

KLASTERISASI KARAKTERISTIK GAME STEAM MENGGUNAKAN METODE K-MEANS (STUDI KASUS: RILISAN GAME TAHUN 2024)

Alfiansyah Hidayat, Bayu Priyatna, Fitria Nurapriani, Tukino

Sistem Informasi, Universitas Buana Perjuangan Karawang

Jl. HS.Ronggo Waluyo, Puseurjaya, Telukjambe Timur,

Karawang, Jawa Barat 41361, Indonesia

si23.alfiansyahhidayat@mhs.ubpkarawang.ac.id

ABSTRAK

Pertumbuhan yang luar biasa dari industri *game* digital di platform seperti Steam telah menghasilkan tumpukan data yang sangat besar yang memerlukan analisis mendalam. Namun, memahami elemen-elemen yang membuat sebuah *game* meraih sukses adalah tantangan tersendiri karena hal ini tidak bisa diukur hanya melalui angka penjualan semata. Oleh sebab itu, penelitian ini bertujuan untuk menerapkan algoritma pengelompokan K-Means guna mengkategorikan *game* Steam yang dirilis pada tahun 2024. Metodologi penelitian mencakup langkah-langkah pra-pemrosesan data, penentuan jumlah kluster yang optimal dengan menggunakan *Elbow Method* yang mengarah pada nilai $k=3$, serta penerapan algoritma K-Means untuk segmentasi berdasarkan berbagai metrik seperti pendapatan, durasi bermain, dan skor ulasan publik. Hasil dari analisis ini berhasil mengidentifikasi tiga kelompok *game* yang memiliki karakteristik yang berbeda secara signifikan. *Game* yang berhasil secara komersial sekaligus mendapatkan pujian kritis, *game* berkualitas tinggi yang sangat dihargai oleh komunitas, dan *game* yang menasar pasar tertentu atau kurang meraih sukses. Temuan ini menunjukkan bahwa pendekatan K-Means sangat efektif dalam menyingkap struktur dan pola yang tersembunyi dalam industri *game* digital.

Kata kunci: Klasterisasi, K-Means, Penambangan Data, Game Steam, Segmentasi Pasar.

1. PENDAHULUAN

Industri permainan digital telah mencatat pertumbuhan yang luar biasa dalam dekade terakhir, menjadikannya salah satu sektor hiburan paling laris di seluruh dunia. Platform distribusi digital, seperti Steam, telah muncul sebagai pusat bagi jutaan gamer dan pengembang, menciptakan aliran data yang luar biasa setiap harinya yang mencerminkan dinamika pasar [1]. Data ini, yang meliputi informasi penjualan, demografi pemain, serta perilaku dalam permainan, merupakan sumber berharga yang dapat dieksplorasi untuk mendapatkan wawasan mendalam [2]. Analisis terhadap data pemain telah terbukti cukup efektif dalam berbagai studi, contohnya untuk memahami pola permainan dalam genre battle royale maupun MOBA [3]; [4]; [5], serta untuk mengidentifikasi karakteristik spesifik dari setiap karakter dalam permainan [6].

Meskipun ketersediaan data sangat melimpah, tantangan muncul saat mencoba menginterpretasikannya guna pengambilan keputusan strategis yang efektif. Mengetahui mana *game* yang terlaris tidaklah cukup; penting untuk menganalisis pola atau faktor yang membuat sebuah permainan meraih kesuksesan, baik dalam aspek finansial maupun penerimaan di kalangan komunitas gamer [7]. Tanpa analisis mendalam, ciri khas dari setiap *game* yang berhasil akan sulit dikenali, padahal pemahaman ini sangat vital untuk merumuskan strategi pemasaran dan pengembangan produk di masa depan [8], [9].

Untuk menghadapi tantangan tersebut, penelitian ini menggunakan teknik data mining guna mengidentifikasi pola-pola tersembunyi dalam data.

