

KLASTERISASI KARAKTERISTIK PEMAIN GAME BERDASARKAN PREFERENSI FITUR DAN MODEL BISNIS MENGGUNAKAN K-MEANS

Ferry Khusnil Arief¹

¹Universitas Nahdlatul Ulama Lampung
Teknik Informatika, Fakultas Sains dan Teknologi
ceryover@gmail.com

Abstrak

Perkembangan industri game di Indonesia mendorong pergeseran menuju model monetisasi berkelanjutan, seperti mikrotransaksi, yang memengaruhi preferensi dan perilaku pemain. Penelitian ini bertujuan mengelompokkan pemain game di Indonesia berdasarkan preferensi fitur game, preferensi monetisasi, dan perilaku aktual menggunakan algoritma K-Means Clustering. Data diperoleh dari 112 responden melalui kuesioner daring dan dianalisis menggunakan Elbow Method serta Silhouette Score untuk menentukan jumlah kluster optimal. Hasil penelitian menunjukkan lima kluster terbaik ($k=5$) dengan Silhouette Score sebesar 0,497, yaitu Pemain Aktif High-Spending, Pemain Anti-Monetisasi, Pemain Story-Visual Enthusiast, Pemain Kompetitif-Sosial Intensif, dan Pemain Kasual Moderat. Penelitian ini menyimpulkan bahwa karakteristik pemain game bersifat heterogen, sehingga pengembang perlu menerapkan strategi fitur dan monetisasi yang disesuaikan dengan setiap segmen pemain serta meminimalkan mekanisme pay-to-win guna menjaga keseimbangan dan kepuasan pemain.

Kata Kunci: Data Mining, K-Means Clustering, Monetisasi Game, Perilaku Pemain, Segmentasi Pemain.

Abstract

The rapid growth of the gaming industry in Indonesia has driven a shift toward sustainable monetization models, such as microtransactions, which influence players' preferences and behaviors. This study aims to classify Indonesian game players based on game feature preferences, monetization preferences, and actual gaming behavior using the K-Means Clustering algorithm. Data were collected through an online questionnaire involving 112 active game players and analyzed using the Elbow Method and Silhouette Score to determine the optimal number of clusters. The results indicate that the optimal clustering consists of five clusters ($k=5$) with a Silhouette Score of 0.497, namely High-Spending Active Players, Anti-Monetization Players, Story-Visual Enthusiasts, Competitive-Social Intensive Players, and Moderate Casual Players. The findings conclude that game players exhibit heterogeneous characteristics, highlighting the need for game developers to implement personalized feature and monetization strategies tailored to each player segment while minimizing pay-to-win mechanisms to maintain ecosystem balance and player satisfaction.

Keywords: Data Mining, K-Means Clustering, Game Monetization, Player Behavior, Player Segmentation.

I. Pendahuluan

Industri game digital di Indonesia mengalami perkembangan yang signifikan seiring dengan meningkatnya adopsi teknologi digital dan akses internet yang luas. Pertumbuhan ini tidak hanya meningkatkan jumlah pemain, tetapi juga mendorong perubahan dalam model bisnis game dari sistem tradisional menuju model berbasis layanan (game as a service). Dalam model ini, pendapatan tidak lagi hanya berasal dari penjualan game di awal, melainkan dari sistem monetisasi berkelanjutan seperti microtransactions, yang memungkinkan pemain membeli berbagai item virtual dalam permainan [1].

Seiring dengan perkembangan tersebut, perilaku dan preferensi pemain game menjadi semakin beragam dan kompleks. Pemain tidak hanya berbeda dalam hal intensitas bermain, tetapi juga dalam preferensi terhadap fitur game seperti visual, gameplay, dan interaksi sosial, serta dalam penerimaan terhadap berbagai bentuk monetisasi [2]. Keberagaman ini menunjukkan bahwa pemain tidak dapat dipandang sebagai kelompok yang homogen [3].

Masalah utama dalam penelitian ini adalah belum adanya pengelompokan karakteristik pemain game di Indonesia secara objektif berdasarkan kombinasi preferensi fitur game, preferensi monetisasi, dan perilaku pemain. Oleh karena itu, penelitian ini bertujuan mengidentifikasi hasil pengelompokan (clustering) pemain game di Indonesia menggunakan algoritma K-Means serta menganalisis karakteristik setiap cluster yang terbentuk.

a. Rumusan Masalah

1. Bagaimana hasil pengelompokan pemain game di Indonesia berdasarkan preferensi

fitur game, monetisasi, dan perilaku pemain menggunakan algoritma K-Means?

