



# Journal of Data Mining and Information Systems

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

DOI Prefix: 10.54259/jdmis.v4i1

Vol. 4, No. 1, February 2026

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](mailto:jurnal.jdmis@gmail.com)**



# Journal of Data Mining and Information Systems

<https://journal.yp3a.org/index.php/JDMIS>  
DOI Prefix: 10.54259/jdmis.v4i1  
Vol. 4, No. 1, February 2026

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

## Volume 4 Nomor 1 (February 2026)

Analisis Sentimen Ulasan Aplikasi Maxim Merchant dengan Support Vector Machine (SVM) dan Random Forest

***Selly Rizkiyah, Indira Zein Rizqin, Milla Akbarany Baktiar Putri, Shindi Shella May Wara, Kartika Maulida Hindrayani***

Klasifikasi Sentimen Ulasan Pengguna Aplikasi Qpon dengan Support Vector Machine dan Logistic Regression

***Iin Febyanti, Arsinta Safira Devi, Salsabila Wardah, Shindy Shella May Wara, Aviolla Terza Damaliana***

Developing Business Intelligence Dashboard for Sales KPI Monitoring in Advertising Agency: A Human-Centered Design Approach

***Ince Ahmad Zarqan, Dimas Yudistira Nugraha, Ganda Tua Sitompul, Adli Abdillah Nababan***

Implementasi Algoritma K-Means Dengan Normalisasi Min-Max Pada Analisis Data Ketidaktersekolahan Anak

***Elsahday Tambunan, Yuni Br Limbeng, Sardo Sipayung***

Penerapan Normalisasi Data pada Angkatan Kerja Indonesia Bulan Februari 2025 Berdasarkan Kelompok Umur

***Anastasya Jesica Sidauruk, Juan Sebastian Sirait, Sardo Sipayung***

Prediksi Diabetes Berbasis Decision Tree Dengan Menggunakan Dataset Pima Indians Diabetes

***Yustri Insani, Marcel Filemon Naibaho, Sardo Pardingotan Sipayung***

Klasifikasi Gempa Bumi Menggunakan Algoritma Decision Tree Berbasis Data BMKG

***Dessianna Natalia Sembiring, Beata Berlina Halawa, Sardo P Sipayung***

Analisis Kualitas Layanan Terhadap Loyalty Behavior ada Aplikasi SRIBU Menggunakan Metode E-Servqual

***Faiz Rizki Saputra, Bayu Waspodo, Evy Nurmiati***



**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](mailto:jurnal.jdmis@gmail.com)**

## **JDMIS (Journal of Data Mining and Information Systems)**

### **Vol. 4 No. 1 (February 2026)**

#### **EDITOR IN CHIEF**

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

## JDMIS (Journal of Data Mining and Information Systems)

### Vol. 4 No. 1 (February 2026)

#### Daftar Isi

Analisis Sentimen Ulasan Aplikasi Maxim Merchant dengan Support Vector Machine (SVM) dan Random Forest

*Selly Rizkiyah, Indira Zein Rizqin, Milla Akbarany Baktiar Putri, Shindi Shella May Wara, Kartika Maulida Hindrayani*.....1-9

Klasifikasi Sentimen Ulasan Pengguna Aplikasi Qpon dengan Support Vector Machine dan Logistic Regression

*In Febyanti, Arsinta Safira Devi, Salsabila Wardah, Shindy Shella May Wara, Aviolla Terza Damaliana*.....10-18

Developing Business Intelligence Dashboard for Sales KPI Monitoring in Advertising Agency: A Human-Centered Design Approach

*Ince Ahmad Zarqan, Dimas Yudistira Nugraha, Ganda Tua Sitompul, Adli Abdillah Nababan*.....19-25

Implementasi Algoritma K-Means Dengan Normalisasi Min-Max Pada Analisis Data Ketidakbersekolahan Anak

*Elsahday Tambunan, Yuni Br Limbeng, Sardo Sipayung*.....26-32

Penerapan Normalisasi Data pada Angkatan Kerja Indonesia Bulan Februari 2025 Berdasarkan Kelompok Umur

*Anastasya Jesica Sidauruk, Juan Sebastian Sirait, Sardo Sipayung*.....33-39

Prediksi Diabetes Berbasis Decision Tree Dengan Menggunakan Dataset Pima Indians Diabetes

*Yustri Insani, Marcel Filemon Naibaho, Sardo Pardingotan Sipayung*.....40-45

Klasifikasi Gempa Bumi Menggunakan Algoritma Decision Tree Berbasis Data BMKG

*Dessianna Natalia Sembiring, Beata Berlina Halawa, Sardo P Sipayung*.....46-52

Analisis Kualitas Layanan Terhadap Loyalty Behavior ada Aplikasi SRIBU Menggunakan Metode E-Servqual

*Faiz Rizki Saputra, Bayu Waspodo, Evy Nurmiati*.....53-62

# Analisis Sentimen Ulasan Aplikasi Maxim Merchant dengan Support Vector Machine (SVM) dan Random Forest

Selly Rizkiyah<sup>1</sup>, Indira Zein Rizqin<sup>2</sup>, Milla Akbarany Baktiar Putri<sup>3</sup>, Shindi Shella May Wara<sup>4</sup>, Kartika Maulida Hindrayani<sup>5</sup>

<sup>1,2,3,4,5</sup>Program Studi Sains Data, Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

Email: <sup>1</sup>23083010010@student.upnjatim.ac.id, <sup>2</sup>23083010015@student.upnjatim.ac.id, <sup>3</sup>23083010021@student.upnjatim.ac.id,

<sup>4</sup>shindi.shella.fasilkom@upnjatim.ac.id, <sup>5</sup>kartika.maulida.ds@upnjatim.ac.id

## ABSTRAK

Perkembangan teknologi digital, khususnya perangkat *mobile*, telah mendorong peningkatan layanan berbasis aplikasi. Salah satu aspek penting dalam pengembangan aplikasi adalah memahami persepsi dan kepuasan pengguna secara mendalam. Penelitian ini bertujuan untuk menganalisis sentimen pengguna terhadap aplikasi Maxim Merchant berdasarkan ulasan yang diperoleh dari platform Google Play Store. Sebanyak lebih dari 2200 ulasan berbahasa Indonesia dikumpulkan menggunakan teknik web *scrapping*. Data ulasan diproses melalui tahapan pra-pemrosesan seperti pembersihan teks, normalisasi, tokenisasi, penghapusan kata tidak penting, dan stemming. Sentimen dikategorikan menjadi positif dan negatif berdasarkan skor ulasan, di mana skor 1 hingga 3 dianggap negatif, dan skor 4 dan 5 dianggap positif. Visualisasi word cloud digunakan untuk menunjukkan kata-kata dominan dari masing-masing kategori sentimen. Data kemudian dikonversi menjadi bentuk numerik menggunakan TF-IDF dan diseleksi menggunakan metode Chi-Square. Klasifikasi dilakukan dengan algoritma Support Vector Machine dan Random Forest. Hasil evaluasi menunjukkan bahwa algoritma Support Vector Machine memberikan performa lebih baik dalam mengklasifikasikan sentimen, terutama dalam menangani data teks berdimensi tinggi.

**Kata Kunci:** Analisis Sentimen, Maxim Merchant, *Support Vector Machine*, *Random Forest*

## ABSTRACT

The development of digital technology, especially mobile devices, has led to an increase in application-based services. One important aspect in app development is to deeply understand user perception and satisfaction. This study aims to analyze user sentiment towards the Maxim Merchant application based on reviews obtained from the Google Play Store platform. A total of more than 2200 Indonesian-language reviews were collected using web scraping techniques. The review data was processed through pre-processing stages such as text cleaning, normalization, tokenization, removal of unimportant words, and stemming. Sentiments are categorized into positive and negative based on the review score, where scores of 1 to 3 are considered negative, and scores of 4 and 5 are considered positive. Word cloud visualization is used to show the dominant words of each sentiment category. The data is then converted into numerical form using TF-IDF and selected using the Chi-Square method. Classification was performed using Support Vector Machine and Random Forest algorithms. The evaluation results show that the Support Vector Machine algorithm performs better in classifying sentiment, especially in handling high-dimensional text data.

**Keywords:** Sentiment Analysis, Maxim Merchant, *Support Vector Machine*, *Random Forest*

## Penulis Korespondensi:

Selly Rizkiyah

Email: 23083010010@student.upnjatim.ac.id

## Article Info

Diterima: 13 Juni 2025

Direvisi: 16 Juni 2025

Disetujui: 19 Juni 2025

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



## 1. PENDAHULUAN

Perkembangan teknologi digital dan pesatnya adopsi perangkat *mobile* telah mendorong pertumbuhan berbagai layanan berbasis aplikasi. Salah satu layanan tersebut adalah *Maxim Merchant*, sebuah aplikasi yang digunakan oleh mitra merchant untuk mengelola pemesanan, transaksi, serta aktivitas operasional lainnya dalam ekosistem layanan *Maxim*. Dengan meningkatnya jumlah pengguna dan kompleksitas fitur yang ditawarkan, penting bagi pengembang untuk terus mengevaluasi dan memahami pengalaman serta kepuasan pengguna dalam menggunakan aplikasi ini.

Salah satu cara untuk memahami persepsi pengguna adalah dengan menganalisis ulasan (*review*) yang diberikan melalui platform *Google Play Store*. Ulasan tersebut seringkali mencerminkan opini jujur pengguna terkait performa aplikasi, kemudahan penggunaan, serta kendala yang mereka alami. Namun, karena sifat data yang tidak terstruktur dan jumlahnya yang besar, analisis manual menjadi tidak efisien dan kurang objektif. Oleh karena itu, pendekatan otomatis melalui teknik *data mining*, khususnya analisis sentimen, menjadi solusi yang relevan untuk mengolah dan menginterpretasi data ulasan secara sistematis [1].

Analisis sentimen bertujuan untuk mengklasifikasikan opini pengguna ke dalam kategori positif atau negatif [2]. Dalam penelitian ini, dilakukan klasifikasi sentimen pada ulasan aplikasi *Maxim Merchant* menggunakan dua algoritma machine learning yang umum digunakan, yaitu *Support Vector Machine (SVM)* dan *Random Forest (RF)*. Pemilihan kedua algoritma ini didasarkan pada efektivitasnya dalam penelitian-penelitian sebelumnya. Penelitian sebelumnya oleh [3] menunjukkan bahwa algoritma *Support Vector Machine (SVM)* dengan kernel linear memberikan performa yang sangat baik dalam klasifikasi sentimen pada data teks, dengan akurasi mencapai 91%. Penelitian tersebut juga menemukan bahwa mayoritas ulasan pengguna memiliki sentimen negatif. Hal ini memperkuat alasan penggunaan *SVM* dalam penelitian ini yaitu kemampuannya menangani data berdimensi tinggi serta klasifikasi pada data teks yang tidak linear. Di lain sisi, algoritma *Random Forest* dalam analisis sentimen, algoritma ini tidak hanya menunjukkan performa yang baik dalam klasifikasi, tetapi juga dinilai praktis untuk diimplementasikan dalam konteks nyata [4]. Penelitian tersebut mengulas secara menyeluruh proses analisis sentimen, mulai dari pengumpulan data hingga pengujian akurasi, serta menekankan efektivitas *Random Forest* dalam membantu meningkatkan pengalaman pengguna aplikasi

Sebelum proses klasifikasi, dilakukan beberapa tahapan preprocessing seperti pembersihan teks, penghapusan ulasan yang tidak relevan, transformasi teks menjadi fitur numerik menggunakan metode *TF-IDF*, serta visualisasi kata menggunakan *wordcloud* untuk memahami konteks isi ulasan. Selanjutnya label sentimen ditentukan berdasarkan rating bintang yang diberikan oleh pengguna, di mana rating rendah diasumsikan sebagai ulasan negatif dan rating tinggi sebagai ulasan positif. Selanjutnya, hasil klasifikasi dievaluasi menggunakan metrik performa seperti akurasi dan *F1-score* untuk mengetahui efektivitas model dalam membedakan jenis sentimen.

Penelitian ini tidak hanya bertujuan untuk mengevaluasi performa model *SVM* dan *Random Forest* dalam konteks analisis sentimen, tetapi juga untuk memberikan gambaran umum mengenai persepsi pengguna terhadap aplikasi *Maxim Merchant*. Dengan memahami pola sentimen pengguna, pengembang dapat memperoleh insight yang berguna untuk meningkatkan kualitas layanan dan fitur aplikasi di masa mendatang.

## 2. METODE PENELITIAN

### 2.1 Teknik Pengambilan Data

Data dalam penelitian ini didapat melalui proses *web scrapping* untuk mengambil ulasan aplikasi *Maxim Merchant* pada platform *Google Play Store*. Penelitian ini mengumpulkan lebih dari 2200 ulasan berbahasa Indonesia, terhitung dari tahun 2021 sampai tanggal 31 Mei 2025. Pengambilan data dilakukan dengan memanfaatkan tautan aplikasi pada *Google Play Store* untuk selanjutnya dilakukan proses scrapping dengan pustaka *google\_play\_scraper* pada *Python*. Proses pengambilan data ini dapat mengambil dan memecah data menjadi bagian-bagian seperti ulasan, skor, versi aplikasi, dan lain sebagainya. Data yang telah di-*scrapping* akan disimpan dalam bentuk *CSV* untuk analisis selanjutnya.

### 2.2 Pre-Processing Data

Data hasil *scrapping* yang akan dianalisis meliputi content atau isi ulasan dan skor atau jumlah rating yang diberikan oleh pengguna. Proses selanjutnya adalah pre-processing data, setelah didapat ulasan berbentuk *CSV* sebelumnya. Pada tahap ini, penelitian memanfaatkan *library* pada *Python* seperti *NLTK* yang berguna untuk pemrosesan bahasa dan *Sastrawi* yang digunakan untuk memproses teks dalam bahasa Indonesia. Tujuan *pre-processing* adalah untuk menghilangkan data yang tidak diperlukan sehingga menghasilkan dokumen yang lebih rinci dan terstruktur, serta menyiapkan data agar siap untuk proses selanjutnya [5]. Proses ini adalah proses yang vital, dimana dalam proses ini akan dilakukan tahap inti pembersihan dan seleksi data mentah ke dalam data yang siap untuk dianalisis.

Dalam penelitian ini, *pre-processing* dilakukan dalam enam tahapan, yaitu sebagai berikut, 1) *Cleaning*, dilakukan penghapusan nilai kosong, terduplikasi, tidak relevan, angka, tanda koma, spasi berlebih, emoji hingga tautan, dan lainnya yang ada pada teks ulasan. 2) *Casefolding*, pada proses ini, teks yang mengandung huruf kapital diubah menjadi huruf kecil. Tujuan dari proses ini adalah untuk membuat berkas teks tanpa perbedaan antara huruf kapital dan huruf kecil [6]. Ini berguna untuk menjaga konsistensi bentuk teks tanpa variasi berlebih. 3) *Fixing Words*, berfungsi memperbaiki, membersihkan dan menormalkan data teks yang terdapat penggunaan bahasa sehari-hari, singkatan, atau bahasa gaul hingga kesalahan tulis (*typo*)

ke dalam bahasa atau penulisan yang sesuai dengan kaidah Bahasa Indonesia. Jika kata-kata mentah tersebut tetap diproses, analisis yang dihasilkan akan menjadi tidak akurat [7].

Langkah selanjutnya, 4) *Tokenizing*, proses dimana dilakukan pemecahan pada teks kalimat menjadi satuan kata-kata yang lebih kecil. Proses ini bekerja dengan cara memecah kata dengan memisahkannya dari adanya tanda baca dan spasi yang ada. Proses ini dapat digunakan untuk menghitung frekuensi kata yang muncul dalam dokumen [8]. 5) *Filtering Stopwords*, dilakukan pembersihan pada teks dari kata-kata yang tidak bermakna dalam analisis, yaitu kata yang tidak memiliki arti atau yang tidak dapat dikelompokkan ke dalam sentimen positif atau negatif. Kata-kata tersebut seperti kata ganti orang, kata seruan, kata penghubung, dan kata lainnya yang tidak memiliki pengaruh dalam proses penentuan klasifikasi [9]. 6) *Stemming*, dilakukan dengan mengembalikan kata ke dalam kata dasarnya. Ini dilakukan dengan menghapus imbuhan seperti awalan, akhiran, sisipan dan sebagainya.

### 2.3 Pelabelan Sentimen

Setelah data selesai melalui tahap *pre-processing*, tahap selanjutnya adalah memberikan label sentimen positif dan negatif pada teks ulasan. Label sentimen positif dan negatif di sini didasarkan pada *rating* atau skor. Karena dalam *platform Google Play Store*, *rating* ulasan maksimal adalah bintang 5. Maka, untuk *rating* bintang 1, 2 dan 3 akan diberi label negatif, sementara *rating* 4 dan 5 diberikan *rating* positif. Pemberian label sentimen ini bertujuan untuk mengidentifikasi pola kalimat atau teks yang ada pada setiap label. Selain itu, dengan memanfaatkan label ini, dapat dibentuk *wordcloud* kata, yang dapat memberikan sorotan atau ringkasan sekilas pada kata-kata penting yang benar-benar mencerminkan isi ulasan dari setiap label sentimen.

### 2.4 Seleksi Fitur dengan TF-IDF

Penelitian ini menggunakan proses pembobotan kata pada dokumen menggunakan metode *Term Frequency Inverse Document Frequency (TF-IDF)* dilakukan dengan menghitung bobot setiap kata dan memberikan skor untuk menunjukkan keunikan kata [10]. Kata-kata yang terlalu sering muncul seperti kata hubung atau kata umum lainnya akan mendapatkan bobot rendah karena dianggap kurang informatif. Sebaliknya, kata-kata yang cukup sering muncul namun spesifik terhadap konteks tertentu akan mendapat bobot lebih tinggi. Dalam proses ini, *TF-IDF* dilakukan dengan hanya mempertahankan kata-kata yang muncul di minimal 10 dokumen, untuk menghilangkan kata yang terlalu langka dan tidak representatif. Dan *max\_features=2000*, yaitu hanya mempertahankan maksimal 2000 kata dengan bobot *TF-IDF* tertinggi, guna menyederhanakan kompleksitas fitur dan menjaga relevansi informasi. Hasil transformasi ini menghasilkan matriks numerik berdimensi dokumen x kata, yang digunakan sebagai input dalam tahap seleksi fitur dan pemodelan. Dalam penelitian ini, digunakan metode *Chi-Squared ( $\chi^2$ )* untuk menilai fitur. *Chi-Square* merupakan salah satu metode untuk penyeleksian fitur yang menggunakan teori statistika untuk menguji independensi sebuah term dengan kategorinya [11]. Kata-kata dengan skor *chi-squared* tertinggi dianggap lebih penting bagi model prediksi. Perlu digarisbawahi bahwa TF-IDF dengan *max\_features=2000* berfokus pada pemilihan kata berdasarkan nilai bobot yang mencerminkan frekuensi relatif dan keunikan kata antar dokumen, sedangkan seleksi *chi-squared* menekankan pada hubungan statistik antara kata dan label. Oleh karena itu, ketika hasil TF-IDF menghasilkan kurang dari 2000 fitur, seperti dalam penelitian ini, metode *chi-squared* hanya melakukan penilaian relevansi tanpa pengurangan fitur lebih lanjut.

### 2.5 Pemodelan dengan SVM dan Random Forest

Dalam penelitian ini, pemodelan dilakukan dengan algoritma machine learning, yaitu, *supervised learning* yang digunakan dalam penelitian ini adalah *SVM* dan *Random Forest*. *Support Vector Machine (SVM)* sendiri adalah proses klasifikasi yang memisahkan label positif dan label negatif menggunakan *hyper-plane* atau garis pemisah. Secara umum, garis pemisah yang memiliki jarak terbesar ke titik data pelatihan terdekat dari setiap kelas akan memiliki akurasi yang lebih tinggi daripada garis pemisah lainnya [12]. *Support Vector Machine (SVM)* adalah algoritma yang cepat dan efektif algoritma yang cepat dan efektif dalam masalah klasifikasi teks [13]. Dalam hal ini, SVM menggunakan kerner linear sebagai parameter utama, yang artinya memisahkan data klasifikasi dengan garis linear. Sementara itu, *Random Forest* adalah salah satu metode dalam klasifikasi yang merupakan pengembangan dari *decision tree* di mana setiap *decision tree* telah dilakukan proses pelatihan dengan menggunakan sampel individu [14]. Model ini bekerja dengan membuat sejumlah pohon keputusan dan menghitung nilai *entropy* dan *information gain* selama fase pelatihan dan menggabungkan hasil prediksi dari masing-masing pohon untuk menetapkan output akhir melalui keputusan suara terbanyak. Pendekatan *entropy* sebagai penentu ketidakmurnian atribut dan *information gain* merupakan nilai perolehan informasi dalam memilah simpul. Dalam penelitian ini, tidak ada penentuan parameter trees yang digunakan. Setelahnya, data akan dibagi menjadi data latih dan data uji dengan rasio 80:20 secara acak.

### 2.6 Evaluasi Model SVM dan Random Forest

Setelah melakukan pemodelan dengan *SVM* dan *Random Forest*, tahap selanjutnya adalah evaluasi hasil pemodelan. Digunakan *confusion matrix* untuk memvisualisasikan performa prediksi model terhadap label aktual. *Confusion matrix* divisualisasikan dalam bentuk *heatmap*, yang terdiri atas nilai *True-Positive (TP)*, *True-Negative (TN)*, *False-Positive (FP)*, dan *False-Negative (FN)*. Data dikatakan sebagai *true positive* apabila data tersebut positif dan diprediksi juga positif, namun apabila data tersebut diprediksi negatif, maka dapat dikatakan sebagai *false negative*, lalu data dikatakan *true negative* apabila data tersebut negatif dan diprediksi juga negatif, namun apabila data tersebut diprediksi positif, maka data tersebut dapat dikatakan sebagai *false positive* [9]. Ini dapat membantu dalam memahami pola kesalahan yang terjadi. Selain itu, evaluasi model dilakukan dengan menggunakan matriks klasifikasi, yaitu *classification\_report*, yang mencakup *precision*, yaitu perbandingan antara *True*

*Positive (TP)* dengan banyaknya data yang diprediksi positif. Kemudian *recall*, perbandingan antara *True Positive (TP)* dengan banyaknya data yang sebenarnya positif. *F1-score* sendiri adalah rata-rata dari nilai *precision* dan *recall*. dan akurasi adalah seberapa banyak prediksi yang benar dari semua prediksi yang dibuat oleh model. Seluruh evaluasi ini digunakan untuk mengukur sejauh mana model mampu mengklasifikasikan label sentimen dengan akurat.

### 3. HASIL DAN PEMBAHASAN

Pada bagian ini dijelaskan hasil-hasil penelitian dan sekaligus diberikan pembahasan yang komprehensif. Hasil dapat disajikan dalam bentuk gambar, grafik, tabel dan lain-lain yang memudahkan pembaca. Pembahasan dapat dilakukan dalam beberapa sub-bab.

#### a. Web Scrapping

Data diperoleh melalui proses *web scrapping* dari ulasan pengguna aplikasi *Maxim Merchant* yang tersedia di *Google Play Store*. Proses ini dilakukan menggunakan pustaka *google-play-scrapers*, yang mampu mengambil semua ulasan pengguna berdasarkan ID aplikasi secara efisien. Data *scrapping* ini dikonversi ke dalam format *DataFrame* dan disimpan dalam bentuk *CSV*. Total data ulasan yang terkumpul adalah sebanyak 2282 entri.

#### b. Pra-pemrosesan Teks Ulasan

Tabel 1. Hasil Pra-pemrosesan Teks Ulasan

No	Content	Text No Emoji	Text Clean	Case Folding	Normalisasi Kata	Tokenisasi	Stopword Removal	Stemming	Teks Akhir
1	Tolong di upgrade lg aplikasi ini. sangat tidak efisien, sdah klik, lama.	Tolong di upgrade lg aplikasi ini. sangat tidak efisien, sdah klik, lama.	tolong di upgrade lg aplikasi inisangat tidak efisien sdah klik lama	tolong di upgrade lg aplikasi inisangat tidak efisien sdah klik lama	tolong di upgrade lagi aplikasi inisangat tidak efisien sudah klik lama	['tolong', 'di', 'upgrade', 'lagi', 'aplikasi', 'inisangat', 'tidak', 'efisien', 'sudah', 'klik', 'lama']	['tolong', 'upgrade', 'aplikasi', 'inisangat', 'efisien', 'klik', 'lama']	tolong upgrade aplikasi inisangat efisiensdh klik lama	tolong upgrade aplikasi inisangat efisiensdh klik lama
2	Perbaiki peraturan atau system Maxim food, kebanyakan driver di non aktifkan secara sepihak.	Perbaiki peraturan atau system Maxim food, kebanyakan driver di non aktifkan secara sepihak.	Perbaiki peraturan atau system Maxim foodkebanyakan driver di non aktifkan secara sepihak	perbaiki peraturan atau system maxim foodkebanyak an driver di non aktifkan secara sepihak	perbaiki peraturan atau system maxim foodkebanyak an driver di non aktifkan secara sepihak	['perbaiki', 'peraturan', 'atau', 'system', 'maxim', 'foodkebanyakan', 'driver', 'di', 'non', 'aktifkan', 'secara', 'sepihak']	['perbaiki', 'peraturan', 'system', 'maxim', 'foodkebanyakan', 'driver', 'non', 'aktifkan', 'sepihak']	baik atur system maxim foodkebanyakan driver non aktif sepihak	baik atur system maxim foodkebanyakan driver non aktif sepihak
3	Proses pendaftaran mmg cepat, stlh di acc oleh admin tidak ada pemberitahuan via WA.	Proses pendaftaran mmg cepat, stlh di acc oleh admin tidak ada pemberitahuan via WA.	Proses pendaftaran mmg cepat stlh di acc oleh admin tidak ada pemberitahuan via WA	proses pendaftaran mmg cepat stlh di acc oleh admin tidak ada pemberitahuan via wa	proses pendaftaran mmg cepat setelah di acc oleh admin tidak ada pemberitahuan via wa	['proses', 'pendaftaran', 'memang', 'cepat', 'setelah', 'di', 'acc', 'oleh', 'admin', 'tidak', 'ada', 'pemberitahuan', 'via', 'wa']	['proses', 'pendaftaran', 'cepat', 'acc', 'admin', 'pemberitahuan', 'wa']	proses daftar cepat acc admin pemberitahuan wa	proses daftar cepat acc admin pemberitahuan wa
...	...	...	...	...	...	...	...	...	...
22	sangat puas	sangat puas	sangat puas	sangat puas	sangat puas	['sangat', 'puas']	['puas']	puas	puas

Berdasarkan Tabel 1. adalah penghapusan emoji dan simbol non-teks. Emoji tidak mengandung informasi linguistik yang dapat diproses oleh model analisis teks berbasis Bahasa Indonesia. Selanjutnya, teks dibersihkan dari elemen-elemen seperti *mention (@user)*, *hashtag (#tag)*, tautan, angka, karakter khusus, dan spasi berlebih. Teks kemudian diubah seluruhnya menjadi huruf kecil (*case folding*) agar tidak terjadi duplikasi kata akibat perbedaan kapitalisasi. Proses normalisasi kosakata informal juga dilakukan menggunakan daftar kamus sederhana untuk mengubah kata tidak baku ke bentuk bakunya, seperti “mmg” menjadi “memang”, atau “tp” menjadi “tapi”. Pada tahap tokenisasi yaitu memecah kalimat menjadi kata-kata individual. Setelah itu dilakukan penghapusan *stopword*, yaitu kata-kata umum seperti “dan”, “yang”, atau “itu” yang tidak memberikan makna penting dalam analisis sentimen. Penghapusan ini dilakukan menggunakan daftar *stopwords* Bahasa Indonesia dan Inggris, ditambah beberapa tambahan dari kosakata informal khas media sosial.

Tabel 2. Distribusi Sentimen

Label_kalimat	count
Negatif	1229
Positif	805

Berdasarkan Tabel 2. terdapat 1.229 kategori negatif dan 805 kategori positif. Menunjukkan bahwa data ulasan yang digunakan cenderung didominasi oleh sentimen negatif. Distribusi data label juga diketahui tidak seimbang.




Gambar 1. WordCloud Sentimen Positif

Pada Gambar 1. menyajikan *wordcloud* dari kata-kata yang paling dominan dan khas dalam ulasan positif pelanggan. *wordcloud* ini dibuat berdasarkan rasio kemunculan kata dalam ulasan positif daripada negatif, sehingga menampilkan kata-kata yang secara unik mencerminkan pengalaman pelanggan yang memuaskan. Kata-kata seperti "semoga", "membantu", "mantap", "bagus", dan "mudah" mendominasi visualisasi, yang mencerminkan dukungan, harapan positif, dan kepuasan terhadap layanan. Kehadiran kata-kata seperti "sukses", "good", "alhamdulillah", dan "terimakasih" menunjukkan respons emosional yang positif dan bahkan spiritual dari sebagian pengguna. Selain itu, munculnya kata seperti "maju", "resto", dan "pelanggan" juga mengindikasikan bahwa sebagian pelanggan menghargai peran sosial aplikasi dalam mendukung usaha kecil atau merchant yang ada.



Gambar 2. WordCloud Sentimen Negatif

Pada Gambar 2, menampilkan *wordcloud* dari kata-kata yang paling dominan dan khas dalam ulasan negatif pelanggan. Visualisasi ini didasarkan pada analisis rasio frekuensi, yang membandingkan kemunculan kata dalam ulasan negatif terhadap ulasan positif. Kata-kata seperti "orderan", "driver", "masuk", "notifikasi", "daftar", dan "ambil" muncul dalam ukuran besar, menunjukkan bahwa isu-isu tersebut merupakan keluhan utama pengguna. Secara umum, kata-kata ini dapat menunjukkan masalah fungsionalitas sistem, seperti kendala saat login, proses pendaftaran, notifikasi yang tidak muncul, atau pengambilan order oleh driver. Selain itu, kata-kata seperti "error", "fiktif", "batalin", dan "tutup" mengindikasikan adanya gangguan teknis, bug aplikasi, atau pengalaman pengguna yang buruk. Beberapa kata emosional seperti "kecewa", "rugi", dan "jelek" juga muncul, menandakan respons emosional pengguna terhadap pengalaman negatif tersebut.



Gambar 3. Diagram 20 Data yang Paling Sering Muncul dalam Ulasan

Gambar 3. adalah visualisasi yang menampilkan 20 kata yang paling sering muncul dalam ulasan pengguna aplikasi *Maxim Merchant*. Kata-kata seperti "order", "aplikasi", "driver", dan "masuk" menjadi yang paling dominan, yang mencerminkan fokus utama perhatian dan pengalaman pengguna terhadap layanan aplikasi tersebut. Dominasi kata-kata ini mengindikasikan bahwa pengguna banyak membahas mengenai proses pemesanan, kualitas aplikasi, interaksi dengan pengemudi, serta kendala teknis seperti kesulitan saat login.

Selain itu, kemunculan kata-kata seperti "daftar", "notifikasi", "tolong", dan "login" mengisyaratkan adanya kebutuhan pengguna akan bantuan atau keluhan terhadap aspek fungsionalitas dan teknis dari aplikasi. Di sisi lain, meskipun lebih sedikit, kata-kata bernuansa positif seperti "mantap", "baik", dan "mudah" juga muncul, yang menunjukkan bahwa sebagian pengguna memiliki pengalaman yang menyenangkan saat menggunakan layanan ini. Beberapa kata seperti "aplikasi" muncul dalam kedua jenis sentimen dengan frekuensi tinggi, yang menunjukkan bahwa kata tersebut bersifat netral dan digunakan secara umum tanpa merepresentasikan sentimen tertentu. Dengan demikian, analisis frekuensi kata tidak hanya membantu mengidentifikasi kata yang paling sering digunakan, tetapi juga memberikan wawasan lebih dalam mengenai persepsi dan pengalaman pengguna berdasarkan konteks sentimen mereka. Seperti pada penelitian sebelumnya yang menyimpulkan bahwa frekuensi kata yang muncul dalam komentar menjadi dasar untuk memahami opini pengguna secara sistematis [15].

Tabel 3. Kata-Kata Dominan dalam Ulasan Negatif Berdasarkan Rasio Frekuensi

Kata	Frekuensi Negatif	Frekuensi Positif	Rasio Negatif
orderan	506	97	5.16
driver	444	81	5.41
masuk	324	56	5.68
ambil	144	16	8.47
notifikasi	143	24	5.72

Berdasarkan Tabel 3. menampilkan kata-kata yang memiliki rasio dominansi tinggi dalam ulasan negatif. Kata seperti "orderan", "driver", dan "masuk" muncul jauh lebih sering dalam ulasan negatif dibandingkan positif. Hal ini mengindikasikan bahwa kata-kata tersebut berkaitan erat dengan keluhan pengguna, terutama mengenai proses pemesanan, akses aplikasi, dan kendala dalam penggunaan layanan. Kata-kata seperti "gagal", "susah", dan "login" bahkan memiliki rasio di atas 8, menunjukkan bahwa aspek teknis dan fungsional aplikasi menjadi sorotan utama dari sisi negatif.

Tabel 4. Kata-Kata Dominan dalam Ulasan Positif Berdasarkan Rasio Frekuensi

Kata	Frekuensi Negatif	Frekuensi Positif	Rasio Positif
mantap	0	38	38.00
alhamdulillah	0	18	18.00
semoga	14	97	6.47
ok	2	19	6.33
masyarakat	0	6	6.00

Berdasarkan Tabel 4. menyajikan kata-kata yang memiliki rasio dominansi tinggi dalam ulasan positif. Kata-kata seperti "mantap", "alhamdulillah", dan "semoga" mendominasi komentar positif dari pengguna. Ini menunjukkan bahwa pengguna tidak

hanya puas terhadap layanan, tetapi juga menyampaikan apresiasi dalam bentuk ekspresi emosional dan religius seperti "aamiin", "berkah", dan "alhamdulillah". Selain itu, kata-kata seperti "bantu", "bermanfaat", dan "umkm" menunjukkan bahwa pengguna merasa bahwa aplikasi memberikan dampak sosial positif, khususnya dalam mendukung usaha mikro dan kecil.

Tabel 5. Top 10 Kata dengan Skor TF-IDF Tertinggi

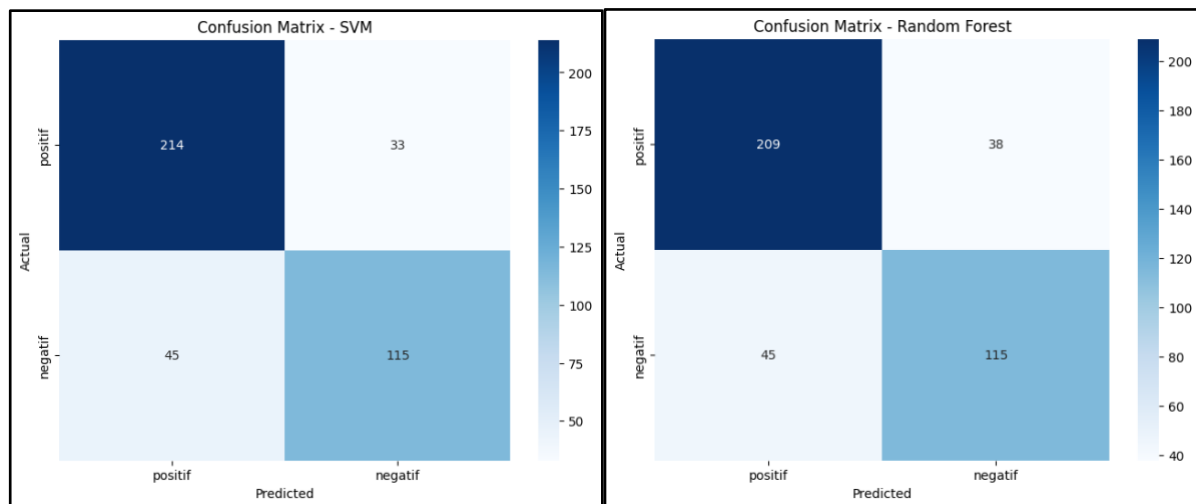
No.	Kata
1	order
2	aplikasi
3	driver
4	masuk
5	maxim
6	daftar
7	bantu
8	bagus
9	pesan
10	tolong

Tabel 5. Menunjukkan 10 kata teratas dengan skor *TF-IDF* tertinggi di seluruh korpus ulasan pengguna aplikasi *Maxim Merchant*. Hasil proses *TF-IDF* berhasil mendapat total 269 kata unik yang memenuhi kriteria frekuensi minimum. Namun, karena hanya terdapat 269 fitur awal yang memenuhi syarat, maka seluruhnya dapat digunakan untuk proses seleksi, tanpa pengurangan lebih lanjut. Kata "order", "aplikasi", dan "driver" muncul sebagai yang paling menonjol, yang menunjukkan bahwa kata-kata ini sangat sering muncul dan dianggap penting dalam mengungkapkan konteks ulasan, baik positif maupun negatif. Kata-kata seperti "tolong", cenderung mengindikasikan masalah atau permintaan, sedangkan kata seperti "bagus", lebih mengarah pada pengalaman positif.