Salah satu metode yang sering dipakai dan efektif untuk segmentasi adalah algoritma klasterisasi K-Means [10], [11]. K-Means telah diterapkan secara luas di berbagai bidang untuk pengelompokan data, mulai dari analisis penjualan produk hingga pola pembelian konsumen dan data minat mahasiswa [7], [10], [12]. Algoritma ini dapat mengelompokkan entitas berdasarkan kesamaan atribut ke dalam sejumlah cluster, di mana setiap cluster mewakili segmen atau kelompok yang homogen [13] [14]. Oleh sebab itu, penelitian ini bertujuan menerapkan algoritma klasterisasi K-Means pada data permainan di platform Steam. Fokus dari studi ini adalah untuk mengelompokkan permainan berdasarkan tiga karakteristik utama: pendapatan (revenue), tingkat keterlibatan pemain (avgPlaytime), dan skor ulasan publik (reviewScore). Dengan melaksanakan klasterisasi, penelitian ini diharapkan mampu mengidentifikasi segmen-segmen permainan yang berbeda serta memaparkan ciri khas unik dari setiap segmen yang terbentuk. Hasil dari analisis ini diharapkan dapat memberikan wawasan berharga bagi para pemangku kepentingan di industri permainan tentang pola-pola kesuksesan yang ada di pasar eksternal *game* digital saat ini.

2. TINJAUAN PUSTAKA

2.1. Data Mining

Data mining adalah proses mengekstraksi atau menambang pola-pola yang menarik dan berharga dari kumpulan data yang besar. Pola-pola ini seringkali sebelumnya tidak diketahui dan berpotensi memberikan keuntungan strategis. Tujuan utama *data*

mining adalah mengubah data mentah menjadi informasi yang dapat dipahami dan digunakan untuk pengambilan keputusan. Salah satu teknik yang paling umum digunakan dalam *data mining* adalah *clustering*, yang bertujuan untuk mengelompokkan data ke dalam beberapa *cluster* atau segmen berdasarkan karakteristik yang serupa. Teknik ini sangat berguna dalam berbagai bidang, termasuk segmentasi data penjualan dan analisis pemasaran.

2.2. Algoritma K-Means

K-Means merupakan salah satu algoritma *non-hierarchical clustering* yang paling populer dan banyak digunakan karena kesederhanaan dan efisiensinya. Algoritma ini bekerja dengan cara membagi data ke dalam k *cluster* yang telah ditentukan sebelumnya. Prosesnya dimulai dengan menentukan k titik pusat *cluster* (*centroid*) secara acak, kemudian setiap data akan dikelompokkan ke dalam *centroid* terdekat berdasarkan perhitungan jarak, umumnya menggunakan *Euclidean Distance*. Setelah semua data dikelompokkan, posisi *centroid* akan diperbarui dengan menghitung nilai rata-rata semua data anggota dalam *cluster*. Proses ini diulang secara iteratif hingga posisi *centroid* tidak lagi berubah atau telah mencapai jumlah iterasi maksimum. Untuk meningkatkan kualitas hasil *cluster*, variasi algoritma seperti *K-Means++* sering digunakan, yang menawarkan metode inisialisasi *centroid* yang lebih cerdas untuk mempercepat konvergensi dan menghasilkan *cluster* yang lebih optimal. Menentukan jumlah k yang optimal merupakan langkah yang krusial dan sering kali menggunakan metode seperti *Elbow Method* untuk mengevaluasi jumlah kluster terbaik berdasarkan nilai *Within-Cluster Sum of Squares* (WCSS).

2.3. Penelitian Terkait

Penerapan algoritma *K-Means* untuk *clustering* telah banyak digunakan dalam berbagai domain, termasuk dalam analisis industri *game*. Beberapa penelitian berfokus pada pengelompokan pemain atau karakter *game* berdasarkan gaya bermain dan statistik performanya. Misalnya, penelitian [3] menggunakan *K-Means* untuk menganalisis statistik pemain *Valorant* profesional, sementara [4] dan [5] menerapkannya untuk mengelompokkan hero dan karakter dalam *game MOBA*. Penelitian lain oleh [6] juga menggunakan *K-Means* untuk menentukan karakteristik karakter dalam *game Zenless Zone Zero*.

Selain analisis pemain, *K-Means* juga efektif untuk segmentasi pasar dan analisis penjualan. [7] dan [12] menunjukkan bagaimana *clustering* dapat digunakan untuk menganalisis data penjualan dan pola pembelian pelanggan untuk mengembangkan strategi pemasaran yang lebih efektif. Khusus dalam konteks *game*, penelitian [1] juga telah mengelompokkan *game* berdasarkan data penjualan terlaris. Penelitian ini akan dibangun di atas fondasi itu dengan mengelompokkan tidak hanya berdasarkan data penjualan (pendapatan),

tetapi juga menggabungkannya dengan metrik keterlibatan pemain (*avgPlaytime*) dan penerimaan publik (*reviewScore*) untuk mendapatkan segmentasi yang lebih komprehensif dari *game-game* terbaru yang dirilis pada platform Steam.

