

Klasifikasi Tingkat Retensi Pemain *Video Game* Online

Mustofa^{1*}, Heru Purwanto², Fabriyan Fandi Dwi Imaniawan³

^{1,2,3}Universitas Bina Sarana Informatika

Jl. Kramat Raya No.98 Jakarta, Indonesia

e-mail: ^{1*}mustofa.mu@bsi.ac.id, ²heru.hrp@bsi.ac.id, ³fabriyan.fbf@bsi.ac.id

Artikel Info : Diterima : 31-07-2024 | Direvisi : 01-08-2024 | Disetujui : 02-08-2024

Abstrak - Internet telah menjadi bagian integral dari kehidupan masyarakat, dengan 5,44 miliar pengguna di seluruh dunia dan 185 juta pengguna di Indonesia. Penggunaan internet mencakup berbagai bidang, termasuk hiburan seperti video game, yang memiliki sekitar 3,38 miliar pengguna global pada tahun 2023 dan terus berkembang. Industri video game menunjukkan potensi pasar yang besar, dengan pendapatan yang signifikan. Untuk memanfaatkan potensi ini, pengembang game harus menjaga loyalitas pemain agar tetap setia. Retensi pemain, yaitu kemampuan game untuk mempertahankan pemain dalam jangka waktu lama, sangat penting dalam meningkatkan pendapatan dan popularitas game. Mengetahui tingkat retensi pemain adalah strategi kunci dalam pemasaran, karena retensi yang tinggi berhubungan dengan loyalitas yang lebih tinggi.

Penelitian sebelumnya telah mengkaji perilaku pemain dan retensi dalam konteks game, namun belum ada model yang komprehensif untuk berbagai jenis game. Penelitian ini bertujuan untuk mengembangkan model klasifikasi yang dapat mengidentifikasi karakteristik pemain dengan tingkat retensi tinggi atau rendah. Model ini diharapkan dapat membantu pengembang game merancang strategi retensi yang lebih efektif. Temuan penelitian ini akan memberikan wawasan mendalam tentang faktor-faktor yang mempengaruhi retensi pemain dan menawarkan panduan bagi pengembang game dalam mengembangkan fitur dan strategi yang lebih baik untuk mempertahankan pemain.

Kata Kunci : Retensi, Seleksi fitur, Klasifikasi

Abstracts - The internet has become an integral part of people's lives, with 5.44 billion users worldwide and 185 million users in Indonesia. Internet use covers a wide range of areas, including entertainment such as video games, which had an estimated 3.38 billion global users in 2023 and continues to grow. The video game industry shows huge market potential, with significant revenues. To exploit this potential, game developers must maintain player loyalty. Player retention, i.e. a game's ability to retain players over a long period of time, is critical in increasing a game's revenue and popularity. Knowing player retention rates is a key strategy in marketing, as high retention is associated with higher loyalty.

Previous research has examined player behavior and retention in the context of games, but there is no comprehensive model for various types of games. This research aims to develop a classification model that can identify the characteristics of players with high or low retention rates. This model is expected to help game developers design more effective retention strategies. The findings of this research will provide in-depth insight into the factors that influence player retention and offer guidance for game developers in developing better features and strategies to retain players.

Keywords : Retention, Feature selection, Classification

PENDAHULUAN

Internet saat ini sudah menjadi bagian penting dalam kehidupan masyarakat. Hampir semua bidang dalam kehidupan manusia sudah menggunakan internet sebagai kebutuhan. Bahkan dalam kehidupan sehari-hari internet telah menjadi alat pemenuh kebutuhan yang sangat penting (Delfiantrisno & Sroyer, 2020). Hal ini dibuktikan dengan begitu masifnya pengguna internet di seluruh dunia. Kini pengguna internet di seluruh dunia telah mencapai 5.44 Milyar pengguna atau 68% dari populasi dunia (We are Social, 2023). Khusus di Indonesia sendiri pengguna internet telah mencapai 185 juta pengguna atau lebih dari 66% dari jumlah penduduk (We are Social, 2024).