Tabel 6. Hasil Evaluasi Model *SVM* dan *Random Forest*

Evaluasi	Label Sentimen	Accuracy	Precision	Recall	F1-Score
<b>SVM</b>	Negatif (0)	0.81	0.83	0.87	0.85
	Positif (1)		0.78	0.72	0.75
<b>Random Forest</b>	Negatif (0)	0.80	0.82	0.85	0.83
	Positif (1)		0.75	0.72	0.73

Berdasarkan Tabel 6. Model *SVM* memperoleh nilai akurasi sebesar 0.81, sedikit lebih tinggi dibandingkan model *Random Forest* yang memiliki akurasi sebesar 0.80. Ini menunjukkan bahwa secara keseluruhan, *SVM* sedikit lebih andal dalam memprediksi kelas sentimen dengan benar. Untuk metrik *precision*, yang mengukur ketepatan prediksi positif, *SVM* menunjukkan performa yang lebih baik pada kedua label sentimen. Pada kelas negatif, *precision SVM* sebesar 0.83, sedangkan *Random Forest* sebesar 0.82. Begitu juga pada kelas positif, *SVM* meraih *precision* 0.78, lebih tinggi dibandingkan *Random Forest* yang hanya memperoleh 0.75. Sementara itu, pada metrik *recall*, yang menilai kemampuan model dalam mendeteksi semua data yang termasuk ke dalam suatu kelas, *SVM* menunjukkan nilai yang cukup tinggi pada kelas negatif (0.87), dibandingkan *Random Forest* (0.85). Untuk kelas positif, kedua model memiliki nilai *recall* yang sama, yaitu 0.72. Ini menunjukkan bahwa kedua model memiliki kemampuan yang relatif sebanding dalam menangkap ulasan positif, namun *SVM* masih sedikit lebih unggul secara keseluruhan. Metrik *f1-score*, yang merupakan rata-rata harmonis dari *precision* dan *recall*, juga memperkuat keunggulan model *SVM*. *F1-score* untuk kelas negatif pada *SVM* adalah 0.85, lebih tinggi dibandingkan *Random Forest* (0.83). Pada kelas positif, *SVM* memperoleh 0.75, sedangkan *Random Forest* hanya 0.73. Evaluasi selanjutnya adalah confusion matrix, yang terdiri atas nilai True-Positive (TP), True-Negative (TN), False-Positive (FP), dan False-Negative (FN). Dengan menggunakan metrik evaluasi ini, dapat dilakukan perbandingan kinerja antara model *SVM* dan *Random Forest* dalam mengklasifikasikan data opini menjadi kelas positif dan negatif.



Gambar 4. *Confusion Matrix* Evaluasi Model dengan *SVM* dan *Random Forest*

Dari Gambar 4. hasil pemodelan dengan *SVM* pada *heatmap* sebelah kiri, terlihat jika sebanyak 214 data terindikasi sebagai *true positive*, lalu sebanyak 45 terindikasi sebagai *false negative*, dan 115 kasus sebagai *true negative* serta 33 kasus sebagai *false positive*. Ini menunjukkan jika *SVM* telah berhasil mengklasifikasikan label sentimen dengan cukup baik, ditandai dengan adanya sedikit kasus *false positive* dan *false negative*. Sementara itu, pada *confusion matrix* pemodelan *Random Forest* pada *heatmap* sebelah kanan, hasil pemodelan dengan *Random Forest*, terlihat jika sebanyak 209 data terindikasi sebagai *true positive*, lalu sebanyak 45 terindikasi sebagai *false negative*, dan 115 kasus sebagai *true negative* serta 38 kasus sebagai *false positive*. Ini menunjukkan jika *Random Forest* juga telah berhasil mengklasifikasikan label sentimen dengan cukup baik, ditandai dengan adanya sedikit kasus *false positive* dan *false negative*. Namun, jika ditelaah lebih lanjut, hasil *SVM* memberikan hasil yang lebih baik, dilihat dari nilai *true positive* yang lebih banyak dibanding dengan hasil *Random Forest*.

Secara keseluruhan, *SVM* kemungkinan dapat melakukan klasifikasi lebih baik pada klasifikasi label sentimen. Ini karena konsep *SVM* adalah untuk menentukan *hyperplane* terbaik yang berfungsi sebagai pemisah dua kelas dalam ruang input [16], sehingga lebih tahan terhadap *overfitting* pada data dengan dimensi tinggi seperti data teks. Sementara *Random Forest* kemungkinan bekerja lebih optimal pada data numerik atau fitur yang saling independen. Untuk itu, metode pemodelan dengan *Random Forest* perlu dilakukan improvisasi yang mendalam seperti yang dilakukan pada jurnal yang berjudul “*An Improved Random Forest Classifier for Text Categorization.*” [17], *Random Forest* ini kemungkinan memiliki performa yang bisa sedikit menurun saat berhadapan dengan data teks yang memiliki korelasi antar kata dan sparsitas tinggi.

#### 4. KESIMPULAN

Hasil analisis menunjukkan bahwa sebanyak 60,4% ulasan pengguna tergolong dalam kategori negatif, sedangkan 39,6% termasuk kategori positif. Hal ini mencerminkan adanya kecenderungan ketidakpuasan dari mayoritas pengguna terhadap pengalaman mereka dalam menggunakan aplikasi tersebut. Pada tahap pemodelan, algoritma *SVM* memberikan performa terbaik dengan akurasi sebesar 81%, disusul oleh *Random Forest* dengan akurasi sebesar 80%. Kedua model mampu mengklasifikasikan sentimen dengan cukup baik, meskipun masih terdapat ruang untuk peningkatan terutama dalam mengklasifikasikan sentimen positif secara lebih akurat.

Adapun keterbatasan dalam penelitian ini terletak pada proses *scrapping* data, dimana karena keterbatasan bahasa dan *tools* dalam proses, keseluruhan ulasan tidak dapat dilakukan analisis, sehingga penelitian ini hanya mengambil ulasan berbahasa Indonesia. Selain itu, keterbatasan lain adalah regulasi aturan pada *Google Play Store* yang membatasi jumlah pengambilan data saat *scrapping* serta ketiadaan penanganan terhadap data yang tidak berdistribusi seimbang. Oleh karena itu, penelitian selanjutnya diharapkan dapat mempertimbangkan untuk melakukan penanganan pada data yang berdistribusi tidak seimbang, dan penggunaan pendekatan *machine learning* yang lebih *advanced* atau integrasi fitur semantik untuk meningkatkan akurasi klasifikasi sentimen serta memperluas wawasan mengenai konteks opini pengguna dalam jangkauan internasional.

Berdasarkan hasil tersebut, dapat disimpulkan bahwa pendekatan *machine learning* dengan algoritma *SVM* lebih efektif digunakan dalam mengidentifikasi sentimen ulasan pengguna aplikasi, karena *SVM* kemungkinan dapat melakukan klasifikasi lebih baik pada klasifikasi label sentimen, daripada *Random Forest* yang cenderung bekerja lebih optimal pada data yang numerik dibanding dengan data teks. Penelitian ini diharapkan dapat memberikan masukan yang berguna bagi pengembang aplikasi *Maxim Merchant* dalam melakukan evaluasi serta peningkatan kualitas layanan berdasarkan masukan pengguna. Sehingga, pihak pengembang dapat meningkatkan stabilitas aplikasi, mempercepat proses layanan pengiriman atau transaksi, serta menanggapi keluhan pengguna secara lebih responsif, khususnya pada aspek-aspek yang sering dikeluhkan dalam ulasan dengan sentimen negatif.

## REFERENSI

- [1] F. A. Larasati, D. E. Ratnawati, and B. T. Hanggara, "Analisis Sentimen Ulasan Aplikasi Dana dengan Metode Random Forest," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 9, pp. 4305–4313, 2022, Accessed: Jun. 03, 2025. [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/download/11562/5130>
- [2] A. A. Permana, M. F. Fahrezi, D. Y. Priyanggodo, D. A. Kristiyanti, and M. Sihotang, "SENTIMEN ANALISIS OPINI MASYARAKAT PADA MEDIA SOSIAL TWITTER TERHADAP VAKSIN BERBAYAR MENGGUNAKAN METODE NAÏVE BAYES CLASSIFIER (NBC)," *JTS : Jurnal Teknik*, vol. 10, no. 2, pp. 84–92, 2021, Accessed: Jun. 03, 2025. [Online]. Available: <https://jurnal.umt.ac.id/index.php/jt/article/download/5471/2953>
- [3] T. R. Salsabilla and N. Pratiwi, "Penerapan Support Vector Machine Untuk Analisis Sentimen pada X (Twitter) Mengenai Obat Penyebab Gagal Ginjal Akut pada Anak," *Jurnal Teknik Informatika dan Komputer*, vol. 3, no. 2, 2024, Accessed: Jun. 03, 2025. [Online]. Available: <https://journal.uhamka.ac.id/index.php/jutikom/article/view/16892>
- [4] G. P. Insany, I. L. Kharisma, and R. Rosmawati, "Penerapan Algoritma Random Forest untuk Menganalisis Ulasan Aplikasi Spotify pada Google Play," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, pp. 369–378, Dec. 2024, doi: 10.29408/edumatic.v8i2.26394.
- [5] G. R. Ramadhan and C. A. Sugianto, "ANALISIS SENTIMEN ULASAN APLIKASI DANA DI GOOGLE PLAY STORE MENGGUNAKAN ALGORITMA NAÏVE BAYES," *Jurnal Mahasiswa Teknik Informatika*, vol. 8, no. 5, 2024, doi: <http://dx.doi.org/10.36040/jati.v8i5.10732>.
- [6] M. R. Hanafi and R. K. R., "Analisis Sentimen pada Ulasan Aplikasi Sirekap di Google Play Menggunakan Algoritma Naive Bayes," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1578–1586, Oct. 2024, doi: 10.57152/malcom.v4i4.1693.
- [7] A. M. B. Ledjap, F. P. Rochmawati, D. A. E. Marsanda, and P. S. Angraini, "Pemanfaatan Natural Language Processing Untuk Pececekan Ejaan Sesuai KBBI," *JAMASTIKA*, vol. 3, no. 2, 2024, Accessed: Jun. 03, 2025. [Online]. Available: <https://jurnal.unw.ac.id/index.php/jamastika/article/view/3255/2381>
- [8] S. J. Angelina, A. B. P. Negara, and H. Muhandi, "Analisis Pengaruh Penerapan Stopword Removal Pada Performa Klasifikasi Sentimen Tweet Bahasa Indonesia," *JUARA (Jurnal Aplikasi dan Riset Informatika)*, vol. 02, no. 1, 2023, doi: 10.26418/juara.v2i1.69680.
- [9] V. Foswanto, E. Sulistianingsih, and H. Perdana, "IMPLEMENTASI WEB SCRAPING UNTUK ANALISIS ULASAN FILM KKN DI DESA PENARI MENGGUNAKAN NAÏVE BAYES CLASSIFIER," *Equator: Journal of Mathematical and Statistical Sciences (EJMSS)*, vol. 3, no. 1, 2024, Accessed: Jun. 03, 2025. [Online]. Available: <https://jurnal.untan.ac.id/index.php/EMSS/article/view/76237/75676603880>
- [10] A. Sukmawati, D. E. Ratnawati, and N. Y. Setiawan, "ANALISIS SENTIMEN APLIKASI GLINTS BERDASARKAN ULASAN GOOGLE PLAY STORE MENGGUNAKAN METODE SUPPORT VECTOR MACHINE," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 1, pp. 2548–964, 2017, Accessed: Jun. 03, 2025. [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/14107/6300>
- [11] T. Ernayanti, M. Mustafid, A. Rusgiyono, and A. Hakim, "PENGUNAAN SELEKSI FITUR CHI-SQUARE DAN ALGORITMA MULTINOMIAL NAÏVE BAYES UNTUK ANALISIS SENTIMEN PELANGGGAN TOKOPEDIA," *Jurnal Gaussian*, vol. 11, pp. 562–571, Nov. 2022, doi: 10.14710/j.gauss.11.4.562-571.
- [12] F. Nufairi, N. Pratiwi, and F. Herlando, "ANALISIS SENTIMEN PADA ULASAN APLIKASI THREADS DI GOOGLE PLAY STORE MENGGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 1, pp. 339–348, Feb. 2024, doi: 10.29100/jupi.v9i1.4929.
- [13] 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)*, 2024, doi: <https://doi.org/10.1109/ITIS64716.2024.10845453>.
- [14] D. Irawan, E. Budi Perkasa, Y. Yurindra, D. Wahyuningsih, and E. Helmud, "Perbandingan Klasifikasi SMS Berbasis Support Vector Machine, Naive Bayes Classifier, Random Forest dan Bagging Classifier," *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 10, pp. 432–437, Dec. 2021, doi: 10.32736/sisfokom.v10i3.1302.
- [15] N. Alvionika, S. Faisal, R. Rahmat, and A. F. N. Masruriyah, "Analisis Sentimen Pada Komentar Instagram Provider By.U Menggunakan Metode K-Nearest Neighbors (KNN)," *Jurnal Algoritma*, vol. 21, no. 2, pp. 50–63, Nov. 2024, doi: 10.33364/algoritma/v.21-2.1672.
- [16] F. A. Kusumo, D. R. S. Saputro, and P. Widyaningsih, "SENTIMENT ANALYSIS OF REVIEWS ON X APPS ON GOOGLE PLAY STORE USING SUPPORT VECTOR MACHINE AND N-GRAM FEATURE SELECTION," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 19, no. 2, pp. 1037–1046, Apr. 2025, doi: 10.30598/barekengvol19iss2pp1037-1046.
- [17] B. Xu, X. Guo, Y. Ye, and J. Cheng, "An improved random forest classifier for text categorization," *Journal of Computers (Finland)*, vol. 7, no. 12, pp. 2913–2920, 2012, doi: 10.4304/jcp.7.12.2913-2920.

# Klasifikasi Sentimen Ulasan Pengguna Aplikasi Qpon dengan Support Vector Machine dan Logistic Regression

Iin Febyanti<sup>1</sup>, Arsinta Safira Devi<sup>2</sup>, Salsabila Wardah<sup>3</sup>, Shindy Shella May Wara<sup>4</sup>, Aviolla Terza Damaliana<sup>5</sup>

<sup>1,2,3,4,5</sup>Ilmu Komputer, Universitas Pembangunan Veteran Jawa Timur, Indonesia

Email: <sup>1</sup>iinfebyanti22@gmail.com, <sup>2</sup>arsintasafira5@gmail.com, <sup>3</sup>salsabilawardah45@gmail.com, <sup>4</sup>shindi.shella.fasilkom@upnjatim.ac.id, <sup>5</sup>aviolla.terza.sada@upnjatim.ac.id

## ABSTRAK

Meningkatnya jumlah ulasan pengguna dalam aplikasi mobile menjadi sumber informasi penting dalam memahami kepuasan dan pengalaman pengguna terhadap layanan. Aplikasi yang digunakan dalam penelitian ini adalah aplikasi Qpon, yang ulasan penggunanya sering berisi opini positif maupun negatif yang dapat memengaruhi keputusan pengguna lain. Oleh karena itu, analisis sentimen diperlukan untuk mengetahui kecenderungan opini dalam ulasan tersebut. Penelitian ini bertujuan untuk mengklasifikasikan ulasan pengguna aplikasi Qpon ke dalam dua kategori sentimen, yaitu positif dan negatif. Data dikumpulkan melalui metode *web scraping*, diperoleh sebanyak 866 data ulasan. Setelah melalui tahapan *preprocessing* teks seperti penghapusan kata tidak penting, normalisasi, dan tokenisasi, data dianalisis menggunakan metode TF-IDF sebagai representasi fitur, kemudian diklasifikasikan menggunakan algoritma *Logistic Regression* dan *Support Vector Machine* (SVM). Proses pengujian dilakukan dengan teknik *Stratified K-Fold Cross Validation* dan diukur berdasarkan lima metrik evaluasi, yaitu akurasi, presisi, *recall*, *F1-score*, dan ROC AUC. Hasil penelitian menunjukkan bahwa SVM memiliki nilai akurasi dan presisi tertinggi, sementara *Logistic Regression* lebih unggul dalam *recall* dan ROC AUC. Penelitian ini menunjukkan bahwa SVM lebih unggul dari sisi ketepatan klasifikasi, sedangkan *Logistic Regression* lebih peka terhadap ulasan positif. Penelitian ini diharapkan dapat digunakan sebagai referensi untuk pengembangan sistem analisis sentimen guna meningkatkan layanan aplikasi berbasis data ulasan pengguna.

**Kata Kunci:** Analisis Sentimen, Logistic Regression, Support Vector Machine (SVM).

## ABSTRACT

The increasing number of user reviews in mobile applications is an important source of information in understanding user satisfaction and experience with the services used. One of the applications used in this study is the Qpon application. Reviews left by users often contain positive or negative opinions that can influence other users in making decisions. Therefore, sentiment analysis is needed to determine the tendency of opinions in these reviews. This study aims to classify Qpon application user reviews into two sentiment categories, namely positive and negative. Data were collected through the web scraping method and obtained 866 review data. After going through text preprocessing stages such as removing unimportant words, normalization, and tokenization, the data were analyzed using the TF-IDF method as a feature representation, then classified using the Logistic Regression and Support Vector Machine (SVM) algorithms. The testing process was carried out using the Stratified K-Fold Cross Validation technique and measured based on five evaluation metrics, namely accuracy, precision, recall, F1-score, and ROC AUC. The results showed that SVM had the highest accuracy and precision values, while Logistic Regression was superior in recall and ROC AUC. These findings indicate that SVM is superior in terms of classification accuracy, while Logistic Regression is more sensitive to positive reviews. This study is expected to be used as a reference for the development of a sentiment analysis system to improve application services based on user review data.

**Keywords:** Logistic Regression, Sentiment Analysis, Support Vector Machine (SVM).

## Penulis Korespondensi:

Iin Febyanti

Email: iinfebyanti22@gmail.com

## Article Info

Diterima: 8 Juni 2025

Direvisi: 30 Juni 2025

Disetujui: 16 Juli 2025

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



## 1. PENDAHULUAN

Pada era digital saat ini, aplikasi *mobile* telah menjadi bagian tak terpisahkan dari kehidupan masyarakat modern. Dalam proses penggunaan aplikasi, pengguna sering kali meninggalkan jejak digital berupa ulasan atau *review*. Ulasan ini menjadi bentuk umpan balik yang tidak hanya merefleksikan pengalaman pengguna, tetapi juga menyimpan informasi penting tentang kualitas, kinerja, dan kepuasan terhadap suatu aplikasi. Namun, karena volume data yang sangat besar dan sifatnya yang tidak terstruktur, analisis manual terhadap ulasan tersebut menjadi tidak efisien dan kurang objektif. Salah satu pendekatan yang digunakan untuk memahami opini publik dari data teks adalah analisis sentimen. Menurut Bing Liu (2020), analisis sentimen merupakan bidang studi yang berfokus pada identifikasi opini, penilaian, emosi, atau sikap seseorang terhadap suatu entitas dan atributnya melalui teks tertulis [1]. Analisis terhadap ulasan ini, khususnya yang bersumber dari platform digital seperti *Google Play Store*, memberikan potensi besar dalam memahami ekspektasi dan persepsi pengguna secara lebih mendalam.

Seiring berkembangnya teknologi dan meningkatnya penggunaan media sosial, data ulasan yang tersedia dalam bentuk teks menjadi semakin melimpah dan tidak terstruktur. Proses membaca dan memahami ribuan bahkan jutaan ulasan secara manual tentu menjadi tidak efisien dan rawan bias subjektivitas. Untuk itu, dibutuhkan pendekatan komputasional berupa *sentiment analysis* atau analisis sentimen, yakni teknik dalam bidang pemrosesan bahasa alami atau *natural language processing* (NLP) yang bertujuan mengidentifikasi opini, emosi, dan sikap terhadap suatu entitas melalui analisis teks. Analisis sentimen memungkinkan pengklasifikasian ulasan ke dalam kategori positif, negatif, atau netral secara otomatis, yang sangat berguna dalam mendukung pengambilan keputusan berbasis data [2].

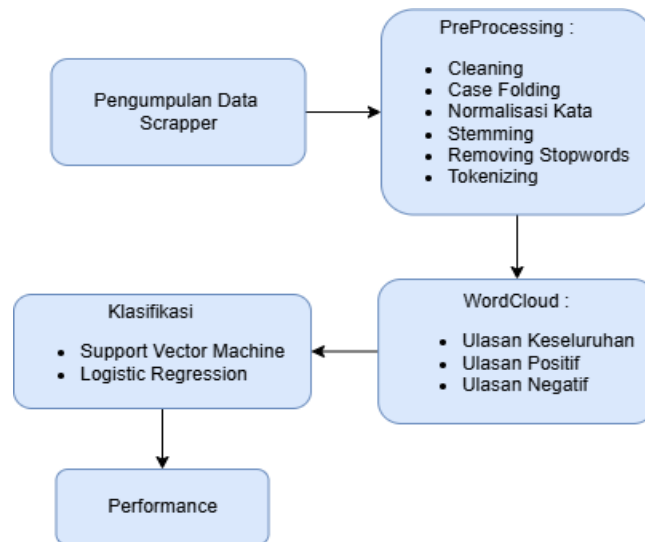
Dalam konteks ini, aplikasi Qpon sebagai salah satu platform layanan diskon dan kupon digital juga mendapatkan berbagai ulasan dari penggunanya. Namun, belum banyak studi yang secara khusus mengevaluasi bagaimana persepsi pengguna terhadap aplikasi ini melalui pendekatan analisis sentimen. Padahal, informasi tersebut dapat menjadi masukan berharga dalam pengembangan fitur dan peningkatan pengalaman pengguna. Penelitian yang ada sebelumnya sebagian besar masih terfokus pada platform *e-commerce* besar seperti Shopee, yang memiliki cakupan layanan luas seperti belanja *online*, pembayaran digital, dan pengiriman barang. Penelitian pada platform tersebut umumnya berfokus pada kepuasan pengguna terhadap produk, layanan pengiriman, dan sistem transaksi. Sementara itu, aplikasi seperti Qpon memiliki karakteristik ulasan yang berbeda, di mana pengguna lebih sering menyoroti efektivitas penukaran voucher, kestabilan sistem promosi, serta responsivitas layanan pelanggan. Untuk mendukung penelitian ini digunakan teknik *web scraping* untuk pengumpulan data dalam jumlah besar. *Web scraping* merupakan metode pengambilan sebuah data secara otomatis dari halaman web[3]. Pengertian lain dari *web scraping* adalah teknik yang digunakan untuk mengekstraksi data dari internet yang kemudian disimpan ke dalam *file* untuk kebutuhan analisis data [3]. *Web scraping* dapat melakukan pencarian apa saja yang tidak bisa dilakukan oleh mesin pencarian tradisional contohnya *Google Search*, hal ini juga terbukti efektif dalam mengumpulkan data teks dari berbagai platform digital lainnya.

Tantangan selanjutnya dalam analisis sentimen adalah menentukan model klasifikasi yang paling akurat untuk memetakan ulasan ke dalam sentimen tertentu. Algoritma *Machine Learning*, seperti *Logistic Regression* dan *Support Vector Machine* (SVM), telah banyak diterapkan dalam studi analisis sentimen. Masing-masing algoritma memiliki keunggulan tersendiri dalam hal akurasi, efisiensi, dan kompleksitas komputasi. Beberapa penelitian mengatakan bahwa *Support Vector Machine* (SVM) menunjukkan kinerja yang lebih unggul dalam analisis sentimen [4], sedangkan studi lainnya menyebutkan bahwa *Logistic Regression* lebih efektif [5]. Karena performa model sangat dipengaruhi oleh karakteristik data yang dianalisis, maka perlu dilakukan evaluasi komparatif guna menentukan model klasifikasi terbaik dalam konteks spesifik, yaitu ulasan pengguna aplikasi Qpon.

Penelitian ini bertujuan untuk mengevaluasi performa sejumlah algoritma klasifikasi dalam menganalisis sentimen ulasan pengguna terhadap aplikasi Qpon yang diperoleh melalui *web scraping*. Dengan menggunakan metrik akurasi sebagai acuan, penelitian ini akan membandingkan beberapa model klasifikasi untuk menemukan model yang paling tepat dan efektif. Diharapkan hasil penelitian ini dapat memberikan kontribusi terhadap pengembangan sistem analisis sentimen yang lebih akurat dan aplikatif, serta menjadi acuan dalam meningkatkan kualitas layanan aplikasi Qpon berdasarkan opini pengguna yang nyata.

## 2. METODE PENELITIAN

Gambar berikut ini menunjukkan diagram alir penelitian kami, dimulai dari pengumpulan data menggunakan *scraper*, dilanjutkan dengan *preprocessing* untuk membersihkan data. Setelah itu, dilakukan visualisasi data dengan *wordcloud*, kemudian tahap klasifikasi, dan diakhiri dengan evaluasi performa model. Diagram ini menggambarkan alur kerja penelitian secara jelas dan terstruktur:



Gambar 1. Diagram Alir

### 2.1. PreProcessing

Pra-pemrosesan data merupakan tahap krusial untuk mempermudah dan meningkatkan kinerja model analitik. Dalam analisis ulasan aplikasi Qpon, proses ini mencakup pembersihan data dari elemen-elemen yang tidak relevan, seperti kata hubung, tanda baca (titik, koma, dan sebagainya), serta kata-kata umum yang tidak memberikan kontribusi makna yang signifikan (*stopwords*). Dengan menghilangkan informasi yang tidak penting, model analitik dapat lebih fokus dalam mengidentifikasi pola-pola yang bermakna dalam data, sehingga proses analisis menjadi lebih efisien dan akurasi hasil yang diperoleh pun meningkat [6].

Tahapan *preprocessing* yang dilakukan dalam penelitian ini :

- 1) *Cleaning*: Pembersihan ini dilakukan untuk menghilangkan simbol titik, koma, *hashtag*, *emoticon*, dan sebagainya pada ulasan Qpon
- 2) *Case Folding*: Proses ini mengubah seluruh huruf dalam teks menjadi bentuk yang konsisten, biasanya huruf kecil. Tujuannya adalah untuk menghilangkan perbedaan antara huruf besar dan kecil, sehingga mempermudah proses perbandingan dan analisis teks [7].
- 3) *Normalisasi Kata*: Proses penyamaan bentuk kata tidak baku atau singkatan ke bentuk baku, dalam ulasan aplikasi, pengguna sering menulis secara informal, seperti "yg" untuk "yang" atau "dgn" untuk "dengan". Tanpa normalisasi, kata-kata tersebut akan dianggap berbeda oleh sistem, meskipun maknanya sama, sehingga dapat menurunkan akurasi analisis. Proses ini dilakukan dengan menelusuri setiap ulasan untuk mengidentifikasi dan mengganti kata tidak baku ke bentuk standar Bahasa Indonesia.
- 4) *Stemming*: Proses pra-pemrosesan teks yang mengubah kata berimbuhan menjadi bentuk dasar (akar kata) untuk menyamakan variasi kata dengan makna serupa. Proses ini mengurangi kompleksitas data dan meningkatkan efektivitas analisis teks.
- 5) *Removing Stopwords*: Proses menghilangkan kata-kata fungsi yang bersifat umum dan tidak membawa makna signifikan dalam teks. Proses ini dilakukan agar analisis dapat lebih fokus pada kata-kata yang memiliki informasi penting, seperti kata penghubung "atau", "serta", "ke", dan "pada", yang biasanya tidak berkontribusi pada pemahaman konteks.
- 6) *Tokenizing*: Proses pemisahan teks atau kalimat menjadi unit-unit terkecil berupa kata atau token. Unit-unit ini menjadi elemen dasar yang digunakan dalam analisis teks dan pemodelan, sehingga memudahkan pemrosesan data secara sistematis [8].

### 2.2. Wordcloud

*Wordcloud* adalah salah satu metode dalam *text mining* yang menyajikan visualisasi kata berdasarkan frekuensinya dalam suatu teks. Kata-kata yang muncul lebih sering akan ditampilkan dengan ukuran huruf yang lebih besar, sehingga memudahkan identifikasi kata-kata yang paling dominan dalam dokumen sumber [9].

### 2.3. Logistic Regression

Regresi logistik merupakan metode analisis statistik yang digunakan untuk memodelkan variabel respons kategori berdasarkan satu atau lebih variabel prediktor, baik kategori maupun kontinu [10]. Metode ini memodelkan peluang terjadinya suatu peristiwa dengan cara mengestimasi logaritma peluang (*log-odds*) dari variabel respons, sehingga berbeda dengan regresi linier yang memprediksi nilai kontinu. Regresi logistik terbagi menjadi dua jenis, yaitu regresi logistik biner untuk variabel respons dengan dua kategori, dan regresi logistik multinomial untuk variabel respons dengan lebih dari dua kategori. Dengan

demikian, regresi logistik sangat berguna untuk mempelajari hubungan antara variabel prediktor dan probabilitas kejadian kategori tertentu [11]. Fungsi tersebut dapat dinyatakan sebagai berikut:

$$\pi(x) = \frac{\exp(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}{1 + \exp(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)} \quad (1)$$

Untuk mempermudah estimasi parameter regresi, model regresi logistik dapat dinyatakan menggunakan transformasi logit dari  $\pi(x)$ , sehingga diperoleh persamaan:

$$g(x) = \ln\left(\frac{\pi(x)}{1 - \pi(x)}\right) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p \quad (2)$$

Keterangan :

$\beta_0$  : Konstanta atau intercept

$\beta_j$  : Koefisien parameter variabel  $x_j$ , di mana  $j = 1, 2, \dots, p$

$p$  : Banyaknya peubah prediktor

$x$  : Peubah prediktor

#### 2.4. Support Vector Machine (SVM)

*Support Vector Machine* (SVM) pertama kali diperkenalkan oleh Vapnik pada tahun 1992 sebagai salah satu metode *learning machine* yang bekerja berdasarkan prinsip *Structural Risk Minimization* (SRM). Prinsip ini bertujuan untuk menemukan *hyperplane* terbaik yang mampu memisahkan dua kelas secara optimal pada *input space* [12]. SVM menggunakan hipotesis berupa fungsi-fungsi linier dalam ruang fitur berdimensi tinggi, dengan mengimplementasikan *learning bias* yang berasal dari teori pembelajaran statistik. SVM mempunyai dasar teoritis yang kuat dan melakukan klasifikasi lebih akurat daripada kebanyakan algoritma lain di banyak aplikasi. Banyak penelitian telah melaporkan bahwa SVM merupakan metode yang paling akurat untuk klasifikasi teks [13]. Pada awalnya, SVM dirancang untuk menangani masalah klasifikasi linier. Namun, seiring dengan perkembangan teknologi dan teori, SVM kini mampu menyelesaikan permasalahan klasifikasi non-linier melalui pemanfaatan fungsi *kernel*. Fungsi ini memungkinkan pemetaan data dari ruang berdimensi rendah ke ruang berdimensi lebih tinggi, sehingga data yang tidak dapat dipisahkan secara linier menjadi dapat dipisahkan. Metode ini termasuk ke dalam kategori non-parametrik dan banyak diterapkan dalam berbagai bidang, seperti klasifikasi data, pengolahan citra, serta pengenalan pola. Ada beberapa pilihan fungsi kernel yang dipakai pada sebuah aplikasi untuk mengatasi masalah metode SVM *non-linier*, seperti dibawah ini [14]:

$$f(x) = x'w + b = 0 \quad (3)$$

Dimana  $b$  merupakan nilai bias yang merupakan scalar, jika  $\hat{w} = \sum_{i=1}^n \hat{\alpha}_i y_i x_i$ , maka metode SVM dapat dijelaskan sebagai berikut :

$$f(x) = \sum_{i=1}^n \alpha_i y_i \phi(x_i)' \phi(x_j) + b \quad (4)$$

Keterangan :

$x$  : Vektor fitur input

$w$  : Vektor bobot dalam ruang fitur

$b$  : Bias atau intersep

$\alpha_i$  : Koefisien Lagrange untuk data latih ke- $i$

$y_i$  : Label kelas untuk data latih ke- $i$

$x_i$  : Vektor fitur dari data latih ke- $i$

$\phi(x)$  : Fungsi pemetaan dari ruang input ke ruang fitur berdimensi tinggi

$\phi(x_i)' \phi(x_j)$  : Hasil perkalian dalam antara dua data yang telah dipetakan ke ruang fitur berdimensi lebih tinggi

$n$  : Jumlah data latih

#### 2.5. Evaluasi Model


Untuk mengetahui seberapa baik model dalam menganalisis sentimen dari hasil ulasan aplikasi Qpon, digunakan beberapa pendekatan penilaian yang umum dipakai dalam analisis, berikut beberapa metrik evaluasi yang digunakan antara lain :

- 1) *Accuracy*: Merupakan ukuran kinerja model yang menunjukkan proporsi prediksi yang benar dari keseluruhan data uji. Nilai *Accuracy* yang tinggi mencerminkan kemampuan model dalam melakukan klasifikasi dengan akurat. *Accuracy* sering kali digunakan sebagai indikator utama untuk menilai performa model klasifikasi [15].
- 2) *Precision*: Berfokus pada seberapa tepat model dalam memprediksi kelas positif. Fokus akurasi ini tidak pada keseluruhan prediksi secara umum, namun hanya pada beberapa banyak dari data yang diprediksi yang benar - benar positif [15].

- 3) *Recall*: Mengukur kemampuan model dalam menangkap semua data yang sebenarnya positif, yaitu proporsi data positif yang berhasil dikenali dari keseluruhan data positif. *Recall* penting untuk memastikan model tidak melewatkan kasus positif, terutama dalam konteks seperti deteksi keluhan pengguna [15].
- 4) *F1 - Score*: Merupakan rata-rata harmonis dari *precision* dan *recall*. Metrik ini digunakan untuk menyeimbangkan ketepatan (*precision*) dan kelengkapan (*recall*) prediksi, khususnya ketika data tidak seimbang, sehingga memberikan gambaran performa model yang lebih menyeluruh [15].
- 5) ROC AUC: Mengukur kemampuan model dalam membedakan antara dua kelas. Nilai AUC yang mendekati 1 menunjukkan performa model yang sangat baik dalam klasifikasi, sedangkan nilai mendekati 0,5 menandakan performa yang kurang baik atau acak.