2. Bagaimana karakteristik setiap cluster pemain yang terbentuk?

b. Tujuan Penelitian

1. Mengidentifikasi hasil pengelompokan pemain game menggunakan algoritma K-Means.
2. Menganalisis karakteristik setiap cluster pemain yang terbentuk.

II. Kajian Pustaka

Berikut merupakan beberapa kajian teori dari penelitian ini:

2.1. Data Mining dan Klasterisasi

Data mining merupakan proses penemuan pola dan informasi bermakna dari kumpulan data besar menggunakan metode statistik, matematika, dan pembelajaran mesin. Klasterisasi adalah salah satu teknik data mining yang bertujuan mengelompokkan data berdasarkan kemiripan karakteristik tanpa label sebelumnya [4][5].

2.2. Algoritma K-Means

K-Means adalah algoritma klasterisasi partisi yang membagi data menjadi k kelompok berdasarkan jarak terdekat ke pusat cluster (centroid). Algoritma ini bekerja secara iteratif: menentukan k, menginisialisasi centroid, menghitung jarak Euclidean, mengelompokkan data, memperbarui centroid, dan mengulangi hingga konvergen [6][7].

2.3. Segmentasi Pemain Game

Segmentasi pemain game adalah proses pengelompokan pemain berdasarkan kemiripan karakteristik seperti preferensi fitur, perilaku bermain, dan penerimaan terhadap monetisasi. Faktor seperti narrative depth, visual aesthetic, gameplay complexity, social interaction, serta

penerimaan terhadap microtransaction dan pay-to-win menjadi dimensi penting dalam memahami perbedaan antar segmen pemain [8][9][10].

2.4. Monetisasi Game

Monetisasi game mengacu pada strategi pengembang untuk menghasilkan pendapatan, termasuk upfront payment, microtransaction, and model freemium. Persepsi pemain terhadap monetisasi bervariasi, mulai dari penerimaan penuh hingga penolakan terhadap mekanisme pay-to-win [1][3][11][12].

III. Metode Penelitian

3.1. Jenis Penelitian

Penelitian ini merupakan penelitian kuantitatif deskriptif dengan pendekatan data mining menggunakan K-Means Clustering.

3.2. Populasi dan Sampel

Populasi penelitian adalah pemain game digital di Indonesia. Data dikumpulkan melalui kuesioner daring yang disebarakan melalui forum game dan media sosial. Dari 120 responden, sebanyak 112 data valid digunakan setelah data cleaning.

3.3. Variabel Penelitian

Penelitian menggunakan sembilan variabel utama: (1) Preferensi Fitur Game: Narrative Depth (X1), Visual Aesthetic (X2), Gameplay Complexity (X3), Social Interaction (X4); (2) Preferensi Monetisasi: Upfront Payment Acceptance (X5), Microtransaction Tolerance (X6), Pay-to-Win Perception (X7); (3) Perilaku Pemain: Playtime Intensity (X8), Spending Frequency (X9). Seluruh variabel diukur menggunakan skala Likert 1–5.

3.4. Metode Analisis Data

Tahapan analisis meliputi: (1) Data Cleaning; (2) Transformasi jawaban ke skor numerik dan perhitungan rata-rata variabel; (3)

Normalisasi Min-Max Scaling; (4) Penentuan jumlah cluster optimal dengan Elbow Method dan Silhouette Score; (5) Clustering K-Means; (6) Evaluasi dan interpretasi. Analisis dilakukan menggunakan Python dengan library scikit-learn [7].

IV. Hasil dan Pembahasan

4.1. Gambaran Umum Data

Data awal berjumlah 120 responden. Setelah data cleaning, 8 responden dihapus karena tidak memenuhi kriteria (bukan pemain game aktif), sehingga total data valid adalah 112 responden.

Tabel 1. Rekapitulasi Data Penelitian

Keterangan	Jumlah
Data awal kuesioner	120
Data dihapus	8
Data valid	112

4.2. Transformasi dan Normalisasi Data

Jawaban kuesioner ditransformasi ke skor numerik, dihitung rata-rata per variabel, kemudian dinormalisasi menggunakan Min-Max Scaling ke rentang 0–1 agar seluruh variabel memiliki bobot setara.

