat dilakukan adalah dengan mengirimkan email marketing pada pelanggan yang telah membeli Pink Regency Teacup And Saucer dan Regency Cakestand 3 Tier berupa penawaran khusus atau informasi mengenai Roses Regency Teacup beserta Saucer. Pada aturan 11 menyatakan jika membeli Green Regency Teacup beserta Saucer dan Regency Cakestand 3 Tier maka cenderung akan membeli Roses Regency Teacup beserta Saucer, sehingga langkah yang dapat dilakukan adalah dengan

mengirimkan email marketing pada pelanggan yang telah membeli Green Regency Teacup beserta Saucer dan Regency Cakestand 3 Tier berupa penawaran khusus atau informasi mengenai Roses Regency Teacup beserta Saucer.

Pada aturan 12 menyatakan jika membeli Green Regency Teacup beserta Saucer, Pink Regency Teacup beserta Saucer, dan Regency Cakestand 3 Tier maka cenderung akan membeli Roses Regency Teacup beserta Saucer, sehingga langkah yang tepat yang dapat dilakukan adalah dengan melakukan pengelolaan persediaan antara keempat produk tersebut. Dan pada aturan 13 menyatakan jika membeli Pink Regency Teacup beserta Saucer, Regency Cakestand 3 Tier, dan Roses Regency Teacup beserta Saucer maka cenderung akan membeli Green Regency Teacup And Saucer, sehingga langkah yang tepat yang dapat dilakukan adalah dengan melakukan pengelolaan persediaan antara keempat produk tersebut.

Penelitian ini memiliki keterbatasan, yaitu usia *dataset* yang digunakan. Data yang digunakan berasal dari tahun 2010 hingga tahun 2011 yang mana kurang relevan dengan kondisi dan perilaku *customer* saat ini, mengingat dinamika *e-commerce* yang terus berkembang. Oleh karena itu, hasil temuan dalam penelitian ini sebaiknya tidak langsung digeneralisasi tanpa mempertimbangkan pengaruh waktu dan perkembangan data-data terbaru.

4. KESIMPULAN

Penelitian ini mengimplementasikan algoritma *Frequent Pattern Growth* (FP-Growth) dalam menganalisis pola transaksi *e-commerce* dan mengevaluasi efektivitasnya dalam menemukan hubungan antarproduk yang sering dibeli bersama. Dengan menggunakan *dataset* transaksi dari toko ritel online berbasis di Inggris yang berisi 541.909 transaksi, penelitian ini berhasil mengidentifikasi 13 aturan asosiasi yang menunjukkan pola pembelian pelanggan dengan tingkat akurasi yang tinggi. Dengan menerapkan *support* sebesar 1% dan *confidence* sebesar 80% didapatkan hasil berupa 13 aturan asosiasi. Aturan tersebut adalah jika membeli Set/6 Red Spotty Paper Cups maka cenderung akan membeli Set/6 Red Spotty Paper Plates. Jika membeli Regency Tea Plate Green maka cenderung akan membeli Regency Tea Plate Roses. Jika membeli Garage Design maka cenderung akan membeli Key Fob. Jika membeli Back Door maka cenderung akan membeli Key Fob. Jika membeli Wooden Tree Christmas Scandinavian maka cenderung akan membeli Wooden Star Christmas Scandinavian. Jika membeli Shed maka cenderung akan membeli Key Fob. Dan lainnya hingga jika membeli Pink Regency Teacup beserta Saucer, Regency Cakestand 3 Tier, dan Roses Regency Teacup beserta Saucer maka cenderung akan membeli Green Regency Teacup And Saucer.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Universitas Bengkulu, khususnya Program Studi Statistika, atas dukungan dan fasilitas yang diberikan selama proses penelitian ini. Penghargaan yang tulus juga disampaikan kepada dosen pembimbing atas bimbingan, saran, serta masukan berharga yang sangat berkontribusi dalam penyempurnaan manuskrip ini. Selain itu, penulis mengapresiasi kerja sama serta bantuan dari rekan-rekan sejawat dalam proses pengolahan dan analisis data. Penulis juga berterima kasih kepada penyedia data yang telah memberikan akses terhadap *dataset* transaksi *e-commerce* yang digunakan dalam penelitian ini. Akhirnya, apresiasi diberikan kepada semua pihak, baik individu maupun organisasi, yang secara langsung maupun tidak langsung turut berkontribusi dalam penyelesaian penelitian dan artikel ini.

REFERENSI

- [1] Y. Rahmanto, A. Rifaini, S. Samsugi, dan S. D. Riskiono, "Sistem Monitoring pH Air Pada Aquaponik Menggunakan Mikrokontroler Arduino UNO," *Jurnal Teknologi dan Sistem Tertanam*, vol. 1, no. 1, pp. 23–28, 2020.
- [2] A. Surahman, B. Aditama, M. Bakri, dan R. Rasna, "Sistem Pakan Ayam Otomatis Berbasis Internet of Things," *Jurnal Teknologi dan Sistem Tertanam*, vol. 2, no. 1, pp. 13–20, 2021.
- [3] S. Samsugi, A. Nurkholis, B. Permatasari, A. Candra, dan A. B. Prasetyo, "Internet of Things Untuk Peningkatan Pengetahuan Teknologi Bagi Siswa," *Journal of Technology and Social for Community Service (JTSCS)*, vol. 2, no. 2, p. 174, 2021.
- [4] C. Zai, "Implementasi Data Mining sebagai Pengolahan Data," *Jurnal Portal Data*, vol. 2, no. 3, 2022.
- [5] H. D. Wijaya dan S. Dwiasnati, "Implementasi Data Mining dengan Algoritma Naïve Bayes pada Penjualan Obat," *Jurnal Informatika*, vol. 7, no. 1, pp. 1–7, 2020.
- [6] F. M. Maghfiroh, S. A. Natalina, & R. Efendi, "Transformasi Ekonomi Digital : *Connection Integration E-commerce* dan *S-Commerce* dalam Upaya perkembangan ekonomi berkelanjutan," *Prosiding Seminar Nasional*, vol 2, no 1, 2023, 1-10.
- [7] Carrie, *E-commerce Data*, kaggle, 12 Desember 2018, [Online]. Tersedia : <https://www.kaggle.com/datasets/carrie1/ecommerce-data/code>
- [8] A. Febiyanto, A. Faqih, R. Herdiyana, N. D. Nuris, & R. Narasati, "Penerapan algoritma *FP-Growth* untuk menentukan pola penjualan produk elektronik," *Jurnal mahasiswa teknik informatika*, vol. 7, no 6, Desember 2023, 3907-3912.
- [9] A. Ardianto, D. Fitriana, "Penerapan algoritma *FP-Growth* rekomendasi trens penjualan atk pada cv. Fajar sukses abadi," *Jurnal telekomunikasi dan komputer*, vol. 9, no. 1, April 2019, 49-50.
- [10] A. S. Khadijah, A. F. Waluyo, "Implementasi Algoritma *FP Growth* Untuk Menganalisis Pola Pembelian Konsumen Balcos Compound," *Jurnal ilmiah teknik informatika dan sistem informasi*, vol. 13, no. 3, Desember 2024: 2450-2463.
- [11] L. Holpiani, F. Putrawansyah, & S. Muntari, "Implementasi algoritma *FP Growth* untuk menganalisa pola penjualan kue pada toko dapur bunda," *Jurnal informatika & rekayasa elektronika*, vol. 7, no. 1, April 2024, 34-42.