### 3. HASIL DAN PEMBAHASAN

Dari proses *web scraping*, diperoleh sebanyak 866 data ulasan. Proses pelabelan dalam penelitian ini dilakukan berdasarkan *rating* bintang pengguna melalui ulasan pada aplikasi Qpon. Untuk pelabelan akan dibagi menjadi dua kategori, yaitu sentimen positif dan sentimen negatif. Ulasan dengan skor lebih dari 3 hingga 5 dikategorikan sebagai sentimen positif, sedangkan ulasan dengan skor 1 hingga 3 dikategorikan ke dalam sentimen negatif.



Gambar 2. Diagram Sentimen Ulasan

Berdasarkan gambar 2. menampilkan jumlah ulasan berdasarkan sentimen, terdapat 535 ulasan yang bersifat positif, sedangkan 331 ulasan bersifat negatif. Jumlah ini menunjukkan bahwa sebagian besar pengguna memberikan respons yang positif terhadap aplikasi Qpon. Hal ini dapat mencerminkan bahwa tingkat kepuasan pengguna yang cukup tinggi terhadap kinerja dan layanan yang ditawarkan oleh aplikasi ini.

#### 3.1. PreProcessing

Tahapan *preprocessing* dalam penelitian ini mencakup *cleaning*, *case folding*, normalisasi kata, *stemming*, *removing stopwords*, dan *tokenizing*. Proses ini tidak hanya menghilangkan elemen-elemen yang tidak relevan seperti tanda baca dan kata-kata umum, tetapi juga menyamakan bentuk kata agar sistem analisis dapat mengenali pola dan makna secara lebih efektif. Sehingga data yang telah diproses ini dapat meningkatkan kualitas data dan memberikan hasil analisis sentimen yang lebih akurat.

Tabel 2. *Cleaning* Teks

Sebelum <i>Cleaning</i>	Sesudah <i>Cleaning</i>
Aplikasi nya sangat membantu untuk makan enak dengan harga murah dengan diskon nya sampai 50%. Real karna saya sudah memperoleh manfaat nya.	Aplikasi nya sangat membantu untuk makan enak dengan harga murah dengan diskon nya sampai Real karna saya sudah memperoleh manfaat nya
Apk nya bagus untuk yang mau berhemat untuk keperluan belanja, makan, dan nonton film sangat rekomend sekali buat anak kos juga cocok yang mau hemat juga.	Apk nya bagus untuk yang mau berhemat untuk keperluan belanja makan dan nonton film sangat rekomend sekali buat anak kos juga cocok yang mau hemat juga

Berdasarkan tabel 2 hasil dari *cleaning* teks, terlihat bahwa proses *cleaning* data berhasil menghilangkan tanda baca seperti titik, koma, dan angka, serta menyederhanakan struktur kalimat tanpa mengubah makna utama dari ulasan. Hal ini penting untuk meningkatkan efektivitas dalam proses analisis berikutnya, karena teks yang bersih dapat meminimalkan *noise* dan memperbaiki akurasi model analisis sentimen yang digunakan.

Tabel 3. *Case Folding* Teks

Sebelum <i>Case Folding</i>	Sesudah <i>Case Folding</i>
Aplikasi nya sangat membantu untuk makan enak dengan harga murah dengan diskon nya sampai Real karna saya sudah memperoleh manfaat nya	aplikasi nya sangat membantu untuk makan enak dengan harga murah dengan diskon nya sampai real karna saya sudah memperoleh manfaat nya
Apk nya bagus untuk yang mau berhemat untuk keperluan belanja makan dan nonton film sangat rekomend sekali buat anak kos juga cocok yang mau hemat juga	apk nya bagus untuk yang mau berhemat untuk keperluan belanja makan dan nonton film sangat rekomend sekali buat anak kos juga cocok yang mau hemat juga

Selanjutnya pada proses case folding, tabel 3, menunjukkan bahwa kata-kata yang sebelumnya mengandung huruf kapital seperti *Aplikasi*, *Real* dan *Apk* telah diubah menjadi huruf kecil secara konsisten. Proses ini bertujuan untuk menghindari kesalahan dalam pengelompokan kata saat tokenisasi, karena sistem analisis teks tidak lagi membedakan kata berdasarkan kapitalisasi. Misalnya, tanpa proses *case folding*, kata "Aplikasi" dan "aplikasi" akan diperlakukan sebagai dua token yang berbeda, padahal secara makna keduanya sama.

Tabel 4. Normalisasi Kata

Sebelum Normalisasi Kata	Sesudah Normalisasi Kata
aplikasi nya sangat membantu untuk makan enak dengan harga murah dengan diskon nya sampai real karna saya sudah memperoleh manfaat nya	aplikasi nya sangat membantu untuk makan enak dengan harga murah dengan diskon nya sampai real karena saya sudah memperoleh manfaat nya
apk nya bagus untuk yang mau berhemat untuk keperluan belanja makan dan nonton film sangat rekomend sekali buat anak kos juga cocok yang mau hemat juga	aplikasi nya baik untuk yang ingin berhemat untuk keperluan belanja makan dan nonton film sangat rekomendasi sekali buat anak kos juga cocok yang ingin hemat juga

Hasil normalisasi pada tabel 4, menunjukkan bahwa kata-kata tidak baku atau singkatan seperti *karna* dan *apk* telah berhasil diubah menjadi bentuk baku seperti *karena* dan *aplikasi*. Selain itu, terdapat juga penyesuaian kata informal atau tidak sesuai konteks menjadi bentuk yang lebih tepat, seperti *rekomend* menjadi *rekomendasi*, dan *mau* menjadi *ingin*. Proses normalisasi ini berfungsi untuk menyamakan berbagai variasi penulisan kata yang sering muncul dalam ulasan pengguna, sehingga dapat mengurangi variasi kata yang tidak perlu dan memperjelas makna dari setiap kalimat.

Tabel 5. *Stemming* Kata

Sebelum <i>Stemming</i>	Sesudah <i>Stemming</i>
aplikasi nya sangat membantu untuk makan enak dengan harga murah dengan diskon nya sampai real karena saya sudah memperoleh manfaat nya	aplikasi nya sangat bantu untuk makan enak dengan harga murah dengan diskon nya sampai real karena saya sudah oleh manfaat nya
aplikasi nya baik untuk yang ingin berhemat untuk keperluan belanja makan dan nonton film sangat rekomendasi sekali buat anak kos juga cocok yang ingin hemat juga	aplikasi nya baik untuk yang ingin hemat untuk perlu belanja makan dan nonton film sangat rekomendasi sekali buat anak kos juga cocok yang ingin hemat juga

Kemudian pada tabel 5, proses *stemming* kata terlihat bahwa beberapa kata berimbuhan seperti *membantu*, *berhemat*, dan *keperluan* telah berhasil diubah menjadi bentuk dasarnya, yaitu *bantu*, *hemat*, dan *perlu*. Proses ini merupakan bagian dari tahapan *stemming* dalam *preprocessing* yang bertujuan untuk menyamakan variasi kata dengan makna serupa. Dengan mengurangi kompleksitas data dan menyederhanakan struktur kata, proses ini membantu meningkatkan konsistensi serta efektivitas dalam analisis teks pada tahap selanjutnya.

Tabel 6. *Stopword*

Sebelum <i>Stopword</i>	Sesudah <i>Stopword</i>
aplikasi nya sangat bantu untuk makan enak dengan harga murah dengan diskon nya sampai real karena saya sudah oleh manfaat nya	aplikasi bantu makan enak harga murah diskon real manfaat
aplikasi nya baik untuk yang ingin hemat untuk perlu belanja makan dan nonton film sangat rekomendasi sekali buat anak kos juga cocok yang ingin hemat juga	aplikasi hemat belanja makan nonton film rekomendasi anak kos cocok hemat

Dari tabel 6 proses *stopword* menunjukkan bahwa sebagian besar kata sambung, kata bantu, kata ganti, dan kata fungsional lainnya seperti *yang*, *untuk*, *dengan*, *karena*, *sudah*, *saya*, dan *nya* telah berhasil dihilangkan sehingga hanya tersisa kata-kata kunci yang merepresentasikan inti dari ulasan pengguna. Proses *stopword* ini penting untuk meningkatkan efisiensi analisis teks, karena dapat mengurangi beban pemrosesan tanpa menghilangkan informasi penting dari isi ulasan.



### 3.3. Permodelan

Dalam penelitian ini, proses klasifikasi sentimen pada ulasan aplikasi Qpon dilakukan menggunakan algoritma *Logistic Regression* dan *Support Vector Machine (SVM)*. Untuk membagi data, digunakan metode *Stratified K-Fold Cross-Validation* sebanyak 5 *fold*, yaitu teknik pembagian data secara berulang ke dalam beberapa bagian (*fold*) dengan tetap menjaga keseimbangan proporsi kelas di setiap *fold*. Pendekatan ini membantu menghasilkan evaluasi model yang lebih adil dan tidak bergantung pada satu kali pembagian data saja. Model *Logistic Regression* dikonfigurasi menggunakan `solver='liblinear'`, yang cocok untuk klasifikasi biner dan data set berukuran kecil hingga sedang, serta menggunakan regularisasi L2 dengan parameter `C=1.0` untuk mengontrol kompleksitas model. Sementara itu, model SVM menggunakan kernel *linear* dan parameter `C=1.0` untuk mengatur margin serta penalti terhadap kesalahan klasifikasi, dan disertai `probability=True` agar memungkinkan perhitungan probabilitas yang diperlukan dalam evaluasi ROC AUC. Dari hasil pengujian, model SVM dan *Logistic Regression* menunjukkan performa terbaik berdasarkan lima metrik evaluasi, yaitu akurasi, presisi, recall, F1-score, dan ROC AUC, dengan masing-masing model unggul di metrik yang berbeda.

Model *Support Vector Machine (SVM)* menunjukkan kinerja yang sangat baik, dengan nilai akurasi tertinggi sebesar 0.925, yang menunjukkan bahwa model ini mampu mengklasifikasikan sebagian besar ulasan dengan benar. SVM juga memiliki nilai presisi tertinggi sebesar 0.958, yang berarti model ini memiliki kemampuan sangat baik dalam melakukan klasifikasi dengan kesalahan minimal. Sementara itu, nilai *recall* sebesar 0.920 menunjukkan bahwa SVM cukup mampu mengenali ulasan positif dengan baik. Nilai *F1-score* sebesar 0.938 menjadi indikator bahwa model ini memiliki keseimbangan yang baik antara presisi dan *recall*. Meskipun demikian, nilai ROC AUC dari SVM sedikit lebih rendah dibandingkan *Logistic Regression*, yaitu 0.964, namun tetap menunjukkan kemampuan diskriminasi yang sangat baik dalam membedakan antara sentimen positif dan negatif.

Sementara itu, model *Logistic Regression* juga memberikan performa yang kompetitif. Nilai akurasi yang diperoleh adalah 0.905, sedikit lebih rendah dibandingkan SVM. Akan tetapi, model ini memiliki nilai *recall* tertinggi sebesar 0.935, yang berarti *Logistic Regression* lebih sensitif dalam mengenali ulasan yang benar-benar positif, sehingga cocok digunakan apabila tujuan utama adalah untuk menghindari kesalahan dalam mengabaikan opini positif pengguna. Nilai presisi dari model ini berada pada angka 0.915, dan *F1-score* sebesar 0.924, menunjukkan performa yang cukup seimbang. Keunggulan utama dari *Logistic Regression* terdapat pada nilai ROC AUC tertinggi sebesar 0.970, yang menunjukkan bahwa model ini sangat baik dalam membedakan antara kedua kelas secara probabilistik.

Tabel 8. Evaluasi Performa Model Klasifikasi

Model	Accuracy	Precision	Recall	F1 - Score	ROC AUC
<i>Logistic Regression</i>	0.905	0.915	<b>0.935</b>	0.924	<b>0.970</b>
<i>Support Vector Machine</i>	<b>0.925</b>	<b>0.958</b>	0.920	<b>0.938</b>	0.964

Berdasarkan hasil tersebut, dapat disimpulkan bahwa SVM lebih unggul dari sisi akurasi dan presisi, sehingga cocok digunakan apabila sistem lebih memprioritaskan ketepatan klasifikasi. Sebaliknya, *Logistic Regression* unggul dalam aspek *recall* dan ROC AUC, sehingga lebih sesuai digunakan apabila sensitivitas dan kemampuan dalam menangkap seluruh opini positif pengguna menjadi prioritas. Pemilihan model terbaik bergantung pada kebutuhan spesifik implementasi di lapangan.

## 4. KESIMPULAN

Penelitian ini bertujuan untuk mengklasifikasikan sentimen ulasan pengguna aplikasi Qpon ke dalam kategori positif maupun negatif menggunakan dua algoritma, yaitu *Support Vector Machine (SVM)* dan *Logistic Regression*. Data sebanyak 866 ulasan dikumpulkan melalui metode web scraping, kemudian diproses melalui tahapan preprocessing seperti cleaning, case folding, normalisasi, stemming, stopword removal, dan tokenizing. Selanjutnya, data direpresentasikan menggunakan metode TF-IDF dan dievaluasi menggunakan teknik *Stratified K-Fold Cross Validation* sebanyak 5 *fold*. Evaluasi dilakukan berdasarkan lima metrik utama, yaitu akurasi, presisi, recall, F1-score, dan ROC AUC.

Hasil penelitian ini menunjukkan bahwa SVM memiliki nilai akurasi (92,5%) dan presisi (95,8%). Hal ini menandakan bahwa SVM mampu melakukan klasifikasi dengan tingkat kesalahan yang sangat rendah. Di sisi lain, *Logistic Regression* menunjukkan performa lebih baik pada matrik *recall* (93,5%) dan ROC AUC (97%), yang berarti lebih sensitif dalam mendeteksi ulasan positif, dan lebih mampu membedakan antara dua kelas sentimen berdasarkan peluangnya. Hal ini menunjukkan bahwa masing-masing algoritma memiliki kelebihan tersendiri.

Dengan demikian, pemilihan model terbaik tergantung pada kebutuhan. Jika ketepatan klasifikasi lebih diutamakan, maka SVM adalah pilihan yang sesuai. Namun, jika yang dibutuhkan adalah kemampuan menangkap sebanyak mungkin ulasan positif dan negatif, maka *Logistic regression* lebih direkomendasikan. Penelitian ini diharapkan dapat menjadi acuan untuk pengembangan sistem analisis sentimen yang dapat membantu peningkatan layanan aplikasi berdasarkan ulasan pengguna.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pengampu mata kuliah Data Mining atas bimbingan dan ilmu yang diberikan selama perkuliahan. Ucapan terima kasih juga disampaikan kepada semua pihak yang telah membantu dalam proses penyusunan artikel ini. Dukungan berupa masukan, bantuan teknis, dan diskusi selama penelitian sangat membantu dalam menyelesaikan analisis. Bantuan dan saran selama pengolahan data sangat berarti bagi kelancaran penelitian ini. Semoga hasil penelitian ini dapat memberikan manfaat dalam pengembangan analisis sentimen berbasis ulasan pengguna pada aplikasi digital di masa depan.

## REFERENSI

- [1] Raihanda Luthfiansyah, Budi Wasito, "ANALISIS SENTIMEN TERHADAP PARA KANDIDAT PRESIDEN 2024 BERDASARKAN NETIZEN PENGGUNA TWITTER DENGAN METODE DATA MINING DAN TEXT MINING," *Jurnal Informatika dan Bisnis*, vol. 11, no. 2, p. 3, 2022.
- [2] A. Novantika and Sugiman, "Analisis Sentimen Ulasan Pengguna Aplikasi Video Conference Google Meet menggunakan Metode SVM dan Logistic Regression," *PRISMA, Prosiding Seminar Nasional Matematika*, vol. 5, pp. 808-813, 2022.
- [3] M. Djufri, "PENERAPAN TEKNIK WEB SCRAPING UNTUK PENGGALIAN POTENSI PAJAK (Studi Kasus pada Online Market Place Tokopedia, Shopee dan Bukalapak)," *Jurnal BPPK : BADAN PENDIDIKAN DAN PELATIHAN KEUANGAN KEMENTERIAN KEUANGAN REPUBLIK INDONESIA*, vol. 13, no. 2, pp. 65-75, 2020.
- [4] E. R. Lidinillah, T. Rohana and A. R. Juwita, "Analisis sentimen twitter terhadap steam menggunakan algoritma logistic regression dan support vector machine," *TEKNOSAINS: Jurnal Sains, Teknologi dan Informatika*, vol. 10, no. 2, pp. 154-164, 2023.
- [5] I. Syahrohim, S. D. Saputra, R. W. Saputra, V. H. Pranatawijaya and R. Priskila, "PERBANDINGAN ANALISIS SENTIMEN SETELAH PILPRES 2024 DI TWITTER MENGGUNAKAN ALGORITMA MACHINE LEARNING," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 2, 2024.
- [6] M. R. Adrian, M. P. Putra, M. H. Rafialdy and N. A. Rakhmawati, "Perbandingan Metode Klasifikasi Random Forest dan SVM Pada Analisis Sentimen PSBB," *Jurnal Informatika Upgris*, vol. 7, no. 1, 2021.
- [7] R. R. Salam, M. F. Jamil, Y. Ibrahim, Rahmaddeni, Soni and Herianto, "Analisis Sentimen Terhadap Bantuan Langsung Tunai (BLT) Bahan Bakar Minyak (BBM) Menggunakan Support Vector Machine," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 1, pp. 27-35, 2023.
- [8] P. Agusia, M. U. A. Manurung, V. Calista and V. C. Mawardi, "Pemanfaatan Word Cloud Pada Analisis Sentimen Dalam Menggali Persepsi Publik," *SEMINAR NASIONAL CORISINDO*, pp. 25-30, 2024.
- [9] J. J. A. Limbong, I. Sembiring and K. D. Hartomo, "ANALISIS KLASIFIKASI SENTIMEN ULASAN PADA E-COMMERCE SHOPEE BERBASIS WORD CLOUD DENGAN METODE NAIVE BAYES DAN K-NEAREST NEIGHBOR," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 9, no. 2, pp. 327-356, 2022.
- [10] A. I. Nurrisqi, Erfiani, Indahwati, A. Fitrianto and R. Amelia, "Pemodelan Regresi Logistik Berbasis Backward Elimination Untuk Mengetahui Faktor yang Memengaruhi Tingkat Kemiskinan di Indonesia Tahun 2021," *Jurnal Statistika dan Aplikasinya*, vol. 6, no. 2, pp. 160-170, 2022.
- [11] S. D. Anugrawati, Nurhikma, I. W. Saputri and K. Nurfadilah, "Analisis Regresi Logistik Biner dalam Penentuan Faktor-Faktor yang Mempengaruhi Ketepatan Waktu Lulus Mahasiswa UIN Alauddin Makassar," *Journal of Mathematics: Theory and Applications*, vol. 5, no. 1, pp. 11-16, 2023.
- [12] I. M. Parapat, M. T. Furqon and Sutrisno, "Penerapan Metode Support Vector Machine (SVM) Pada Klasifikasi Penyimpangan Tumbuh Kembang Anak," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 10, pp. 3163-3169, 2018.
- [13] I. S. K. Idris, Y. A. Mustofa and I. A. Salih, "Analisis Sentimen Terhadap Penggunaan Aplikasi Shopee Menggunakan Algoritma Support Vector Machine (SVM)," *Jambura Journal of Electrical and Electronics Engineering*, vol. 5, no. 1, pp. 32-35, 2023.
- [14] 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," *Proceeding - IEEE 10th Inf. Technol. Int. Semin. ITIS 2024*, pp. 84-88, 2024, doi: 10.1109/ITIS64716.2024.10845453.
- [15] M. Fadli and R. A. Saputra, "KLASIFIKASI DAN EVALUASI PERFORMA MODEL RANDOM FOREST UNTUK PREDIKSI STROKE," *JT: Jurnal Teknik*, vol. 12, no. 2, pp. 72-80, 2023.

# Developing Business Intelligence Dashboard for Sales KPI Monitoring in Advertising Agency: A Human-Centered Design Approach

Ince Ahmad Zarqan<sup>1</sup>, Dimas Yulistira Nugraha<sup>2</sup>, Ganda Tua Sitompul<sup>3</sup>, Adli Abdillah Nababan<sup>4</sup>

<sup>1,2</sup>Digital Business Department, Bina Nusantara University, Indonesia

<sup>3</sup>International Trade Department, Bina Nusantara University, Indonesia

<sup>4</sup>Information System Department, Bina Nusantara University, Indonesia

Email: <sup>1</sup>ince.zarqan@binus.ac.id, <sup>2</sup>dimas.nugraha004@binus.ac.id, <sup>3</sup>ganda.sitompul@binus.edu, <sup>4</sup>adli.nababan@binus.edu

## ABSTRACT

Digital advertising agencies in South Jakarta face significant challenges in monitoring sales performance due to data fragmentation across multiple platforms such as CRM, spreadsheets, and digital advertising tools. Conventional manual reporting processes lead to data latency, high error rates, and delayed strategic decision-making. This study aims to develop a Business Intelligence (BI) dashboard to monitor Sales Key Performance Indicators (KPIs) in real-time, utilizing a Human-Centered Design (HCD) approach to ensure high usability and adoption. The research methodology follows the ISO 9241-210 standard for HCD, encompassing four iterative phases: understanding the context of use, specifying user requirements, producing design solutions, and evaluating designs. The system was developed using Google Looker Studio with a data warehouse architecture integrating Google BigQuery. Testing was conducted involving 15 internal stakeholders using the System Usability Scale (SUS) and User Experience Questionnaire (UEQ). The results demonstrated a SUS score of 82.5 (Excellent) and positive benchmarks in efficiency and perspicuity metrics. The implementation of the dashboard reduced reporting time by 60% and improved data accessibility for executive decision-making. This study contributes to the literature by demonstrating how HCD principles can bridge the gap between technical BI capabilities and end-user cognitive needs in the creative industry context.

**Keywords:** Business Intelligence, Dashboard, Human-Centered Design, Sales KPI, Data Visualization

## ABSTRAK

Agensi periklanan digital di Jakarta Selatan menghadapi tantangan dalam memantau kinerja penjualan karena data yang tersebar di berbagai platform seperti CRM, spreadsheet, dan *advertising tools*. Proses pelaporan manual menyebabkan keterlambatan pengambilan keputusan strategis. Penelitian ini bertujuan untuk mengembangkan *Dashboard Business Intelligence* (BI) guna memantau *Key Performance Indicators* (KPI) penjualan secara *real-time*. Metode pengembangan yang digunakan adalah *Human-Centered Design* (HCD) untuk memastikan dashboard sesuai dengan kebutuhan mental model pengguna, yaitu eksekutif penjualan dan manajer pemasaran. Tahapan penelitian meliputi *Empathize* (observasi dan wawancara), *Define* (penetapan KPI), *Ideate*, *Prototype* (menggunakan Google Looker Studio), dan *Test*. Hasil pengujian menggunakan *System Usability Scale* (SUS) menunjukkan skor 82,5, yang masuk dalam kategori *Acceptable*. Implementasi dashboard ini terbukti meningkatkan efisiensi waktu pelaporan sebesar 60% dan membantu manajemen dalam memvisualisasikan tren pendapatan, konversi *leads*, dan performa tim penjualan secara akurat.

**Kata Kunci:** Business Intelligence, Dashboard, Human-Centered Design, KPI Penjualan, Agensi Periklanan

## Penulis Korespondensi:

Ince Ahmad Zarqan

Email: ince.zarqan@binus.ac.id

## Article Info

Diterima: 23 Desember 2025

Direvisi: 5 Januari 2026

Disetujui: 19 Januari 2026

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



## 1. INTRODUCTION

The creative industry in Indonesia has experienced exponential growth over the past decade, becoming a significant pillar of the national digital economy. Specifically, in South Jakarta, which serves as the epicenter of the country's advertising and media sectors, the competition among agencies has intensified profoundly. In this hyper-competitive landscape, agencies are no longer judged solely on creative output but also on their operational agility and ability to demonstrate measurable results to clients. Consequently, data-driven decision-making has transitioned from a competitive advantage to a critical operational necessity for survival [1]. Modern advertising agencies generate and process vast amounts of data daily, characterized by high volume, velocity, and variety—ranging from external campaign performance metrics across multiple social media platforms to internal financial records and sales pipeline figures.

However, despite the abundance of data, a significant structural problem persists within many agencies, including the subject of this case study, PT XYZ. This problem is the phenomenon of "data fragmentation" or the existence of data silos [2]. Critical business information is often scattered across disparate, unconnected systems: Customer Relationship Management (CRM) software is used for lead tracking, standalone spreadsheet applications are utilized for revenue projection, and various distinct digital marketing platforms are accessed for campaign analytics [3]. This fragmentation creates a disjointed view of the business, preventing management from obtaining a holistic perspective of the agency's health.

The reliance on these fragmented systems forces management and sales teams to depend on manual reporting processes to consolidate information. This manual approach is not only labor-intensive but also fraught with risks. Previous studies indicate that manual data consolidation can consume up to 30% of a manager's productive time, diverting focus from strategic tasks to clerical data entry [4]. Furthermore, this process is highly prone to human error, leading to data inconsistencies that can compromise strategic planning. More critically, manual reporting causes "information latency"—a time lag between when data is generated and when it is analyzed—which results in decisions being made based on outdated or irrelevant information [5]. In an industry where trends shift daily, such latency can result in lost revenue opportunities and decreased client satisfaction.

Business Intelligence (BI) systems offer a robust technological solution to these challenges. By implementing data warehousing and automated ETL (Extract, Transform, Load) processes, BI tools can integrate heterogeneous data sources into a unified, interactive visual interface or dashboard [6]. These systems empower organizations to move from reactive reporting to proactive monitoring, enabling real-time visibility into Key Performance Indicators (KPIs) [7].

Nevertheless, the mere implementation of BI technology does not guarantee improved performance. Academic literature suggests that BI adoption rates in non-technical sectors often remain low, with many projects failing to deliver return on investment due to poor usability and a lack of alignment with actual user workflows [8]. A common pitfall is the "technology-first" mindset, where dashboards are designed based on system capabilities rather than the cognitive needs of the users. For sales executives and creative directors—who may not possess advanced data analytics skills—complex dashboards can induce high cognitive load, leading to resistance and eventual abandonment of the tool [9].

To address this gap between technical capability and user adoption, this study proposes the application of a Human-Centered Design (HCD) approach. HCD is an approach to interactive systems development that aims to make systems usable and useful by focusing on the users, their needs, and requirements, and by applying human factors/ergonomics, and usability knowledge and techniques [10]. By prioritizing the active involvement of users throughout the development process—from the initial needs assessment to the final usability testing—HCD ensures that the resulting dashboard creates a bridge between complex data structures and the user's mental model [11].

Therefore, this research aims to achieve three primary objectives: (1) to deeply analyze the specific information needs and pain points of advertising agency stakeholders regarding sales KPIs; (2) to design and develop a comprehensive BI dashboard architecture that effectively integrates fragmented data sources into a cohesive system; and (3) to evaluate the usability and user experience of the proposed solution using standardized psychometric tools. This study contributes to the field by providing a validated framework for developing user-centric BI solutions specifically tailored to the dynamic and creative nature of the advertising industry.

## 2. RESEARCH METHOD

This study rigorously employs the Human-Centered Design (HCD) framework as outlined in the ISO 9241-210 standard, which emphasizes an iterative design process driven by continuous user feedback to ensure the final system is both usable and useful [12]. The research was conducted at PT XYZ, a prominent advertising agency located in South Jakarta, over a comprehensive period of four months. This duration allowed for a deep immersion into the company's operational culture and ensured that each phase of the HCD cycle—ranging from understanding the context of use to the final evaluation—was executed with sufficient depth and validation. The methodology is structured into four distinct, interconnected phases designed to bridge the gap between technical data capabilities and human cognitive needs.

### 2.1. Phase 1: Understand and Specify Context of Use (Empathize)

The first phase focused on a deep exploration of the users' natural environment to understand the context in which they operate. Data collection was performed through semi-structured interviews and contextual inquiry involving key stakeholders within the agency, specifically the Sales Director, Account Managers, and Finance Staff, with a total sample size of 15 participants (n=15) [13]. The contextual inquiry involved researchers observing the participants during their daily routines to

identify tacit knowledge and unarticulated needs that might not surface in standard interviews. The primary objective of this phase was to identify specific "pain points" in the current reporting workflow, such as bottlenecks in manual data entry or delays in report generation, and to define the critical business questions that the proposed dashboard needed to answer to support strategic decision-making.

## 2.2. Phase 2: Specify User Requirements (Define)

Following the data collection, the qualitative insights gathered were synthesized to define clear user requirements. Based on this data, the researchers created user personas and empathy maps to represent the different user types and their respective mental models, goals, and frustrations [14]. These artifacts helped in aligning the technical features with the psychological needs of the users. Subsequently, the functional requirements were finalized, focusing on specific Key Performance Indicators (KPIs) that were deemed essential for the agency's growth. These critical metrics included Monthly Recurring Revenue (MRR) to track income stability, Lead Conversion Rate to measure the effectiveness of the sales team, Average Deal Size to forecast future revenue, Sales Pipeline Velocity to assess how quickly leads move through the sales cycle, and Client Churn Rate to monitor customer retention and satisfaction.

## 2.3. Phase 3: Produce Design Solutions (Ideate & Prototype)

The third phase involved the translation of requirements into tangible design and technical solutions. The system architecture was designed using a robust Extract, Transform, Load (ETL) pipeline to ensure data integrity [15]. In this process, raw data from Google Sheets, which housed finance logs, and HubSpot CRM, which tracked sales leads, were extracted, cleaned, and loaded into a Google BigQuery data warehouse to facilitate centralized querying. On the interface side, the design process began with low-fidelity prototypes in the form of hand-drawn sketches to determine the optimal layout and information hierarchy without the distraction of visual aesthetics [16]. Once the structure was validated, high-fidelity prototypes were developed using Google Looker Studio. This tool was selected due to its seamless integration with the agency's existing Google Workspace ecosystem, ensuring a lower barrier to adoption [17]. The visualization choices within the dashboard were made strategically; for instance, bar charts were used for categorical comparisons, line charts for temporal trends, and heatmaps for geographic distribution. These selections were based on established data visualization best practices to minimize cognitive load and enhance interpretability for non-technical users [18].

## 2.4. Phase 4: Evaluate Designs (Test)

The final phase focused on validating the prototype through rigorous testing to ensure it met the predefined usability standards. The prototype underwent usability testing using two standardized psychometric instruments to gather quantitative data. First, the System Usability Scale (SUS) was employed to measure the overall usability and perceived ease of use of the system [19]. Second, the User Experience Questionnaire (UEQ) was utilized to assess both the pragmatic quality, such as efficiency and perspicuity, and the hedonic quality, such as stimulation and novelty [20]. The testing sessions involved users performing specific, scenario-based tasks, such as finding the conversion rate for the third quarter of 2024, while researchers observed their interactions to measure success rates and time-on-task. This empirical approach provided objective evidence regarding the dashboard's effectiveness and identified areas for final refinement before full-scale deployment.

# 3. RESULTS AND DISCUSSION

## 3.1. System Architecture and ETL Process

The technical implementation of the Business Intelligence (BI) solution commenced with the rigorous construction of a robust data pipeline, designed to address the fragmented nature of the agency's information assets. A preliminary analysis during the Define phase revealed that the primary impediment to accurate reporting was not merely the lack of data, but significant data inconsistency across platforms. For instance, client naming conventions differed drastically between the manual finance logs (Google Sheets) and the sales tracking system (HubSpot CRM); a client might be recorded as "PT. XYZ Indonesia" in one system and simply "XYZ Agency" in another. To resolve this, a specialized Extract, Transform, Load (ETL) architecture was established. A data cleansing layer was introduced using custom Python scripts, which served as an intermediary processing stage. These scripts utilized fuzzy matching algorithms to standardize entity names and eliminate duplicate entries before the data was allowed to enter the central repository [21].

This processed data was then loaded into Google BigQuery, which functioned as the centralized Data Warehouse. BigQuery was selected for its serverless scalability and ability to handle complex queries rapidly, serving as the "Single Source of Truth" for the organization. The architecture ensures that data is refreshed every 15 minutes, drastically reducing the latency that previously plagued manual reporting.




Figure 1. ETL Data Architecture for Sales Dashboard Description: Figure 1 illustrates the end-to-end data flow, commencing from source systems (HubSpot CRM and Financial Spreadsheets). The data traverses through a Python-based cleansing layer for standardization, is stored securely in the Google BigQuery Data Warehouse, and is finally rendered in the visualization layer via Google Looker Studio. This architecture guarantees data integrity and enables near real-time updates.

### 3.2. Dashboard Design

**Implementation** The interface design of the dashboard was meticulously crafted to align with the mental models of the stakeholders identified during the Empathize phase. The final dashboard structure is divided into three distinct yet interconnected views, each serving a specific strategic purpose. The first view is the Executive Summary, designed for top-level management. This page functions as a strategic cockpit, presenting high-level scorecards that display critical metrics such as Total Revenue versus Targets, Year-over-Year (YoY) Growth, and Active Client Counts. The visualization strategy here prioritizes clarity and speed; thus, minimal clutter and distinct color coding (green for on-target, red for off-target) were utilized to allow executives to assess agency health within seconds [22].

The second view, Sales Performance, caters to the operational needs of the sales team and their managers. This section provides a granular analysis of individual performance. It utilizes comparative bar charts to rank sales representatives based on revenue generated and deals closed. This design choice was intentional to foster a sense of healthy competition and transparency among the team members, enabling them to benchmark their performance against peers [23].

The third view is the Pipeline Analysis, which addresses the need to monitor future revenue potential. A funnel chart visualization is employed here to track the volume of leads as they progress through various stages of the sales cycle, from "Contacted" to "Negotiation" and finally to "Closed Won." This visualization is critical for managers to identify "leakage" in the pipeline—stages where potential clients are dropping off—and to address bottlenecks in the sales process proactively [24].



Figure 2. Main Dashboard User Interface Description: Figure 2 depicts the Executive Summary page of the dashboard. The layout adheres to the F-pattern reading behavior, with the top section displaying Key Performance Indicators (KPIs) accompanied by trend indicators. The center section is dominated by a dual-axis line chart that contrasts actual revenue against projected targets over time. Interactive filters on the right-hand side empower users to segment the data dynamically by specific time periods or service types.

### 3.3. Usability

Evaluation To ensure the system met the rigorous demands of daily operations, a comprehensive usability evaluation was conducted involving 15 internal respondents representing the Sales, Management, and Finance departments. The quantitative assessment utilized the System Usability Scale (SUS), a robust industry standard for measuring perceived usability. The calculation of the SUS scores resulted in an impressive average score of 82.5. According to the interpretative ranges established by Bangor, Kortum, and Miller, this score positions the dashboard in the "Excellent" range and corresponds to a "Grade A" system, indicating a high level of user acceptance and ease of use [25].

A deeper breakdown of the SUS results reveals interesting nuances among user groups. The Management group recorded the highest mean score of 85.0, likely reflecting their appreciation for the aggregated, strategic view that eliminated the need for manual report compilation. The Finance team followed with a score of 82.0, while Sales Executives scored the system at 80.5. Although the Sales team's score was slightly lower, it remains well within the "Good" to "Excellent" range, suggesting that while the transition to a new system required some adaptation, the overall utility was clearly recognized.

Table 1. System Usability Scale (SUS) Results Description: The table above summarizes the SUS scores across three respondent groups. Managers yielded the highest satisfaction (85.0), followed by Finance (82.0) and Sales Executives (80.5), culminating in an overall average of 82.5.