3. METODE PENELITIAN

Bagian ini akan menjelaskan secara rinci langkah-langkah teknis yang diambil dalam penelitian, mulai dari pengumpulan data hingga analisis hasil. Hal ini harus ditulis secara sistematis sehingga penelitian Anda dapat dipahami dan, jika perlu, direplikasi oleh peneliti lain.

3.1. Kerangka Penelitian

Penelitian ini dilakukan melalui beberapa tahap yang dijelaskan dalam alur kerja berikut:

- Pengumpulan Data: Mengumpulkan dataset *game* dari platform Steam.
- Pra-pemrosesan Data: Memilih fitur yang relevan, membersihkan data dari nilai yang hilang, dan menskalakan fitur untuk normalisasi data.
- Penentuan Jumlah Cluster (k): Menggunakan *Elbow Method* untuk menentukan jumlah cluster yang paling optimal untuk dataset.
- Implementasi Model K-Means: Menerapkan algoritma K-Means pada data yang diproses untuk membentuk *cluster game*.
- Analisis dan Interpretasi: Melakukan analisis profil setiap *cluster* yang terbentuk untuk memahami karakteristiknya dan menarik kesimpulan.

3.2. Sumber Data

Data yang digunakan dalam penelitian ini adalah kumpulan data publik yang berisi daftar *game* yang dirilis di platform Steam sepanjang tahun 2024. Kumpulan data ini berisi berbagai atribut untuk setiap *game*, tetapi penelitian ini akan berfokus pada empat atribut utama: *name* (nama *game*), *revenue* (pendapatan), *avgPlaytime* (rata-rata waktu bermain), dan *reviewScore* (skor ulasan). Setelah tahap pembersihan data, total data yang dianalisis berjumlah ratusan entri *game* yang valid.

3.3. Pra-pemrosesan Data

Tahap pra-pemrosesan data merupakan langkah krusial untuk menyiapkan data sebelum analisis.

- Pemilihan Fitur: Tiga fitur numerik utama dipilih sebagai dasar pengelompokan, yaitu *revenue*, *avgPlaytime*, dan *reviewScore*. Ketiga fitur ini dipilih karena dapat mewakili aspek keberhasilan finansial, keterlibatan pemain, dan penerimaan publik terhadap suatu permainan secara komprehensif.
- Pembersihan Data: Pembersihan data dilakukan dengan membuang semua baris yang berisi nilai kosong atau null pada kolom fitur yang dipilih.

- c. Penskalaan Fitur: Karena rentang nilai ketiga fitur sangat berbeda (misalnya, revenue bernilai jutaan, sedangkan reviewScore bernilai puluhan), penskalaan dilakukan menggunakan StandardScaler. Proses ini mengubah distribusi setiap fitur sehingga memiliki rata-rata (mean) 0 dan simpangan baku 1. Penskalaan ini wajib dilakukan agar tidak ada satu fitur pun yang mendominasi perhitungan jarak pada algoritma K-Means[13].

3.4. Proses Klusterisasi

Proses pengelompokan dilakukan dengan menggunakan algoritma K-Means yang langkah-langkahnya dijelaskan sebagai berikut:

- a. Penentuan Jumlah Cluster (k) dengan Elbow Method: Untuk menentukan jumlah cluster (k) yang paling optimal digunakan Elbow Method. Metode ini bekerja dengan menjalankan algoritma K-Means untuk rentang nilai k (dari 1 sampai 10) dan menghitung nilai *Within-Cluster Sum of Squares* (WCSS) untuk setiap k. WCSS merupakan jumlah kuadrat jarak antara setiap titik data dengan centroid cluster-nya. Hasil WCSS kemudian diplot pada suatu grafik. Titik “elbow” pada grafik, di mana penurunan nilai WCSS tidak lagi signifikan, dipilih sebagai nilai k optimal [10]. Berdasarkan analisis dataset ini, nilai k = 3 ditetapkan sebagai jumlah cluster yang paling optimal.
- b. Implementasi Algoritma K-Means: Setelah nilai k optimal diperoleh, model K-Means dilatih menggunakan data yang diskalakan. Algoritma akan mengelompokkan setiap permainan ke dalam satu dari tiga kluster berdasarkan kedekatannya dengan pusat kluster (centroid).