Ada banyak hal yang dilakukan masyarakat dengan internet, mulai dari pekerjaan, pendidikan hingga hiburan. Salah satu hiburan yang cukup populer di internet adalah *video game*. Pengguna *video game* di seluruh dunia pada tahun 2023 diperkirakan sekitar 3.38 juta pengguna dan diproyeksikan akan bertambah 6.6% setiap tahunnya (Wijman T et al., 2023). Tidak mengherankan pendapatan dari sektor *video game* sangat tinggi. Pendapatan dari *video game* di Indonesia sendiri diperkirakan mencapai 3,667 Juta USD di tahun 2024. Tentu ini menggambarkan betapa tingginya potensi pasar industri *game* di Indonesia.

Tingginya potensi industri *video game* ini harus dimanfaatkan dengan baik, terlebih jika perusahaan pengembang *video game* telah memiliki jumlah pemain yang sangat banyak. Menjaga loyalitas pemain sangat dibutuhkan agar pemain tetap setia memainkan *video game* yang dikelola oleh pengembang. Hal ini penting karena industri jasa pengembang *video game* tidak lepas dari kemungkinan beralihnya pemain dari satu *video game* ke *video game* yang lain dengan berbagai alasan (Siahaya et al., 2023). Untuk dapat bertahan, pengembang *video game* harus mempertahankan pemain *video game*-nya untuk mendapatkan profitabilitas.

Dalam dunia pemasaran retensi menjadi perhatian khusus perusahaan. Retensi merupakan kemauan bertahan konsumen dari suatu produk atau layanan (Moesarofah, 2021). Perusahaan banyak melakukan kajian terhadap retensi pelanggan, karena pelanggan dengan retensi lebih tinggi memiliki tingkat loyalitas lebih tinggi (Darmawan et al., 2020). Mengetahui tingkat retensi pemain merupakan hal strategis bagi perusahaan. Dalam konteks *video game*, retensi pemain merujuk pada kemampuan *game* untuk membuat pemain terus bermain dalam jangka waktu yang lama. Ketika retensi tinggi, pemain cenderung menghabiskan lebih banyak waktu dan uang dalam *game*, yang pada gilirannya meningkatkan pendapatan bagi pengembang *game*. Sebaliknya, jika retensi rendah, pemain cenderung berhenti bermain setelah waktu yang singkat, yang dapat mengakibatkan penurunan pendapatan dan popularitas *game*.

Memiliki pengetahuan tingkat retensi pemain dapat menjadi acuan arah strategi pemasaran untuk memenangkan persaingan pasar yang merupakan masalah umum pada perusahaan (Sinambela et al., 2022). Retensi pemain merupakan salah satu aspek kunci dalam kesuksesan jangka panjang *video game* online. Tingkat retensi yang tinggi menunjukkan bahwa pemain tetap terlibat dan terus bermain, yang berdampak langsung pada pendapatan dan popularitas *game*. Maka perlu dilakukan kajian tentang perilaku pemain untuk mengukur tingkat retensi agar pengembang memiliki acuan untuk membuat kebijakan.

Beberapa penelitian telah dilakukan untuk mengkaji tentang perilaku pemain diantaranya (Karmakar et al., 2022) yang menganalisis retensi dengan memodelkan beberapa karakteristik pemain dalam *game* beserta probabilitas berhenti bermain. Namun penelitian ini lebih fokus kepada *game* dengan karakteristik RPG (Role Played *Game*) saja sehingga variabel pencapaian pemain berdasarkan level menjadi perilaku utama. Selain itu (Subarkah et al., 2023) juga telah melakukan analisis tentang perilaku pemain di *video game* berbasis MOBA (Multiplayer Online Battle Arena) untuk memutuskan melakukan pembelian yang merupakan hasil dari tingginya retensi.