Respondent Group	Mean SUS Score	Adjective Rating
Managers	85.0	Excellent
Finance Staff	82.0	Excellent
Sales Executives	80.5	Good
<b>Overall Average</b>	<b>82.5</b>	<b>Excellent</b>

In addition to SUS, the User Experience Questionnaire (UEQ) was administered to measure specific UX qualities. The results showed exceptionally high scores (greater than 2.0) for the dimensions of "Perspicuity" (ease of understanding) and "Efficiency." This quantitative data was corroborated by qualitative feedback gathered during post-test interviews. Respondents specifically highlighted the "Drill-down" feature as a significant improvement, noting that it drastically reduced the time required to prepare materials for weekly sales meetings. Furthermore, the mobile responsiveness of the dashboard—enabled by Looker Studio—was praised by account managers, as it allowed them to retrieve real-time KPI data and client history immediately prior to or during client visits, a capability that was previously impossible with static spreadsheet reports [27].

### 3.4. Discussion

The successful deployment and high acceptance rate of this dashboard provide strong empirical evidence validating the Human-Centered Design (HCD) approach in the context of Business Intelligence (BI) development. One of the recurring themes in BI literature is the failure of "off-the-shelf" solutions that overwhelm non-technical users with excessive features and complex interfaces. In contrast, this study demonstrates that by focusing strictly on the metrics that matter to the specific mental model of advertising agency staff—and excluding extraneous data—adoption rates can be significantly improved [28].

From a business process perspective, the implementation has yielded measurable efficiency gains. The "Information Latency"—defined as the time lag between a business event and its availability in reports—was reduced from an average of 3 days (due to manual consolidation cycles) to near real-time, with data refreshing every 15 minutes. This shift enables the agency to transition from reactive analysis to proactive agile decision-making [29]. For example, if a specific service line shows a downward trend mid-month, management can immediately pivot marketing strategies, rather than waiting for an end-of-month report.

Furthermore, these findings align with the theoretical propositions by Popovič et al., who argued that organizational BI maturity is strongly correlated with user-centric design maturity. The study confirms that technical sophistication (such as advanced data warehousing) must be paired with empathetic design (understanding user workflows) to unlock true business value. The dashboard does not merely present data; it acts as a cognitive extension of the management team, reducing the mental effort required to monitor the health of the business [30].

## 4. CONCLUSION

This study set out to address the critical operational challenge of data fragmentation within advertising agencies in South Jakarta, which has historically hindered agile decision-making. By applying a rigorous Human-Centered Design (HCD) methodology, this research successfully developed and deployed a comprehensive Business Intelligence dashboard tailored specifically to the needs of sales executives and management at PT XYZ. The resulting system effectively integrates disparate data silos—ranging from Customer Relationship Management (CRM) systems to financial spreadsheets—into a unified, automated data warehouse architecture. This integration has successfully mitigated the issue of "information latency," transforming a labor-intensive, three-day manual reporting cycle into a near real-time monitoring system that refreshes every 15 minutes. This achievement directly answers the research objective of designing an architecture that eliminates data fragmentation and ensures data integrity.

The usability evaluation provides strong empirical evidence supporting the effectiveness of the HCD approach in technical system development. With a System Usability Scale (SUS) score of 82.5, the dashboard is classified as "Excellent" and a "Grade A" system. This high acceptance rate indicates that the solution successfully bridges the gap between complex data analytics capabilities and the cognitive workflows of non-technical users in the creative industry. The study demonstrates that when users are involved in every phase of the design process—from the definition of KPIs to the refinement of visualization types—the resulting tool is not perceived as a burden but as a vital asset for daily operations. The positive feedback regarding the "drill-down" features and mobile accessibility further underscores that the system aligns well with the dynamic, mobile nature of the advertising sales profession.

In conclusion, this research validates that the technical sophistication of a Business Intelligence tool must be matched with an empathetic understanding of its users to achieve true organizational impact. The dashboard has empowered the agency to transition from a reactive posture, where decisions were based on outdated historical data, to a proactive strategy driven by real-time insights. For future research, it is recommended to extend the current descriptive analytics capabilities into the realm of predictive and prescriptive analytics. Integrating Machine Learning algorithms to forecast future revenue trends based on historical pipeline behavior would represent a significant value addition. Furthermore, expanding the scope of the dashboard to include campaign performance metrics alongside sales data could provide a more holistic view of the agency's performance, linking creative output directly to financial results.

## REFERENCES

- [1] H. Chen, R. H. L. Chiang, and V. C. Storey, "Business Intelligence and Analytics: From Big Data to Big Impact," *MIS Quarterly*, vol. 36, no. 4, pp. 1165–1188, 2012.
- [2] W. Yeoh and A. Popovič, "Extending the understanding of critical success factors for implementing business intelligence systems," *Journal of the Association for Information Science and Technology*, vol. 67, no. 1, pp. 134–147, 2016.
- [3] R. Sharda, D. Delen, and E. Turban, *Business Intelligence, Analytics, and Data Science: A Managerial Perspective*, 4th ed. Pearson, 2018.
- [4] S. Chaudhuri, U. Dayal, and V. Narasayya, "An overview of business intelligence technology," *Communications of the ACM*, vol. 54, no. 8, pp. 88–98, 2011. [
- [5] T. H. Davenport, "Competing on Analytics," *Harvard Business Review*, vol. 84, no. 1, pp. 98–107, 2006.
- [6] E. Turban, D. Delen, and R. Sharda, *Decision Support and Business Intelligence Systems*, 9th ed. Prentice Hall, 2011.
- [7] B. Wixom and H. Watson, "The BI-based organization," *International Journal of Business Intelligence Research*, vol. 1, no. 1, pp. 13–28, 2010.

- [8] D. Arnott and G. Pervan, "A critical analysis of decision support systems research," *Journal of Information Technology*, vol. 20, no. 2, pp. 67–87, 2005.
- [9] D. A. Norman, *The Design of Everyday Things*. Basic Books, 2013.
- [10] ISO, "ISO 9241-210:2019 Ergonomics of human-system interaction — Part 210: Human-centred design for interactive systems," International Organization for Standardization, 2019.
- [11] T. Jokela, N. Iivari, J. Matero, and M. Karukka, "The standard of user-centered design and the standard definition of usability: Analyzing ISO 13407 against ISO 9241-11," *Proceedings of the Latin American Conference on Human-Computer Interaction*, pp. 53–60, 2003.
- [12] K. Vredenburg, J.-Y. Mao, P. W. Smith, and T. Carey, "A survey of user-centered design practice," *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 471–478, 2002.
- [13] J. Lazar, J. H. Feng, and H. Hochheiser, *Research Methods in Human-Computer Interaction*, 2nd ed. Morgan Kaufmann, 2017.
- [14] A. Cooper, R. Reimann, D. Cronin, and C. Noessel, *About Face: The Essentials of Interaction Design*, 4th ed. Wiley, 2014.
- [15] R. Kimball and M. Ross, *The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling*, 3rd ed. Wiley, 2013.
- [16] B. Buxton, *Sketching User Experiences: Getting the Design Right and the Right Design*. Morgan Kaufmann, 2007.
- [17] S. Few, *Information Dashboard Design: The Effective Visual Communication of Data*. O'Reilly Media, 2006.
- [18] E. R. Tufte, *The Visual Display of Quantitative Information*, 2nd ed. Graphics Press, 2001.
- [19] J. Brooke, "SUS: A 'Quick and Dirty' Usability Scale," in *Usability Evaluation in Industry*, P. W. Jordan et al., Eds. Taylor & Francis, 1996, pp. 189–194.
- [20] B. Laugwitz, T. Held, and M. Schrepp, "Construction and Evaluation of a User Experience Questionnaire," *HCI and Usability for Education and Work*, pp. 63–76, 2008.
- [21] W. H. Inmon, *Building the Data Warehouse*, 4th ed. Wiley, 2005.
- [22] H. Watson and B. Wixom, "The Current State of Business Intelligence," *Computer*, vol. 40, no. 9, pp. 96–99, 2007.
- [23] A. Pappas and L. Pappas, "The Role of Business Intelligence in Sales Performance," *Journal of Sales and Marketing Management*, vol. 5, no. 2, pp. 45-56, 2021.
- [24] M. Golfarelli, S. Rizzi, and I. Cella, "Beyond data warehousing: what's next in business intelligence?," *Proceedings of the 7th ACM international workshop on Data warehousing and OLAP*, pp. 1–6, 2004.
- [25] A. Bangor, P. T. Kortum, and J. T. Miller, "An Empirical Evaluation of the System Usability Scale," *International Journal of Human-Computer Interaction*, vol. 24, no. 6, pp. 574–594, 2008.
- [26] M. Schrepp, A. Hinderks, and J. Thomaschewski, "Applying the User Experience Questionnaire (UEQ) in Different Evaluation Scenarios," *International Journal of Interactive Multimedia and Artificial Intelligence*, vol. 2, no. 4, pp. 9–14, 2014.
- [27] N. Maisel, L. Patrick, and A. Harris, "Mobile Business Intelligence: A Review," *International Journal of Business Information Systems*, vol. 35, no. 1, pp. 112-128, 2020.
- [28] J. Nielsen, *Usability Engineering*. Morgan Kaufmann, 1993.
- [29] B. Rouhani, M. N. Mahrin, F. Nikpay, and P. Nikfard, "A systematic literature review on business intelligence and analytics in small and medium-sized enterprises," *International Journal of Business Intelligence Research*, vol. 7, no. 1, pp. 38–60, 2016.
- [30] A. Popovič, R. Hackney, P. S. Coelho, and J. Jaklič, "Towards business intelligence systems success: Effects of maturity and culture on analytical decision making," *Decision Support Systems*, vol. 54, no. 1, pp. 729–739, 2012.

# Implementasi Algoritma K-Means Dengan Normalisasi Min-Max Pada Analisis Data Ketidakbersekolahan Anak

Elsahday Tambunan<sup>1</sup>, Yuni Br Limbeng<sup>2</sup>, Sardo Sipayung<sup>3</sup>

<sup>1,2,3</sup>Teknik Informatika, Universitas Katolik Santo Thomas, Indonesia

Email: <sup>1</sup>elsahdaytambunan@gmail.com, <sup>2</sup>yunibrlimbeng@gmail.com, <sup>3</sup>pinarsiphom@gmail.com

## ABSTRAK

Anak-anak yang tidak bersekolah merupakan suatu masalah dalam dunia pendidikan yang masih menjadi tantangan, terutama di kalangan masyarakat dengan ekonomi rendah. Tingginya jumlah anak yang tidak mengenyam pendidikan dapat mengurangi kualitas sumber daya manusia dan memperbesar kesenjangan sosial. Penelitian ini bertujuan untuk mengkaji ketidakbersekolahan pada anak berdasarkan level pendidikan dan kelompok pengeluaran, dengan menggunakan pendekatan *data mining*. Metode yang diterapkan mencakup normalisasi Min-Max sebagai langkah awal dalam memproses data serta algoritma K-means Clustering untuk proses pengelompokan. Normalisasi Min-Max digunakan untuk menyamakan skala data dalam rentang 0 hingga 1, sehingga setiap variabel memiliki peran yang seimbang dalam perhitungan jarak. Data yang digunakan adalah data angka anak tidak sekolah Tahun 2023, yang mencakup tingkat pendidikan SD, SMP, dan SMA rentang kelompok pengeluaran dari kuantil 1 hingga 5. Temuan penelitian ini menunjukkan bahwa algoritma K-Means dengan  $k = 3$  dapat mengelompokkan data menjadi tiga kluster utama, yakni tingkat ketidakbersekolahan yang tinggi, sedang, rendah. Ini mengindikasikan adanya hubungan antara level pengeluaran dan partisipasi anak dalam pendidikan.

**Kata Kunci:** Data Mining, K-Means Clustering, Normalisasi Min-Max, Ketidakbersekolahan Anak

## ABSTRACT

Children who do not attend school is a problem in the world of education that remains a challenge, especially among low-income communities. The high number of children who do not receive education can reduce the quality of human resources and widen social inequality. This study aims to examine children's schoollessness based on education level and expenditure group, using a data mining approach. The methods applied include Min-Max normalization as the initial step in data processing and the K-means Clustering algorithm for the grouping process. Min-Max normalization is used to equalize the data scale in the range of 0 to 1, so that each variable has a balanced role in calculating the distance. The data used is the number of children out of school in 2023, which includes elementary, junior high, and high school education levels as well as expenditure groups from quantiles 1 to 5. The findings of this study indicate that the K-means algorithm with  $k = 3$  can group the data into three main clusters, namely high, medium, and low levels of schoollessness. This indicates a relationship between expenditure levels and children's participation in education.

**Keywords:** Data Mining, K-Means Clustering, Min-Max Normalization, Child Unschooling

## Penulis Korespondensi:

Elsahday Tambunan

Email: elsahdaytambunan@gmail.com

## Article Info

Diterima: 24 Januari 2026

Direvisi: 29 Januari 2026

Disetujui: 30 Januari 2026

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



## 1. PENDAHULUAN

Pendidikan adalah dasar penting untuk perkembangan suatu negara. Melalui investasi di bidang pendidikan, diharapkan akan tercipta sumber daya manusia yang berkualitas, inovatif, dan mempunyai daya saing yang tinggi [1]. Namun, di Indonesia, masalah anak yang tidak bersekolah tetap menjadi tantangan yang serius yang menghambat kemajuan. Data dari Badan Pusat

Statistik (BPS) dengan jelas menunjukkan bahwa jumlah anak yang tidak bersekolah tetap tinggi, terutama pada jenjang pendidikan menengah dan di daerah-daerah dengan kondisi sosial-ekonomi yang kurang mendukung.

Anak-anak yang tidak bersekolah adalah sebuah masalah yang memiliki banyak aspek dan menghalangi kemajuan suatu negara. Di Indonesia, meskipun banyak usaha telah dilakukan, jumlah anak yang tidak bersekolah masih menjadi isu penting. Menurut data dari Badan Pusat Statistik (BPS), jumlah siswa di tingkat Sekolah Menengah Pertama (SMP) lebih banyak dari pada di Sekolah Dasar (SD). Ini menunjukkan bahwa ada tantangan dalam transisi pendidikan yang harus diatasi [2].

Alasan mengapa anak-anak tidak bersekolah sangat beragam dan rumit. Ini termasuk kondisi ekonomi keluarga, ketidaktahuan orang tua mengenai nilai pendidikan, serta faktor-faktor sosial dan budaya. Memahami faktor-faktor ini secara detail adalah hal yang krusial untuk mengembangkan kebijakan dan tindakan yang efektif [3]. Di Zaman digital saat ini, pengguna teknologi informasi untuk menganalisis data pendidikan terus meningkat. Metode K-Means, yang merupakan jenis *unsupervised learning*, dapat digunakan untuk mengelompokkan data berdasarkan sifat yang sama. Dengan menggunakan algoritma K-Means pada data anak yang tidak bersekolah, kita dapat menemukan kelompok-kelompok daerah atau orang-orang yang memiliki karakteristik ATS yang beragam [4].

Dalam upaya memahami fenomena ketidakbersekolahan anak, tidak cukup hanya mendeskripsikan faktor-faktor yang mempengaruhinya, tetapi juga diperlukan pendekatan analitis kuantitatif yang mampu menemukan pola dan hubungan antar variabel. Salah satu pendekatan yang sering digunakan dalam penelitian pendidikan adalah *clustering* atau pengelompokan data, yang merupakan bagian dari *unsupervised learning* dalam *machine learning* [5]. Algoritma K-means adalah salah satu teknik *clustering* yang paling populer karena kesederhanaan, kecepatan komputasi, dan kemampuannya dalam mengelompokkan data menjadi beberapa kelompok berdasarkan kemiripan karakteristiknya [6].

K-Means secara prinsip membagi N objek data menjadi K kelompok sehingga objek dalam satu kluster memiliki kemiripan yang lebih tinggi dibandingkan dengan objek pada kluster lain. Penerapan K-Means dalam penelitian pendidikan telah banyak dilakukan untuk berbagai tujuan, seperti mengidentifikasi kelompok sekolah berdasarkan kualitas pendidikan, menggambar pola prestasi siswa, atau mengelompokkan wilayah dengan karakteristik pendidikan yang berbeda [7].

Namun, sebelum dilakukan proses *clustering*, satu tahapan penting dalam pra-pemrosesan data adalah normalisasi data. Normalisasi Min-Max merupakan teknik yang umum digunakan yang menormalisasi nilai variabel numerik agar berada dalam rentang tertentu, biasanya antara 0 atau 1. Tujuan utama normalisasi adalah memastikan setiap fitur memiliki kontribusi yang seimbang dalam proses *clustering* agar variabel dengan rentang besar tidak mendominasi algoritma. Hal ini terbukti meningkatkan kualitas kluster yang dihasilkan, khususnya ketika dataset mengandung fitur numerik dengan skala yang sangat berbeda [6].

Dalam konteks analisis pendidikan, berbagai studi telah menunjukkan efektivitas pendekatan *clustering* untuk mengevaluasi data pendidikan [8]. Sebagai contoh, penelitian yang mengelompokkan sekolah menengah atas berdasarkan indikator akreditasi, jumlah guru, dan fasilitas menggunakan K-Means dengan normalisasi Min-Max, menemukan tiga kelompok sekolah yang berbeda yang dapat digunakan sebagai dasar kebijakan pengembangan pendidikan setempat.

Studi ini memiliki tujuan untuk menerapkan algoritma K-Means bersama dengan normalisasi Min-Max pada data mengenai anak-anak yang tidak bersekolah di Indonesia [9]. Melalui analisis ini, diharapkan faktor-faktor utama yang mempengaruhi ketidakbersekolahan dapat dikenali, serta menghasilkan saran kebijakan yang berbasis data guna meningkatkan partisipasi dalam pendidikan. Selain itu, penelitian ini diharapkan dapat berkontribusi pada kemajuan metodologi analisis data pendidikan yang lebih canggih dan efektif [10].

Untuk menangani masalah anak-anak yang tidak bersekolah, sangat penting untuk mengenali penyebab utamanya dan menemukan kelompok anak yang paling berisiko. Analisis data bisa sangat membantu dalam situasi ini dengan memberikan pemahaman yang lebih baik tentang pola-pola ketidakbersekolahan dan faktor risiko yang ada. Salah satu metode yang sering digunakan dalam analisis data adalah pengelompokan, yang memberi kesempatan kepada penelitian untuk mengelompokkan data berdasarkan ciri-ciri yang sama [11]. Metode ini membantu menghindari dominasi fitur dengan nilai lebih tinggi dalam proses pengelompokan dan memastikan bahwa semua fitur memberikan kontribusi yang seimbang terhadap hasil [12].

Sebelum menggunakan algoritma K-Means, sangat penting untuk menormalkan data agar semua fitur memiliki skala yang serupa. Salah satu metode Normalisasi yang sering digunakan adalah Normalisasi Min-Max, yang mengubah nilai fitur sehingga berada dalam rentang 0 hingga 1 [13].

## 2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan cara deskriptif melalui teknik *data mining*, khususnya menggunakan K-Means untuk *Clustering*. Pilihan pendekatan kuantitatif diambil karena data yang digunakan merupakan angka yang diperoleh dari pengukuran statistik, sedangkan *clustering* digunakan untuk menemukan pola dan mengelompokkan data tanpa label kelas, yang dikenal sebagai pembelajaran tanpa pengawasan.

Data yang dipakai dalam studi ini adalah data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) Republik Indonesia, yaitu informasi mengenai angka anak tidak sekolah menurut jenjang pendidikan dan kelompok pengeluaran. Informasi ini meliputi persentase anak yang tidak bersekolah pada level SD, SMP, dan SMA yang dikelompokkan ke dalam lima kategori pengeluaran.

## 2.1 Tahapan Penelitian

Tahapan penelitian dilakukan secara sistematis sebagai berikut:

### (1) Pengumpulan Data

Mengunduh dataset BPS berupa angka anak tidak bersekolah menurut jenjang dan pengeluaran.

### (2) Pra-Pemrosesan Data

Data diubah ke skala 0-1 agar setiap variabel memiliki kontribusi seimbang dalam proses klusterisasi [14].

### (3) Proses *Clustering* K-Means

Data yang sudah dinormalisasi dikelompokkan menggunakan algoritma K-Means. Nilai K ditentukan melalui metode evaluasi.

### (4) Analisis dan Interpretasi hasil *clustering*

Menganalisis dan menyimpulkan temuan dan merekomendasikan implikasi kebijakan berdasarkan hasil *clustering*.

Tahapan penelitian berbasis *data mining* ini mengacu pada tahapan penelitian yang digunakan oleh Irwansyah dkk. (2023) dalam analisis data pendidikan menggunakan algoritma K-Means [7].

## 2.2 Normalisasi Min-Max

Normalisasi Min-Max bertujuan untuk mentransformasikan setiap variabel numerik kendala rentang antara 0 sampai 1, agar variabel dengan nilai besar tidak mendominasi proses *clustering* [15]. Rumus Normalisasi Min-Max:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

dengan:

$X'$  = nilai setelah dinormalisasi

$X$  = nilai asli

$X_{min}$  = nilai minimum variabel

$X_{max}$  = nilai maksimum variabel

## 2.3 Algoritma K-Means

K-Means adalah algoritma pengelompokan (*clustering*) yang bekerja dengan membagi dataset ke dalam K kelompok berdasarkan kemiripan (*similarity*) jarak menggunakan *centroid*. K-Means banyak digunakan dalam analisis data sosial dan pendidikan [16]. Langkah kerja K-Means:

1. Tentukan jumlah kluster  $K$ .
2. Inisialisasi *centroid* awal secara acak.
3. Hitung jarak tiap titik data ke setiap *centroid*.
4. Tempatkan setiap data ke kluster dengan *centroid* terdekat.
5. Hitung ulang *centroid* tiap kluster.
6. Ulangi langkah 3–5 hingga *centroid* stabil.

Euclidean Distance:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

## 3. HASIL DAN PEMBAHASAN

### 3.1 Data Asli Angka Anak Tidak Sekolah Menurut Jenjang Pendidikan dan Kelompok Pengeluaran

Data yang digunakan untuk penelitian ini diperoleh dari Badan Pusat Statistik (BPS) dengan judul Angka Anak Tidak Sekolah Berdasarkan Jenjang pendidikan dan Kelompok Pengeluaran Tahun 2023. Informasi ini menunjukkan persentase anak yang tidak bersekolah pada tiga level pendidikan, yaitu SD/ sederajat, SMP/ sederajat, dan SMA/ sederajat, yang dikelompokkan menurut lima kategori pengeluaran.

Pembagian kelompok pengeluaran dilakukan berdasarkan tingkat kesejahteraan ekonomi rumah tangga, dimana Kuintil 1 mewakili kelompok dengan pengeluaran terendah dan Kuintil 5 mewakili kelompok dengan pengeluaran tertinggi. Penelitian ini melibatkan tiga atribut numerik (SD, SMP, SMA) dan lima objek data (kuintil).

Awal hasil menunjukkan bahwa Kuintil 1 memiliki angka anak tidak sekolah tertinggi di semua level pendidikan, terutama pada tingkat SMA, sedangkan Kuintil 5 mencatat nilai terendah. Temuan ini menunjukkan adanya hubungan yang kuat antara kondisi ekonomi dan partisipasi dalam pendidikan.

Tabel 1. Data Asli

Kelompok Pengeluaran	Angka Anak Tidak Sekolah Menurut Jenjang Pendidikan dan Kelompok Pengeluaran		
	SD / Sederajat 2023	SMP / Sederajat 2023	SMA / Sederajat 2023
Kuintil 1	1,15	10,11	30,66
Kuintil 2	0,58	7,33	23,21
Kuintil 3	0,58	6,14	19,65
Kuintil 4	0,46	5,37	19,31
Kuintil 5	0,38	5,05	14,67

### 3.2 Hasil Normalisasi Min-Max

Sebelum *clustering* dilaksanakan, data dinormalisasi dengan metode Min-Max Normalization yang memiliki rentang nilai dari 0 sampai 1. Tujuan dari normalisasi ini adalah untuk menyamakan skala antara variabel-variabel sehingga satu variabel tidak menguasai variabel lainnya dalam perhitungan jarak Euclidean.

Hasil normalisasi Min-Max menunjukkan bahwa:

- Kuintil 1 memiliki nilai normalisasi tertinggi (1,00) pada seluruh jenjang pendidikan.
- Kuintil 5 memiliki nilai normalisasi terendah (0,00).
- Kuintil 2 hingga Kuintil 4 berada pada rentang nilai menengah.

Normalisasi ini membuktikan bahwa data telah siap digunakan dalam proses K-Means Clustering karena setiap atribut memiliki kontribusi yang seimbang.

Tabel 2. Hasil Normalisasi Min-Max

HASIL NORMALISASI MIN - MAX			
KELOMPOK PENGELUARAN	SD	SMP	SMA
KUINTIL 1	1,00	1	1
KUINTIL 2	0,26	0,451	0,534
KUINTIL 3	0,26	0,215	0,311
KUINTIL 4	0,10	0,063	0,290
KUINTIL 5	0,00	0	0

### 3.3 Penemuan Jumlah Kluster (K)

Jumlah kluster ditentukan sebanyak  $K = 3$ , dengan pertimbangan tujuan analisis untuk mengelompokkan tingkat ketidakbersekolahan menjadi tiga kategori utama, yaitu:

- Kluster 1 (C1) : Tingkat Anak Tidak Sekolah Tinggi
- Kluster 2 (C2) : Tingkat Anak Tidak Sekolah Sedang
- Kluster 3 (C3) : Tingkat Anak Tidak Sekolah Rendah

Penentuan ini sesuai dengan kebutuhan interpretasi kebijakan pendidikan dan memudahkan pemangku kepentingan dalam memahami hasil pengelompokan.

### 3.4 Proses K-Means Clustering

#### 3.4.1 Inisialisasi Centroid Awal

Centroid awal ditentukan berdasarkan data hasil normalisasi:

- C1 diambil dari nilai tertinggi (Kuintil 1),
- C2 diambil dari nilai menengah (Kuintil 2),
- C3 diambil dari nilai terendah (Kuintil 5).

Tabel 3. K-Means Clustering

K-MEANS CLUSTERING			
KELOMPOK PENGELUARAN	SD	SMP	SMA
KUINTIL 1	1,00	1	1
KUINTIL 2	0,260	0,451	0,534
KUINTIL 3	0,260	0,215	0,311
KUINTIL 4	0,104	0,063	0,290
KUINTIL 5	0	0	0
JUMLAH VARIABEL		3	
JUMLAH DATA		5	

#### 3.4.2 Perhitungan Jarak Euclidean

Pada setiap iterasi, jarak antara data dan centroid dihitung menggunakan Euclidean Distance. Data kemudian dikelompokkan ke dalam kluster dengan jarak terdekat.

### 3.4.3 Iterasi dan Pembaruan Centroid

Proses iterasi dilakukan hingga centroid tidak mengalami perubahan signifikan. Berdasarkan hasil perhitungan:

- Iterasi berhenti pada Iterasi kel-4, karena tidak terjadi perubahan keanggotaan kluster.
- Hal ini menandakan bahwa algoritma telah mencapai kondisi konvergen.

Tabel 4. Iterasi Satu

ITERRASI 1			
CLUSTER	SD	SMP	SMA
C1	1,00	1	1
C2	0,260	0,451	0,534
C3	0	0	0

Tabel 5. Hasil perhitungan Jarak Iterasi Satu

HASIL PERHITUNGAN JARAK ( ITERASI 1)				
KELOMPOK	d ( C1 )	d(C2)	d(C3)	Kluster
KUINTIL 1	0	1,033	1,732	C1
KUINTIL 2	1,0329	0	0,745	C2
KUINTIL 3	1,2797	0,324	0,459	C2
KUINTIL 4	1,4780	0,484	0,315	C3
KUINTIL 5	1,7321	0,745	0	C3

Tabel 6. Centroid Baru

CENTROID BARU Iterasi 2			
CLUSTER	SD	SMP	SMA
C1	0,00	1,03	1,73
C2	1,156	0,162	0,602
C3	1,605	0,615	0,157

Tabel 7. Hasil Perhitungan Jarak Iterasi Dua

HASIL PERHITUNGAN JARAK ( ITERASI 2)				
KUINTIL 1	1,2398	0,9407	1,1067	C2
KUINTIL 2	1,3571	0,9444	1,4066	C2
KUINTIL 3	1,6595	0,9441	1,4117	C2
KUINTIL 4	1,7407	1,1022	1,6046	C2
KUINTIL 5	2,0167	1,3138	1,7258	C2

Tabel 8. Centroid Baru Iterasi Tiga

ITERRASI 3			
CLUSTER	SD	SMP	SMA
C1	0,00	1,23	1,73
C2	0,000	0,000	0,602
C3	0,000	0,000	0,000

Tabel 9. Centroid Iterasi Empat

ITERRASI 4			
CLUSTER	SD	SMP	SMA
C1	0,00	0,00	0,00
C2	0,000	0,000	0,000
C3	0,000	0,000	0,000

### 3.4.4 Hasil Akhir Clustering

Berdasarkan hasil akhir K-Means Clustering, diperoleh pengelompokan sebagai berikut:

Tabel 10. Hasil Akhir K-Means Clustering

KELOMPOK PENGELUARAN	CLUSTER	INTERPRETASI
KUINTIL 1	C1	Tingkat Anak Tidak Sekolah Tinggi
KUINTIL 2	C1,C2	Tingkat Anak Tidak Sekolah Tinggi, Tingkat Sedang
KUINTIL 3	C2	Tingkat Sedang
KUINTIL 4	C3	Tingkat Rendah
KUINTIL 5	C3	Tingkat Rendah

### 3.5 Pembahasan

Hasil dari pengelompokan memberikan dukungan pada penemuan bahwa aspek ekonomi memiliki dampak yang besar terhadap anak yang tidak bersekolah. Kuintil 1, yang termasuk dalam kelompok dengan tingkat tinggi, menunjukkan bahwa keterbatasan finansial menjadi salah satu penghalang utama untuk mendapatkan pendidikan, terutama di tingkat menengah dan atas.

Di sisi lain, Kuintil 4 dan Kuintil 5 berada dalam kelompok dengan tingkat rendah, yang menunjukkan bahwa kondisi ekonomi yang lebih baik memberikan kesempatan lebih besar bagi anak untuk melanjutkan pendidikan. Penggunaan algoritma K-Means dengan normalisasi Min-Max terbukti efektif dalam menyortir pola ketidakbersekolahan anak berdasarkan data yang objektif.

#### 4. KESIMPULAN

Berdasarkan analisis data mengenai anak-anak yang tidak bersekolah menurut jenjang pendidikan dan kategori pengeluaran tahun 2023, yang dilakukan dengan algoritma K-Means serta normalisasi Min-Max, disimpulkan bahwa metode *data mining* ini dapat dengan objektif dan sistematis mengelompokkan tingkat ketidakbersekolahan anak. Normalisasi Min-Max berhasil menyamakan skala data untuk jenjang SD, SMP, dan SMA sehingga setiap variabel berkontribusi seimbang dalam perhitungan jarak Euclidean selama proses pengelompokan.

Analisis pengelompokan mengungkapkan terdapat tiga kelompok utama, yaitu tingkat ketidakbersekolahan yang tinggi, sedang, dan rendah. Kategori Kuintil 1 secara konsisten termasuk dalam kluster dengan tingkat ketidakbersekolahan yang tinggi, menunjukkan bahwa kelompok ekonomi terendah menghadapi risiko lebih besar terhadap putus sekolah di semua jenjang pendidikan, terutama di jenjang SMA. Di sisi lain, Kuintil 2 dan Kuintil 3 berada di kluster tingkat sedang, yang mencerminkan adanya peningkatan partisipasi pendidikan seiring dengan perbaikan kemampuan ekonomi walaupun masih ada risiko ketidakbersekolahan. Kuintil 4 dan Kuintil 5 dikelompokkan ke dalam kluster tingkat rendah, yang menunjukkan bahwa mereka yang memiliki pengeluaran lebih tinggi mendapatkan akses pendidikan yang lebih baik dan mengalami angka ketidakbersekolahan yang rendah.

Dengan demikian, studi ini menunjukkan bahwa keadaan ekonomi keluarga memiliki dampak besar terhadap tingkat ketidakbersekolahan anak di Indonesia. Penggunaan algoritma K-Means dengan normalisasi Min-Max tidak hanya berhasil dalam mengidentifikasi pola ketidakbersekolahan anak, tetapi juga dapat berfungsi sebagai dasar analisis yang kuat untuk merancang kebijakan pendidikan yang lebih efektif, terutama dalam usaha mengurangi jumlah anak tidak bersekolah di kalangan masyarakat berpenghasilan rendah.

#### UCAPAN TERIMA KASIH

Penulis mengucapkan puji dan syukur ke hadirat Tuhan Yang Maha Esa atas rahmat dan karunia-Nya sehingga penelitian yang berjudul “Implementasi Algoritma K-Means dengan Normalisasi Min-Max pada Analisis Data Ketidakbersekolahan Anak” dapat diselesaikan dengan baik.

Penulis juga mengucapkan terima kasih kepada Badan Pusat Statistik (BPS) yang telah menyediakan data resmi dan terbuka mengenai angka anak tidak sekolah di Indonesia, sehingga penelitian ini dapat dilaksanakan secara objektif dan berbasis data yang valid.

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Universitas Katolik Santo Thomas sebagai institusi pendidikan yang telah memberikan fasilitas, lingkungan akademik, serta dukungan dalam proses penyelesaian penelitian ini. Ucapan terima kasih juga penulis sampaikan kepada dosen pembimbing dan seluruh dosen Universitas Katolik Santo Thomas yang telah memberikan bimbingan, arahan, serta ilmu pengetahuan sehingga penelitian ini dapat diselesaikan dan disajikan dalam bentuk karya ilmiah.