- [12] M. Hafiz, T. Novita, D. Guswandi, H. Syahputra, & L. Mayola, "Implementasi data mining menggunakan algoritma *FP Growth* untuk menganalisa transaksi penjualan ekspor online," *Jurnal teknologi dan sistem informasi bisnis*, vol. 5, no. 3, Juli 2023, 242-249.
- [13] A. H. Talia, N. Suarna, & D. Pratama, "Penerapan algoritma *FP Growth* dalam analisis pola transaksi untuk optimalitas pengelolaan data transaksi di toko lia," *Jurnal Kecerdasan Buatan dan Teknologi Informasi*, vol. 3, no. 1, Januari 2024, 23-36.
- [14] A. H. Wibowo, K. A. Sekarjati, I. Mustofa, N. S. Makhulina, & R. Dewangga, "Penerapan *Association Rule-Market Basket Analysis* (AR-MBA) Dalam Menentukan Strategi *Product Bundling*: Studi Kasus Pada Minimarket AKPRIND MART," *Jurnal Teknik Industri Terintegrasi*, vol. 7, no. 1, 2024, 379-386.
- [15] M. A. Saifudin, H. E. Wahanani, & A. Junaidi, "Implementasi algoritma asosiasi *FP Growth* dan klasifikasi *K Means* terhadap pola pembelian konsumen di *marketplace* shopee," *Jurnal mahasiswa teknik informatika*, vol. 8, no. 1, Februari 2024, 764-771.
- [16] J. A. Jenderal Yani No and S. Selatan, "Penerapan Algoritma *FP-Growth* Untuk Menentukan Pola Pengambilan Treatment," Bulan Oktober, 2022.
- [17] E. Munanda and S. Monalisa, "Penerapan Algoritma *Fp-Growth* Pada Data Transaksi Penjualan Untuk Penentuan Tataletak Barang 1," *Jurnal Ilmiah Rekayasa dan Manajemen Sistem Informasi*, vol. 7, no. 2, pp. 173–184, 2021.
- [18] M. Yudho Ardianto and S. Adinugroho, "Penentuan Tata Letak Produk menggunakan Algoritma *FP-Growth* pada Toko ATK," 2021.
- [19] Nurasih, "Implementasi Algoritma *FP-Growth* Pada Pengenalan Pola Penjualan. Jurnal Terapan Informasi Nusantara," *Jurnal terapan informatika nusantara*, vol. 1, no. 9, Februari 2021 438-3444.

Deteksi Sentimen Komentar Aplikasi Gobis Suroboyo dengan Metode Naive Bayes dan Metode Regresi Logistik

Shifa Elmaliyasari¹, Muhammad Arsyad Alzam², Nanda Aulia Pratiwi³, Shindi Sheila May Wara⁴, Kartika Maulida Hindrayani⁵

^{1,2,3,4,5}Program Studi Sains Data, Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

Email: ¹23083010022@student.upnjatim.ac.id, ²23083010082@student.upnjatim.ac.id, ³23083010011@student.upnjatim.ac.id,

⁴shindi.shella.fasilkom@upnjatim.ac.id, ⁵kartika.maulida.ds@upnjatim.ac.id

ABSTRAK

Penelitian ini membahas analisis sentimen terhadap komentar pengguna aplikasi Gobis Suroboyo menggunakan algoritma Naive Bayes dan Regresi Logistik. Data diperoleh melalui metode *web scraping* dari Google Play Store, dengan total 1.015 komentar yang kemudian melalui proses pra-pemrosesan teks seperti pembersihan data, *case folding*, *stemming*, normalisasi, *filtering*, *tokenizing*, dan pemilihan fitur menggunakan TF-IDF. Label sentimen ditentukan berdasarkan rating pengguna, dengan rating di atas 3 sebagai positif dan 3 ke bawah sebagai negatif. Hasil penelitian menunjukkan bahwa algoritma Naive Bayes lebih baik dalam mengklasifikasikan sentimen positif dengan *precision* sebesar 81% dan *f1-score* sebesar 77%, sedangkan Regresi Logistik unggul pada sentimen negatif dengan *precision* sebesar 82% dan *f1-score* sebesar 82%. Visualisasi *WordCloud* memperlihatkan kata-kata dominan seperti “aplikasi”, “bagus”, dan “halte” yang mencerminkan perhatian pengguna terhadap fitur aplikasi dan layanan transportasi. Temuan ini menunjukkan bahwa kedua algoritma memiliki performa yang kompetitif dan dapat diandalkan untuk mengevaluasi opini publik terhadap layanan digital berbasis komentar. Penelitian ini diharapkan dapat menjadi acuan bagi pengembang aplikasi dan pemerintah daerah dalam meningkatkan kualitas layanan publik digital.