4.3. Penentuan Jumlah Cluster Optimal

Penentuan jumlah cluster menggunakan Elbow Method dan Silhouette Score. Hasil evaluasi disajikan pada Tabel 2.

Tabel 2. Hasil Elbow Method dan Silhouette Score

k	WCSS	Silhouette Score
2	52,3039	0,4109
3	39,4143	0,3963
4	32,7826	0,4076
5	26,3677	0,4970

6	23,2605	0,4315
7	20,3455	0,4207
8	17,8753	0,4383
9	16,0889	0,4242
10	14,3006	0,4270

Berdasarkan Tabel 2, $k = 5$ dipilih sebagai jumlah cluster terbaik karena memberikan WCSS yang cukup rendah dan Silhouette Score tertinggi (0,4970).

4.4. Hasil Clustering

Proses clustering K-Means dengan $k = 5$ menghasilkan distribusi responden sebagai berikut:

Tabel 3. Jumlah Anggota Setiap Cluster

Cluster	Jumlah	Persentase
C1	39	34,82%
C2	21	18,75%
C3	22	19,64%
C4	21	18,75%
C5	9	8,04%

4.5. Karakteristik Setiap Cluster

Karakteristik cluster dianalisis berdasarkan rata-rata variabel utama $X1-X9$ sebagaimana disajikan pada Tabel 4.

Tabel 4. Rata-Rata Variabel Utama Setiap Cluster

Cluster	Jml	X1	X2	X3	X4	X5	X6	X7	X8	X9
C1	39	3,57	3,88	3,83	3,61	3,49	4,75	3,84	4,89	4,83
C2	21	3,30	3,72	3,51	3,42	2,04	1,47	4,31	3,77	1,42
C3	22	4,70	4,72	3,97	3,19	3,47	3,27	3,05	3,19	2,63
C4	21	3,80	3,70	4,36	4,47	3,22	3,22	3,23	4,24	2,93
C5	9	3,40	3,69	3,40	3,02	2,73	2,76	3,02	2,58	2,27

Berdasarkan Tabel 4, setiap cluster memiliki karakteristik yang berbeda:

Cluster 1 (Pemain Aktif High-Spending): Memiliki Microtransaction Tolerance ($X6=4,75$), Playtime Intensity ($X8=4,89$), dan Spending Frequency ($X9=4,83$) tertinggi. Kelompok pemain aktif yang terbuka terhadap pembelian dalam game.

Cluster 2 (Pemain Anti-Monetisasi): Memiliki Upfront Payment ($X5=2,04$), Microtransaction Tolerance ($X6=1,47$), dan Spending ($X9=1,42$) terendah, namun Pay-to-Win Perception ($X7=4,31$) tertinggi. Menolak monetisasi tetapi aktif bermain.

Cluster 3 (Story-Visual Enthusiast): Unggul pada Narrative Depth ($X1=4,70$) and Visual Aesthetic ($X2=4,72$). Mengutamakan pengalaman cerita dan visual.

Cluster 4 (Kompetitif-Sosial Intensif): Tertinggi pada Gameplay Complexity ($X3=4,36$) and Social Interaction ($X4=4,47$). Menyukai tantangan gameplay dan interaksi sosial.

Cluster 5 (Kasual Moderat): Nilai relatif sedang-rendah pada seluruh aspek. Masih menikmati game tetapi dengan intensitas dan pengeluaran lebih rendah.

4.6. Pembahasan

Berdasarkan preferensi fitur game, Cluster 3 sangat menonjol pada cerita dan visual, sedangkan Cluster 4 unggul pada gameplay dan interaksi sosial. Cluster 1 memiliki nilai fitur cukup tinggi namun tidak dominan pada satu aspek. Cluster 2 dan 5 menunjukkan nilai sedang.

Dari sisi monetisasi, Cluster 1 menunjukkan toleransi tertinggi terhadap microtransaction, sementara Cluster 2 secara tegas menolak. Perbedaan ini memperkuat bahwa pemain game tidak homogen dalam merespons monetisasi [13].

Berdasarkan perilaku, Cluster 1 memiliki intensitas bermain dan spending tertinggi.

Cluster 4 aktif bermain tetapi spending sedang. Cluster 2 aktif bermain namun spending terendah. Temuan ini menunjukkan variasi perilaku signifikan antar kelompok pemain.