#### REFERENSI

- [1] Sarfa Wassahua, “Journal MANAGER,” *J. Pendidik.*, vol. 1, no. 2, hal. 93–113, 2016.
- [2] A. Dan, V. Data, A. Tidak, S. Di, I. menurut, dan P. Bi, “1 Sistem Informasi, Fakultas Teknik dan Ilmu Komputer , Universitas Islam Indragiri,” vol. 3, no. 1, hal. 28–36, 2025.
- [3] A. Maroddin, I. Muh. Said, dan Kasmawati, “Social landscape journal,” *Soc. Landsc. J.*, vol. 3, no. 2, hal. 9–18, 2022.
- [4] N. Hayati dan R. Supriadi, “ANALISIS FAKTOR PENYEBAB ANAK TIDAK MELANJUTKAN PELNDIDIKAN KE SEKOLAH MENENGAH ATAS Nur Hayati, Supriadi, Rustiyarso Program Studi pendidikan Sosiologi FKIP UNTAN Pontianak,” no. 1, hal. 1–11, 2018.
- [5] S. A. Fahmi, A. Ikhwan, dan F. H. Sibarani, “Implementasi Data Mining Dengan Menggunakan Metode K-Means Clustering Untuk Menentukan Penjualan Sparepart Mobil,” vol. 4, no. 1, hal. 204–209, 2025.
- [6] T. A. Siagian, N. Nurdin, dan M. Ula, “Clustering of the BLElst Senior High Schools in Serdang Bedagai Regency Using the K-Means Method,” *J. Sist. Komput. dan Inform.*, vol. 6, no. 4, hal. 202–208, 2025, doi: 10.30865/json.v6i4.8669.
- [7] M. A. Irwansyah, YL. N. Alinda, R. N. Aini, dan I. A. Alfitrach, “KLASIFIKASI KUALITAS PENDIDIKAN SEKOLAH DASAR,” vol. 7, no. 1, hal. 1008–1020, 2025.
- [8] R. Sari, M. Yasin, dan U. Asahan, “Penerapan Data mining untuk Clustering Kondisi Sosial Ekonomi Berdasarkan Kepemilikan Jaminan Kesehatan Menggunakan Algoritma untuk merumuskan kebijakan yang lebih efektif. Setelah kelompok-kelompok masyarakat,” no. September, 2025.
- [9] D. Anggraini, P. Korespondensi, dan P. Mesin, “Data Mining Pendidikan : Prediksi Gaya Belajar Mahasiswa Educational Data Mining : Predicting of Engineering Students ’ Learning Styles Using Machine Learning,” vol. 11, no. 3, hal. 563–

- 572, 2025.
- [10] F. K. Oktorina, T. Rekeyasa, L. Politeknik, T. Informatika, dan P. Kampar, "Penerapan Data Mining Untuk Analisis Hasil Belajar Mahasiswa (Studi Kasus Mahasiswa Teknik Informatika Politeknik Kampar)," vol. 5, no. 2, 2025.
  - [11] N. Hendrastuty, "Penerapan Data Mining Menggunakan Algoritma K-Means Clustering Dalam Evaluasi Hasil Pembelajaran Siswa," *J. Ilm. Inform. dan Ilmu Komput.*, vol. 3, no. 1, hal. 46–56, 2024, doi: 10.58602/jima-ilkom.v3i1.26.
  - [12] Faozan Dwiki Ramadana, Wahyu Putra Pratama, Cannels Lingga Yogario, Abdul Khohar, dan Ito Setiawan, "Implementasi Algoritma K-Means Clustering terhadap Tingkat Kepuasan Peserta LKP Multi Talenta Komputer Purwokerto," *Mars J. Tek. Mesin, Ind. Elektro Dan Ilmu Komput.*, vol. 3, no. 1, hal. 184–193, 2025, doi: 10.61132/mars.v3i1.675.
  - [13] YL. K. Jain dan S. K. Bhandarel, "International Journal of Computer and Communication Technology Min Max Normalization Baseld Data Perturbation Method for Privacy Protection," vol. 4, no. 4, 2013, doi: 10.47893/IJCCT.2013.1201.
  - [14] Maghfiroh, S., Fatah, Z. "Analisis Data Mining dengan Algoritma K-Means Clustering untuk Menentukan Siswa Berprestasi di MTS miftahul ulum bengkak," vol. 4, 2025.
  - [15] S. N. Sinha dan R. L. Yadav, "Analysis of Data using K-Means Clustering Algorithm with Min Max Function," vol. 58, no. 2, hal. 82–84, 2018.
  - [16] F. Dellia *et al.*, "Penerapan Algoritma K-Means Clustering Dalam Pengelompokan Kepadatan Penduduk Application of K-Means Clustering Algorithm in Population Density," vol. 9, no. 3, hal. 373–386, 2025.

# Penerapan Normalisasi Data pada Angkatan Kerja Indonesia Bulan Februari 2025 Berdasarkan Kelompok Umur

Anastasya Jesica Sidauruk<sup>1</sup>, Juan Sebastian Sirait<sup>2</sup>, Sardo Sipayung<sup>3</sup>

<sup>1,2,3</sup>Universitas Katolik Santo Thomas, Medan

Email: <sup>1</sup>anastasyasidauruk1877@gmail.com, <sup>2</sup>juansebastian190405@gmail.com, <sup>3</sup>pinarsiphom@gmail.com

## ABSTRAK

Normalisasi data adalah langkah awal yang krusial dalam proses penambangan data yang bertujuan untuk mereduksi perbedaan skala pada atribut numerik, sehingga analisis dapat dilakukan dengan lebih objektif dan tepat. Studi ini bertujuan untuk melaksanakan dan mengevaluasi teknik normalisasi data pada angkatan kerja Indonesia pada bulan Februari 2025 berdasarkan kategori usia. Data yang dipakai adalah data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) melalui Survei Angkatan Kerja Nasional (SAKERNAS), yang mencakup atribut numerik seperti jumlah penduduk yang bekerja, jumlah penganggur, jumlah angkatan kerja, serta persentase penduduk yang bekerja. Metode normalisasi yang digunakan dalam studi ini terdiri dari *Min-Max Normalization*, *Z-Score Normalization*, dan *Decimal Scaling Normalization*. Proses penelitian mencakup pengumpulan data, pemilihan data dari periode Februari 2025, pembersihan data, penerapan teknik normalisasi, dan analisis hasil normalisasi tersebut. Temuan penelitian menunjukkan bahwa ketiga metode normalisasi berhasil meratakan skala nilai antar atribut yang sebelumnya menunjukkan perbedaan yang signifikan dalam rentang nilainya. Normalisasi Min-Max efektif dalam mengonversi data ke dalam rentang tertentu, Z-Score dapat mengetahui penyimpangan dari nilai rata-rata, sedangkan Decimal Scaling mempermudah perbandingan proporsional antara kategori usia. Secara empiris, penelitian ini mengkonfirmasi bahwa kelompok usia 25-44 tahun adalah yang paling dominan dalam struktur angkatan kerja Indonesia pada Februari 2025. Implementasi normalisasi data terbukti meningkatkan kualitas data dan menyokong analisis ketenagakerjaan yang lebih akurat.

**Kata Kunci:** Normalisasi Data, Penambangan Data, Angkatan Kerja, BPS Indonesia

## ABSTRACT

Data normalization is a crucial initial step in the data mining process, aiming to reduce scale differences in numerical attributes, allowing for more objective and accurate analysis. This study aims to implement and evaluate data normalization techniques on the Indonesian workforce in February 2025 based on age category. The data used is secondary data obtained from the Central Bureau of Statistics (BPS) thru the National Labor Force Survey (SAKERNAS), which includes numerical attributes such as the number of employed people, the number of unemployed, the size of the labor force, and the percentage of the working population. The normalization methods used in this study consist of *Min-Max Normalization*, *Z-Score Normalization*, and *Decimal Scaling Normalization*. The research process includes data collection, selection of data from the period February 2025, data cleaning, application of normalization techniques, and analysis of the normalization results. The research findings indicate that all three normalization methods successfully leveled the value scales across attributes that previously showed significant differences in their value ranges. Min-Max normalization is effective in converting data to a specific range, Z-Score can identify deviations from the mean value, while Decimal Scaling facilitates proportional comparisons between age categories. Empirically, this study confirms that the 25-44 age group will be the most dominant in the structure of the Indonesian workforce in February 2025. Implementing data normalization has proven to improve data quality and support more accurate labor analysis.

**Keywords:** Data Normalization, Data Mining, Labor Force, BPS Indonesia

## Penulis Korespondensi:

Anastasya Jesica Sidauruk

Email: Universitas Katolik Santo Thomas

## Article Info

Diterima: 19 Januari 2026

Direvisi: 21 Januari 2026

Disetujui: 22 Januari 2026

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



## 1. PENDAHULUAN

*Data mining* merupakan kegiatan mencari informasi dan pola yang berguna dari kumpulan data yang sangat besar. Kegiatan *data mining* meliputi pengumpulan data, ekstraksi data, analisis data, serta statistik data. Proses ini juga sering disebut sebagai penemuan pengetahuan, ekstraksi pengetahuan, analisis data/pola, pengambilan informasi, dan variasi lainnya [1].

Metode normalisasi data merupakan langkah untuk menyamakan beberapa variabel sehingga rentang nilainya serupa, tanpa ada yang terlalu ekstrem, baik dari sisi besar maupun kecil, agar analisis statistik dapat dilakukan dengan lebih efisien. Beberapa pendekatan dalam normalisasi data mencakup *Min-Max Normalization*, *Z-score Normalization*, dan *Decimal Scaling Normalization* [2]. Di antara metode-metode tersebut, salah satu yang sering diterapkan adalah Metode *Decimal Scaling*, yang mengubah data dengan cara normalisasi untuk menyelaraskan rentang nilai dari setiap atribut menggunakan skala tertentu, dengan cara memindahkan posisi desimal pada nilai-nilai data sesuai yang diinginkan [2]. Hal ini bertujuan untuk menciptakan data dengan kualitas yang lebih baik [3]. Penelitian terdahulu menunjukkan bahwa perbedaan dalam rentang nilai di setiap atribut selama proses transformasi data dapat menyebabkan atribut dengan nilai yang jauh lebih kecil tidak berfungsi dengan baik dibandingkan atribut lain. Oleh karena itu, data yang dinormalisasi menggunakan metode *Decimal Scaling* menunjukkan hasil yang secara signifikan lebih baik dibandingkan dengan hasil klasifikasi tanpa melakukan transformasi data [4].

Data angkatan kerja di Indonesia dikumpulkan oleh Badan Pusat Statistik (BPS) melalui sejumlah kegiatan statistik, termasuk survei. Survei yang khusus dibuat untuk mendapatkan informasi mengenai ketenagakerjaan adalah Survei Angkatan Kerja Nasional (SAKERNAS). BPS melaksanakan SAKERNAS secara terjadwal dua kali setahun, yaitu di bulan Februari dan Agustus, dengan jangkauan yang mencakup seluruh wilayah Indonesia. Dari hasil survei ini diperoleh data penting mengenai situasi ketenagakerjaan yang kemudian dipublikasikan secara resmi oleh BPS. Tujuan publikasi data tenaga kerja adalah untuk memberikan gambaran mengenai kondisi serta karakteristik tenaga kerja, termasuk jumlah angkatan kerja, individu yang bekerja, dan mereka yang menganggur. Selain itu, data tersebut juga menyajikan informasi tentang pola distribusi angkatan kerja berdasarkan karakteristik tertentu, salah satunya adalah usia. Informasi ini krusial untuk memahami struktur ketenagakerjaan pada periode waktu tertentu, termasuk bulan Februari 2025. Dalam pelaksanaan SAKERNAS, pertanyaan mengenai ketenagakerjaan difokuskan pada populasi yang berada dalam usia kerja, yakni individu yang berusia 15 tahun ke atas. Pada tahap pemrosesan data, individu usia kerja dikelompokkan berdasarkan karakteristik tertentu untuk menghasilkan informasi ketenagakerjaan yang sesuai [5]. Data yang telah diproses tersebut disajikan dalam format tabel dan memiliki berbagai atribut numerik dengan skala nilai yang bervariasi, sehingga memerlukan tahap awal pemrosesan data, salah satunya adalah dengan menerapkan normalisasi data sebelum digunakan dalam proses penambangan data [6].

Data angkatan kerja yang dirilis oleh Badan Pusat Statistik (BPS) disajikan dalam bentuk angka dengan berbagai atribut yang memiliki satuan dan rentang nilai yang berbeda-beda. Atribut seperti total tenaga kerja, jumlah orang yang bekerja, dan total pengangguran memiliki nilai skala yang cukup besar, sedangkan atribut lain yang berhubungan dengan karakteristik tertentu, seperti kelompok usia, memiliki nilai skala yang lebih kecil. Perbedaan nilai skala antara atribut tersebut dapat menyebabkan dominasi atribut dengan nilai yang lebih besar dalam analisis data, sehingga atribut dengan nilai lebih rendah menjadi kurang berpengaruh [7]. Situasi ini bisa membuat hasil analisis menjadi bias dan tidak mencerminkan karakteristik data secara keseluruhan jika tidak ada tahap praproses data yang dilakukan. Oleh karena itu, sangat penting untuk menerapkan teknik normalisasi data guna menyelaraskan skala nilai antar atribut, sehingga proses analisis data bisa dilakukan dengan lebih objektif dan tepat [8].

Penelitian ini bertujuan untuk mengimplementasikan metode normalisasi data dengan menggunakan *Min-Max Normalization* pada data angkatan kerja Indonesia pada bulan Februari 2025 berdasarkan kategori usia yang diambil dari Badan Pusat Statistik. Pelaksanaan normalisasi ini difokuskan pada penyeragaman skala nilai di antara atribut numerik sehingga data memiliki struktur yang lebih baik dan siap untuk digunakan dalam proses penggalian data [9]. Penelitian ini diharapkan mampu memberikan sumbangan berupa peningkatan mutu data statistik ketenagakerjaan dan menjadi acuan dalam penerapan teknik praproses data, terutama dalam hal normalisasi data, pada data resmi yang diterbitkan oleh BPS.

## 2. METODE PENELITIAN

Metode riset yang diterapkan dalam studi ini bertujuan untuk menjelaskan langkah-langkah dalam penerapan normalisasi data pada data tenaga kerja Indonesia bulan Februari 2025 menurut kategori usia. Riset ini menggunakan pendekatan kuantitatif dengan memanfaatkan data sekunder yang diambil dari Badan Pusat Statistik (BPS). Langkah-langkah penelitian dirancang dengan sistematis agar proses penelitian ini dapat dimengerti dan dipertanggungjawabkan dari segi ilmiah.

Dataset yang digunakan dalam studi ini adalah data sekunder yang diambil dari Badan Pusat Statistik (BPS) di Indonesia. Informasi tersebut merupakan data mengenai tenaga kerja Indonesia pada bulan Februari 2025 yang diorganisir berdasarkan kelompok usia. Data dari BLPS dipilih karena sifatnya yang resmi, dapat dipercaya, dan luas penggunaannya dalam penelitian akademik serta pengambilan keputusan publik [8].

### 2.1 Tahapan Penelitian

Tahapan penelitian dilakukan secara sistematis agar hasil yang diperoleh dapat dipertanggungjawabkan secara ilmiah. Adapun tahapan penelitian yang dilakukan adalah sebagai berikut:

### 1. Pengumpulan Data

Data angkatan kerja Indonesia bulan Februari 2025 dikumpulkan dari publikasi resmi Badan Pusat Statistik (BPS). Data yang dikumpulkan mencakup informasi angkatan kerja berdasarkan kelompok umur.

### 2. Seleksi Data

Pada tahap ini dilakukan pemilihan data yang relevan dengan tujuan penelitian, yaitu data angkatan kerja pada bulan Februari 2025. Data di luar periode tersebut tidak digunakan dalam proses analisis.

### 3. Pembersihan Data (*Data Cleaning*)

Tahap pembersihan data dilakukan untuk memastikan data bebas dari kesalahan, nilai kosong (*missing value*), dan inkonsistensi data. Proses ini bertujuan agar data yang digunakan siap untuk tahap normalisasi.

### 4. Normalisasi Data

Setelah data bersih, dilakukan proses normalisasi data menggunakan metode *Min-Max Normalization*. Normalisasi ini bertujuan untuk menyamakan rentang nilai antar atribut numerik agar tidak terjadi dominasi atribut tertentu dalam analisis.

### 5. Analisis Hasil Normalisasi

Data yang telah dinormalisasi kemudian dianalisis untuk melihat perubahan skala nilai serta kesiapan data untuk tahap penambangan data selanjutnya.

## 2.2 Metode Normalisasi Data

Penelitian ini menerapkan tiga teknik untuk normalisasi data, yaitu Normalisasi Min-Max, Normalisasi Z-Score, dan Normalisasi Skala Desimal. Pemanfaatan beberapa teknik normalisasi bertujuan untuk menganalisis karakteristik dari hasil normalisasi serta mengevaluasi kecocokan setiap teknik terhadap data tenaga kerja di Indonesia berdasarkan kategori usia.

### 2.2.1 Normalisasi Min-Max

Normalisasi Min-Max adalah teknik yang mengubah nilai data ke dalam *range* tertentu, biasanya di antara 0 hingga 1. Metode ini menjaga rasio jarak antar data, sehingga sering diterapkan pada fase pra-proses data [10].

Normalisasi min-max adalah pendekatan normalisasi yang memodifikasi angka dalam data secara linier, menjadikan nilai tertinggi 1 dan nilai terendah 0. Metode ini berguna untuk menurunkan nilai-nilai ekstrem pada fitur yang paling berpengaruh dalam proses pengklasifikasian. Rumus untuk normalisasi min-max dapat ditemukan dalam Rumus [11].

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

### 2.2.2 Z-Score Normalization

Z-Score Normalization merupakan metode normalisasi yang mengubah nilai data berdasarkan nilai rata-rata (*mean*) dan simpangan baku (standar deviasi). Metode ini menghasilkan data dengan rata-rata 0 dan standar deviasi 1.

Nilai Z-Score merupakan ukuran penyimpangan data dari nilai rata-ratanya ( $\mu$ ) yang diukur dalam satuan standar deviasinya ( $\sigma$ ). Z-Score ini juga disebut dengan Nilai Standar atau Nilai baku. Persamaan (1) merupakan formula untuk menghitung nilai Z-Score dari setiap data yang diamati ( $x$ ) [12]. Persamaan 1 merupakan formula untuk mengetahui Z-Score [13]:

$$Z = \frac{X - \mu}{\sigma}$$

### 2.2.3 Decimal Scaling Normalization

Salah satu cara untuk menormalkan data yang umum dipakai adalah dengan menggunakan metode skala desimal. Metode ini adalah teknik untuk mentransformasi data melalui normalisasi agar sebanding dalam jangkauan nilai setiap atribut dengan skala tertentu dengan cara memindahkan posisi desimal data ke arah yang diinginkan [14]. Hal ini bertujuan untuk memperoleh data yang lebih efektif [15]. Penelitian sebelumnya mengungkapkan bahwa perbedaan jangkauan nilai pada tiap atribut selama proses transformasi data bisa menyebabkan atribut dengan nilai yang jauh lebih kecil tidak berfungsi dengan baik, sehingga data yang dinormalisasi menggunakan metode skala desimal menunjukkan hasil yang lebih baik secara signifikan dibandingkan dengan klasifikasi yang tidak melakukan transformasi data [4].

Metode desimal Scaling berfungsi dengan memindahkan posisi titik desimal pada nilai-nilai data. Jumlah pemindahan titik desimal ditentukan oleh nilai absolut maksimum dari setiap fitur data atau variabel. Rumus untuk mentransformasi pengukuran desimal dengan  $j$  adalah nilai terkecil sehingga nilai  $\max(|x'_i|) < 1$ , seperti yang dijelaskan berikut ini [16]:

$$X' = \frac{X}{10^j}$$

### 3. HASIL DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini adalah statistik ketenagakerjaan Indonesia berdasarkan penduduk umum pada Februari 2025, yang diperoleh dari Badan Pusat Statistik (BPS). Kelompok usia yang dianalisis meliputi kelompok usia berikut: 15–24 tahun, 25–34 tahun, 35–44 tahun, 45–54 tahun, 55–64 tahun, dan 65 tahun. Atribut numerik yang digunakan adalah jumlah karyawan, jumlah pekerja, dan jumlah pengangguran.

Berdasarkan data yang dikumpulkan, terbukti bahwa jumlah pekerja dan karyawan sangat besar (jutaan orang), meskipun jumlah karyawan relatif kecil. Perbedaan skala ini menunjukkan bahwa data tidak memiliki keseragaman skala, sehingga proses normalisasi harus diselesaikan sebelum analisis lebih lanjut.

#### 3.1. Hasil Penelitian

##### 3.1.1 Data Asli Angkatan Kerja Bulan Februari 2025

Data asli mengindikasikan adanya perbedaan yang cukup signifikan antara kelompok usia. Kelompok usia yang produktif, terutama yang berusia antara 25 hingga 44 tahun, menunjukkan angka angkatan kerja dan penduduk yang bekerja paling tinggi dibandingkan dengan kelompok usia lainnya. Di sisi lain, kelompok yang berusia 65 tahun ke atas menunjukkan jumlah angkatan kerja dan pengangguran yang cenderung lebih rendah.

Perbedaan signifikan dalam nilai antara atribut dan kelompok usia ini dapat menghasilkan bias jika data dipakai langsung dalam analisis *data mining*. Untuk itu, langkah normalisasi data menjadi krusial guna menyelaraskan rentang nilai antar atribut numerik. Berikut merupakan datanya:

Tabel 1. Data Asli

IE-Kelompok Umur	Angkatan Kerja (AK) Menurut Kelompok Umur							
	Bekerja 2025		Jumlah Pengangguran 2025		Jumlah AK 2025		% Bekerja / AK 2025	
	Februari	Agustus	Februari	Agustus	Februari	Agustus	Februari	Agustus
15-24	18421906	18913205	3549928	3843567	21971834	22756772	83.84	83.11
25-34	33184087	33490603	1939099	1791256	35123186	35281859	94.48	94.92
35-44	33951539	33819741	684028	728703	34635567	34548444	98.03	97.89
45-54	30245618	30231916	528796	572637	30774414	30804553	98.28	98.14
55-64	19706443	19750464	416113	333664	20122556	20084128	97.93	98.34
65+	10261587	10336335	160343	191680	10421930	10528015	98.46	98.18
Total	145771180	146542264	7278307	7461507	153049487	154003771	95.24	95.15

Tabel 2. Data AK

IE-Kelompok Umur	Angkatan Kerja (AK) Menurut Kelompok Umur bulan Februari 2025			
	Bekerja	Jumlah Pengangguran	Jumlah AK	% Bekerja / AK
15-24	18421906	3549928	21971834	83.84
25-34	33184087	1939099	35123186	94.48
35-44	33951539	684028	34635567	98.03
45-54	30245618	528796	30774414	98.28
55-64	19706443	416113	20122556	97.93
65+	10261587	160343	10421930	98.46
Total	145771180	7278307	153049487	95.24

##### 3.1.2 Hasil Normalisasi Min–Max

Hasil normalisasi menggunakan metode Min–Max menunjukkan bahwa data berhasil dipetakan ke dalam rentang nilai tertentu sesuai batas minimum dan maksimum. Kelompok umur 35–44 tahun dan 45–54 tahun memperoleh nilai tertinggi pada variabel bekerja dan angkatan kerja, menegaskan peran dominan kelompok usia produktif menengah dalam perekonomian.

Kelompok umur 15–24 tahun menunjukkan nilai negatif pada variabel % Bekerja/AK, yang menandakan rendahnya rasio bekerja dibandingkan angkatan kerja. Kondisi ini sejalan dengan fakta bahwa sebagian besar kelompok usia ini masih berada pada jenjang pendidikan formal. Metode Min–Max sangat efektif untuk visualisasi data dan pemodelan berbasis skala tetap, meskipun sensitif terhadap nilai ekstrem.

Tabel 3. Hasil Normalisasi min max

IE-Kelompok Umur	Bekerja	Jumlah Pengangguran	Jumlah AK	% Bekerja / AK
15-24	8160318.7	3389584.955	11549904	-11.59957749
25-34	22922500	1778755.955	24701256	-0.959577493
35-44	23689952	523684.9548	24213637	2.590422507
45-54	19984031	368452.9548	20352484	2.840422507

55-64	9444855.7	255769.9548	9700625.7	2.490422507
65+	-0.302242	-0.045167958	-0.296725	3.020422507

### 3.1.3 Hasil Normalisasi Desimal Scaling

Berdasarkan hasil yang diperoleh dari normalisasi dengan penerapan Metode Desimal Scaling, semua nilai data telah berhasil direformasi ke dalam rentang antara 0 sampai 1. Kelompok umur antara 25 hingga 44 tahun mencatat nilai tertinggi pada variabel tenaga kerja dan jumlah angkatan kerja, yang menunjukkan keberadaan dominan kelompok usia yang produktif dalam struktur kerja di tingkat nasional.

Sebaliknya, kategori usia 65 tahun ke atas menunjukkan nilai terendah pada hampir semua variabel, yang mencerminkan penurunan partisipasi dalam dunia kerja sejalan dengan bertambahnya usia. Persentase aktif bekerja relatif tinggi di hampir semua kelompok umur menandakan bahwa mayoritas angkatan kerja telah terserap dalam pasar tenaga kerja.

Penerapan Metode Desimal Scaling terbukti berhasil dalam menyederhanakan skala data tanpa menghilangkan perbandingan proporsional antar kelompok umur, sehingga analisis perbandingan awal menjadi lebih mudah dilakukan.

Tabel 4. Hasil Normalisasi Desimal Scaling

IE-Kelompok Umur	Bekerja	Jumlah Pengangguran	Jumlah AK	% Bekerja / AK
15-24	0.18421906	0.3549928	0.21971834	0.8384
25-34	0.33184087	0.1939099	0.35123186	0.9448
35-44	0.33951539	0.0684028	0.34635567	0.9803
45-54	0.30245618	0.0528796	0.30774414	0.9828
55-64	0.19706443	0.0416113	0.20122556	0.9793
65+	0.10261587	0.0160343	0.1042193	0.9846

### 3.1.4 Hasil Normalisasi Z-Score

Normalisasi Z-Score menghasilkan angka positif dan negatif yang mencerminkan seberapa jauh data berada dari rata-rata dalam hal satuan deviasi standar. Kelompok usia 35–44 tahun menunjukkan nilai Z-Score tertinggi dalam variabel pekerjaan dan jumlah angkatan kerja, yang menunjukkan bahwa kelompok ini memiliki posisi yang jauh di atas rata-rata nasional.

Di sisi lain, kelompok usia 15–24 tahun dan 65 tahun ke atas menunjukkan nilai Z-Score negatif, terutama dalam variabel pekerjaan, yang menunjukkan bahwa tingkat partisipasi kerja mereka berada di bawah rata-rata. Hal ini bisa dijelaskan oleh tingkat pendidikan pada usia muda dan faktor kesehatan serta pensiun pada usia lanjut.

Variabel % Bekerja/AK menunjukkan variasi Z-Score yang cukup signifikan, yang menunjukkan adanya perbedaan dalam tingkat efektivitas penyerapan tenaga kerja di antara kelompok umur. Metode Z-Score sangat berguna untuk mengenali kelompok umur yang menunjukkan perbedaan signifikan dari keadaan rata-rata nasional.

Tabel 5. Hasil Normalisasi Z-Score

IE-Kelompok Umur	Bekerja	Jumlah Pengangguran	Jumlah AK	% Bekerja / AK
15-24	-0.670660993	1.965739472	-0.398468055	-2.159640677
25-34	1.01500715	0.6107386	1.083370297	-0.131522689
35-44	1.102641178	-0.445004934	1.028427465	0.545152016
45-54	0.679468412	-0.575583347	0.593369183	0.592805164
55-64	-0.523981915	-0.670370295	-0.606836826	0.526090756
65+	-1.602473831	-0.885519496	-1.699862064	0.62711543
Rata-rata	24295196.67	1213051.167	25508247.83	95.17
Standard Deviasi	8757465.733	1188802.925	8875024.716	5.2462431

## 3.2. Pembahasan

Hasil penelitian menunjukkan bahwa setiap teknik normalisasi menghasilkan karakteristik data yang berbeda, sehingga memberikan implikasi yang bervariasi terhadap analisis lanjutan dan penerapan algoritma *Machine Learning*. Normalisasi Min–Max menghasilkan data dengan rentang nilai yang seragam, sehingga efektif digunakan pada algoritma yang sensitif terhadap skala, seperti *K-Means* dan Jaringan Syaraf Tiruan. Namun, kelemahan utama metode ini terletak pada sensitivitasnya terhadap nilai ekstrem (*outlier*). Pada data angkatan kerja, kelompok usia dengan jumlah tenaga kerja yang sangat besar berpotensi mempersempit rentang nilai kelompok lainnya, sehingga mengurangi representasi variasi data secara keseluruhan.

Sebaliknya, Normalisasi Z-Score lebih unggul dalam mendeteksi penyimpangan karena proses normalisasi didasarkan pada nilai rata-rata dan simpangan baku. Nilai positif dan negatif yang dihasilkan merepresentasikan tingkat deviasi suatu kelompok umur terhadap rata-rata nasional. Dalam konteks data angkatan kerja, metode ini efektif untuk mengidentifikasi kelompok usia dengan tingkat partisipasi kerja yang berada jauh di atas atau di bawah kondisi rata-rata, sehingga relevan untuk analisis anomali dan evaluasi ketimpangan pasar tenaga kerja. Penerapan Z-Score pada algoritma pengelompokan seperti *K-Means* memungkinkan pembentukan klaster yang lebih informatif karena jarak antar data mencerminkan deviasi statistik, bukan sekadar perbedaan skala.

Sementara itu, Normalisasi Skala Desimal mempertahankan proporsi data asli dengan menyederhanakan skala nilai tanpa menghilangkan hubungan relatif antar atribut. Metode ini relatif stabil terhadap nilai ekstrem dan sesuai digunakan pada tahap analisis eksploratif maupun sebagai praproses untuk algoritma klasifikasi yang tidak terlalu sensitif terhadap distribusi data.

Secara keseluruhan, temuan dari studi ini menegaskan bahwa pemilihan teknik normalisasi perlu diselaraskan dengan tujuan dari analisis serta algoritma *Machine Learning* yang diterapkan. Normalisasi yang sesuai dapat meningkatkan mutu pemodelan, mempercepat pelatihan model, dan menghasilkan analisis ketenagakerjaan yang lebih tepat dan dapat diandalkan.

#### 4. KESIMPULAN

Penelitian ini bertujuan untuk menerapkan teknik normalisasi data pada data angkatan kerja Indonesia bulan Februari 2025 berdasarkan kelompok umur, sebagaimana telah diuraikan pada bagian pendahuluan. Berdasarkan hasil dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa tujuan penelitian berhasil dicapai. Hasil penerapan tiga metode normalisasi, yaitu Min–Max Normalization, Z-Score Normalization, dan Decimal Scaling Normalization, menunjukkan bahwa proses normalisasi mampu menyelaraskan skala nilai antar atribut numerik yang sebelumnya memiliki perbedaan rentang nilai yang cukup signifikan. Dengan demikian, potensi bias dalam analisis data akibat dominasi atribut tertentu dapat diminimalkan.

Secara empiris, hasil penelitian mengonfirmasi bahwa kelompok usia 25–44 tahun merupakan kelompok usia paling dominan dalam struktur angkatan kerja Indonesia pada Februari 2025, dengan tingkat partisipasi dan penyerapan tenaga kerja yang tinggi. Sementara itu, kelompok usia 15–24 tahun masih menunjukkan tingkat partisipasi kerja yang relatif rendah, dan kelompok usia 65 tahun ke atas mengalami penurunan aktivitas kerja yang bersifat struktural. Temuan ini konsisten dengan data dan publikasi resmi Badan Pusat Statistik (BPS). Dari sisi metodologis, setiap teknik normalisasi memiliki keunggulan masing-masing. Normalisasi Min–Max efektif untuk pemetaan data dalam rentang tertentu, Z-Score unggul dalam mendeteksi penyimpangan terhadap rata-rata, dan Decimal Scaling mempermudah analisis perbandingan awal tanpa menghilangkan proporsi data. Oleh karena itu, pemilihan metode normalisasi sebaiknya disesuaikan dengan kebutuhan analisis lanjutan. Sebagai prospek pengembangan, hasil penelitian ini dapat dijadikan dasar untuk penerapan teknik penambangan data lebih lanjut, seperti *clustering* atau klasifikasi, guna menggali pola ketenagakerjaan yang lebih kompleks. Selain itu, penelitian selanjutnya dapat memperluas cakupan data dengan menambahkan dimensi wilayah, tingkat pendidikan, atau periode waktu yang berbeda untuk memperoleh gambaran ketenagakerjaan yang lebih komprehensif.

#### UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Badan Pusat Statistik (BPS) Republik Indonesia atas ketersediaan data ketenagakerjaan yang bersifat terbuka dan dapat diakses oleh publik, sehingga penelitian ini dapat dilaksanakan dengan baik. Ucapan terima kasih juga disampaikan kepada Universitas Katolik Santo Thomas atas dukungan akademik dan fasilitas yang diberikan selama proses penyusunan penelitian ini. Selain itu, penulis mengapresiasi berbagai pihak yang telah memberikan masukan dan dukungan, baik secara langsung maupun tidak langsung, sehingga penelitian ini dapat diselesaikan dan disajikan dalam bentuk artikel ilmiah.

#### REFERENSI

- [1] A. J. Wahidin and W. A. Syukrilla, *Data mining*.
- [2] P. P. Alloreung, A. Erna, and M. Bagussahrir, “Analisis Performa Normalisasi Data untuk Klasifikasi K-Nearest Neighbor pada Dataset Penyakit,” vol. 9, no. 3, pp. 178–191, 2024.
- [3] Y. D. Pratama and A. Salam, “Comparison of Data Normalization Techniques on KNN Classification Performance for Pima Indians Diabetes Dataset,” vol. 9, no. 3, 2025.
- [4] M. R. Kusnaldi, T. Gulo, and S. Aripin, “Penerapan Normalisasi Data Dalam Mengelompokkan Data Mahasiswa Dengan Menggunakan Metode K-Means Untuk Menentukan Prioritas Bantuan Uang Kuliah Tunggal,” vol. 3, no. 4, pp. 330–338, 2022, doi: 10.47065/josyc.v3i4.2112.
- [5] A. Transactions and M. Learning, “Evaluating the Impact of Data Normalization on Rice Classification Using Machine Learning Algorithms,” pp. 162–171, 2024.
- [6] K. Lima and P. Kota, “Angkatan kerja,” 2021.
- [7] H. S. Silva *et al.*, “The Impact of Feature Scaling In Machine Learning : Effects on Regression and Classification Tasks,” 2025, doi: 10.1109/ACCESS.2025.3635541.
- [8] B. P. Statistik, *No Title*. 2025. [Online]. Available: <https://www.bps.go.id/id>
- [9] J. Manoel *et al.*, “The Impact of Feature Scaling In Machine Learning : Effects on Regression and Classification Tasks,” vol. XX, no. X, 2025.
- [10] B. Practices, “Data Preprocessing and Feature Engineering for Data Mining :,” 2025.
- [11] J. Reynaldo, P. P. Adikara, and R. C. Wihandika, “Analisis Sentimen Mengenai Produk Toyota Avanza Menggunakan Metode Learning Vector Quantization Versi 3 ( LVQ 3 ) dengan Seleksi Fitur Chi Square , Lexicon-Based Features serta Normalisasi Min-Max,” vol. 4, no. 3, pp. 830–839, 2020.
- [12] K. Penderita, D. Menggunakan, and M. L. D. A. N. Z-score, “Jurnal Teknologi Terpadu,” vol. 8, no. 2, pp. 94–99, 2022.

- 
- [13] P. Studi and T. Informatika, "PENDEKATAN Z-SCORE DAN FUZZY DALAM PENGUJIAN AKURASI," vol. 3, no. 2, pp. 149–156, 2020.
  - [14] M. A. Othman and A. Samad, "When to Use Standardization and Normalization : Empirical Evidence From Machine Learning Models and XAI," *IEEE Access*, vol. 12, no. July, pp. 135300–135314, 2024, doi: 10.1109/ACCESS.2024.3462434.
  - [15] L. B. V. De Amorim, G. D. C. Cavalcanti, and R. M. O. Cruz, "The choice of scaling technique matters for classification performance," pp. 1–37, 2022.
  - [16] Y. Kim, M. Keun, N. Fu, J. Liu, J. Wang, and J. Srebric, "Investigating the impact of data normalization methods on predicting electricity consumption in a building using different artificial neural network models," *Sustain. Cities Soc.*, vol. 118, no. June 2024, p. 105570, 2025, doi: 10.1016/j.scs.2024.105570.

# Prediksi Diabetes Berbasis Decision Tree Dengan Menggunakan Dataset Pima Indians Diabetes

Yustri Insani<sup>1</sup>, Marcel Filemon Naibaho<sup>2</sup>, Sardo Pardingotan Sipayung<sup>3</sup>

<sup>1,2,3</sup>Universitas Katolik Santo Thomas, Medan, Indonesia

Email: <sup>1</sup>berasayustriinsani@gmail.com, <sup>2</sup>marcel01052005@gmail.com, <sup>3</sup>pinarsiphom@gmail.com

## ABSTRAK

Diabetes melitus merupakan penyakit kronis yang ditandai dengan meningkatnya kadar glukosa dalam darah dan dapat menimbulkan berbagai komplikasi serius apabila tidak ditangani sejak dini. Penelitian ini bertujuan untuk memprediksi penyakit diabetes menggunakan algoritma *Decision Tree* dengan *dataset* Pima Indians Diabetes. Tahapan penelitian meliputi pengolahan data, pembentukan model *Decision Tree* menggunakan kriteria entropy, serta evaluasi kinerja model. Hasil penelitian menunjukkan bahwa model mencapai akurasi sebesar 76,62%. Pengujian melalui *confusion matrix* menghasilkan 83 sampel *True Negative*, 35 sampel *True Positive*, 16 sampel *False Positive*, dan 20 sampel *False Negative*. Atribut Glukosa ditemukan sebagai faktor paling dominan dalam diagnosis, diikuti oleh BMI dan *Age*. Model yang dihasilkan mampu membentuk aturan keputusan yang jelas dan mudah dipahami sehingga dapat digunakan sebagai sistem pendukung keputusan dalam diagnosis awal diabetes.