3.5. Analisis dan Interpretasi Cluster

Setelah model K-Means selesai dijalankan dan setiap permainan mendapatkan label kluster-nya, tahap selanjutnya adalah analisis. Untuk setiap kluster yang terbentuk, nilai rata-rata (mean) dari tiga fitur (revenue, *avgPlaytime*, reviewScore) dihitung. Proses ini, yang disebut profiling, bertujuan untuk mengidentifikasi karakteristik dominan setiap kluster. Berdasarkan profil tersebut, setiap kluster dapat diinterpretasikan dan diberi label deskriptif yang mencerminkan segmen permainan yang diwakilinya.


4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil proses pengelompokan data *game* Steam menggunakan algoritma K-Means serta pembahasan mendalam tentang karakteristik setiap kluster yang terbentuk.

4.1. Hasil Penentuan jumlah Cluster

Langkah pertama dalam penerapan algoritma K-Means adalah menentukan jumlah kluster (k) yang optimal. Untuk tujuan ini, digunakan Elbow Method. Metode ini dijalankan dengan menghitung nilai

Within-Cluster Sum of Squares (WCSS) untuk jumlah kluster k dari 1 hingga 10. Hasil perhitungan WCSS divisualisasikan dalam grafik untuk menemukan “titik siku”, yaitu titik di mana penurunan nilai WCSS tidak lagi signifikan.



Gambar 1. Grafik Elbow Method untuk Penentuan Jumlah Cluster Optimal

Berdasarkan Gambar 2, dapat diamati bahwa terjadi penurunan WCSS yang tajam dari k=1 ke k=2, dan dari k=2 ke k=3. Namun, setelah k=3, laju penurunan mulai mencapai titik puncak dan membentuk “siku”. Titik ini menunjukkan bahwa penambahan jumlah kluster lebih dari tiga tidak memberikan peningkatan yang signifikan terhadap efektivitas pengelompokan data. Oleh karena itu, jumlah kluster optimal yang dipilih untuk penelitian ini adalah k=3. Pemilihan k yang tepat menggunakan metode ini merupakan praktik standar dalam penelitian pengelompokan untuk memastikan kualitas hasil pengelompokan [10].

4.2. Hasil Evaluasi Model

Evaluasi Model yang Dihasilkan, Kualitas model klusterisasi telah diuji dengan menggunakan metrik internal untuk menilai keabsahan struktur kluster yang terbentuk. Berikut adalah rincian dari hasil dan pemahamannya:

- a. Nilai Silhouette: 0.6511 Skor ini tergolong sangat baik. Nilai yang sangat mendekati 1 dibandingkan dengan 0 menunjukkan bahwa kluster yang terbentuk itu padat dan terdefinisi dengan jelas. Ini berarti setiap anggota kluster saling mirip satu sama lain dan memiliki perbedaan yang signifikan dari anggota kluster lainnya.
- b. Nilai Davies-Bouldin: 0.8557 Skor ini menunjukkan hasil yang memuaskan. Nilai yang melangkah 0 menandakan bahwa setiap kluster memiliki pemisahan yang jelas dari kluster terdekatnya, yang mendukung keabsahan pengelompokan.

Kedua hasil evaluasi kuantitatif ini secara konsisten menunjukkan bahwa model K-Means dengan k=3 telah berhasil mengidentifikasi tiga segmen pasar yang berbeda dan relevan dalam dataset *game* Steam

4.3. Proses Klasterisasi

Setelah menetapkan $k=3$, algoritma K-Means diterapkan pada dataset. Hasilnya, setiap permainan dibagi menjadi satu dari tiga klaster. Untuk memahami karakteristik unik setiap klaster, proses pembuatan profil dilakukan dengan menghitung nilai rata-rata setiap fitur (pendapatan, *avgPlaytime*, dan *reviewScore*) untuk semua anggota klaster. Hasil perhitungan profil klaster disajikan dalam Tabel 1


Tabel 1. Profil Rata-rata Setiap Cluster

Cluster	revenue	avgPlaytime	reviewScore
0	\$4,417,380.14	38.99 jam	77.27
1	\$849,711.81	8.73 jam	1.22
2	\$172,003.54	11.04 jam	83.08

4.4. Proses Klasterisasi

Berdasarkan profil pada Tabel 1, setiap klaster dapat diartikan sebagai segmen pasar *game* yang berbeda. Visualisasi distribusi data dalam ruang 3D pada Gambar 3 juga menunjukkan bagaimana ketiga klaster ini terpisah satu sama lain.