Dari penelitian sebelumnya, sudah diketahui perilaku pemain *game*, namun belum dijelaskan bagaimana membuat sebuah model untuk mengetahui karakteristik pemain dengan tingkat retensi tinggi ataupun rendah. Pengembang memerlukan pengetahuan ini untuk menentukan strategi yang berbeda bagi masing-masing karakteristik. Selain itu, penelitian sebelumnya dikhususkan pada jenis *game* tertentu, sehingga tidak bisa digunakan pada semua jenis *game*.

Penelitian ini berkontribusi pada literatur dengan menyediakan pemahaman yang lebih mendalam tentang faktor-faktor yang mempengaruhi retensi pemain. Menawarkan model untuk mengelompokkan pemain dengan tingkat retensi yang berbeda yang dapat membantu pengembang *game* meningkatkan strategi retensi mereka. Dengan memahami faktor-faktor kunci yang mempengaruhi retensi pemain, pengembang *game* dapat merancang fitur dan strategi yang lebih efektif untuk mempertahankan pemain dan memastikan kesuksesan jangka panjang.

METODE PENELITIAN

Metode penelitian yang digunakan pada penelitian klasifikasi pemain sepak bola ini memiliki beberapa tahap yang merujuk pada metode CRIPS-DM terdiri dari beberapa tahapan seperti *business understanding* yaitu tahapan dalam menentukan latar belakang penelitian, masalah penelitian dan batasan penelitian serta penentuan tujuan penelitian, di tahap ini peneliti mencoba memahami masalah secara umum. *Data understanding* yaitu tahapan pengumpulan data untuk dilakukan penelitian, memahami karakteristik data dan menyiapkan data untuk bisa menentukan penanganan yang tepat. *Data preparation* yaitu tahapan pengolahan data tahap awal agar sesuai dengan permodelan yang direncanakan sehingga data dapat digunakan sebagai data penelitian eksperimen. *Modelling* yaitu tahapan memilih metode yang diusulkan dan dilakukan proses pengujian/eksperimen model. *Evaluation* yaitu tahapan evaluasi terhadap model yang diuji. dan tahapan terakhir adalah *development* untuk melakukan dan menyimpulkan hasil analisa dari setiap tahap yang telah dilakukan dalam penelitian. Metode penelitian memiliki tahapan-tahapan yang cukup jelas, diantaranya:

1. Business Understanding

Pada tahapan ini, diawali dengan menyusun kerangka penelitian yang akan dilakukan, menentukan latar belakang penelitian, masalah penelitian, batasan penelitian dan tujuan penelitian serta data yang akan digunakan,

waktu pelaksanaan serta hasil apa yang ingin dicapai. Penelitian akan menggunakan dataset untuk melakukan klasifikasi pemain *game* menjadi tiga tingkat retensi yaitu High, Medium dan Low.

2. Data Understanding

Data yang digunakan dalam penelitian ini adalah data sekunder yang berisi perilaku dari 49033 pemain *game* secara acak dari beragam usia. Data diklasifikasikan dalam tiga kategori yaitu sebanyak 10336 High, 19374, Medium, 10324 Low.

3. Data Preparation

Pada tahapan ini, akan dilakukan analisa dari 49033 data pemain *game*. Pelabelan dikelompokan dalam tiga kategori yaitu pemain High, Medium dan Low. Data-data tersebut diatas kemudian digunakan sebagai data eksperimen dalam penelitian penentuan kategori.