**Kata Kunci:** Diabetes, Pohon Keputusan, Pembelajaran Mesin, Klasifikasi, Kemampuan interpretasi

## ABSTRACT

*Diabetes mellitus is a chronic disease characterized by increased blood glucose levels and can lead to various serious complications if not treated early. This research aims to predict diabetes using the Decision Tree algorithm with the Pima Indians Diabetes dataset. The research stages include data processing, forming a Decision Tree model using the entropy criterion, and evaluating model performance. The results show that the model achieved an accuracy of 76.62%. Testing through a confusion matrix produced 83 True Negative samples, 35 True Positive samples, 16 False Positive samples, and 20 False Negative samples. The Glucose attribute was found to be the most dominant factor in the diagnosis, followed by BMI and Age. The resulting model is able to form clear and easy-to-understand decision rules so that it can be used as a decision support system in the early diagnosis of diabetes.*

**Keywords:** Diabetes, Decision Tree, Data Mining, Machine Learning, Classification, Interpretability

## Penulis Korespondensi:

Marcel Filemon Naibaho

Email: marcel01052005@gmail.com

## Article Info

Diterima: 28 Januari 2026

Direvisi: 2 Februari 2026

Disetujui: 2 Februari 2026

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



## 1. PENDAHULUAN

*Data mining* merupakan teknik pemrosesan data yang bertujuan mengungkap pola tersembunyi dalam *dataset*. *Output* dari proses ini bisa dimanfaatkan untuk membuat keputusan strategis ke depannya. Teknik ini juga sering disebut sebagai pengenalan pola [1].

Diabetes melitus adalah penyakit tidak menular yang telah menjadi isu kesehatan dunia dengan tingkat kejadian yang terus naik. Organisasi Kesehatan Dunia (WHO) menggambarkan diabetes sebagai kondisi kronis yang disebabkan oleh peningkatan kadar gula darah, yang dapat menimbulkan komplikasi berat jika tidak segera diatasi [2]. Di Indonesia, penyakit ini berkontribusi besar terhadap peningkatan angka mortalitas. Walaupun diagnosis tradisional melalui pemeriksaan laboratorium memberikan

hasil yang tepat, pendekatan ini membutuhkan waktu lama dan biaya tinggi. Oleh karena itu, teknik *data mining dan machine learning* semakin populer untuk mempercepat dan menyederhanakan proses diagnosis.

*Database* Diabetes Suku Pima Indian memiliki signifikansi khusus karena mencerminkan situasi dunia nyata, sehingga memungkinkan para peneliti untuk menilai efektivitas model pembelajaran mendalam dalam meramalkan risiko diabetes pada populasi yang sangat rentan [3]. Berbagai kajian sebelumnya telah menggunakan algoritma *machine learning* untuk meramalkan diabetes. Algoritma *Decision Tree* dikenal efektif dalam klasifikasi karena menghasilkan model yang mudah dijelaskan dan dipahami [4].

Beberapa penelitian sebelumnya telah menerapkan algoritma *machine learning* untuk prediksi diabetes [5]. Whitten et al. menjelaskan bahwa data mining memungkinkan penggalian pola dari data kesehatan dalam jumlah besar untuk mendukung pengambilan keputusan medis [6]. Quinlan memperkenalkan algoritma *Decision Tree* sebagai metode klasifikasi yang mampu menghasilkan model keputusan yang bersifat interpretatif dan mudah dipahami [7]. Algoritma C4.5 adalah metode yang bisa diterapkan untuk membuat pohon keputusan. Pohon keputusan atau *Decision Tree*, termasuk salah satu teknik yang relatif sederhana bagi manusia untuk memahaminya. Ini merupakan model prediktif yang memanfaatkan bentuk pohon atau hierarki. Inti dari pohon keputusan adalah mengonversi data menjadi struktur pohon dan seperangkat aturan keputusan [8]. Penelitian ini juga menunjukkan bahwa algoritma *machine learning* seperti *Decision Tree*, *Naïve Bayes*, dan *Support Vector Machine* dapat digunakan untuk memprediksi diabetes dengan tingkat akurasi yang cukup baik [9]. Meskipun demikian, sebagian penelitian sebelumnya lebih berfokus pada peningkatan akurasi model tanpa membahas secara mendalam interpretasi hasil dan faktor-faktor utama yang mempengaruhi keputusan model. Selain itu, masih terdapat keterbatasan dalam penelitian yang mengaitkan hasil klasifikasi secara langsung dengan kondisi medis yang mudah dipahami oleh pengguna non-teknis. Oleh karena itu, diperlukan penelitian yang tidak hanya menekankan pada performa model, tetapi juga pada interpretabilitas dan kejelasan aturan keputusan yang dihasilkan.

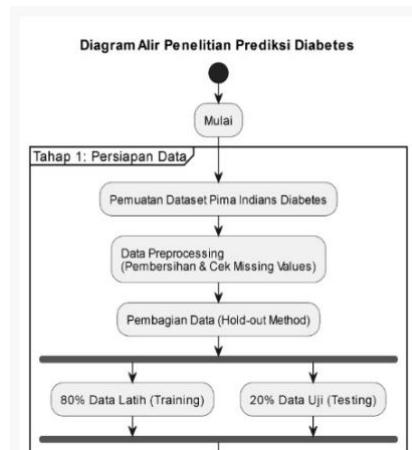
Dataset Pima Indians Diabetes merupakan *dataset* standar yang banyak digunakan dalam penelitian prediksi diabetes karena bersifat valid dan telah diuji secara luas dalam berbagai studi sebelumnya [10]. Namun, pemanfaatan *dataset* ini dengan fokus pada analisis struktur pohon keputusan dan identifikasi atribut paling berpengaruh masih relatif terbatas.

Berdasarkan uraian tersebut, beberapa peneliti sebelumnya berfokus pada penerapan berbagai algoritma *machine learning* untuk meningkatkan akurasi prediksi diabetes. Terdapat studi terbatas yang mengkaji interpretasi model *Decision Tree* secara mendalam untuk mengidentifikasi faktor-faktor utama penyebab diabetes berdasarkan *dataset* standar. Meskipun penelitian sebelumnya telah banyak menerapkan berbagai algoritma *machine learning* untuk prediksi diabetes dengan tingkat akurasi yang baik, sebagian besar studi tersebut cenderung berfokus pada optimasi performa model tanpa membahas secara mendalam interpretasi hasil serta faktor utama yang memengaruhi keputusan model. Oleh karena itu, penelitian ini hadir untuk mengisi celah tersebut dengan menekankan pada analisis struktur pohon keputusan menggunakan algoritma *Decision Tree*, sehingga tidak hanya menghasilkan prediksi yang akurat, tetapi juga memberikan transparansi mengenai alur logika diagnosis melalui visualisasi yang jelas. Tujuan penelitian ini adalah menghasilkan model prediksi yang akurat, mudah dipahami, serta dapat digunakan sebagai sistem pendukung keputusan dalam diagnosis awal penyakit diabetes.

## 2. METODE PENELITIAN

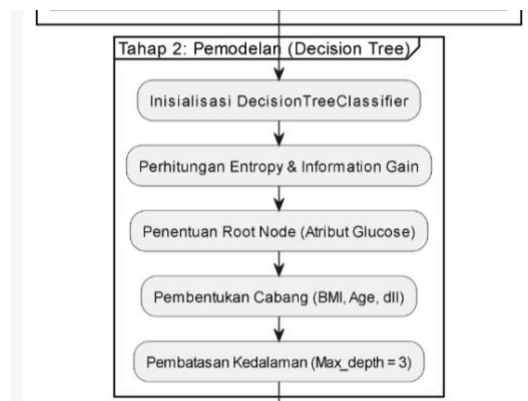
Metode penelitian yang digunakan dalam penelitian ini terdiri dari beberapa tahapan. Sesi ini menyediakan ulasan padat tentang inovasi yang telah dicapai dalam penggunaan teknologi. Orang yang hidup dengan diabetes menjadi target utama pemberitahuan dari model klasifikasi yang diusulkan, yang juga menyertakan kontribusi ke dalam kumpulan data diabetes. Tahap pertama adalah pengumpulan data, yaitu menggunakan *dataset* Pima Indians Diabetes yang berisi data medis pasien seperti *Glucose*, BMI, Age, dan atribut lainnya [11]. *Dataset* ini dipilih karena bersifat valid dan telah banyak digunakan dalam penelitian sebelumnya. Tahap kedua adalah *preprocessing* data yang meliputi pembersihan data dan penyesuaian format data agar dapat diproses oleh algoritma *Decision Tree*. Tahap selanjutnya adalah pembagian data menjadi data latih dan data uji untuk membangun dan menguji model. Kajian ini memanfaatkan *dataset* sekunder Pima Indians Diabetes yang diunduh dari platform Kaggle. *Dataset* mencakup 768 entri data dengan 8 variabel medis sebagai prediktor independen dan 1 variabel target (*Outcome*). Komposisi kelas dalam *dataset* menunjukkan 500 sampel non-diabetes (65,1%) dan 268 sampel diabetes (34,9%) [12]. Sifat data ini mengindikasikan ketidakseimbangan ringan yang sering terjadi pada kasus kesehatan.

Prosedur dalam penelitian ini dirancang secara terstruktur melalui empat tahapan utama untuk menjamin keandalan model klasifikasi yang dihasilkan. Tahap awal difokuskan pada persiapan data, mulai dari pemuatan *dataset* Pima Indians Diabetes hingga proses *preprocessing* untuk menjamin kualitas data, yang dilanjutkan dengan pembagian *dataset* menggunakan metode *hold-out* (80% data latih dan 20% data uji) [13]. Selanjutnya, dilakukan proses pemodelan inti dengan menginisialisasi *Decision Tree Classifier* menggunakan kriteria entropi dan pembatasan kedalaman pohon (*max\_depth=3*). Seluruh rangkaian alur kerja sistematis mulai dari persiapan hingga evaluasi kinerja model digambarkan secara mendetail dalam diagram alir penelitian.



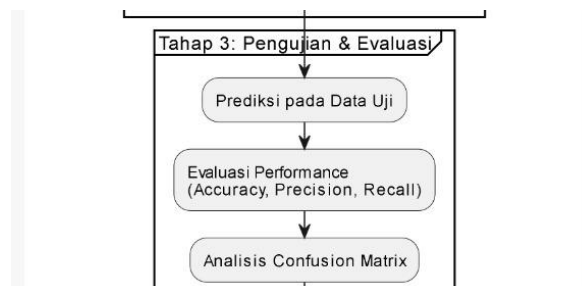
Gambar 1. Tahap 1 Persiapan data

Implementasi algoritma *Decision Tree* pada penelitian ini menghasilkan sebuah model visual yang merepresentasikan logika pengambilan keputusan diagnosa diabetes secara transparan. Berdasarkan hasil pemodelan terhadap 614 sampel data latih, atribut Glukosa teridentifikasi sebagai akar utama (*root node*) yang memiliki pengaruh paling signifikan dalam membedakan kelas pasien. Struktur pohon ini membagi data berdasarkan ambang batas tertentu, seperti nilai glukosa  $\leq 127.5$ , serta pengaruh variabel pendukung lainnya seperti Age (Usia) dan BMI. Visualisasi ini memungkinkan tenaga medis untuk memahami pola klasifikasi diagnosa melalui serangkaian percabangan kondisi yang mudah diinterpretasikan.



Gambar 2. Tahap 2 Pemodelan

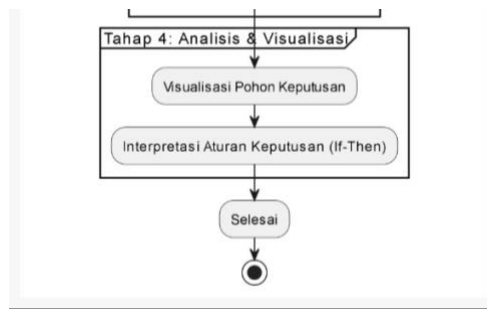
Setelah model berhasil dibangun pada tahap sebelumnya, langkah krusial berikutnya adalah mengukur sejauh mana kemampuan algoritma dalam melakukan prediksi secara akurat. Tahapan ini melibatkan penggunaan data uji (*testing data*) yang belum pernah dikenali oleh model untuk melihat performa klasifikasi di kondisi nyata. Evaluasi dilakukan secara komprehensif menggunakan metrik *Accuracy*, *Precision*, dan *Recall* guna memastikan model tidak hanya unggul secara angka, tetapi juga handal dalam mendeteksi kelas diabetes. Rincian langkah-langkah dalam proses pengujian dan evaluasi kinerja model ini disajikan secara sistematis.



Gambar 3. Tahap 3 Pengujian & Evaluasi

Tahap akhir dari metodologi ini adalah mentransformasi hasil komputasi algoritma ke dalam bentuk yang dapat diinterpretasikan oleh manusia, khususnya tenaga medis. Proses ini difokuskan pada pembuatan visualisasi pohon keputusan untuk mengidentifikasi variabel klinis yang paling berpengaruh terhadap risiko diabetes. Melalui interpretasi aturan keputusan (*if-then rules*), hasil prediksi yang kompleks diubah menjadi informasi yang transparan dan mudah dipahami sebagai dasar

pengambilan keputusan medis. Alur kerja pada tahap final yang mencakup visualisasi dan interpretasi aturan hasil klasifikasi ini diperlihatkan secara sistematis.



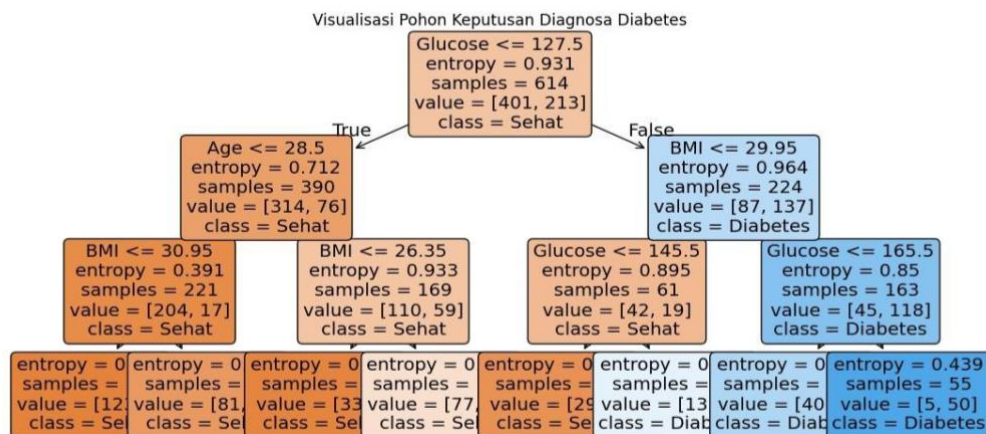
Gambar 4. Tahap 4 Analisis & Visualisasi

Pembagian Data (*Data Splitting*) menerapkan teknik *hold-out*, di mana *dataset* dipisah menjadi 80% set pelatihan (*training set*) dengan 614 sampel dan 20% set pengujian (*testing set*) dengan 154 sampel. Pemisahan dilakukan secara acak untuk mencegah bias pada evaluasi model.

Pembangunan Model: Menerapkan algoritma *Decision Tree* dengan entropi sebagai basis penghitungan pemisahan simpul. Visualisasi dan analisis, mengonversi model matematis menjadi representasi pohon keputusan untuk menemukan variabel yang paling signifikan. Eksperimen ini dikembangkan dengan bahasa pemrograman Python 3.14 [14]. *Library* utama yang diterapkan yaitu Pandas yaitu Untuk pengelolaan dan eksplorasi struktur data. Scikit-Learn (Sklearn) Untuk penerapan algoritma *Decision Tree*, pemisahan data *hold-out*, serta kalkulasi metrik evaluasi. Matplotlib Untuk penyajian visual hasil pohon keputusan dalam format grafik [15]. Untuk menilai performa model secara obyektif, diterapkan beberapa indikator evaluasi yang berasal dari *Confusion Matrix*, yakni Akurasi (*Accuracy*) Menghitung proporsi total ramalan yang tepat (sehat dan diabetes) terhadap seluruh data pengujian. Presisi (*Precision*) Menilai ketepatan model dalam meramalkan kelas positif (diabetes) relatif terhadap total hasil yang diramalkan positif. Sensitivitas (*Recall*) Mengukur kapasitas model untuk mendeteksi semua sampel yang benar-benar positif diabetes [16]. Indikator ini amat penting di bidang medis untuk mengurangi *false-negative*.

### 3. HASIL DAN PEMBAHASAN

Dari hasil pengolahan *dataset* Pima Indians Diabetes dengan algoritma *Decision Tree*, fitur Glukosa teridentifikasi sebagai elemen paling signifikan dalam menentukan diagnosis diabetes. Fitur ini dipilih sebagai simpul akar karena memiliki nilai *Information Gain* tertinggi dibandingkan yang lain. Secara klinis, hal ini menegaskan bahwa tingkat gula darah adalah penanda utama untuk mendeteksi gangguan metabolisme tubuh. Pohon keputusan yang dihasilkan dari proses *training* dibatasi pada kedalaman maksimal tiga level (*max\_depth=3*) untuk mempertahankan kemudahan pemahaman dan menghindari *overfitting*. Visualisasi struktur logika tersebut disajikan pada gambar berikut.



Gambar 5. Hasil Pohon Keputusan Diagnosa Diabetes

Berdasarkan Gambar 5, logika klasifikasi dapat diuraikan melalui aturan keputusan (*decision rules*) berikut:

1. Simpul Akar (*Glucose*): Jika kadar glukosa pasien  $\leq 127.5$ , model cenderung mengklasifikasikan sebagai "Sehat", meskipun masih mempertimbangkan usia dan BMI.
2. Faktor Usia (*Age*): Di kelompok glukosa rendah, individu dengan usia  $\leq 28.5$  tahun secara konsisten dikategorikan sebagai Sehat. Namun, untuk pasien yang lebih tua, BMI menjadi faktor tambahan.

3. Faktor Obesitas (BMI) Di kelompok dengan glukosa tinggi ( $> 127.5$ ), BMI di atas 29.85 menjadi pemicu utama diagnosis Diabetes. Ini menunjukkan bahwa gabungan gula darah tinggi dan berat badan berlebihan adalah prediktor risiko yang sangat kuat.

Setelah menjelaskan mekanisme klasifikasi berdasarkan aturan keputusan yang telah diuraikan sebelumnya, langkah berikutnya melibatkan evaluasi tingkat akurasi aturan tersebut dalam mengantisipasi data yang belum dikenal. Proses pengujian ini dilakukan dengan menggunakan 154 sampel data pengujian yang tidak pernah terlibat dalam proses pelatihan model. Hasil evaluasi tersebut kemudian divisualisasikan dalam bentuk matriks penilaian untuk membandingkan *output* prediksi model dengan kondisi aktual pasien di dunia nyata. Penilaian kinerja ini krusial untuk memastikan bahwa model tidak hanya menawarkan kemudahan interpretasi visual, tetapi juga menunjukkan tingkat kepercayaan yang dapat dipertanggungjawabkan secara medis, sebagaimana tercermin dalam hasil analisis *Confusion Matrix* berikut.

Tabel 1. Confusion Matrix Hasil Prediksi Diabetes

	Prediksi: Sehat (0)	Prediksi: Diabetes (1)
Aktual: Sehat (0)	83 ( <i>True Negative</i> )	16 ( <i>False Positive</i> )
Aktual: Diabetes (1)	20 ( <i>False Negative</i> )	35 ( <i>True Positive</i> )

Berdasarkan data pada Tabel 1, dapat disimpulkan performa objektif dari model tersebut. Dari keseluruhan 99 sampel pasien yang sebenarnya tidak menderita diabetes, model mampu mengidentifikasi 83 di antaranya dengan tepat. Di sisi lain, dari 55 sampel pasien yang benar-benar terdiagnosis diabetes, model berhasil mengenali 35 sampel secara benar. Meskipun demikian, masih ada 20 kasus *False Negative*, yakni individu dengan diabetes yang diprediksi sebagai sehat, yang merupakan aspek krusial dalam penilaian klinis. Untuk menilai kinerja model secara komprehensif sesuai dengan kriteria pembelajaran mesin standar, data dari matriks tersebut diubah menjadi persentase metrik evaluasi dalam tabel berikut.

Tabel 2. Hasil Penilaian Performa Model

Indikator Evaluasi	Hasil Perhitungan
Akurasi ( <i>Accuracy</i> )	76,62%
Presisi ( <i>Precision</i> )	0,69
Sensitivitas ( <i>Recall</i> )	0,64
F1-Score	0,66

Evaluasi kinerja yang tercermin dalam Tabel 2 mengungkapkan bahwa model mencapai tingkat akurasi sebesar 76,62%. Angka presisi 0,69 mengindikasikan bahwa ketika model mengklasifikasikan pasien sebagai penderita diabetes, keakuratan prediksinya adalah 69%. Adapun nilai *Recall* yang mencapai 0,64 menunjukkan kemampuan model untuk mendeteksi 64% dari total kasus diabetes dalam *dataset* pengujian. Walaupun masih ada peluang untuk meningkatkan sensitivitas agar mengurangi jumlah *false-negative*, secara umum model ini telah memenuhi harapan sebagai alat bantu keputusan awal yang jelas dan mudah dipahami oleh profesional kesehatan.

#### 4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa pendekatan *supervised learning* dengan algoritma *Decision Tree* mampu digunakan secara efektif dalam memprediksi penyakit diabetes menggunakan *dataset* Pima Indians Diabetes. Proses pembentukan model melalui tahapan pengumpulan data, *preprocessing*, pembagian data menggunakan metode *hold-out*, serta pembangunan model berbasis entropi menghasilkan struktur pohon keputusan yang jelas dan mudah dipahami. Evaluasi model pada 154 sampel pengujian menunjukkan performa yang kuat, dengan tingkat akurasi mencapai 76,62%. Lebih lanjut, analisis melalui Matriks Kebingungan mengungkapkan 83 sampel Negatif Benar, 35 sampel Positif Benar, 16 sampel Positif Palsu, serta 20 sampel Negatif Palsu. Model ini juga mencatat nilai presisi sebesar 0,81 untuk kategori non-diabetes dan 0,69 untuk kategori diabetes.

Model yang dikembangkan mampu menghasilkan aturan klasifikasi yang sederhana dan mudah diinterpretasi, sehingga cocok sebagai alat bantu keputusan untuk diagnosis awal diabetes. Atribut Glukosa teridentifikasi sebagai prediktor utama, sebagaimana tercermin dari posisinya sebagai simpul akar dalam struktur pohon keputusan. Hal ini menawarkan keuntungan transparansi bagi profesional kesehatan untuk memahami keterkaitan logis antara indikator risiko medis. Secara umum, studi ini menegaskan potensi algoritma Pohon Keputusan sebagai instrumen deteksi dini yang dapat dijelaskan dengan baik.

Sebagai prospek pengembangan dan studi lanjut ke depannya, disarankan penerapan teknik evaluasi yang lebih mendalam seperti validasi silang *k-fold* guna meningkatkan stabilitas hasil. Penelitian lanjutan juga dapat membandingkan efektivitasnya dengan algoritma klasifikasi lainnya, seperti *Random Forest* atau *Support Vector Machine*, serta mengintegrasikan variasi atribut medis yang lebih luas. Transformasi model ini menjadi aplikasi komputer yang dapat diakses langsung oleh masyarakat akan berkontribusi besar dalam upaya pencegahan dan pengelolaan penyakit diabetes.

Kedua, dalam penelitian berikut, bisa dilakukan perbandingan performa antara algoritma *Decision Tree* dan algoritma klasifikasi lainnya seperti *Random Forest*, *Support Vector Machine*, atau *Naive Bayes*. Dengan perbandingan ini, diharapkan akan terlihat metode yang paling tepat untuk memprediksi penyakit diabetes berdasarkan karakteristik data yang digunakan.

Ketiga, jika jumlah data dan atribut medis yang lebih komprehensif ditambahkan—seperti riwayat keluarga, tekanan darah, dan kadar kolesterol—ini mungkin akan meningkatkan akurasi dan ketepatan model prediksi. Dengan data yang lebih bervariasi, model yang dihasilkan bisa lebih baik mencerminkan kondisi medis pasien secara keseluruhan.

Terakhir, penelitian ini bisa dikembangkan menjadi sistem atau aplikasi komputer yang dapat langsung digunakan oleh tenaga medis atau masyarakat sebagai alat bantu untuk diagnosis awal. Dengan pengembangan ini, diharapkan hasil penelitian dapat memberikan kontribusi signifikan dalam usaha pencegahan dan pengendalian penyakit diabetes.

## REFERENSI

- [1] R. Y. Averina and I. G. N. J. A. Widagda, “肖沉 1, 2, 孙莉 1, 2Δ, 曹杉杉 1, 2, 梁浩 1, 2, 程焱 1, 2,” *Tjyybjb.Ac.Cn*, vol. 27, no. 2, pp. 635–637, 2021.
- [2] J. B. Cole and J. C. Florez, “Genetics of diabetes mellitus and diabetes complications,” *Nat. Rev. Nephrol.*, vol. 16, no. 7, pp. 377–390, 2020, doi: 10.1038/s41581-020-0278-5.
- [3] A. Mousa, W. Mustafa, and R. B. Marqas, “A Comparative Study of Diabetes Detection Using The Pima Indian Diabetes Database,” *J. Univ. Duhok*, vol. 26, no. 2, pp. 277–288, 2023, doi: 10.26682/suod.2023.26.2.24.
- [4] B. T. Jijo and A. M. Abdulazeez, “Classification Based on Decision Tree Algorithm for Machine Learning,” *J. Appl. Sci. Technol. Trends*, vol. 2, no. 1, pp. 20–28, 2021, doi: 10.38094/jastt20165.
- [5] I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions,” *SN Comput. Sci.*, vol. 2, no. 3, pp. 1–21, 2021, doi: 10.1007/s42979-021-00592-x.
- [6] F. Ardyansyah, E. Daniati, and A. Ristyawan, “Pemanfaatan Data Mining untuk Analisis Keputusan,” *Agustus*, vol. 8, pp. 2549–7952, 2024.
- [7] S. Pewekar, M. Tirkey, A. Mallik, R. Shaikh, and S. A. Wagle, “Diabetes Prediction Using Machine Learning,” *Lect. Notes Electr. Eng.*, vol. 1196 LNEE, no. 8, pp. 67–76, 2024, doi: 10.1007/978-981-97-7862-1\_5.
- [8] A. H. Nasrullah, “Implementasi Algoritma Decision Tree Untuk Klasifikasi Produk Laris,” *J. Ilm. Ilmu Komput.*, vol. 7, no. 2, pp. 45–51, 2021, doi: 10.35329/jiik.v7i2.203.
- [9] H. Chen, S. Hu, R. Hua, and X. Zhao, “Improved naive Bayes classification algorithm for traffic risk management,” *EURASIP J. Adv. Signal Process.*, vol. 2021, no. 1, 2021, doi: 10.1186/s13634-021-00742-6.
- [10] O. Y. Inonu, K. Magda, and A. Amarudin, “Analisis Kinerja Algoritma Random Forest Dengan Model Machine Learning Pada Dataset Penyakit Diabetes,” *Expert J. Manaj. Sist. Inf. dan Teknol.*, vol. 15, no. 1, p. 1, 2025, doi: 10.36448/expert.v15i1.4312.
- [11] Merdin Shamal Salih, “Diabetic Prediction based on Machine Learning Using PIMA Indian Dataset,” *Commun. Appl. Nonlinear Anal.*, vol. 31, no. 5s, pp. 138–156, 2024, doi: 10.52783/cana.v31.1008.
- [12] M. Kahn, “Diabetes,” UCI Machine Learning Repository. [Online]. Available: <https://doi.org/10.24432/C5T59G>
- [13] E. O. Manhitu, Y. P. K. Kelen, and D. Chrisinta, “Implementasi algoritma k-nearest neighbor untuk klasifikasi omset usaha mikro di kabupaten timor tengah utara,” *Zo. J. Sist. Inf.*, vol. 7, no. 1, pp. 304–316, 2025.
- [14] Putri and Nur, “Penggunaan Bahasa Python Untuk Analisis Dan Visualisasi Data Penduduk Di Desa Sumberjo, Nganjuk,” *J. Pengabd. Kpd. Masy.*, vol. 3, no. 3, pp. 206–217, 2023, [Online]. Available: [https://jurnalkip.samawa-university.ac.id/karya\\_jpm/index](https://jurnalkip.samawa-university.ac.id/karya_jpm/index)
- [15] A. S. Saabith, T. Vinohraj, and M. Fareez, “A Review on Python Libraries and Ides for Data Science,” *Int. J. Res. Eng. Sci. ISSN*, vol. 09, no. 11, pp. 36–53, 2021, [Online]. Available: [www.ijres.org](http://www.ijres.org)
- [16] M. Azhari, Z. Situmorang, and R. Rosnelly, “Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes,” *J. Media Inform. Budidarma*, vol. 5, no. 2, p. 640, 2021, doi: 10.30865/mib.v5i2.2937.

# Klasifikasi Gempa Bumi Menggunakan Algoritma Decision Tree Berbasis Data BMKG

Dessianna Natalia Sembiring<sup>1</sup>, Beata Berlina Halawa<sup>2</sup>, Sardo P Sipayung<sup>3</sup>

<sup>1,2,3</sup>Ilmu Komputer, Universitas Katolik Santo Thomas, Medan, Indonesia

Email: <sup>1</sup>desiana01724@gmail.com, <sup>2</sup>brataberlinahalawa@gmail.com, <sup>3</sup>pinarsiphom@gmail.com

## ABSTRAK

Penelitian ini dilakukan untuk mengklasifikasikan gempa bumi menggunakan algoritma *Decision Tree* berbasis data Badan Meteorologi, Klimatologi, dan Geofisika. Indonesia merupakan wilayah yang memiliki tingkat aktivitas seismik tinggi sehingga diperlukan metode klasifikasi yang mampu mengelompokkan gempa bumi berdasarkan karakteristiknya secara sistematis. Data penelitian terdiri atas parameter magnitudo dan kedalaman gempa bumi yang kemudian diklasifikasikan ke dalam kelas gempa ringan, sedang, dan kuat. Tahapan penelitian meliputi pengumpulan data, pra-proses data, penentuan kelas gempa, pembentukan model klasifikasi menggunakan algoritma *Decision Tree*, serta evaluasi hasil klasifikasi. Hasil penelitian menunjukkan bahwa algoritma *Decision Tree* mampu mengklasifikasikan gempa bumi dengan baik berdasarkan kombinasi nilai magnitudo dan kedalaman. Model yang dihasilkan membentuk aturan keputusan yang jelas dan mudah dipahami dalam membedakan kelas gempa ringan, sedang, dan kuat. Kesimpulan dari penelitian ini menunjukkan bahwa algoritma *Decision Tree* dapat digunakan sebagai metode yang efektif dan interpretatif untuk klasifikasi gempa bumi berbasis data Badan Meteorologi, Klimatologi, dan Geofisika.

**Kata Kunci:** Gempa Bumi, Pohon Keputusan, Klasifikasi

## ABSTRACT

*This study was conducted to classify earthquakes using the Decision Tree algorithm based on data from the Meteorology, Climatology, and Geophysics Agency. Indonesia is a region with high seismic activity, which requires a systematic classification method to group earthquakes according to their characteristics. The data used in this study consisted of earthquake magnitude and depth parameters, which were classified into light, moderate, and strong earthquake classes. The research stages included data collection, data preprocessing, determination of earthquake classes, construction of a classification model using the Decision Tree algorithm, and evaluation of the classification results. The results showed that the Decision Tree algorithm was able to classify earthquakes effectively based on the combination of magnitude and depth values. The resulting model generated clear and easily interpretable decision rules to distinguish between light, moderate, and strong earthquake classes. The conclusion of this study indicated that the Decision Tree algorithm could be used as an effective and interpretable method for earthquake classification based on data from the Meteorology, Climatology, and Geophysics Agency.*

**Keywords:** Earthquake, Decision Tree, Classification

## Penulis Korespondensi:

Dessianna Natalia Sembiring

Email: desiana01724@gmail.com

## Article Info

Diterima: 29 Januari 2026

Direvisi: 2 Februari 2026

Disetujui: 2 Februari 2026

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



## 1. PENDAHULUAN

Data gempa bumi yang digunakan dalam penelitian ini diambil dari Badan Meteorologi, Klimatologi, dan Geofisika pada periode 4 Desember 2025 hingga 4 Januari 2026. Data diperoleh langsung dari situs resmi BMKG yang menyediakan informasi kejadian gempa bumi secara daring setelah gempa terjadi. Informasi gempa bumi tersebut disajikan dalam format *Extensible Markup Language*, yang memuat data tanggal, waktu kejadian, wilayah gempa, magnitudo, serta kedalaman gempa

bumi di Indonesia. Selama periode pengambilan data, tercatat sebanyak 15 kejadian gempa bumi. Berdasarkan data yang dikumpulkan, nilai magnitudo gempa bumi berada pada rentang 5.0 hingga 5.8 skala Richter, dengan kedalaman gempa berkisar antara 18 kilometer hingga 96 kilometer. Data gempa bumi ini selanjutnya digunakan sebagai *dataset* penelitian untuk proses klasifikasi gempa bumi ke dalam kelas gempa ringan, sedang, dan kuat berdasarkan parameter magnitudo dan kedalaman menggunakan algoritma *Decision Tree* [1].


Klasifikasi gempa bumi pada penelitian ini dilakukan menggunakan algoritma *Decision Tree* dengan memanfaatkan parameter magnitudo dan kedalaman gempa sebagai atribut utama. Penggunaan algoritma *Decision Tree* dipilih karena kemampuannya dalam menghasilkan aturan keputusan yang bersifat interpretatif dan mudah dipahami untuk analisis data seismik. Penelitian oleh Akbar *et al.* menunjukkan bahwa *Decision Tree* efektif digunakan dalam mengklasifikasikan tingkat risiko gempa bumi berdasarkan parameter seismik seperti magnitudo dan kedalaman, serta mampu membentuk pola klasifikasi yang jelas dan akurat [2].

Gempa bumi adalah fenomena alam yang terjadi akibat pelepasan energi di dalam bumi yang disebabkan oleh pergerakan [3] lempeng tektonik, aktivitas patahan, atau aktivitas vulkanik, sehingga menimbulkan getaran pada permukaan bumi [4]. Besarnya dampak gempa bumi dipengaruhi oleh beberapa parameter utama, di antaranya magnitudo dan kedalaman gempa. Gempa bumi yang terjadi di Indonesia pada daerah 26 Km Barat Daya Enggano Bengkulu merupakan salah satu contoh gempa bumi yang tingkat kedalamannya tinggi [5].