Visualisasi 3D Hasil Klasterisasi Game Steam ($k=3$)



Gambar 2. Visualisasi 3D Sebaran Data Game Berdasarkan Cluster

- a. **Klaster 0: Segmen Sukses Komersial dan Kritis**
Klaster ini memiliki nilai pendapatan rata-rata, *avgPlaytime*, dan *reviewScore* yang jauh lebih tinggi dibandingkan dengan dua klaster lainnya. Game dalam segmen ini dapat diartikan sebagai "game terlaris" yang sukses secara menyeluruh. Pendapatan tinggi menunjukkan kesuksesan komersial, waktu bermain tinggi menunjukkan kemampuan *game* untuk membuat pemain tetap terlibat, dan skor ulasan tinggi menunjukkan penerimaan yang sangat baik dari publik. Temuan ini konsisten dengan studi lain yang mengidentifikasi klaster produk berkinerja tinggi dalam analisis penjualan [1], [7].

- b. **Klaster 1: Segmen Niche Hits**

Klaster ini menunjukkan karakteristik yang menarik: nilai pendapatan rata-rata yang jauh lebih rendah daripada Klaster 0, tetapi masih memiliki *reviewScores* tinggi dan *avgPlaytime* sedang. Segmen ini mewakili *game* yang mungkin tidak mendominasi pasar secara finansial, tetapi berkualitas tinggi dan disukai oleh komunitas pemainnya. *Game-game* ini mungkin merupakan "permata tersembunyi" atau *game* indie yang telah membangun basis penggemar yang loyal. Hal ini menunjukkan bahwa keberhasilan sebuah *game* tidak selalu diukur dari pendapatan saja, tetapi juga dari kepuasan pemain[2].

- c. **Klaster 2: Segmen Pasar Niche atau Kurang Berhasil**

Klaster ini mencatat nilai rata-rata terendah pada ketiga fitur (pendapatan, *avgPlaytime*, *reviewScore*). Game dalam grup ini mewakili produk yang kesulitan menembus pasar atau gagal menarik minat pemain yang luas. Namun, *game-game* ini mungkin masih melayani pasar yang sangat spesifik (niche) atau merupakan *game* eksperimental. Klaster ini berfungsi sebagai garis dasar yang menunjukkan karakteristik *game* yang kurang menonjol di pasar Steam yang sangat kompetitif.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil menerapkan algoritma klasterisasi K-Means untuk menganalisis dan mengelompokkan game Steam yang dirilis pada tahun 2024 berdasarkan metrik finansial, keterlibatan pemain, dan penerimaan publik. Hasil analisis berhasil mengidentifikasi tiga segmen (klaster) *game* yang berbeda secara signifikan, yaitu: (1) segmen *game* yang sukses secara komersial dan kritis yang unggul dalam semua metrik, (2) segmen *game* berkualitas yang dicintai oleh masyarakat meskipun tidak mendominasi secara finansial, dan (3) segmen *game* ceruk atau pasar yang kurang sukses. Temuan ini menunjukkan bahwa K-Means merupakan metode yang efektif untuk mengungkap pola pasar yang lebih kompleks daripada sekadar melihat data penjualan. Untuk penelitian lebih lanjut, disarankan untuk memperkaya analisis dengan menambahkan fitur lain seperti genre *game* atau data demografi pemain. Selain itu, hasilnya dapat dibandingkan dengan algoritma klasterisasi lain seperti K-Medoids untuk menguji ketahanan hasil klasterisasi[14], atau menerapkan analisis ke rentang data multi-tahun untuk mengamati evolusi segmen pasar dari waktu ke waktu.