Profiling identitas menunjukkan Cluster 1 didominasi laki-laki usia 26–30 tahun, bekerja, pengguna PC/laptop. Cluster 2 didominasi pelajar/mahasiswa usia 21–25 tahun, pengguna mobile. Cluster 3 memiliki komposisi gender paling seimbang dengan genre RPG/Adventure. Cluster 4 didominasi pelajar/mahasiswa pengguna PC dan mobile. Cluster 5 didominasi pemain muda dengan pendapatan rendah dan platform mobile.

Secara keseluruhan, pemain game di Indonesia memiliki karakteristik beragam dan tidak dapat dipandang sebagai kelompok homogen. K-Means mampu membentuk segmentasi berdasarkan kemiripan preferensi dan perilaku pemain.

V. Kesimpulan dan Saran

5.1 Kesimpulan

Pemain game di Indonesia memiliki karakteristik heterogen. Melalui K-Means diperoleh lima klaster: (1) Pemain Aktif High-Spending; (2) Pemain Anti-Monetisasi; (3) Story-Visual Enthusiast; (4) Kompetitif-Sosial Intensif; (5) Kasual Moderat. Silhouette Score 0,497 menunjukkan kualitas cluster cukup baik.

5.2 Saran

Pengembang game disarankan merancang strategi monetisasi tersegmentasi. Penelitian selanjutnya disarankan menggunakan data transaksi aktual dan algoritma klasterisasi alternatif sebagai pembanding.

Daftar Pustaka

[1] P. Rita, R. Ramos, and R. G. Caetano, “The role of microtransactions in impulse buying

and purchase intention in the video game market,” vol. 50, 2024, doi: 10.1016/j.entcom.2024.100693.

[2] E. Gibson, M. D. Griffiths, F. Calado, and A. Harris, “Videogame player experiences with micro-transactions: An interpretative phenomenological analysis,” *Comput. Human Behav.*, vol. 145, p. 107766, 2023, doi: 10.1016/j.chb.2023.107766.

[3] D. Zandle, R. Meyer, and N. Ballou, “The changing face of desktop video game monetisation: An exploration of exposure to loot boxes, pay to win, and cosmetic microtransactions in the most-played Steam games of 2010-2019,” 2020, doi: 10.1371/journal.pone.0232780.

[4] Y. Su, P. Backlund, and H. Engström, “Comprehensive review and classification of game analytics,” *Serv. Oriented Comput. Appl.*, vol. 15, no. 2, pp. 141–156, 2021, doi: 10.1007/s11761-020-00303-z.

[5] Y. Qiu, Y. Gong, and G. Liu, “User Behavior Analysis and Clustering in a MMO Mobile Game: Insights and Recommendations,” pp. 1–16, 2024.

[6] Q. Zhou and B. Sun, “Adaptive K-means clustering based under-sampling methods to solve the class imbalance problem,” *Data Inf. Manag.*, vol. 8, no. 3, p. 100064, 2024, doi: 10.1016/j.dim.2023.100064.

[7] F. Pedregosa, R. Weiss, and M. Brucher, “Scikit-learn: Machine Learning in Python,” vol. 12, pp. 2825–2830, 2011.

[8] V. Klézl and S. Kelly, “Negativists, enthusiasts and others: a typology of players in free-to-play games,” pp. 7939–7960, 2023.

[9] M. Angel, E. García-Cabrera, F. Luna-Perej, L. Sevillano-Ramos, and L. Mir, “Video game player profiles among university students: Impact of game

preferences and academic background,” vol. 9, 2025, doi: 10.1016/j.caeo.2025.100280.

- [10] G. K. S. Lee, “In-App Purchase Behaviour and Game Design in Mobile Gaming: A Review of Monetisation and Player Experience,” 2025.
- [11] M. J. Lehtonen, J. T. Harviainen, and A. Kultima, “How monetization mechanisms in mobile games influence consumers’ identity extensions,” *Serv. Bus.*, vol. 17, no. 1, pp. 113–136, 2023, doi: 10.1007/s11628-022-00518-4.
- [12] W. H. Hanrahan, “Microtransactions in the video game industry: Commodification and contradiction,” 2023.
- [13] V. Klézl and S. Kelly, “Negativists, enthusiasts and others: a typology of players in free-to-play games,” 2022.