4. Modelling

Pada tahapan ini, akan dilakukan analisis komparasi menggunakan metode klasifikasi *data mining* yang akan diusulkan. Metode yang diusulkan untuk pengolahan data pemain ini adalah penggunaan Algoritma *Random Forest*, dengan pengujian menggunakan *10 k-fold cross validation*. Kemudian data diolah kembali dengan menambahkan teknik-teknik seleksi fitur, *Correlation Attribute Evaluator*, *Gain Ratio Attribute Evaluator*, *Info Gain Attribute Evaluator*, algoritma untuk mendapatkan nilai akurasi. Hasil evaluasi dari nilai akurasi akan dikomparasi untuk menentukan model algoritma terbaik

5. Evaluation

Evaluasi dilakukan berdasarkan nilai akurasi, AUC. Validasi juga dilakukan dengan *10 k-fold cross validation*. Validasi menggunakan *10-fold cross validation* dilakukan dengan membagi dataset menjadi 10 bagian, satu bagian sebagai data uji, sedangkan bagian lain dijadikan sebagai data latih. Proses validasi dilakukan berulang, mulai bagian pertama sebagai data uji sampai bagian kesepuluh, sehingga semua data dalam dataset diuji secara bergantian. Tahapan ini akan melihat secara mendetail mengenai hasil kinerja algoritma yang diujikan pada dataset.

6. Deployment

Tahapan ini merupakan tahapan terakhir dalam standar permodelan dalam data mining yaitu *Cross-Industry Standard Process for Data Mining* (CRIPS-DM). pada tahap ini hasil pengujian dianalisa untuk mengetahui nilai akurasi dari tiap-tiap algoritma yang diusulkan. *Random Forest* yang telah dikombinasikan dengan seleksi fitur yang telah diujikan dilihat nilai akurasi dan *ROC area*. Perbandingan hasil pengujian dari setiap algoritma juga dilakukan pada tahapan ini. Hasil analisis diharapkan dapat digunakan sebagai pertimbangan untuk pengambilan keputusan. Dalam tahapan ini akan dilakukan pembuatan laporan berupa penulisan hasil penelitian dari pendahuluan sampai kesimpulan dan penutup

HASIL DAN PEMBAHASAN

Tujuan dari penelitian adalah untuk melakukan klasifikasi pemain video game berdasarkan tiga kategori yaitu High, Medium dan Low. Penelitian ini akan menggunakan algoritma *Random Forest* dengan menggunakan aplikasi *Weka*. Pengujian juga dilakukan dengan menambahkan Teknik seleksi fitur *Correlation Attribute Evaluator*, *Gain Ratio Attribute Evaluator*, *Info Gain Attribute Evaluator* dan *CFS Subset Evaluator*.

1. Data Preparation

Sebanyak 49033 data perilaku pemain *video game* online dengan 12 fitur yang akan digunakan memiliki detail sebagai berikut:

Tabel 1. Daftar Fitur

No	Fitur	Keterangan
1	Age	19-50
2	Gender	Male/Female
3	Location	USA/Europe/Asia/Other
4	Game Genre	Action/RPG/Simulation/Sport/Strategy
5	Play Time (Hours)	0-24
6	In Game Purchase	0/1
7	Game Difficult	Hard/Medium/Easy
8	Session Per Week	0-19
9	Average Session Duration(Minutes)	0-180
10	Player Level	0-100
11	Achievment	1-50
12	Retensi	Class

Sebanyak 49033 data perilaku pemain *video game* online dengan 12 fitur, untuk mengetahui fitur mana yang paling penting untuk menentukan retensi pemain maka dilakukan seleksi fitur dengan menggunakan

beberapa metode diantaranya fitur Correlation Attribute Evaluator, Gain Ratio Attribute Evaluator, Info Gain Attribute Evaluator dan CFS Subset Evaluator.

Dari seleksi fitur fitur Correlation Attribute Evaluator menggunakan metoda ranking didapatkan hasil seperti yang ditampilkan pada Tabel 2. Menunjukkan saran agar mengikutkan semua fitur yang ada.

Tabel 2. Hasil seleksi Correlation Attribute Evaluator

No	Value	Feature ID	Feature
1	0.26335	8	SessionsPerWeek
2	0.24915	9	AvgSessionDurationMinutes
3	0.04806	11	AchievementsUnlocked
4	0.04595	10	PlayerLevel
5	0.00729	5	PlayTimeHours
6	0.00673	1	Age
7	0.00477	6	InGamePurchases
8	0.00412	7	GameDifficulty
9	0.00408	4	GameGenre
10	0.0033	3	Location
11	0.00316	2	Gender

Seleksi fitur Gain Ratio Attribute Evaluator menggunakan metoda ranking didapatkan hasil seperti yang ditampilkan pada Tabel 3. Menunjukkan saran agar mengikutkan semua fitur yang ada namun kita bisa melihat fitur ranking ke 9, 10 dan 11 memiliki value 0.