Kata Kunci: Analisis Sentimen, Naïve Bayes, Regresi Logistik, Gobis Suroboyo

ABSTRACT

This research discusses sentiment analysis of user comments on the Gobis Suroboyo application using the Naive Bayes algorithm and Logistic Regression. Data was obtained through web scraping method from Google Play Store, with a total of 1,015 comments which then went through text pre-processing such as data cleaning, case folding, stemming, normalisation, filtering, tokenizing, and feature selection using TF-IDF. Sentiment labels were determined based on user ratings, with ratings above 3 as positive and 3 and below as negative. The results show that the Naive Bayes algorithm is better at classifying positive sentiment with a precision of 81% and f1-score of 77%, while Logistic Regression excels at negative sentiment with a precision of 82% and f1-score of 82%. The WordCloud visualisation shows dominant words such as “app”, “good”, and “bus stop” that reflect users attention to the app features and transportation services. The findings show that both algorithms have competitive and reliable performance for evaluating public opinion on comment-based digital services. This research is expected to be a reference for app developers and local governments in improving the quality of digital public services.

Keywords: Sentiment Analysis, Naïve Bayes, Logistic Regression, Gobis Suroboyo

Penulis Korespondensi:

Shifa Elmaliyasari

Email: 23083010022@student.upnjatim.ac.id

Article Info

Diterima: 9 Juni 2025

Direvisi: 12 Juni 2025

Disetujui: 16 Juni 2025

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



1. PENDAHULUAN

Dalam era digital saat ini, layanan publik semakin banyak mengadopsi platform digital sebagai sarana utama untuk berinteraksi dengan masyarakat. Salah satu contohnya adalah aplikasi Gobis Suroboyo, yang dirancang untuk memberikan layanan informasi transportasi berbasis *real-time* kepada warga Surabaya. Aplikasi ini memungkinkan pengguna untuk mengakses jadwal keberangkatan, rute perjalanan, serta lokasi armada transportasi umum seperti bus secara lebih akurat. Namun demikian, efektivitas suatu aplikasi tidak hanya dapat diukur dari fungsionalitasnya saja, melainkan juga dari umpan balik yang diberikan oleh pengguna melalui platform seperti Google Play Store. Kolom komentar pada Google Play Store menjadi salah satu media penting untuk menangkap pengalaman pengguna secara langsung, termasuk permasalahan teknis, kepuasan layanan, maupun saran perbaikan. Komentar pengguna mencerminkan pengalaman nyata dan dapat dijadikan dasar evaluasi kualitas layanan secara objektif maupun pengambilan keputusan berbasis data oleh pengelola layanan.

Analisis sentimen merupakan metode dalam *text mining* yang digunakan untuk mengevaluasi opini pengguna berdasarkan teks ulasan [1]. Teknik ini memungkinkan sistem untuk mengklasifikasikan opini menjadi kategori positif dan negatif. Dalam konteks aplikasi layanan publik, pendekatan ini sangat penting karena dapat mengungkap kepuasan atau keluhan pengguna secara masif dan cepat tanpa harus survei secara langsung yang dapat memakan waktu dan biaya. Selain itu, analisis sentimen juga dapat digunakan untuk memantau persepsi publik secara berkala, mendeteksi isu-isu krusial yang sedang berkembang, serta merumuskan strategi peningkatan kualitas layanan berdasarkan data yang bersifat empiris.

Sejumlah penelitian sebelumnya telah dilakukan untuk mengkaji efektivitas algoritma klasifikasi dalam analisis sentimen pada berbagai jenis aplikasi. Nugraha dan Gustian pada penelitiannya menggunakan algoritma Naive Bayes Classifier untuk mengklasifikasikan komentar pengguna dari tiga aplikasi transportasi online (Gojek, Grab, dan Maxim), dan menunjukkan bahwa aplikasi Maxim memperoleh akurasi tertinggi yaitu 93% [2]. Dalam studi yang berbeda, Nugroho, Susilo, dan Retnoningsih membandingkan performa beberapa algoritma termasuk Naive Bayes, Random Forest, dan Regresi Logistik dalam menganalisis ulasan pengguna aplikasi "Access by KAI", dan menyimpulkan bahwa Regresi Logistik menghasilkan akurasi terbaik sebesar 84% [3]. Penelitian lain oleh Dinda membandingkan kinerja algoritma Naive Bayes dan Regresi Logistik dalam konteks prediksi penyakit jantung. Hasilnya menunjukkan bahwa Naive Bayes sedikit lebih unggul dengan akurasi 85,50% dibanding Regresi Logistik yang mencapai 83,19% [4]. Adapun Insan et al. yang menganalisis sentimen pengguna terhadap aplikasi BRImo dan menunjukkan bahwa algoritma Naive Bayes mampu mengklasifikasikan ulasan dengan akurasi sebesar 84,52%, yang memperkuat efektivitas metode ini dalam mengolah data teks dari ulasan pengguna di Google Play Store [5].

Temuan-temuan ini menunjukkan bahwa baik Naive Bayes maupun Regresi Logistik memiliki performa yang kompetitif dalam berbagai konteks klasifikasi teks, namun belum ada studi yang secara khusus membandingkannya pada aplikasi layanan publik lokal seperti Gobis Suroboyo. Padahal, karakteristik teks ulasan yang pendek, informal, dan dalam bahasa Indonesia memiliki tantangan tersendiri dalam proses klasifikasi otomatis. Penelitian ini bertujuan untuk mengisi kekosongan tersebut dengan membandingkan performa dua algoritma klasifikasi, yakni Naive Bayes dan Regresi Logistik, dalam menganalisis sentimen komentar pengguna aplikasi Gobis Suroboyo di Google Play Store. Penelitian ini diharapkan dapat memberikan insight kepada pengembang aplikasi dan pemerintah daerah mengenai persepsi publik terhadap layanan digital mereka.