Magnitudo dan kedalaman merupakan dua parameter fundamental dalam studi gempa bumi karena keduanya secara langsung memengaruhi karakteristik seismik dan potensi dampak suatu kejadian gempa. Magnitudo menggambarkan besarnya energi yang dilepaskan saat gempa terjadi, sementara kedalaman menunjukkan lokasi sumber gempa di bawah permukaan bumi, yang memengaruhi intensitas guncangan yang dirasakan di permukaan [6]. Kombinasi antara magnitudo dan kedalaman sering digunakan dalam evaluasi seismisitas dan karakter gempa, termasuk dalam analisis distribusi frekuensi-magnitudo yang memberikan gambaran tentang aktivitas kegempaan wilayah tertentu. Penelitian oleh Yuliatmoko dan rekan pada Jurnal Meteorologi dan Geofisika menunjukkan pentingnya parameter magnitudo dalam kaitannya dengan distribusi gempa serta variabel seismik lainnya dalam identifikasi pola seismik di zonal seismik Indonesia, yang mencerminkan relevansi magnitudo dan parameter terkait dalam kajian kegempaan regional [7].

## 2. METODE PENELITIAN

Pada penelitian ini digunakan metodologi penelitian berbasis *data mining* untuk mengklasifikasikan kejadian gempa bumi di Indonesia menggunakan algoritma *Decision Tree*. Metodologi yang digunakan bertujuan untuk menghasilkan model klasifikasi yang akurat serta mudah diinterpretasikan. Tahapan penelitian dilakukan secara sistematis mulai dari pengumpulan data hingga evaluasi hasil klasifikasi [8]. Tahapan alur penelitian dapat dijelaskan sebagai berikut:



Gambar 1. Tahapan alur penelitian

## 2.1. Pengumpulan Data

Pengumpulan data pada penelitian ini menggunakan Dataset gempa bumi yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) [9]. Data yang digunakan merupakan data kejadian gempa bumi historis yang tercatat dalam periode tertentu dan disediakan secara terbuka oleh BMKG.

Dataset mencakup beberapa atribut utama, antara lain tanggal dan waktu kejadian, koordinat lintang dan bujur, magnitudo, serta kedalaman gempa. Data yang diperoleh kemudian diseleksi untuk memastikan kelengkapan dan konsistensi data sebelum digunakan pada tahap selanjutnya. Data gempa bumi yang digunakan dalam penelitian ini merupakan data resmi yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) melalui laman Data Gempa Bumi Terbuka BMKG (<https://data.bmkg.go.id>). Data yang digunakan dalam penelitian ini dibatasi pada kejadian gempa bumi dengan magnitudo  $\geq 5,0$  dan selanjutnya diolah menggunakan Microsoft Excel sebagai *dataset* untuk proses klasifikasi.

## 2.2. Pengolahan Data Menggunakan XML

Data gempa bumi yang diperoleh dalam format XML kemudian diproses untuk mengekstraksi atribut-atribut yang relevan. Pada tahap ini dilakukan:

- Pembacaan struktur XML
- Pengambilan elemen data yang diperlukan (tanggal, waktu, koordinat, magnitudo, dan kedalaman)
- Penyusunan ulang data agar siap untuk dikonversi ke format tabel

Proses ini bertujuan untuk memastikan bahwa data mentah dari BMKG telah terstruktur dengan baik sebelum dilakukan pengolahan lebih lanjut. Berikut ini bentuk data XML yang sudah di ambil dari data gempa bumi.

```
This XML file does not appear to have any style information associated with it. The document tree is shown below.
<?xml version="1.0" encoding="UTF-8" ?>
<Infogempa>
  <gempa>
    <Tanggal>30 Jan 2026</Tanggal>
    <Jam>08:15:29 WIB</Jam>
    <DateTime>2026-01-30T01:15:29+00:00</DateTime>
    <point>
      <coordinates>-0.39,124.63</coordinates>
    </point>
    <Lintang>0.39 LS</Lintang>
    <Bujur>124.63 BT</Bujur>
    <Magnitudo>5.1</Magnitudo>
    <Kedalaman>10 km</Kedalaman>
    <Wilayah>110 km Tenggara BOLAANGUKI-BOLSEL-SULUT</Wilayah>
    <Potensi>Tidak berpotensi tsunami</Potensi>
  </gempa>
  <gempa>
    <Tanggal>27 Jan 2026</Tanggal>
    <Jam>08:20:44 WIB</Jam>
    <DateTime>2026-01-27T01:20:44+00:00</DateTime>
    <point>
      <coordinates>-8.14,111.33</coordinates>
    </point>
    <Lintang>8.14 LS</Lintang>
    <Bujur>111.33 BT</Bujur>
    <Magnitudo>5.5</Magnitudo>
    <Kedalaman>105 km</Kedalaman>
    <Wilayah>25 km TimurLaut PACITAN-JATIM</Wilayah>
    <Potensi>Tidak berpotensi tsunami</Potensi>
  </gempa>
  <gempa>
    <Tanggal>26 Jan 2026</Tanggal>
    <Jam>07:54:02 WIB</Jam>
    <DateTime>2026-01-26T00:54:02+00:00</DateTime>
    <point>
      <coordinates>-7.71,127.81</coordinates>
```

Gambar 2. Data XML

## 2.3. Konversi dan Pengolahan Data Menggunakan Microsoft Excel

Setelah data diekstraksi dari *file* XML, data kemudian dikonversi ke dalam format Microsoft Excel (.xlsx). Pada tahap ini dilakukan:

- Penyusunan data dalam bentuk tabel
- Pembersihan data dari nilai kosong atau tidak valid
- Pengelompokan data berdasarkan kriteria tertentu, seperti rentang magnitudo gempa

Microsoft Excel digunakan karena kemampuannya dalam mengelola dan memvisualisasikan data secara sederhana serta memudahkan proses eksplorasi data sebelum dilakukan klasifikasi menggunakan algoritma *Decision Tree*.

### 2.4. Pembentukan Dataset untuk Decision Tree

Data yang telah diolah dalam Microsoft Excel selanjutnya digunakan sebagai Dataset untuk proses klasifikasi. Pada tahap ini ditentukan:

- a. Atribut *input* (misalnya magnitudo dan kedalaman)
- b. Kelas target (kategori gempa bumi)

Dataset ini kemudian disiapkan untuk diproses menggunakan algoritma *Decision Tree*.

## 3. HASIL DAN PEMBAHASAN

### 3.1. Hasil Pengumpulan dan Karakteristik Data

Data gempa bumi yang digunakan dalam penelitian ini diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Data yang digunakan merupakan data historis gempa bumi yang mencakup informasi tanggal dan waktu kejadian, lokasi gempa (lintang dan bujur), magnitudo, serta kedalaman gempa.

Berdasarkan hasil pengumpulan data, diperoleh sejumlah data gempa bumi yang selanjutnya digunakan sebagai *Dataset* penelitian. Data ini kemudian diklasifikasikan ke dalam dua kelas, yaitu Bahaya dan Tidak Bahaya, berdasarkan kriteria magnitudo dan kedalaman gempa.

Penggunaan data BMKG sebagai sumber data dinilai tepat karena BMKG merupakan lembaga resmi yang menyediakan data gempa bumi di Indonesia dan telah digunakan secara luas pada penelitian sejenis [10].

```

1  <?php
2  // Kode Baris PHP untuk Mengolah Data gempaterkini.xml
3  $data = simplexml_load_file("https://data.bmkg.go.id/DataAMKG/TEWS/gempaterkini.xml") or die ("Gagal ambil!");
4  echo "<h2>Daftar 15 Gempabumi M 5.0+</h2>";
5  $i = 1;
6  foreach($data->gempa as $gempaM5) {
7      echo "No: " . $i . "<br>";
8      echo "Tanggal: " . $gempaM5->Tanggal . "<br>";
9      echo "Jam: " . $gempaM5->Jam . "<br>";
10     echo "DateTime: " . $gempaM5->DateTime . "<br>";
11     echo "Magnitudo: " . $gempaM5->Magnitude . "<br>";
12     echo "Kedalaman: " . $gempaM5->Kedalaman . "<br>";
13     echo "Koordinat: " . $gempaM5->point->coordinates . "<br>";
14     echo "Lintang: " . $gempaM5->Lintang . "<br>";
15     echo "Bujur: " . $gempaM5->Bujur . "<br>";
16     echo "Lokasi: " . $gempaM5->wilayah . "<br>";
17     echo "Potensi: " . $gempaM5->Potensi . "<br><br>";
18     $i++;
19 }
20 ?>
    
```

Gambar 3. Hasil pengumpulan data

### 3.2. Hasil Pra-Pemrosesan dan Pengolahan Data

Data gempa bumi yang diperoleh dari BMKG selanjutnya diolah melalui format XML untuk mengekstraksi atribut yang dibutuhkan. Setelah itu, data dikonversi ke dalam Microsoft Excel untuk dilakukan pembersihan data (*data cleaning*), penghapusan data tidak lengkap, serta transformasi data ke dalam bentuk tabular.

Pada tahap ini, dilakukan pengelompokan nilai magnitudo ke dalam kategori Rendah, Sedang, dan Tinggi guna mempermudah proses klasifikasi. Proses pra-pemrosesan ini bertujuan untuk meningkatkan kualitas data dan mengurangi potensi kesalahan pada tahap klasifikasi.

Hasil pra-pemrosesan menunjukkan bahwa data telah siap digunakan untuk pembentukan model klasifikasi menggunakan algoritma *Decision Tree* [11].

Tabel 1. Hasil pengolahan data

NO	TANGGAL	WAKTU (WIB)	KEDALAMAN	WILAYAH
1	04-Des-25	03:46:57	10 km	170 km Tenggara Tutuyan, Sulut
2	06-Des-25	03:42:25	35 km	74 km Barat Daya Wanokaka, NTT
3	06-Des-25	07:44:34	99 km	54 km Barat Laut Halmahera Barat
4	07-Des-25	11:55:55	103 km	150 km Barat Laut Sinabung, Aceh
5	09-Des-25	14:02:53	10 km	54 km Barat Laut Sinabung, Aceh
6	20-Des-25	17:33:27	102 km	1 km Timur Laut Puhuwato, Gorontalo

7	21-Des-25	11;02;10	144 km	143 km Timur Laut Tanimbar
8	21-Des-25	19;21;46	27 km	133 km Barat Laut Jailolo, Maluku Utara
9	27-Des-25	07;22;32	19 km	26 km Tenggara Enggano, Bengkulu
10	27-Des-25	08;10;13	18 km	26 km Barat Daya Enggano Bengkulu
11	01-Jan-26	09;56;23	96 km	40 km Timur Laut Karatung, Sulut
12	01-Jan-26	10;05;25	189 km	209 km Barat Laut Tanimbar
13	01-Jan-26	13;02;00	133 km	26 km Tenggara Lanny Jaya, Papua
14	03-Jan-26	01;29;57	88 km	134 km Barat Laut Tual, Maluku
15	04-Jan-26	03;46;57	102 km	44 km Timur Laut Pulau Karatung, Sulut

### 3.3. Hasil Perhitungan Entropi dan Information Gain

Perhitungan entropi dan *information gain* dilakukan untuk menentukan atribut terbalik yang digunakan sebagai *node* dalam pohon keputusan. Atribut Magnitudo menghasilkan nilai *information gain* tertinggi, atribut Kedalaman yang halnya menghasilkan nilai *gain* [12]. Hal ini menunjukkan bahwa atribut Magnitudo memiliki pengaruh paling besar dalam proses klasifikasi tingkat bahaya gempa bumi. Dengan demikian, atribut Magnitudo dipilih sebagai *node* akar (*root node*) pada pembentukan pohon keputusan [13].

Setelah hasil pra-pemrosesan data dilakukan maka akan masuk ke hasil perhitungan entropi dan informasi *gain* pada *Node*. Dimana hasil nilai *gain* tertinggi itu ialah hasil dari data gempa bumi Magnitudo dengan nilai 0,7168 dan hasil entropi tertinggi pada nilai 0,5446.

Tabel 2. Hasil perhitungan informasi pada *node* awal

NODE		Jumlah	Bahaya	Tidak Bahaya	Entropi	Gain
1	<b>Data Gempa Bumi</b>	15	6	9	0,9710	
	<b>Magnitudo</b>					<b>0,7168</b>
	Rendah	5	0	5	0,0000	
	Sedang	7	2	5	0,5446	
	Tinggi	3	3	0	0,0000	
	<b>Kedalaman</b>					<b>0,1451</b>
	Dangkal	6	4	2	0,918296	
	Menengah	9	2	7	0,764205	

Setelah hasil pada *Node* 1 sudah didapatkan nilai *gain* yang tertinggi maka akan dilanjutkan untuk tahap yang berikutnya yaitu *Node*2 dengan nama data gempa bumi Magnitudo-sedang, maka akan dilakukan untuk perhitungan data dimana nilai *gain* tertinggi itu masuk ke data gempa bumi Kedalaman dengan nilai 0,4696.

Tabel 3. Hasil perhitungan informasi pada *node*1

NODE 1		Jumlah	Bahaya	Tidak Bahaya	Entropi	Gain
1	<b>Magnitudo-Sedang</b>	7	2	5	0,8631	
	<b>Kedalaman</b>					<b>0,4696</b>
	Dangkal	3	2	1	0,9183	
	Menengah	4	0	4	0,0000	

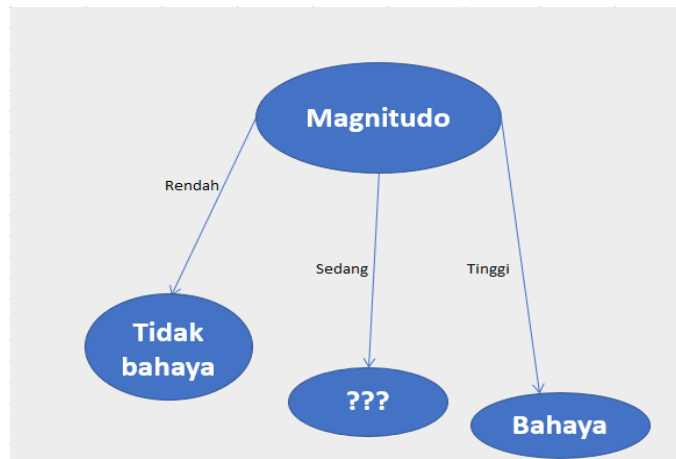
### 3.4. Hasil Pembentukan Pohon Keputusan

Berdasarkan hasil perhitungan *information gain*, pohon keputusan yang terbentuk menunjukkan bahwa:

- Gempa dengan Magnitudo Rendah diklasifikasikan sebagai Tidak Bahaya
- Gempa dengan Magnitudo Tinggi diklasifikasikan sebagai Bahaya
- Gempa dengan Magnitudo Sedang memerlukan atribut tambahan, yaitu Kedalaman, untuk menentukan kelas bahaya


Struktur pohon keputusan ini menghasilkan aturan (*rule*) klasifikasi yang sederhana dan mudah dipahami, sehingga model yang dihasilkan bersifat *interpretable* dan dapat digunakan sebagai dasar pengambilan keputusan [14].

Jika data sudah lengkap dan sudah didapatkan nilai tertinggi dari nilai entropi dan informasi nilai *gain*, maka setelah itu akan masuk ke pembentukan pohon keputusan dimana bentuk pohon keputusan dari *Node* awal dengan data gempa bumi Magnitudo yang sudah didapatkan hasilnya, maka pembentukan pohon sebagai berikut.



Gambar 4. Hasil pembentukan pohon keputusan *node* awal

Lanjut untuk *Node* 1 dengan dari data gempa bumi Magnitudo menjadi data gempa bumi Magnitudo-Sedang, dengan data yang sudah selesai dan sudah lengkap maka setelah itu akan masuk ke pembentukan pohon keputusan dimana bentuk pohon keputusan dari *Node* 1 sebagai berikut.



Gambar 5. Hasil pembentukan pohon keputusan *Node* 2

### 3.5. Evaluasi Model Klasifikasi

Evaluasi model klasifikasi dilakukan dengan menganalisis hasil klasifikasi yang diperoleh dari pohon keputusan. Evaluasi ini difokuskan pada kejelasan aturan klasifikasi dan kesesuaian hasil klasifikasi dengan kondisi data aktual.

Hasil evaluasi menunjukkan bahwa algoritma *Decision Tree* mampu menghasilkan model klasifikasi yang konsisten, sistematis, dan mudah ditelusuri. Berdasarkan perhitungan *information gain*, atribut Magnitudo memiliki nilai gain tertinggi sebesar 0,7168, sehingga dipilih sebagai akar (*root*) pohon keputusan. Hal ini menunjukkan bahwa magnitudo merupakan faktor paling dominan dalam menentukan tingkat bahaya gempa bumi pada data yang digunakan.

Pada cabang Magnitudo Sedang, dilakukan pemisahan lanjutan menggunakan atribut Kedalaman, yang menghasilkan nilai *information gain* sebesar 0,4696. Pemisahan ini mampu meningkatkan kejelasan klasifikasi, di mana gempa dengan kedalaman dangkal cenderung diklasifikasikan sebagai bahaya, sedangkan gempa dengan kedalaman menengah diklasifikasikan sebagai tidak bahaya.

Meskipun evaluasi dilakukan secara manual menggunakan Microsoft Excel, hasil yang diperoleh tetap sejalan dengan konsep evaluasi model klasifikasi secara umum, khususnya dalam mengukur ketepatan pemilihan atribut dan konsistensi aturan klasifikasi yang dihasilkan. Model yang terbentuk menunjukkan bahwa *decision tree* efektif dalam merepresentasikan pola data gempa bumi secara logis dan mudah dipahami [15].

## 4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa algoritma *Decision Tree* mampu digunakan secara efektif dalam mengklasifikasikan kejadian gempa bumi berdasarkan data yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Data gempa bumi yang bersumber dari BMKG, yang diproses melalui format XML dan

selanjutnya diolah menggunakan Microsoft Excel, terbukti dapat dimanfaatkan sebagai *dataset* yang terstruktur dan layak untuk proses klasifikasi.

Hasil perhitungan menunjukkan bahwa dari total 15 data gempa bumi, diperoleh nilai entropi awal sebesar 0,9710, yang menggambarkan tingkat ketidakpastian data sebelum dilakukan proses klasifikasi. Berdasarkan perhitungan *information gain*, atribut Magnitudo memiliki nilai gain tertinggi sebesar 0,7168, sehingga dipilih sebagai *node* akar (*root node*) dalam pembentukan pohon keputusan. Nilai ini menunjukkan bahwa magnitudo merupakan atribut yang paling berpengaruh dalam menentukan tingkat bahaya gempa bumi pada *dataset* yang digunakan.

Pada proses pemisahan lanjutan, khususnya pada data dengan Magnitudo Sedang yang berjumlah 7 data, diperoleh nilai entropi sebesar 0,8631. Atribut Kedalaman kemudian digunakan sebagai pemisah dengan menghasilkan nilai *information gain* sebesar 0,4696, yang menunjukkan kemampuan atribut tersebut dalam mengurangi ketidakpastian data. Hasil klasifikasi pada tahap ini menunjukkan bahwa gempa dengan kedalaman dangkal cenderung diklasifikasikan sebagai bahaya, sedangkan gempa dengan kedalaman menengah diklasifikasikan sebagai tidak bahaya.

Struktur pohon keputusan yang dihasilkan mampu membentuk aturan klasifikasi (*decision rules*) yang jelas, sistematis, dan mudah dipahami, sehingga model yang dibangun bersifat interpretatif (*interpretable*). Setiap keputusan klasifikasi dapat ditelusuri secara logis berdasarkan nilai atribut yang digunakan, yang menjadi keunggulan utama algoritma *Decision Tree*.

Secara keseluruhan, penelitian ini menunjukkan bahwa penerapan algoritma *Decision Tree* berbasis data BMKG dapat digunakan sebagai pendekatan awal dalam pengelompokan tingkat bahaya gempa bumi di Indonesia. Dengan nilai *information gain* yang signifikan pada atribut utama, model yang dihasilkan dinilai mampu merepresentasikan karakteristik data gempa bumi secara efektif. Hasil penelitian ini diharapkan dapat menjadi referensi bagi penelitian selanjutnya serta mendukung pengembangan sistem analisis dan mitigasi bencana gempa bumi berbasis data.

## REFERENSI

- [1] D. P. Sinaga, R. Marwati, B. Avip, dan P. Martadiputra, "Aplikasi Web Prediksi Dampak Gempa di Indonesia Menggunakan Metode Decision Tree dengan Algoritma C4.5," vol. 5, no. April, hal. 97–108, 2023.
- [2] N. Akbar, H. Alghifari, N. Abdillah, dan O. Dahwanu, "Klasifikasi Risiko Gempa Bumi menggunakan metode Decision Tree," vol. 6, no. 2, hal. 683–694, 2025.
- [3] H. Tantyoko, D. K. Sari, dan AL. R. Wijaya, "PREDIKSI POTENSIAL GEMPA BUMI INDONESIA MENGGUNAKAN METODE RANDOM FOREST DAN FEATURE SELECTION," vol. 6, hal. 83–89, 2023.
- [4] V. N. Maret, T. Duha, M. Laia, A. K. Hudal, dan A. Jasuma, "Jurnal Informatika Klasifikasi Data Gempa Bumi di Pulau Sumatera Menggunakan Algoritma Naïve Bayes Jurnal Informatika," vol. 2, no. 1, 2023.
- [5] AL. F. Pramudya, AL. Mahadi, P. Perdana, D. F. Islamy, dan F. Ramos, "EKSTRAKSI INFORMASI KERUSAKAN BANGUNAN PASCA GEMPA," vol. 02, no. 02, hal. 21–30, 2023.
- [6] O. Somantri, "Prediksi Kekuatan Gempa Bumi Indonesia Berdasarkan Nilai Magnitudo Menggunakan Neural Network," vol. 2, hal. 203–207, 2021.
- [7] K. Gempa dan B. Dengan, "Penerapan Data Sains Untuk Klasifikasi Wilayah Yang Terdampak," vol. 7, no. 2, hal. 390–402, 2024.
- [8] A. Z. D. Nur Adiya, A. F. Desvita, AL. Fidela, D. Amelia, dan T. Astuti, "Penerapan Data Mining Untuk Klasifikasi Kualitas Udara di Daerah Istimewa Yogyakarta Menggunakan Algoritma C4.5," JDMIS J. Data Min. Inf. Syst., vol. 2, no. 2, hal. 59–65, 2024, doi: 10.54259/jdmis.v2i2.2800.
- [9] R. R. AL. Rahman dan AL. W. Wijayanto, "Pengelompokan Data Gempa Bumi Menggunakan Algoritma DbSCAN," J. Meteorol. dan Geofis., vol. 22, no. 1, hal. 31, 2021, doi: 10.31172/jmg.v22i1.738.
- [10] AL. Jufriansah, Y. Pramudya, AL. Khusnani, dan S. Saputra, "Analysis of Earthquake Activity in Indonesia by Clustering Method," J. Phys. Theor. Appl., vol. 5, no. 2, hal. 92, 2021, doi: 10.20961/jphys-theor-appl.v5i2.59133.
- [11] S. AL. Alasadi dan W. S. Bhaya, "Review\_of\_Data\_Preprocessing\_Techniques," 2017.
- [12] R. K. Amin, Indwiarti, dan Y. Sibaroni, "Implementation of decision tree using C4.5 algorithm in decision making of loan application by debtor (Case study: Bank pasar of Yogyakarta Special Region)," 2015 3rd Int. Conf. Inf. Commun. Technol. ICoICT 2015, vol. 0, hal. 75–80, 2015, doi: 10.1109/ICoICT.2015.7231400.
- [13] H. Chauhan dan A. Chauhan, "Implementation of decision tree algorithm c4.5," Int. J. Sci. Res. Publ., vol. 3, no. 10, hal. 4–6, 2013, [Daring]. Tersedia pada: <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Implementation+of+decision+tree+algorithm+c4.5#0>
- [14] M. Informatics, "ShiftTree : An Interpretable Model-Based," hal. 48–64, 2011.
- [15] M. A. Al-Hashem, A. M. Alqudhalh, dan Q. Qananwah, "Performance Evaluation of Different Machine Learning Classification Algorithms for Disease Diagnosis," Int. J. E-Health Med. Commun., vol. 12, no. 6, hal. 1–28, 2021, doi: 10.4018/IJEHMC.20211101.oal5.

# Analisis Kualitas Layanan Terhadap Loyalty Behavior ada Aplikasi SRIBU Menggunakan Metode E-Servqual

Faiz Rizki Saputra<sup>1</sup>, Bayu Waspodo<sup>2</sup>, Evy Nurmiati<sup>3</sup>

<sup>1,2,3</sup>Sistem Informasi, UIN Syarif Hidayatullah Jakarta, Indonesia

Email: <sup>1</sup>faizrizky456@gmail.com, <sup>2</sup>bayu.waspodo@uinjkt.ac.id, <sup>3</sup>evy.nurmiati@uinjkt.ac.id

## ABSTRAK

Fenomena rendahnya *rating* aplikasi dan adanya keluhan teknis pada Google Play Store menjadi latar belakang utama penelitian ini untuk mengevaluasi sejauh mana dimensi kualitas layanan mampu mempertahankan basis pengguna. Metode yang digunakan adalah *E-SERVQUAL* yang mencakup tujuh dimensi yaitu *Efficiency*, *System Availability*, *Fulfillment*, *Privacy*, *Responsiveness*, *Contact*, dan *Compensation*. Data dikumpulkan melalui kuesioner dari 405 responden pengguna aplikasi SRIBU Mobile dan dianalisis menggunakan pendekatan *Partial Least Square-Structural Equation Modeling* melalui perangkat lunak SmartPLS. Hasil penelitian menunjukkan bahwa kualitas layanan secara agregat dinilai baik dengan nilai rata-rata 1,0379. Hasil pengujian hipotesis mengonfirmasi bahwa dimensi *Efficiency*, *System Availability*, *Fulfillment*, *Privacy*, *Responsiveness*, dan *Contact* berpengaruh signifikan terhadap kepuasan pengguna. Selanjutnya, kepuasan pengguna terbukti memiliki pengaruh positif dan signifikan yang sangat kuat terhadap *loyalty behavior* dengan nilai *path coefficient* sebesar 0,875. Namun, dimensi *Compensation* ditemukan tidak memiliki pengaruh signifikan terhadap kepuasan. Selain itu, dimensi *Contact* dan *Compensation* menunjukkan nilai kesenjangan negatif, yang mengindikasikan adanya aspek layanan yang belum memenuhi ekspektasi pengguna. Penelitian ini merekomendasikan PT SRIBU Digital Kreatif untuk memprioritaskan perbaikan pada saluran dukungan pelanggan dan kebijakan kompensasi guna meminimalkan kegagalan layanan dan memperkuat loyalitas pengguna di tengah persaingan ekonomi digital yang ketat.

**Kata Kunci:** Aplikasi Mobile, *E-servqual*, Kualitas Layanan, Loyalty Behavior, SRIBU

## ABSTRACT

The phenomenon of low app ratings and technical complaints on the Google Play Store became the background of this main research to expand which service quality dimensions are able to maintain the user base. The method used is *E-SERVQUAL* which includes seven dimensions: *Efficiency*, *System Availability*, *Fulfillment*, *Privacy*, *Responsiveness*, *Contact*, and *Compensation*. Data were collected through questionnaires from 405 respondents who use the SRIBU Mobile application and analyzed using the *Partial Least Square-Structural Equation Modeling* approach through SmartPLS software. The results showed that the aggregate service quality was assessed as good with an average value of 1.0379. The results of hypothesis testing confirmed that the dimensions of *Efficiency*, *System Availability*, *Fulfillment*, *Privacy*, *Responsiveness*, and *Contact* have a significant effect on user satisfaction. Furthermore, user satisfaction was proven to have a very strong positive and significant influence on loyalty behavior with a path coefficient value of 0.875. However, the *Compensation* dimension was found to have no significant influence on satisfaction. In addition, the *Contact* and *Compensation* dimensions showed poor values indicating that there are aspects of the service that have not met user expectations. This study recommends that PT SRIBU Digital Kreatif prioritize improvements to customer support channels and compensation policies to minimize service failures and strengthen user loyalty amidst intense digital economic competition.

**Keywords:** Mobile Application, *E-servqual*, Service Quality, Loyalty Behavior, SRIBU

## Penulis Korespondensi:

Faiz Rizki Saputra

Email: faizrizky456@gmail.com

## Article Info

Diterima: 26 Januari 2026

Direvisi: 31 Januari 2026

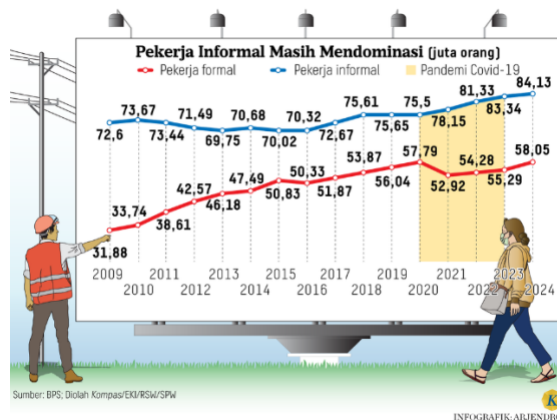
Disetujui: 9 Maret 2026

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



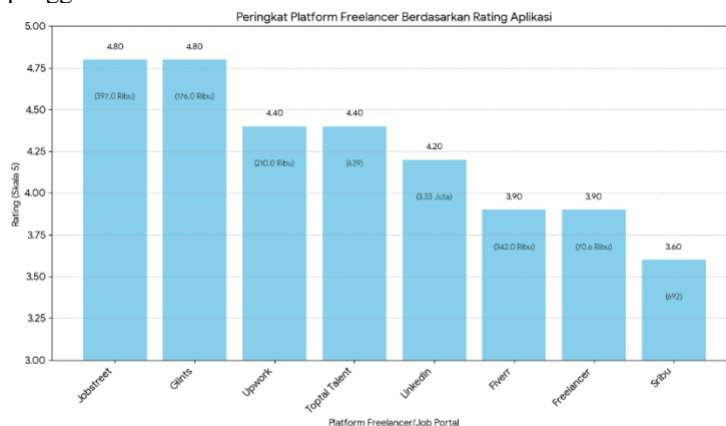
## 1. PENDAHULUAN

Latar Belakang Ekonomi global saat ini tengah mengalami transformasi struktural yang signifikan akibat perluasan ekonomi digital dan industri kreatif [1]. Fenomena ini melahirkan sistem ekonomi baru yang dikenal sebagai *gig economy*, di mana model kerja lepas (*freelancing*) dan *crowdsourcing* menjadi pilar utama dalam menghubungkan penyedia layanan dengan konsumen secara global. Pada Gambar 1 di Indonesia, data Badan Pusat Statistik (BPS) per Februari 2024 menunjukkan dominasi pekerja informal yang mencapai angka proyeksi 84,13 juta orang, melampaui jumlah pekerja formal. Pertumbuhan ini didorong oleh fleksibilitas yang ditawarkan oleh platform digital dalam memfasilitasi monetisasi kreativitas secara efisien.



Gambar 1. Data pekerja informal dan formal di Indonesia 2024

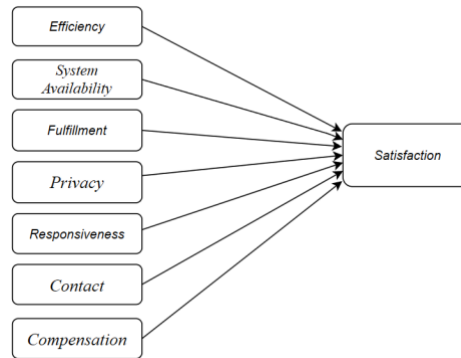
Pernyataan Masalah Meskipun ekosistem digital berkembang pesat, keberlanjutan platform *freelance* sangat bergantung pada loyalitas pengguna yang dipicu oleh kualitas layanan. SRIBU, sebagai pelopor platform *crowdsourcing* desain di Indonesia sejak 2013, kini menghadapi tantangan kompetitif yang serius [2]. Pada Gambar 2 data Google Play Store per Juni 2025 menunjukkan SRIBU hanya memiliki rating 3,6 dengan jumlah ulasan yang jauh tertinggal dibandingkan platform global seperti Fiverr (3,9) atau LinkedIn. Analisis ulasan pengguna mengungkap adanya defisiensi pada layanan digital, mulai dari masalah teknis seperti *force close* dan bug notifikasi, hingga kendala operasional seperti proses verifikasi yang lambat dan ketidakkonsistenan fitur pendaftaran. Ketidakpuasan ini berisiko tinggi meningkatkan *churn rate* dan menghambat pembentukan perilaku loyalitas pengguna.



Gambar 2. Peringkat Platform *Freelancer* Berdasarkan Rating

Penelitian terdahulu telah membuktikan bahwa kualitas layanan elektronik (*e-service quality*) memiliki kaitan erat dengan kepuasan dan loyalitas di berbagai sektor digital. Secara teoretis, model *E-SERVQUAL* yang dikembangkan oleh [3] merupakan instrumen komprehensif untuk mengukur kualitas layanan melalui tujuh dimensi utama *efficiency*, *system availability*, *fulfillment*, *privacy*, *responsiveness*, *contact*, dan *compensation*. Penggunaan metode ini telah banyak diaplikasikan pada platform *e-commerce* dan perbankan digital, namun masih terbatas pada konteks platform *crowdsourcing* kreatif di Indonesia.

Literatur Terkait Penelitian terdahulu telah membuktikan bahwa dimensi kualitas layanan elektronik memiliki pengaruh signifikan terhadap kepuasan dan loyalitas. Penggunaan metode *E-SERVQUAL* pada Gambar 3 telah diaplikasikan pada berbagai platform seperti Tokopedia untuk mengukur efisiensi [4], Netflix untuk ketersediaan sistem [5], hingga aplikasi perbankan seperti BRImo untuk dimensi responsivitas [6]. Secara teoretis, kepuasan pengguna dalam kerangka *E-Servqual* tercipta apabila pengalaman aktual pengguna mampu memenuhi atau melampaui harapan mereka terhadap tujuh dimensi utama *efficiency*, *system availability*, *fulfillment*, *privacy*, *responsiveness*, *contact*, dan *compensation* [3].



Gambar 3. Model E-Servqual

Penelitian ini mengusulkan analisis komprehensif menggunakan metode E-Servqual. Studi ini secara sistematis mengevaluasi kontribusi ketujuh dimensi kualitas layanan elektronik terhadap *loyalty behavior* pengguna aplikasi SRIBU Mobile. Pendekatan berbasis teori ini digunakan untuk memberikan rekomendasi perbaikan strategis yang terukur bagi pengembangan sistem, menggantikan pengambilan keputusan yang selama ini cenderung bersifat intuitif atau informal.

Nilai baru dari penelitian ini terletak pada analisis mendalam terhadap platform *crowdsourcing* lokal pertama di Indonesia dalam konteks *gig economy* yang spesifik. Berbeda dengan studi umum, penelitian ini mengintegrasikan keluhan pengguna dari data *real-time* (ulasan aplikasi dan wawancara) dengan model akademik terstruktur untuk memetakan titik kegagalan layanan yang berdampak langsung pada stabilitas ekonomi para *freelancer*. Inovasi penelitian ini memberikan advokasi ilmiah bagi talenta kreatif lokal agar platform yang mereka gunakan dapat berkembang menjadi ekosistem yang lebih adaptif, kompetitif, dan mampu mempertahankan basis pengguna di tengah persaingan ekonomi digital yang ketat.

## 2. LANDASAN TEORI

### 2.1. Analisis

Menurut [7] pengertian analisis adalah kegiatan berpikir untuk menguraikan suatu keseluruhan menjadi komponen sehingga dapat mengenal tanda-tanda komponen, hubungannya satu sama lain dan fungsi masing-masing dalam satu keseluruhan yang terpadu. Analisis data dapat dilakukan dengan beragam metode dan perangkat, yang disesuaikan dengan jenis data yang dikumpulkan. Untuk data kuantitatif, metode yang umum digunakan meliputi analisis statistik misalnya, statistika deskriptif, inferensial, regresi, atau korelasi untuk mengidentifikasi hubungan numerik dan signifikansi.