Tabel 3. Hasil seleksi Gain Ratio Attribute Evaluator

No	Value	Feature ID	Feature
1	0.1017088	8	SessionsPerWeek
2	0.0661236	9	AvgSessionDurationMinutes
3	0.0023212	11	AchievementsUnlocked
4	0.0023014	10	PlayerLevel
5	0.0000671	4	GameGenre
6	0.0000506	7	GameDifficulty
7	0.0000347	3	Location
8	0.0000219	2	Gender
9	0	6	InGamePurchases
10	0	5	PlayTimeHours
11	0	1	Age

Seleksi fitur Info Gain Attribute Evaluator menggunakan metoda ranking didapatkan hasil seperti yang ditampilkan pada Tabel 4. Menunjukkan saran agar mengikutkan semua fitur yang ada namun kita bisa melihat fitur ranking ke 9, 10 dan 11 juga memiliki value 0 seperti hasil menggunakan seleksi Gain Ratio Attribute Evaluator.

Tabel 4. Hasil seleksi Info Gain Attribute Evaluator

No	Value	Feature ID	Feature
1	0.3990148	8	SessionsPerWeek
2	0.2427847	9	AvgSessionDurationMinutes
3	0.0044569	11	AchievementsUnlocked
4	0.003574	10	PlayerLevel
5	0.0001557	4	GameGenre
6	0.0000752	7	GameDifficulty

7	0.000064	3	Location
8	0.0000213	2	Gender
9	0	6	InGamePurchases
10	0	5	PlayTimeHours
11	0	1	Age

Dari seleksi CFS Subset Evaluator menggunakan metoda ranking didapatkan hasil seperti yang ditampilkan pada Tabel 5. Menunjukkan saran agar mengikutkan semua fitur yang digunakan hanya fitur SessionsPerWeek, AvgSessionDurationMinutes, AchievementsUnlocked dan Player Level

Tabel 5. Hasil seleksi Info Gain Attribute Evaluator

No	Feature ID	Feature
1	8	SessionsPerWeek
2	9	AvgSessionDurationMinutes
3	11	AchievementsUnlocked
4	10	PlayerLevel

2. Modeling

Metode klasifikasi yang digunakan untuk permodelan data adalah Random Forest. Metode Random forest awalnya diujikan tanpa menggunakan teknik seleksi fitur untuk mengetahui akurasi dasar dari setiap metode dengan menggunakan 11 fitur. Hal ini dilakukan untuk mengetahui sejauh mana teknik seleksi fitur mempengaruhi kinerja algoritma.

Kemudian di tahap selanjutnya dilakukan pengujian setiap metode dikombinasikan dengan seleksi fitur Correlation Attribute Evaluator, Gain Ratio Attribute Evaluator, Info Gain Attribute Evaluator dan CFS Subset Evaluator untuk mengetahui perbedaan akurasi jika masing-masing metode setelah fitur diseleksi.

3. Evaluation

Eveluasi dapat dilakukan dengan melihat hasil pengujian dari model yang telah diuji. Hasil pengujian model dengan Random Forest dapat digunakan untuk mengetahui nilai accuracy, precision, recall, dan ROC Area pada model. Baik permodelan yang belum ditambahkan seleksi fitur ataupun yang telah kombinasikan dengan teknik seleksi fitur Correlation Attribute Evaluator, Gain Ratio Attribute Evaluator, Info Gain Attribute Evaluator dan CFS Subset Evaluator. Untuk memvalidasi permodelan ini juga diterapkan 10 k-fold cross validation.