2. METODE PENELITIAN

2.1 Teknik Pengambilan Data

2.1.1 Sumber Data

Dengan adanya media sosial, orang dapat secara bebas menyatakan pendapat mereka. Hal ini merupakan bentuk partisipasi pasif yang bermanfaat dalam perencanaan kota, karena membantu perancang dan penyedia layanan kota membuat keputusan yang lebih baik. Salah satu contohnya adalah transportasi umum perkotaan, di mana pengguna terus memberikan umpan balik, baik komentar positif maupun kritik [6]. Data yang digunakan dalam penelitian ini berasal dari ulasan pengguna aplikasi GoBis Suroboyo di Google Play Store. Platform ini dipilih sebagai sumber utama karena dua alasan. Pertama, Google Play Store memberikan akses publik ke berbagai ulasan pengguna, termasuk rating dan teks komentar. Kedua, data yang diperoleh secara *real-time* memungkinkan untuk menggambarkan pengalaman pengguna saat ini secara akurat. Penelitian ini menggunakan berbagai kriteria untuk menentukan sumber data.

2.1.2 Metode Pengumpulan Data

Pengambilan data dilakukan dengan metode *web scraping*, yang secara otomatis mengekstrak data ulasan dari Google Play Store. *Web Scraping* adalah proses mengekstrak data dari internet dengan cara apa pun. Ini dapat mengubah data tidak terstruktur menjadi data terstruktur yang dapat disimpan dan divalidasi di *database*. Metode ini dipilih karena mampu mengumpulkan data dalam jumlah besar dengan efisiensi sambil mengurangi kesalahan manusia yang mungkin terjadi saat mengumpulkan data secara manual. Beberapa tahapan penting diperlukan dalam proses ini, termasuk penyaringan ulasan berdasarkan kriteria khusus dan penerapan filter. Sebelum dianalisis, data melalui proses validasi untuk memastikan bahwa data sudah lengkap dan akurat. Meskipun Metode ini memiliki beberapa kelemahan, seperti keterbatasan untuk mengakses Google Play Store dan data historis yang terlalu lama.

2.2 Pra-pemrosesan Data

Tahap pra-pemrosesan data merupakan langkah yang sangat penting dalam melakukan analisis sentimen berbasis *text mining*, karena data mentah dari Google Play Store umumnya tidak terstruktur. Langkah-langkah yang dilakukan dalam pra-pemrosesan data adalah sebagai berikut :

1. Proses *Cleaning*
Proses *Cleaning* merupakan tahapan yang bertujuan untuk menghapus simbol-simbol atau karakter khusus, username, angka, serta tautan yang tidak relevan untuk proses analisis.
2. Proses *Case Folding*
Proses *Case Folding* mengubah seluruh huruf pada komentar menjadi huruf kecil atau *lowercase* untuk menyamakan format teks. Daftar kata yang diubah seperti “Aplikasi Ini bAgus” menjadi “aplikasi ini bagus”.
3. Proses *Stemming*
Proses *Stemming* bertujuan untuk mengubah kata berimbuhan menjadi bentuk baku. Anggap kata “menunggu” menjadi “tunggu”.
4. Proses Normalisasi Kata
Proses Normalisasi Kata akan mengubah kata-kata singkatan atau campuran bahasa menjadi kata dalam bentuk baku, seperti “tdk” menjadi “tidak”. Tahapan ini dilakukan agar model mengenali makna kata dengan benar.
5. Proses *Filtering*
Proses *Filtering* dilakukan dengan menghapus kata sambung dan tidak mengandung informasi yang spesifik, seperti “dan”, “dengan”, ataupun “yang”. *Filtering* dilakukan dengan menggunakan daftar *stopwords* yang telah didefinisikan.
6. Proses *Tokenizing*
Proses *Tokenizing* merupakan proses pemecahan kalimat menjadi unit-unit kata atau token. Sebagai contoh, kalimat “Aplikasi ini sangat berguna” akan diubah menjadi ["aplikasi", "ini", "sangat", "berguna"].
7. Proses Pemilihan Fitur
Proses Pemilihan Fitur bertujuan untuk menentukan kata-kata yang paling relevan agar dapat digunakan dalam klasifikasi sentimen. Menggunakan metode *Term Frequency-Inverse Document Frequency (TF-IDF)* untuk membantu menonjolkan kata-kata yang bersifat unik dan bermakna dalam analisis.
8. Proses *Labeling*
Proses *Labeling* akan mengkategorikan komentar berdasarkan nilai rating yang diberikan pengguna. Jika rating lebih dari 3, maka komentar diklasifikasikan sebagai sentimen ‘positif’ sedangkan jika rating 3 ke bawah, maka dikategorikan sebagai ‘negatif’.

2.3 Analisis Sentimen dengan Naive Bayes

Metode Naive Bayes merupakan algoritma klasifikasi berbasis probabilistik yang banyak digunakan dalam analisis sentimen karena kesederhanaannya dan efektivitasnya dalam menangani data teks berdimensi tinggi. Algoritma ini menghitung probabilitas sebuah teks termasuk dalam kelas tertentu (misalnya sentimen positif atau negatif) dengan mengasumsikan independensi antar kata. Penelitian oleh Hilmi dan Irwiensyah membuktikan efektivitas metode ini dalam menganalisis ulasan pengguna TikTok, dengan akurasi 83,66% [7]. Sementara itu, Khofifah dan Rahayu berhasil mengelompokkan sentimen masyarakat terhadap destinasi wisata menggunakan pendekatan serupa [8]. Rumus dasar Naive Bayes:

$$P(C_i | X) \propto P(C_i) \cdot \prod_{j=1}^n P(x_j | C_i) \quad (1)$$

Keterangan:

- $P(C_i | X)$: Probabilitas bahwa X dokumen termasuk ke dalam kelas C_i
- $P(C_i)$: Probabilitas awal (prior) dari kelas C_i
- $P(x_j | C_i)$: Probabilitas kata ke- j muncul dalam dokumen yang termasuk kelas C_i
- X : Dokumen atau ulasan yang dianalisis, terdiri dari beberapa kata fitur
- x_j : Kata ke- j dalam dokumen
- n : Jumlah total kata (fitur) dalam dokumen
- $\prod_{j=1}^n$: Simbol perkalian terhadap semua probabilitas $P(x_j | C_i)$ dari $j = 1$ hingga n
- \propto : Simbol proporsionalitas yang menyatakan bahwa hasilnya sebanding

Metode ini digunakan untuk mengklasifikasikan komentar pengguna aplikasi Gobis Suroboyo menjadi sentimen positif dan negatif.