DAFTAR PUSTAKA

- [1] M. W. Qasthari and R. Kurniawan, "Penggunaan Algoritma K-Means Clustering untuk Mengelompokkan Pemain Berdasarkan Gaya Bermain Pada Battle Royale Call of Duty Mobile," *Future Academia: The Journal of*

- Multidisciplinary Research on Scientific and Advanced*, vol. 2, no. 3, pp. 280–292, 2024.
- [2] S. Shahibah, N. Triyasri, A. A. Inanti, J. Rachel, and N. D. Pratama, “Analisis Klastering dari Data Behavior Online Gaming Menggunakan Algoritma K-Means,” *JoDMAApps (Journal of Data Science Methods and Applications)*, vol. 1, no. 1, pp. 18–24, 2025.
- [3] M. I. Muharizki and D. B. Arianto, “Analisis Clustering Dengan Metode K-Means Terhadap Statistik Permainan Pro-Player Valorant Pada Kompetisi Valorant Champions 2022,” *Serunai: Jurnal Ilmiah Ilmu Pendidikan*, vol. 9, no. 1, pp. 40–47, 2023.
- [4] D. A. Akmal, R. Buatun, and A. Sihombing, “Klasifikasi Tingkat Minat Belanja Online Melalui Media Sosial pada Masyarakat di Kota Binjai Menggunakan Algoritma K-Means,” *BRIDGE: Jurnal publikasi Sistem Informasi dan Telekomunikasi*, vol. 2, no. 3, pp. 214–228, 2024.
- [5] Prasetyo M. Bimo and Oktarina Dwi, “Penerapan Data Mining dalam Klasifikasi Penjualan Top Up Game Menggunakan Metode K-Nearest Neighbor,” *Merkurius: Jurnal Riset Sistem Informasi dan Teknik Informatika*, vol. 3, no. 2, pp. 1–12, 2025, doi: <https://doi.org/10.61132/merkurius.v3i2.750>.
- [6] L. Maulida, “Penggunaan Algoritma K-means dalam Menentukan Karakter Game Zenless Zone Zero,” *REMIK: Riset dan E-Jurnal Manajemen Informatika Komputer*, vol. 9, no. 1, pp. 403–414, 2025.
- [7] T. P. Panjaitan *et al.*, “Klasterisasi Data Penjualan Menggunakan Algoritma K-Mean Dengan RapidMiner,” *JoDMAApps (Journal of Data Science Methods and Applications)*, vol. 1, no. 1, pp. 25–32, 2025.
- [8] N. Kusmawanti, N. Suarna, and W. Prihartono, “PENGELOMPOKKAN LAGU TRADISIONAL DI MEDIA SOSIAL TIKTOK MENGGUNAKAN ALGORITMA K-MEANS,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 3, pp. 2962–2967, 2024.
- [9] F. P. A. Hasibuan, S. Sumarno, and I. Parlina, “Penerapan K-Means pada Pengelompokan Penjualan Produk Smartphone,” *SATESI: Jurnal Sains Teknologi dan Sistem Informasi*, vol. 1, no. 1, pp. 15–20, 2021.
- [10] R. Sidik, N. Suarna, and A. R. Dikananda, “Analisa Data Set Peminatan Siswa Menggunakan Algoritma K-Means Dengan Optimize Parameter Di Sekolah Menengah Kejuruan,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 2, pp. 1197–1203, 2023.
- [11] M. Billah, M. A. Zartesyia, and D. S. Prasvita, “Penerapan Collaborative Filtering, PCA dan K-Means dalam Pembangunan Sistem Rekomendasi Film,” in *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya*, 2021, pp. 579–587.
- [12] S. W. Harjono, N. W. Utami, and I. G. A. P. D. Putri, “Klasterisasi Tingkat Penjualan pada Startup Panak. id dengan Algoritma K-Means,” *Jurnal Ilmiah Teknologi Informasi Asia*, vol. 17, no. 1, pp. 55–66, 2023.
- [13] W. Aristika and W. J. Hartono, “Penerapan clustering K-Means untuk menentukan pengaruh media sosial Facebook terhadap usaha mikro, kecil dan menengah (UMKM) di Kecamatan Pekanbaru Kota,” *Jurnal Ilmu Komputer dan Bisnis*, vol. 11, no. 1, pp. 2389–2395, 2020.
- [14] O. Soleh and D. Jonas, “Penggunaan Algoritma K-Means untuk Segmentasi Data Pelanggan pada Sistem Pemasaran Berbasis Data Mining,” *Nusa: Journal of Science Studies*, vol. 1, no. 2, pp. 63–69, 2024.