### 2.2. Kualitas Layanan

Kualitas layanan merupakan konsep fundamental yang merujuk pada kapabilitas organisasi dalam upaya memenuhi dan melampaui kebutuhan serta keinginan konsumen, yang diwujudkan melalui penyampaian layanan secara akurat dan konsisten untuk memenuhi ekspektasi pengguna [8]. Secara operasional, kualitas layanan dapat diukur melalui pendekatan komparatif, yaitu dengan membandingkan persepsi aktual konsumen terhadap atribut-atribut layanan yang telah mereka terima dengan ekspektasi ideal yang mereka harapkan dari penyedia layanan tersebut.

### 2.3. Loyalty Behavior

*Loyalty Behavior* adalah kecenderungan terukur dari konsumen untuk secara berkelanjutan menggunakan produk atau layanan tertentu, sebuah tindakan yang memiliki dampak langsung pada penjualan dan keberlanjutan bisnis [9]. Konsep ini lebih menekankan pada aspek perilaku (*behavioral*) daripada sikap (*attitudinal*), di mana loyalitas termanifestasi melalui tindakan nyata seperti pembelian berulang atau penggunaan layanan secara rutin [10].

### 2.4. Crowdsourcing

*Crowdsourcing* didefinisikan oleh [11] sebagai praktik strategis untuk memperoleh layanan, ide, konten, atau solusi spesifik dari kumpulan individu yang tidak terbatas atau kerumunan, yang umumnya dilakukan melalui panggilan terbuka dan *platform digital*, sebagai alternatif dari keterlibatan karyawan internal atau kontraktor tradisional. Istilah ini pertama kali dikemukakan oleh Jeff Howe pada tahun 2006, merupakan gabungan dari leksikon *crowd* dan *outsourcing*, secara harfiah menggambarkan pemanfaatan kapabilitas kolektif dari kerumunan untuk menyelesaikan tugas-tugas tertentu.

### 2.5. E-Servqual

Model E-Servqual adalah sebuah kerangka pengukuran kualitas layanan yang dikembangkan secara spesifik untuk lingkungan daring, dengan akar teoritis yang kuat dari model SERVQUAL tradisional. Evolusi model ini bermula dari karya [3] pada tahun 1980-an yang memperkenalkan SERVQUAL untuk mengukur kualitas layanan dalam konteks interaksi tatap muka konvensional. Namun, menurut [12] seiring dengan percepatan pertumbuhan internet, *e-commerce*, dan diversifikasi layanan digital, para peneliti menyadari adanya karakteristik unik pada kualitas layanan daring yang tidak sepenuhnya dapat diakomodasi oleh model SERVQUAL tradisional.


### 2.6. Penelitian Terdahulu

Table 1. Studi Terdahulu

No	Judul	Nama	Variabel	Hasil
1	Pengaruh E-Service Quality Terhadap Loyalitas Pelanggan Dengan Kepuasan Pelanggan Sebagai Variabel Intervening Di E-Commerce Shopee (Studi Kasus Pada Gen-Z Kota Palu)	[13]	<i>Efficiency, Fulfilment, System Availability, Privacy, Responsiveness, Compensation, Contact</i>	Hasil analisis menunjukkan bahwa peningkatan kualitas layanan elektronik yang diberikan oleh Shopee secara langsung berkontribusi pada peningkatan kepuasan pelanggan, yang pada gilirannya memperkuat loyalitas mereka terhadap merek. Temuan ini menegaskan pentingnya perusahaan untuk terus mengoptimalkan e-service quality guna meningkatkan pengalaman berbelanja pelanggan, terutama di kalangan Gen-Z di Kota Palu
2	Pengaruh Kualitas E-service Terhadap Loyalitas Pelanggan Di Shopee Melalui Kepuasan Pelanggan Sebagai Variabel Intervening Pada Pengguna Aplikasi Shopee Di Surabaya	[14]	<i>Efficiency, Fulfilment, System Availability, Privacy, Responsiveness, Compensation, Contact</i>	Hasil penelitian menunjukkan bahwa kepuasan yang dimiliki konsumen Shopee terhadap aplikasi berbelanja ini sudah cukup tinggi. Kepuasan ini tumbuh karena kemampuan Shopee untuk memberikan fitur-fitur berbelanja yang mudah dipahami oleh konsumennya baik itu datanya hingga keamanan saat bertransaksi. Dengan kepuasan yang tinggi maka hal ini akan sejalan dengan citra perusahaan Shopee yang baik dimata konsumennya. Citra perusahaan yang baik sangat penting bagi suatu perusahaan karena dengan citra yang baik menandakan bahwa suatu perusahaan tersebut mampu memberikan layanan yang memuaskan konsumennya serta kinerjanya yang baik.
3	Pengaruh Kepuasan Nasabah Dan E-Service Quality Terhadap Loyalitas Nasabah Pengguna M-Banking Bca	[15]	<i>Efficiency, Fulfilment, System Availability, Privacy, Responsiveness, Compensation, Contact</i>	Hasil penelitian ini dapat disimpulkan bahwa kepuasan nasabah dan e-servqual secara parsial dan simultan berpengaruh signifikan terhadap loyalitas nasabah pengguna m-banking BCA. Semakin baik kepuasan & e-servqual yang dirasakan nasabah dalam menggunakan m-banking BCA maka semakin meningkat loyalitas nasabah terhadap bank BCA. Dalam penelitian ini diharapkan bank BCA dapat menjaga tingkat kepuasan nasabah dan e-servqual yang baik agar loyalitas nasabah tetap terjaga dan juga diharapkan adanya peningkatan layanan call center yang baik dari bank BCA dalam menanggapi keluhan-keluhan yang disampaikan nasabah apabila terjadi kendala.

### 3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksplanatori untuk menguji hubungan sebab-akibat antara variabel dimensi *E-SERVQUAL* (independen) terhadap kepuasan pengguna dan *loyalty behavior* (dependen). Penelitian dilakukan secara terstruktur melalui serangkaian tahapan yang dimulai dari studi literatur, observasi ulasan publik pada Google Play Store, hingga wawancara mendalam dengan pihak manajemen SRIBU untuk mendapatkan pemahaman kontekstual dari sisi penyedia layanan.



Gambar 4. Tahapan Penelitian

Penelitian ini menggunakan desain penelitian eksplanatori dengan pendekatan kuantitatif untuk menguji hubungan kausalitas antar variabel penelitian. Tahapan penelitian dimulai dengan identifikasi masalah melalui observasi ulasan pengguna pada Google Play Store dan wawancara dengan manajemen platform SRIBU untuk memahami fenomena kualitas layanan secara mendalam. Populasi dalam studi ini mencakup seluruh pengguna aplikasi SRIBU Mobile, dengan teknik pengambilan sampel menggunakan metode *non-probability sampling* melalui pendekatan *purposive sampling*. Data primer dikumpulkan melalui penyebaran kuesioner daring yang menggunakan skala Likert untuk mengukur persepsi responden terhadap tujuh dimensi *E-Servqual* yang meliputi *efficiency*, *system availability*, *fulfillment*, *privacy*, *responsiveness*, *contact*, dan *compensation*.

Tabel 2 Daftar Pertanyaan Pemilik Usaha

No	Pertanyaan
1	Kenapa SRIBU membuat aplikasi mobile?
2	Apakah ada data internal untuk mengukur kepuasan pengguna?
3	Bagaimana SRIBU mengidentifikasi masalah teknis yang dialami pengguna?
4	Apakah pernah terjadi down server?
5	Bagaimana SRIBU menjaga privasi pengguna?
6	Apakah ada kasus kerugian pengguna karena aplikasi SRIBU?
7	Saluran komunikasi apa yang disediakan untuk pengguna?
8	Apakah ada tim khusus untuk menangani keluhan user?

Selain wawancara, peneliti juga menyebarkan kuesioner langsung terhadap para pengguna aplikasi SRIBU. Kuesioner ini dirancang sebagai serangkaian pertanyaan tertulis yang terstruktur, yang kemudian disebarkan kepada seluruh pengguna aplikasi SRIBU di Indonesia untuk diisi sesuai dengan petunjuk yang diberikan. Populasi mencakup seluruh pengguna aplikasi SRIBU Mobile. Teknik pengambilan sampel menggunakan metode *Non-Probability Sampling* dengan pendekatan *Purposive Sampling*, di mana responden dipilih berdasarkan kriteria pengalaman penggunaan aplikasi dalam kurun waktu tertentu.

Tujuan utama dari metode ini adalah untuk mengumpulkan data empiris mengenai tingkat kepuasan pengguna aplikasi SRIBU Mobile terhadap loyalty behavior. Hasil dari tahapan ini berupa data pengguna yang akan diproses lebih lanjut, mencakup data demografi responden dan data hasil dari persepsi serta harapan mereka terhadap kualitas layanan aplikasi.

Tabel 3 Daftar Pertanyaan Kuesioner

Variabel	Kode	Indikator
<i>Efficiency</i>	EF1	Kemudahan Mengakses Aplikasi
	EF2	Kecepatan Mengakses Aplikasi
	EF3	Kemudahan Penggunaan Aplikasi
<i>System Availability</i>	SA1	Keandalan Server Selama Lalu Lintas Tinggi
	SA2	Ketersediaan Fitur Utama
	SA3	Kecepatan Pemulihan Setelah Gangguan
	SA4	Keamanan Sistem yang Andal
<i>Fulfillment</i>	FL1	Kecepatan & Ketepatan Informasi Produk
	FL2	Produk Sesuai Dengan Harapan
	FL3	Ketepatan Janji
<i>Privacy</i>	PR1	Perlindungan Data Pribadi
	PR2	Keamanan Transaksi
	PR3	Pencegahan Penipuan
<i>Responsiveness</i>	RP1	Ketepatan Penanganan Masalah
	RP2	Ketanggapan Penanganan Masalah
	RP3	Kemampuan untuk Menyediakan Solusi
<i>Contact</i>	CT1	Kemudahan Akses Kontak
	CT2	Kualitas Interaksi
	CT3	Waktu Respons
<i>Compensation</i>	CP1	Kompensasi atas masalah
	CP2	Kompensasi adil
<i>Kepuasan</i>	KP1	Kepuasan Terhadap Aplikasi
	KP2	Pengalaman Aplikasi
	KP3	Kinerja Aplikasi
	KP4	Bermanfaat Bagi Pengguna
<i>Loyalty Behavior</i>	LB1	Ulasan Positif
	LB2	Rekomendasi Teman
	LB3	Lanjutkan Pembelian

Selanjutnya data yang terkumpul diolah melalui dua pendekatan analisis utama yaitu analisis data pls-sem & analisis kualitas layanan. Analisis data pls-sem mencakup analisis demografi responden, pengujian *Outer Model* untuk validitas instrumen, dan pengujian *Inner Model* untuk membuktikan hubungan kausalitas antara kualitas layanan terhadap loyalitas pengguna. Analisis kualitas layanan (*E-Servqual*) mencakup analisis gap dengan membandingkan nilai persepsi dan harapan pada tujuh dimensi *E-Servqual* untuk mengidentifikasi indikator layanan yang memerlukan perbaikan mendesak. Penggunaan pls-sem bertujuan untuk melihat "pengaruh" secara statistik, sedangkan analisis gap bertujuan untuk melihat "kualitas layanan secara nyata" berdasarkan ekspektasi pengguna.

Data hasil akan dimulai dengan analisis demografi responden untuk memberikan gambaran profil peserta penelitian. Selanjutnya, analisis statistik kuantitatif akan disajikan, mencakup hasil pengukuran tingkat kepuasan pengguna terhadap

kualitas fungsional sistem. Penelitian ini juga akan menyajikan hasil dari analisis *outer* model, analisis *inner* model dan analisis gap. Temuan dari ketiga analisis ini akan dievaluasi dengan cermat melalui perbandingan dan pertimbangan terhadap literatur ilmiah terkait, sehingga dapat memberikan pemahaman yang kuat dan terpercaya mengenai hubungan antarvariabel.

Rekomendasi dan saran penelitian akan disusun berdasarkan kesimpulan yang ditarik dari hasil analisis data. Temuan ini akan menjadi referensi utama bagi studi mendatang. Saran spesifik untuk penelitian selanjutnya juga akan diberikan, ditujukan bagi peneliti yang tertarik pada bidang serupa, dengan harapan agar mereka dapat mempertimbangkan, mengevaluasi, dan menyempurnakan aspek-aspek yang belum tercakup dalam penelitian ini. Rekomendasi yang akan disajikan mencakup hasil dan interpretasi dari analisis *outer model*, *inner model* dan analisis gap serta prioritas perbaikan dan pengembangan yang teridentifikasi

#### 4. HASIL DAN PEMBAHASAN

##### 4.1. Karakteristik Responden

Pengumpulan data yang dilakukan selama 16 hari (5–21 November 2025) berhasil menjangkit 405 responden pengguna aplikasi SRIBU Mobile. Analisis demografis menunjukkan mayoritas responden adalah laki-laki (62,2%) dengan kelompok usia dominan antara 23–27 tahun (45,2%). Dari sisi pekerjaan, pengguna inti platform adalah pekerja lepas/*freelancer* (54,8%). Menariknya, 52,8% responden merupakan pengguna baru dengan durasi penggunaan 1–4 bulan, yang mengindikasikan bahwa persepsi kualitas layanan dibentuk pada fase adaptasi aplikasi yang relatif baru diluncurkan pada tahun 2024.

Tabel 4 Analisis Demografi

No	Kategori	Hasil	Presentase
1	Jenis kelamin	Laki-laki	62,2%
2	Usia	23–27 tahun	45,2%
3	Pekerjaan	<i>freelancer</i>	54,8%
4	Sudah berapa lama menggunakan aplikasi SRIBU Mobile?	1–4 bulan	52,8%
5	Sudah berapa lama menggunakan internet?	<10 Tahun	70,6%
6	Seberapa sering membuka aplikasi dan melakukan transaksi menggunakan aplikasi SRIBU Mobile?	Jarang	43,5%
7	Sebagai apa kamu menggunakan aplikasi SRIBU Mobile	<i>Freelancer</i>	65,7%

##### 4.2. Outer Model

Validitas dan reliabilitas instrumen diuji melalui empat tahap. Seluruh indikator memiliki nilai *outer loading* di atas 0,5. Uji reliabilitas menunjukkan nilai *Cronbach's Alpha* dan *Composite Reliability* (CR) seluruh variabel melebihi ambang batas 0,7. Validitas konvergen terpenuhi dengan nilai *Average Variance Extracted* (AVE) di atas 0,5 untuk semua konstruk. Terakhir, uji *discriminant validity* melalui kriteria *Fornell-Larcker* mengonfirmasi bahwa setiap konstruk memiliki korelasi terkuat dengan variabelnya sendiri dibandingkan dengan variabel lain.

Tabel 5 Outer Model

Variabel	IND	OL	Cross Loading								SA	CA	CR	AVE	FL
			CP	CT	EF	FL	KP	LB	PR	RP					
Compensation	CP1	0.937	0.937	0.720	0.365	0.489	0.580	0.527	0.607	0.608	0.600	0.870	0.939	0.885	0.941
	CP2	0.944	0.944	0.748	0.483	0.550	0.615	0.584	0.677	0.727	0.677				
Contact	CT1	0.946	0.718	0.946	0.710	0.846	0.730	0.700	0.872	0.876	0.815	0.889	0.931	0.818	0.926
	CT2	0.859	0.637	0.859	0.617	0.762	0.573	0.499	0.789	0.782	0.593				
Efficiency	CT3	0.906	0.752	0.906	0.602	0.638	0.747	0.704	0.789	0.849	0.701	0.854	0.911	0.773	0.879
	EF1	0.887	0.285	0.501	0.887	0.668	0.573	0.476	0.522	0.536	0.547				
Fulfillment	EF2	0.887	0.387	0.646	0.887	0.774	0.634	0.503	0.609	0.690	0.644	0.899	0.937	0.832	0.912
	EF3	0.864	0.514	0.718	0.864	0.665	0.624	0.607	0.625	0.679	0.601				
Kepuasan	FL1	0.911	0.506	0.732	0.745	0.911	0.532	0.485	0.762	0.721	0.661	0.892	0.925	0.756	0.875
	FL2	0.934	0.478	0.753	0.699	0.934	0.545	0.466	0.776	0.737	0.610				
Kepuasan	FL3	0.890	0.524	0.763	0.741	0.890	0.638	0.511	0.748	0.731	0.676	0.892	0.925	0.756	0.875
	KP1	0.858	0.479	0.589	0.669	0.534	0.858	0.786	0.516	0.598	0.599				
Kepuasan	KP2	0.899	0.672	0.737	0.578	0.599	0.899	0.759	0.617	0.635	0.730	0.892	0.925	0.756	0.875
	KP3	0.881	0.540	0.661	0.662	0.603	0.881	0.722	0.516	0.619	0.601				
Kepuasan	KP4	0.840	0.513	0.663	0.513	0.461	0.840	0.777	0.595	0.545	0.698	0.892	0.925	0.756	0.875

Tabel 6 Outer Model

Variabel	IND	OL	Cross Loading								SA	CA	CR	AVE	FL
			CP	CT	EF	FL	KP	LB	PR	RP					
Loyalty Behavior	LB1	0.915	0.478	0.687	0.555	0.502	0.818	0.915	0.582	0.613	0.666	0.898	0.936	0.830	0.911
	LB2	0.945	0.593	0.714	0.532	0.546	0.845	0.945	0.608	0.639	0.666				
Privacy	LB3	0.873	0.548	0.531	0.566	0.411	0.723	0.873	0.444	0.518	0.522	0.792	0.878	0.706	0.868
	PR1	0.761	0.506	0.610	0.596	0.619	0.454	0.360	0.761	0.633	0.629				

	<b>PR2</b>	0.900	0.630	0.839	0.555	0.783	0.647	0.615	0.900	0.747	0.767				
	<b>PR3</b>	0.854	0.577	0.806	0.550	0.689	0.502	0.507	0.854	0.809	0.601				
Responsiveness	<b>RP1</b>	0.925	0.640	0.823	0.692	0.750	0.620	0.621	0.743	0.925	0.696				
	<b>RP2</b>	0.927	0.628	0.856	0.658	0.775	0.634	0.597	0.846	0.927	0.663	0.928	0.954	0.874	0.935
	<b>RP3</b>	0.952	0.722	0.913	0.685	0.725	0.677	0.606	0.842	0.952	0.755				
System Availability	<b>SA1</b>	0.808	0.635	0.644	0.615	0.548	0.695	0.596	0.610	0.582	0.808				
	<b>SA2</b>	0.758	0.509	0.648	0.462	0.576	0.525	0.429	0.714	0.634	0.758				
	<b>SA3</b>	0.887	0.580	0.687	0.645	0.605	0.683	0.641	0.636	0.678	0.887	0.829	0.885	0.660	0.812
	<b>SA4</b>	0.790	0.462	0.564	0.454	0.604	0.523	0.519	0.666	0.561	0.790				

### 4.3. Inner Model

Analisis Model Struktural (*Inner Model*) bertujuan untuk mengevaluasi faktor-faktor yang terlibat dalam penelitian bersama dengan hubungan yang dihipotesiskan antar variabel laten. Proses ini dilaksanakan melalui enam tahapan pengujian yang komprehensif. Pengujian signifikansi hubungan kausal dilakukan melalui analisis  $\beta$  (*path coefficient*),  $R^2$  (*coefficient of determination*), *t-test* atau *t-statistic* menggunakan metode bootstrapping.

Selain itu, kekuatan eksplanatori dan kemampuan prediktif model dinilai melalui pengujian  $f^2$  (*effect size*),  $Q^2$  (*predictive relevance*), dan  $q^2$  (*relative impact*) diuji menggunakan metode blindfolding atau PLSpredict [16]. Keenam tahapan pengujian ini secara kolektif memberikan dasar empiris yang kuat untuk menginterpretasikan hubungan antar variabel dan memvalidasi hipotesis yang diajukan dalam penelitian.

Pengujian hipotesis dilakukan melalui metode bootstrapping untuk melihat pengaruh antar variabel sebagaimana terangkum dalam tabel berikut:

Tabel 7 Inner Model

Hx	Jalur	$\beta$	T	P	$R^2$	$Q^2$
H1	EF → KP	0.330	5.869	0.000	0.722	0.714
H2	SA → KP	0.428	9.999	0.000	0.722	0.714
H3	FL → KP	-0.153	3.095	0.002	0.722	0.714
H4	PR → KP	-0.363	6.835	0.000	0.722	0.714
H5	RP → KP	-0.234	3.159	0.002	0.722	0.714
H6	CT → KP	0.822	7.466	0.000	0.722	0.714
H7	CP → KP	0.053	1.209	0.227	0.722	0.714
H8	KP → LB	0.875	70.249	0.000	0.766	0.585

Tabel 8 Inner Model

$f^2$		$q^2$				Analisis					
$R^2$ -in	$R^2$ -ex	$f^2$	$Q^2$ -in	$Q^2$ -ex	$q^2$	$\beta$	T	$R^2$	$f^2$	$Q^2$	$q^2$
0.722	0.691	0.112	0.714	0.684	0.105	S	A	Baik	K	PR	K
0.722	0.669	0.191	0.714	0.661	0.185	S	A	Baik	M	PR	M
0.722	0.717	0.018	0.714	0.710	0.014	S	A	Baik	K	PR	K
0.722	0.704	0.065	0.714	0.697	0.059	S	A	Baik	K	PR	K
0.722	0.714	0.029	0.714	0.708	0.021	S	A	Baik	K	PR	K
0.722	0.668	0.194	0.714	0.661	0.185	S	A	Baik	M	PR	M
0.722	0.721	0.004	0.714	0.714	0	IS	R	Baik	K	PR	K
0.766	0.609	0.670	0.585	0.596	-0.011	S	A	Baik	B	PR	K

Analisis *Coefficient of Determination* ( $R^2$ ) menunjukkan bahwa variabel kualitas layanan mampu menjelaskan 72,2% variasi Kepuasan Pengguna, sementara Kepuasan mampu menjelaskan 76,6% variasi *Loyalty Behavior*.

### 4.3. Analisis Kualitas Layanan (*Gap Analysis*)

*Gap analysis* digunakan untuk membandingkan antara persepsi dan harapan pengguna. Secara agregat, nilai kualitas pelayanan ( $Q$ ) adalah 1,038 ( $>1$ ), yang berarti layanan SRIBU Mobile secara umum telah memenuhi standar pengguna. Namun, terdapat 5 indikator yang memiliki kesenjangan negatif, yaitu pada variabel *Contact* (CT1, CT2, CT3) dan *Compensation* (CP1, CP2). Hal ini mengindikasikan bahwa saluran komunikasi dan sistem ganti rugi belum sepenuhnya memenuhi ekspektasi pengguna.

Tabel 9 Gap Analysis

No	Variabel	Importance/I	Performance/P	Gap	$Q=P/I$
1	Efficiency	3.91	4.17	0.26	1.0665
2	System Availability	3.67	4.09	0.42	1.1144
3	Fulfillment	3.86	4.06	0.20	1.0518
4	Privacy	3.66	3.99	0.33	1.0902


5	<i>Responsiveness</i>	3.80	4.10	0.30	1.0789
6	<i>Contact</i>	4.03	3.79	-0.24	0.9404
7	<i>Compensation</i>	4.00	3.75	-0.25	0.9375
	Mean	3.847	3.993	0.146	1.0379

Temuan ini secara konsisten selaras dengan kerangka teoretis *service quality* yang dikembangkan oleh [3]. Teori ini menegaskan bahwa meskipun hasil *gap analysis* secara agregat menunjukkan nilai positif mengindikasikan kinerja layanan yang baik secara keseluruhan perbaikan yang terfokus tetap mutlak diperlukan pada aspek-aspek yang mencatat kesenjangan negatif. Hal ini krusial untuk meningkatkan kepuasan pengguna secara holistik dan mencegah titik kegagalan layanan. Dalam konteks aplikasi SRIBU Mobile, disarankan untuk memprioritaskan peningkatan kualitas layanan pada dimensi *Compensation* dan *Contact*. Fokus pada perbaikan ini bertujuan untuk memastikan keadilan dan ketepatan dalam penanganan masalah yang berujung pada kerugian pengguna dan memastikan saluran komunikasi dapat dihubungi secara efektif, profesional, dan responsif saat pengguna mengalami permasalahan. Lebih lanjut, disarankan untuk melakukan penelitian eksplorasi tambahan guna mengidentifikasi akar penyebab spesifik yang melatarbelakangi terbentuknya kesenjangan negatif pada dimensi-dimensi tersebut. Pengetahuan mendalam ini akan memungkinkan perancangan strategi perbaikan yang efektif, terarah, dan berbasis bukti.

#### 4.4. Hasil Visualisasi Dashboard

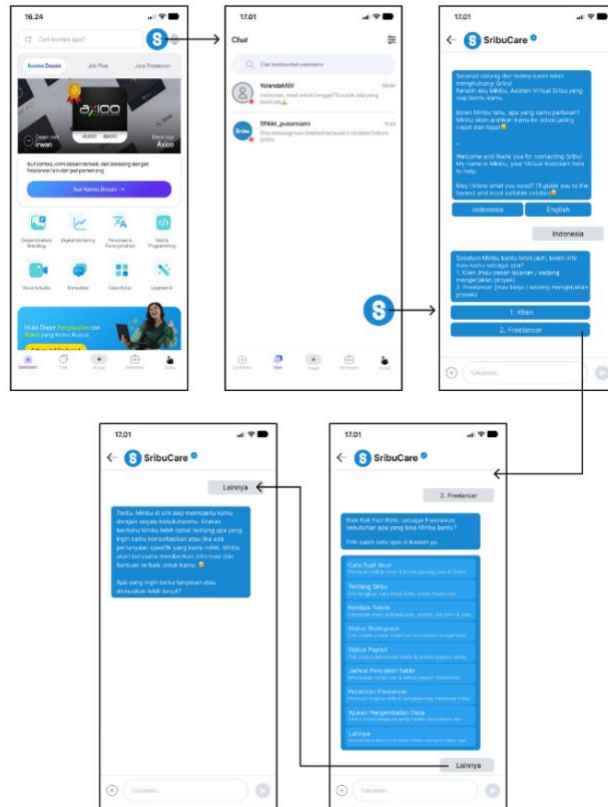
Berdasarkan hasil analisis *inner model* mengenai pengaruh berbagai variabel terhadap kepuasan dan loyalitas pengguna aplikasi SRIBU Mobile, disusun sejumlah rekomendasi yang dapat diterapkan oleh pengembang aplikasi untuk meningkatkan penggunaan aplikasi tersebut.

Pada Gambar 5 merupakan alur dari penambahan fitur *login page*, yang mana pada halaman *login* terdapat beberapa pilihan kategori login. Permasalahan pengguna tidak dapat mengakses aplikasi SRIBU tanpa login, pengguna bisa melihat pilihan layanan yang disediakan aplikasi SRIBU.




Gambar 5. Rekomendasi Fitur *Login Page*

Gambar 6 merupakan alur dari penambahan fitur *chatbot*, yang mana pada halaman *chatbot* terdapat beberapa pilihan kategori permasalahan. Ketika Permasalahan pengguna tidak ada pada pilihan kategori tersebut dan ingin berkomunikasi langsung dengan *customer service*, pengguna bisa memilih pilihan “Lainnya”.



Gambar 6. Rekomendasi Fitur Chatbot

Gambar 7 merupakan *design* dari rekomendasi pemberian kompensasi terhadap pengguna aplikasi SRIBU Mobile.



Gambar 7. Rekomendasi Pemberian Kompensasi

## 5. KESIMPULAN

Secara keseluruhan, kualitas layanan aplikasi SRIBU Mobile dinilai sudah baik, yang dibuktikan dengan nilai rata-rata kualitas layanan sebesar 1,0379 (melampaui ambang batas 1). Berdasarkan analisis gap, mayoritas indikator menunjukkan nilai kesenjangan positif, yang berarti kinerja layanan aktual telah melampaui harapan pengguna. Namun, masih terdapat defisiensi pada dimensi *Compensation* dan *Contact* yang mencatat gap negatif, mengindikasikan adanya aspek dukungan pelanggan dan penanganan masalah finansial yang belum sepenuhnya memenuhi ekspektasi pengguna.

Kualitas layanan elektronik berpengaruh signifikan dalam membentuk kepuasan pengguna. Hasil pengujian menunjukkan bahwa dimensi *Efficiency*, *System Availability*, *Fulfillment*, *Privacy*, *Responsiveness*, dan *Contact* memiliki pengaruh signifikan terhadap kepuasan. Dimensi *System Availability* dan *Contact* menjadi pendorong positif yang kuat. Namun,

ditemukan bahwa dimensi *Fulfillment*, *Privacy*, dan *Responsiveness* memiliki pengaruh negatif namun signifikan, yang menunjukkan adanya disonansi antara ekspektasi standar layanan dengan realitas penggunaan. Sementara itu, dimensi *Compensation* tidak memiliki pengaruh signifikan terhadap kepuasan pengguna SRIBU Mobile.

Terdapat pengaruh positif dan signifikan yang sangat kuat antara Kepuasan Pengguna terhadap *Loyalty Behavior* dengan nilai koefisien jalur sebesar 0,875 dan nilai T-statistik sebesar 70,249. Hal ini menunjukkan bahwa kepuasan merupakan mediator sekaligus prediktor kunci yang menentukan loyalitas. Semakin tinggi kualitas layanan yang dirasakan pengguna sehingga menciptakan kepuasan, maka semakin tinggi pula kecenderungan pengguna untuk terus menggunakan aplikasi SRIBU, memberikan rekomendasi positif (*word-of-mouth*), dan bertahan di platform tersebut meskipun terdapat tawaran dari kompetitor.

## UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih yang sebesar-besarnya kepada SRIBU 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 SRIBU.

## REFERENSI

- [1] K. Feher, D. Junaidy, D. Larasati, A. Kovacs, and B. Rahardjo, "Creative Industries and Digital Economy – Perspectives from Southeast Asia and Central Europe," Tamas Novak, Ed., Budapest Business School University of Applied Sciences, 2017, pp. 151–172.
- [2] R. Gondokusumo, "Kisah Ryan Gondokusumo, dari Sulit Cari Kerja hingga Bangun Bisnis 1,2 Juta Freelancer," Blog SRIBU.
- [3] A. Parasuraman, V. A. Zeithaml, and A. Malhotra, "E-S-QUAL a multiple-item scale for assessing electronic service quality," *J. Serv. Res.*, vol. 7, no. 3, pp. 1–21, Feb. 2005, doi: 10.1177/1094670504271156.
- [4] C. Anjanette Niman and D. Agustin Pratama Sari, "E-SERVQUAL ANALYSIS ON TOKOPEDIA APPLICATION (CASE STUDY ON GENERATION Z IN DKI JAKARTA)," *International Student Conference on Business, Education, Economics, Accounting, and Management (ISC-BEAM)*, vol. 3, no. 1, pp. 11–27, Apr. 2025, doi: <https://doi.org/10.21009/ISC-BEAM.013.02>.
- [5] I. Felicia Effendi and Widyastuti, "The Effect of Variety Seeking, Dissatisfaction, and Service Quality Toward Brand Switching on Netflix Streaming Service," *Social Science Studies*, vol. 4, no. 1, pp. 52–65, Jan. 2024, doi: 10.47153/sss41.7862024.
- [6] P. R. Damayanti and G. S. Palupi, "Penerapan Metode E-Service Quality dan Importance Performance Analysis (IPA) untuk Analisis Kualitas Layanan Transfer Terhadap Kepuasan Pengguna Aplikasi BRImo," *Journal of Emerging Information Systems and Business Intelligence*, vol. 4, no. 3, pp. 115–125, Jul. 2023, doi: <https://doi.org/10.26740/jeisbi.v4i3.55156>.
- [7] Y. Septiani, E. Arribe, and R. Diansyah, "ANALISIS KUALITAS LAYANAN SISTEM INFORMASI AKADEMIK UNIVERSITAS ABDURRAB TERHADAP KEPUASAN PENGGUNA MENGGUNAKAN METODE SEVQUAL," *JURNAL TEKNOLOGI DAN OPEN SOURCE*, vol. 3, no. 1, pp. 131–143, Jun. 2020, doi: <https://doi.org/10.36378/jtos.v3i1.560>.
- [8] L. Setiyani and E. Tjandra, "ANALISIS KEBUTUHAN FUNGSIONAL APLIKASI PENANGANAN KELUHAN MAHASISWA STUDI KASUS:STMIK ROSMA KARAWANG," *Jurnal Inovasi Pendidikan dan Teknologi Informasi*, vol. 2, no. 1, pp. 8–17, Feb. 2021, doi: <https://doi.org/10.52060/pti.v2i01.465>.
- [9] S. Worthington, R. Russell-Bennett, and C. Härtel, "A tri-dimensional approach for auditing brand loyalty," *Journal of Brand Management*, vol. 17, no. 4, pp. 243–253, Jan. 2010, doi: 10.1057/bm.2009.24.
- [10] S. Rahayu and M. Harsono, "Loyalitas Konsumen : Konseptualisasi, Antecedent dan Konsekuensi," *Jurnal Ekonomi & Ekonomi Syariah*, vol. 6, no. 2, pp. 1581–1593, Jun. 2023, doi: 10.36778/jesy.v6i2.1169.
- [11] A. Kittur and R. E. Kraut, "Harnessing the wisdom of crowds in wikipedia: Quality through coordination," in *Proceedings of the ACM Conference on Computer Supported Cooperative Work, CSCW*, 2008, pp. 37–46. doi: 10.1145/1460563.1460572.
- [12] S. Altuntas, T. Dereli, and İ. Kaya, "Monitoring patient dissatisfaction: a methodology based on SERVQUAL scale and statistical process control charts," *Total Quality Management and Business Excellence*, vol. 31, no. 9–10, pp. 978–1008, Jul. 2020, doi: 10.1080/14783363.2018.1457434.
- [13] K. J. Prabawanti, S. Bachri, P. Ponirin, and A. Asriadi, "PENGARUH E-SERVICE QUALITY TERHADAP LOYALITAS PELANGGAN DENGAN KEPUASAN PELANGGAN SEBAGAI VARIABEL INTERVENING DI E-COMMERCE SHOPEE (STUDI KASUS PADA GEN-Z KOTA PALU)," *COSTING: Journal of Economic, Business and Accounting*, no. 6, pp. 5680–5690, Nov. 2024, doi: [doi.org/10.31539/costing.v7i6.12973](https://doi.org/10.31539/costing.v7i6.12973).
- [14] D. Ambarwati and J. Dwiridotjahjono, "Pengaruh Kualitas E-service Terhadap Loyalitas Pelanggan Di Shopee Melalui Kepuasan Pelanggan Sebagai Variabel Intervening Pada Pengguna Aplikasi Shopee Di Surabaya," *El-Mal: Jurnal Kajian Ekonomi & Bisnis Islam*, vol. 4, no. 2, pp. 454–466, Sep. 2023, doi: 1047467/elmal.v4i2.1496.
- [15] L. Tanzil and R. Budi Lestari, "PENGARUH KEPUASAN NASABAH DAN E-SERVICE QUALITY TERHADAP LOYALITAS NASABAH PENGGUNA M-BANKING BCA," *Multi Data Palembang Student Conference*, vol. 2, pp. 515–520, Apr. 2023, doi: [doi.org/10.35957/mdp-sc.v2i2.4470](https://doi.org/10.35957/mdp-sc.v2i2.4470).
- [16] J. F. . Hair, G. T. M. . Hult, C. M. . Ringle, and Marko. Sarstedt, *A primer on partial least squares structural equation modeling (PLS-SEM)*, 2nd ed. Sage, 2017.