2.4 Analisis Sentimen dengan Regresi Logistik

Metode Regresi Logistik merupakan algoritma klasifikasi yang digunakan untuk memprediksi probabilitas suatu data termasuk ke dalam kelas tertentu, seperti sentimen positif atau negatif. Dalam penelitian ini, algoritma ini dipilih karena mampu

menangani data teks berdimensi tinggi secara efisien. Penelitian oleh Averina et al. menunjukkan bahwa Regresi Logistik dapat mengklasifikasikan sentimen ulasan film dengan akurasi 83% untuk dua kelas menggunakan fitur *CountVectorizer* dan teknik *dimensionality reduction* [9]. Temuan ini menjadi dasar pemilihan metode Regresi Logistik dalam penelitian ini untuk mengklasifikasikan komentar aplikasi Gobis Suroboyo. Secara matematis, fungsi logistik dalam klasifikasi biner didefinisikan sebagai:

$$P(y = 1 | x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}} \quad (2)$$

Keterangan:

- $P(y = 1 | x)$: Probabilitas bahwa input x termasuk dalam kelas 1 (misalnya: sentimen positif)
- e : Bilangan eksponensial natural (Euler), dengan nilai mendekati 2,718
- β_0 : Intersep atau konstanta model (bias)
- $\beta_1, \beta_2, \dots, \beta_n$: Koefisien regresi untuk masing-masing fitur
- x_1, x_2, \dots, x_n : Nilai fitur atau variabel independen dalam data teks
- n : Jumlah total fitur yang digunakan dalam model klasifikasi

3. HASIL DAN PEMBAHASAN

3.1. Data Scraping

Data scraping pada penelitian ini dilakukan pada tanggal 12 Mei 2025 menggunakan tools Google Collaboratory. Proses ini bertujuan untuk mengambil komentar atau ulasan pengguna terhadap aplikasi GoBis yang tersedia pada platform Google Play Store, dengan rentang skor atau rating dari 1 hingga 5. Berdasarkan data yang tersedia saat itu, terdapat total 2.604 komentar, tetapi hanya 1.015 komentar yang berhasil di *scraping* karena adanya keterbatasan teknis atau kebijakan akses data. Hasil *scraping* tersebut kemudian disimpan dalam bentuk file Excel (.csv) dan dilanjutkan ke tahap pra-pemrosesan data untuk analisis lebih lanjut.

Tabel 1. Hasil *scraping* data

	Waktu	Komentar	Skor
0	5/1/2025 12:20	Aplikasi sebetulnya bagus untuk penggunaan transportasi umum dlm mengurangi pemakaian kendaraan pribadi, Akan tetapi tampilannya perlu diperbaiki. Karena sangat...	3
1	5/7/2025 0:53	Dulu udah install ini dan uninstall krn app ini sdh nggak berguna lagi semenjak ada mitra darat. saya kira itu...	1
2	4/28/2025 6:45	Dengan adanya aplikasi ini sangat menguntungkan bagi kita pengguna transfort dgn bus, bnyk arah...	5
...
1012	10/26/2024 4:37	sangat senang	5
1013	5/18/2022 0:02	Cakep bgt	5
1014	4/28/2019 9:39	👍👍👍	5

3.2. Data Pem-prosesan

Pra-pemrosesan merupakan langkah penting sebelum mengimplementasikan algoritma klasifikasi pada data. Tahap-tahap pada langkah pra-pemrosesan data adalah sebagai berikut:

a. *Cleaning*

Langkah awal yang dilakukan adalah membersihkan data dari karakter atau elemen yang tidak diperlukan seperti tanda baca, angka, atau simbol khusus. Bertujuan untuk menghilangkan elemen-elemen yang tidak relevan agar teks menjadi lebih bersih dan terstruktur untuk dianalisis.

Tabel 2. Proses *cleaning* data

Teks	Cleaning
Aplikasi sebetulnya bagus untuk penggunaan transportasi umum dlm mengurangi pemakaian kendaraan pribadi, Akan tetapi tampilannya perlu diperbaiki.	Aplikasi sebetulnya bagus untuk penggunaan transportasi umum dlm mengurangi pemakaian kendaraan pribadi Akan tetapi tampilannya perlu diperbaiki

b. *Case Folding*

Proses ini mengubah seluruh huruf dalam teks menjadi huruf kecil. Hal ini penting agar sistem tidak membedakan antara kata yang seharusnya sama akan tetapi ditulis dengan perbedaan kapitalisasi. Langkah ini bertujuan untuk menyamakan format teks dengan mengubah seluruh huruf menjadi huruf kecil demi konsistensi dalam pengolahan.

Tabel 3. Proses *case folding*

Teks	Case Folding
Aplikasi sebetulnya bagus untuk penggunaan transportasi umum dlm mengurangi pemakaian kendaraan pribadi Akan tetapi tampilannya perlu diperbaiki	aplikasi sebetulnya bagus untuk penggunaan transportasi umum dlm mengurangi pemakaian kendaraan pribadi akan tetapi tampilannya perlu diperbaiki

c. *Stemming*

Stemming dilakukan untuk mengembalikan setiap kata ke bentuk dasarnya. Hal ini membantu mengurangi jumlah variasi kata dan menyatukan kata-kata yang berasal dari akar yang sama.

Tabel 4. Proses *stemming*

Teks	Steeming
aplikasi sebetulnya bagus untuk penggunaan transportasi umum dlm mengurangi pemakaian kendaraan pribadi akan tetapi tampilannya perlu diperbaiki	aplikasi betul bagus untuk guna transportasi umum dlm kurang pakai kendra pribadi akan tetapi tampil perlu baik

d. Normalisasi Kata

Tahapan ini bertugas menyesuaikan kata tidak baku atau kata gaul menjadi bentuk yang standar dan sesuai dengan kamus.

Tabel 5. Proses normalisasi kata

Teks	Normalisasi Data
aplikasi betul bagus untuk guna transportasi umum dlm kurang pakai kendra pribadi akan tetapi tampil perlu baik	aplikasi betul bagus untuk guna transportasi umum dalam kurang pakai kendra pribadi akan tetapi tampil perlu baik

e. *Filtering*

Filtering digunakan untuk menyaring kata-kata yang dianggap tidak membawa informasi penting dalam analisis, seperti kata sambung atau kata umum.

Tabel 6. Proses *filtering* data

Teks	Filtering
aplikasi betul bagus untuk guna transportasi umum dalam kurang pakai kendra pribadi akan tetapi tampil perlu baik	aplikasi bagus transportasi pakai kendra pribadi tampil

f. *Tokenizing*

Tokenizing memecah teks menjadi bagian-bagian kecil seperti kata, frasa, atau kalimat. Proses ini penting untuk mengidentifikasi unit dasar dari teks yang akan dianalisis dalam tahapan selanjutnya.

Tabel 7. Proses *Tokenizing*

Teks	Tokenizing
aplikasi bagus transportasi pakai kendra pribadi tampil	'aplikasi', 'bagus', 'transportasi', 'pakai', 'kendara', 'pribadi', 'tampil'

g. Pemilihan Fitur

Hasil data yang dihasilkan pada tahapan sebelumnya akan dilakukan tahap pemilihan fitur menggunakan metode TF-IDF. Metode ini bertujuan mengubah kumpulan dokumen teks menjadi bentuk numerik agar dapat dianalisis oleh model Naive Bayes dan Regresi Logistik.

Tabel 8. Proses pemilihan fitur

Dokumen	aplikasi	bagus	bantu	...	tolong	transportasi	tunggu
0	0.154514	0.179958	0.000000	...	0.196603	0.555644	0.000000
1	0.373359	0.000000	0.000000	...	0.000000	0.671313	0.000000
2	0.513341	0.000000	0.000000	...	0.000000	0.000000	0.000000

...
1013	0.000000	0.000000	0.000000	...	0.000000	0.000000	0.000000
1014	0.000000	0.000000	0.000000	...	0.000000	0.000000	0.000000
1015	0.000000	0.000000	0.000000	...	0.000000	0.000000	0.000000

h. Labeling

Proses *labeling* untuk mengategorikan komentar berdasarkan *rating* yang diberikan pengguna. Komentar dengan *rating* di atas 3 diberi label sentimen positif, sedangkan *rating* 3 ke bawah diberi label negatif. Berikut ditampilkan tabel yang menunjukkan proporsi jumlah data berlabel positif dan negatif yang telah diperoleh.

Tabel 9. Proses *labeling*

Label	Jumlah	Proporsi(%)
Positif	555	54.7337
Negatif	460	45.2663

3.3. Evaluasi Model


Evaluasi performa merupakan tahap penting untuk menilai seberapa baik model dalam mengelompokkan data ke dalam kelas yang sesuai. Evaluasi ini biasanya dilakukan dengan menggunakan metrik seperti akurasi, *precision*, *recall*, dan *f1-score*. Akurasi mengukur proporsi keseluruhan prediksi yang benar, *precision* menunjukkan ketepatan prediksi positif, *recall* mengukur kemampuan model dalam menangkap data positif secara benar, dan *f1-score* memberikan gambaran keseimbangan antara *precision* dan *recall*.

Tabel 10. Hasil evaluasi model

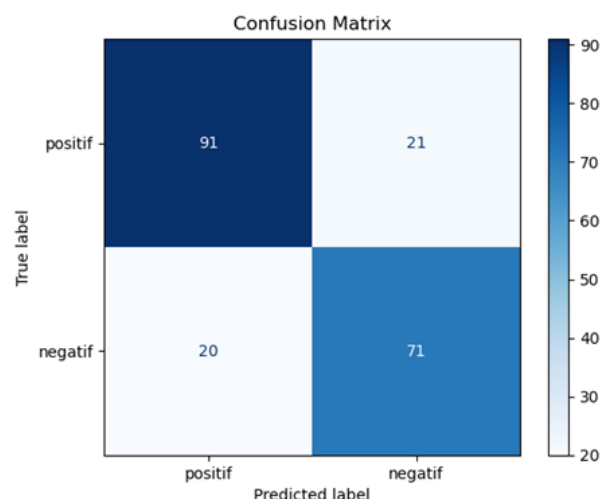
Modeling	Accuracy	Precision	Recall	F1-score
Naive Bayes	80.2%	Positif	81%	73%
		Negatif	80%	87%
Regresi Log	79.8%	Positif	77%	78%
		Negatif	82%	81%

Berdasarkan tabel yang menunjukkan bahwa Naive Bayes lebih unggul dalam memprediksi kelas positif dengan nilai *precision* sebesar 81% dibanding Regresi Logistik dengan nilai *precision* sebesar 77%, disisi lain Regresi Logistik lebih baik untuk memprediksi kelas negatif dengan nilai *precision* sebesar 82% dibanding Naive Bayes dengan nilai sebesar 80%. Nilai *recall* Naive Bayes lebih tinggi untuk kelas negatif sebesar 87%, sementara Regresi Logistik menunjukkan performa yang lebih seimbang sebesar 78% untuk kelas positif dan 81% untuk kelas negatif. *F1-score* Regresi Logistik juga lebih konsisten di kedua kelas, yakni sebesar 78% untuk kelas positif dan 82% untuk kelas negatif, sedangkan Naive Bayes unggul pada kelas negatif dengan nilai 83% dibanding dengan kelas positif yaitu 77%. Hal ini menunjukkan bahwa model Regresi Logistik memiliki performa yang lebih seimbang. Keseimbangan ini penting karena menunjukkan bahwa model tidak condong atau bias terhadap salah satu kelas saja. Model yang seimbang lebih andal karena mampu memprediksi berbagai sentimen secara konsisten, meski akurasi per kelas sedikit lebih rendah dibanding model yang bias ke satu kelas.

Untuk memahami performa model klasifikasi secara lebih mendalam, selain menggunakan matrik evaluasi seperti *precision*, *recall*, dan *f1-score*, analisis juga dilakukan melalui *confusion matrix*. *Confusion matrix* memberikan gambaran rinci mengenai jumlah prediksi benar dan salah untuk masing-masing kelas, termasuk *true positive*, *false positive*, *true negative*, dan *false negative*. Pendekatan ini penting untuk menilai efektivitas model, terutama ketika terdapat ketidakseimbangan kelas atau ketika kesalahan klasifikasi pada satu kelas memiliki dampak yang lebih besar.



Gambar 1. *Confusion matriks* Naïve Bayes



Gambar 2. *Confusion matriks* Regresi Logistik

Berdasarkan *confusion matrix* dari kedua model klasifikasi, terlihat bahwa Naive Bayes menghasilkan 97 prediksi benar untuk kelas positif dan 66 untuk kelas negatif, dengan kesalahan masing-masing 15 dan 25. Di sisi lain, Regresi Logistik memprediksi 91 data positif dan 71 data negatif dengan benar, serta menghasilkan kesalahan klasifikasi sebanyak 21 dan 20. Naive Bayes memperoleh akurasi sebesar 80.2%, sedangkan Regresi Logistik menghasilkan akurasi sebesar 79.8%. Hal ini menunjukkan bahwa Naive Bayes lebih akurat dalam mendeteksi kelas positif, sementara Regresi Logistik sedikit lebih baik dalam mengenali kelas negatif. Meskipun selisih akurasinya kecil, perbedaan distribusi prediksi benar antar kelas ini bisa menjadi pertimbangan penting tergantung pada prioritas klasifikasi dalam konteks penggunaan model.

3.4. Visualisasi Data

Penelitian ini juga dilengkapi dengan visualisasi data dalam bentuk *WordCloud* untuk memberikan gambaran umum mengenai kata-kata yang paling sering muncul dalam kumpulan komentar pengguna. Visualisasi ini bertujuan untuk memudahkan identifikasi topik atau istilah yang dominan secara intuitif. Pada penelitian ini hasil dari *WordCloud* untuk seluruh data komentar aplikasi Gobis dapat dilihat pada gambar sebagai berikut:



Gambar 3. *WordCloud* seluruh komentar

Berdasarkan visualisasi *WordCloud* dari seluruh data komentar, terlihat bahwa kata-kata seperti “aplikasi”, “bus”, “bagus”, “tolong”, dan “halte” merupakan yang paling dominan muncul. Hal ini menunjukkan bahwa pengguna banyak memberikan perhatian terhadap aspek teknis dari aplikasi serta layanan transportasi yang disediakan. Selain itu, kemunculan kata seperti “bantu”, “rute”, “menunggu”, dan “surabaya” juga mengindikasikan adanya interaksi pengguna terkait informasi rute, lokasi, dan pengalaman penggunaan layanan di kota tersebut. Dominasi kata-kata tersebut mencerminkan fokus utama komentar, baik berupa pujian, masukan, maupun keluhan terhadap layanan transportasi yang sedang dievaluasi. Berikut ini wordcloud dari data komentar positif dan negatif mengenai data komentar aplikasi Gobis yang dapat dilihat pada gambar sebagai berikut :



Gambar 4. WordCloud komentar positif



Gambar 5. WordCloud komentar negatif

Berdasarkan hasil visualisasi *WordCloud* dari komentar dengan sentimen positif, terlihat bahwa kata-kata seperti “bagus,” “bantu,” “terima kasih,” “surabaya,” “nyaman,” dan “bersih” mendominasi. Hal ini mencerminkan bahwa pengguna merasa puas terhadap layanan, terutama dalam hal kenyamanan, kebersihan, serta kemudahan penggunaan aplikasi. Kemunculan kata “terima kasih” dan “bantu” menunjukkan adanya apresiasi dari pengguna terhadap manfaat layanan yang mereka rasakan. Sementara itu, pada *WordCloud* komentar dengan sentimen negatif, kata-kata seperti “tolong,” “masuk,” “error,” “penuh,” “daftar,” dan “jadwal” tampak lebih menonjol. Ini mengindikasikan adanya berbagai keluhan pengguna terkait kendala teknis maupun operasional, seperti kesulitan login, aplikasi error, serta masalah kapasitas dan ketepatan jadwal. Jika dibandingkan, perbedaan kosakata yang dominan antara komentar positif dan negatif dapat memberikan gambaran menyeluruh mengenai aspek layanan yang perlu dipertahankan maupun yang perlu ditingkatkan.

Hasil tersebut menunjukkan bagaimana model klasifikasi memproses dan memahami opini pengguna secara efektif. Sebagai contoh, komentar “Dulu udah install ini dan uninstall... Sungguh, sebuah kecanggihan gimmick yang memper ruwet keadaan saja” berhasil diklasifikasikan sebagai negatif, yang mencerminkan ketidakpuasan pengguna terhadap perubahan kebijakan aplikasi. Kata-kata seperti “hapus,” “gimmick,” “memper”, dan “ruwet” turut memperkuat identifikasi sentimen tersebut. Sebaliknya, komentar “Dengan adanya aplikasi ini sangat menguntungkan... keliling kota Sby mengasyikkan dan murah meriah” diklasifikasikan sebagai positif, ditandai dengan kata-kata seperti “untung,” “asyik”, dan “murah”. Temuan ini memperlihatkan bahwa model tidak hanya mampu bekerja pada data yang telah diproses, tetapi juga memahami konteks opini dalam komentar asli secara akurat.

4. KESIMPULAN

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan performa algoritma Naive Bayes dan Regresi Logistik dalam mengklasifikasikan sentimen komentar pengguna terhadap aplikasi Gobis Suroboyo yang diambil dari Google Play Store. Berdasarkan hasil evaluasi, dapat disimpulkan bahwa algoritma Naive Bayes memiliki keunggulan dalam mengidentifikasi komentar dengan sentimen positif dengan nilai *precision* sebesar 81% dan *f1-score* sebesar 77%, sementara Regresi Logistik menunjukkan performa yang lebih seimbang untuk kedua kelas dengan *f1-score* sebesar 78% untuk sentimen positif dan 82% untuk sentimen negatif. Dari segi akurasi keseluruhan, kedua model memiliki perbedaan yang sangat tipis, yaitu 80.2% untuk Naive Bayes dan 79.8% untuk Regresi Logistik.

Analisis *confusion matrix* memperkuat temuan ini, di mana Naive Bayes lebih tepat dalam mengklasifikasikan komentar positif, sementara Regresi Logistik lebih tepat pada komentar negatif. Bukti klasifikasi pada komentar asli menunjukkan bahwa model mampu mengidentifikasi sentimen secara akurat dan memahami konteks opini pengguna, sehingga berdampak langsung pada kualitas interpretasi data. Visualisasi dalam bentuk *WordCloud* juga mengungkapkan bahwa kata-kata seperti “aplikasi”, “bus”, “bagus”, “halte”, dan “tolong” mendominasi komentar pengguna, mencerminkan fokus utama terhadap aspek teknis dan kualitas layanan transportasi. Penelitian ini memberikan kontribusi terhadap pengembangan sistem evaluasi layanan publik berbasis data ulasan, serta memberikan masukan yang berharga bagi pengembang aplikasi dan pemerintah daerah dalam meningkatkan layanan. Penelitian ini dapat dikembangkan lebih lanjut dengan menerapkan teknik *ensemble learning*, memperluas cakupan data, serta menambahkan klasifikasi multikategori sentimen atau analisis emosi untuk memperkaya interpretasi opini publik secara *real-time*.

REFERENSI

- [1] S. Rahayu, Y. MZ, J. E. Bororing, dan R. Hadiyat, “Implementasi Metode K-Nearest Neighbor (K-NN) untuk Analisis Sentimen Kepuasan Pengguna Aplikasi Teknologi Finansial FLIP,” *Edumatic: Jurnal Pendidikan Informatika*, vol. 6, no. 1, hlm. 98–106, Jun 2022, doi: 10.29408/edumatic.v6i1.5433.
- [2] D. Nugraha dan D. Gustian, “Analisis Sentimen Penggunaan Aplikasi Transportasi Online Pada Ulasan Google Play Store dengan Metode Naive Bayes Classifier,” 2024.
- [3] M. A. S. Nugroho, D. Susilo, dan D. Retnongsih, “ANALISIS SENTIMEN ULASAN APLIKASI “ACCESS BY KAI” MENGGUNAKAN ALGORITMA MACHINE LEARNING,” *Jurnal Teknik Informasi dan Komputer (Tekinkom)*, vol. 7, no. 2, hlm. 820, Des 2024, doi: 10.37600/tekinkom.v7i2.1854.

- [4] D. A. Nugroho, "Perbandingan Kinerja Algoritma Logistic Regression dan Naïve Bayes dalam Prediksi Penyakit Jantung," Laporan Skripsi, Fakultas Ilmu Komputer, Universitas Mercu Buana, Jakarta, 2023.
- [5] M. Khoirul, U. Hayati, dan O. Nurdian, "ANALISIS SENTIMEN APLIKASI BRIMO PADA ULASAN PENGGUNA DI GOOGLE PLAY MENGGUNAKAN ALGORITMA NAIVE BAYES," 2023.
- [6] O. Lock dan C. Pettit, "Social media as passive geo-participation in transportation planning—how effective are topic modeling & sentiment analysis in comparison with citizen surveys?," *Geo-Spatial Information Science*, vol. 23, no. 4, hlm. 275–292, 2020, doi: 10.1080/10095020.2020.1815596.
- [7] N. F. Hilmi dan F. Irwiansyah, "Analisis Sentimen Terhadap Aplikasi Tiktok Dari Ulasan Pada Google Playstore Menggunakan Metode Naïve Bayes," *SMATIKA JURNAL*, vol. 14, no. 01, hlm. 146–156, Jul 2024, doi: 10.32664/smatika.v14i01.1210.
- [8] W. Khofifah, D. N. Rahayu, dan A. M. Yusuf, "Analisis Sentimen Menggunakan Naive Bayes Untuk Melihat Review Masyarakat Terhadap Tempat Wisata Pantai Di Kabupaten Karawang Pada Ulasan Google Maps," *Jurnal Interkom: Jurnal Publikasi Ilmiah Bidang Teknologi Informasi dan Komunikasi*, vol. 16, no. 4, hlm. 28–38, Jan 2022, doi: 10.35969/interkom.v16i4.192.
- [9] A. Averina, H. Hadi, dan J. Siswantoro, "Analisis Sentimen Multi-Kelas Untuk Film Berbasis Teks Ulasan Menggunakan Model Regresi Logistik," *Teknika*, vol. 11, no. 2, hlm. 123–128, Jun 2022, doi: 10.34148/teknika.v11i2.461.
- [10] S. S. M. Wara, A. F. Adziima, M. Nasrudin and A. R. Pratama, "Predictive Analysis of Government Application Comment on Playstore with Clustered Support Vector Machine," *2024 IEEE 10th Information Technology International Seminar (ITIS)*, Surabaya, Indonesia, 2024, pp. 84–88, doi: 10.1109/ITIS64716.2024.10845453.
- [11] B. Ramadhani dan R. R. Suryono, "Komparasi Algoritma Naïve Bayes dan Logistic Regression Untuk Analisis Sentimen Metaverse," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 8, no. 2, hlm. 714, Apr 2024, doi: 10.30865/mib.v8i2.7458.
- [12] C. Zai dan A. Rahman Isnain, "Komparasi Algoritma Naïve Bayes dan Support Vector Machine (SVM) pada Analisis Sentimen Capcut," vol. 9, no. 1, hlm. 2024.
- [13] H. Parasian Doloksaribu dan Y. T. Samuel, "KOMPARASI ALGORITMA DATA MINING UNTUK ANALISIS SENTIMEN APLIKASI PEDULILINDUNGI," vol. 16, no. 1, 2022, doi: 10.47111/JTI.
- [14] Friska Aditia Indriyani, Ahmad Fauzi, dan Sutan Faisal, "Analisis sentimen aplikasi tiktok menggunakan algoritma naïve bayes dan support vector machine," *TEKNOSAINS: Jurnal Sains, Teknologi dan Informatika*, vol. 10, no. 2, hlm. 176–184, Jul 2023, doi: 10.37373/tekno.v10i2.419.
- [15] J. Homepage, N. C. Agustina, D. Herlina Citra, W. Purnama, C. Nisa, dan A. Rozi Kurnia, "MALCOM: Indonesian Journal of Machine Learning and Computer Science The Implementation of Naïve Bayes Algorithm for Sentiment Analysis of Shopee Reviews on Google Play Store Implementasi Algoritma Naive Bayes untuk Analisis Sentimen Ulasan Shopee pada Google Play Store," vol. 2, hlm. 47–54, 2022.