Percobaan pertama dilakukan dengan menerapkan metode klasifikasi yang mengkasifikasikan pemain game dalam tiga kelas retensi yaitu pemain High, Medium dan Low. Untuk memvalidasi pengujian ini peneliti menggunakan 10 k-fold cross validation. Percobaan pertama memberikan hasil pengujian yang dipaparkan pada Tabel 6.

Tabel 6. Pengujian Random Forest

Akurasi	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area
91.2724 %	0.913	0.058	0.913	0.913	0.912	0.861	0.946	0.907

Pengujian awal telah memberikan hasil yang cukup baik dengan nilai akurasi mencapai 91.2724%. Namun pengujian dilanjutkan dengan menggunakan saran dari seleksi fitur. Sebelum menggunakan seleksi fitur, Ditemukan bahwa teknik seleksi fitur Correlation Attribute Evaluator, Gain Ratio Attribute Evaluator, dan Info Gain Attribute Evaluator tidak mengeliminasi satupun fitur yang ada. Namun pada tabel 3 dan tabel 4 hasil dari seleksi fitur Gain Ratio Attribute Evaluator, dan Info Gain Attribute Evaluator memiliki kesamaan yaitu 3 fitur dengan ranking terendah memiliki value 0. Dengan temuan ini dilakukanlah pengujian dengan menghilangkan fitur tersebut dan mengujinya kembali dengan metode Random Forest.

Hasil pengujian dengan hanya menggunakan 9 fitur terbaik dari Gain Ratio Attribute Evaluator, dan Info Gain Attribute Evaluator menunjukkan hasil positif peningkatan akurasi yang dapat dilihat pada Tabel 7.

Tabel 7. Pengujian Random Forest + 9 Fitur terbaik

Akurasi	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area
91.6696 %	0.917	0.054	0.917	0.917	0.916	0.867	0.946	0.906

Optimasi masih bisa dilakukan dengan menambahkan metode bagging untuk optimalisasi. Setelah penambahan

bagging akurasi random forest dengan 9 fitur terbaik meningkat menjadi 91.7095 %. Untuk detail hasil pengujian ditunjukkan pada Tabel 8.

Tabel 7. Optimasi Random Forest + 9 Fitur terbaik

Akurasi	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area
91.7095 %	0.917	0.054	0.917	0.917	0.916	0.867	0.946	0.906

Pengujian selanjutnya menggunakan 4 fitur hasil seleksi fitur CFS Subset Evaluator. menggunakan Random forest. Hasilnya menunjukkan akurasi yang lebih baik yaitu mencapai 92.0592 %. Detail hasil pengujian ditunjukkan pada Tabel 8.

Tabel 8. Pengujian Random Forest + CFS Subset Evaluator.

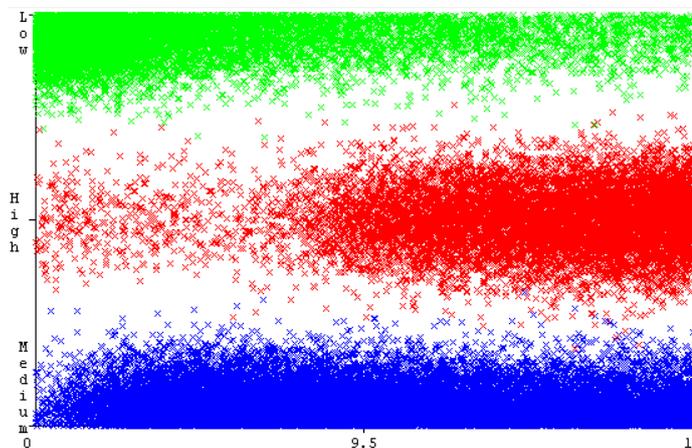
Akurasi	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area
91.7095 %	0.917	0.054	0.917	0.917	0.916	0.867	0.946	0.906

Optimasi masih bisa dilakukan dengan menambahkan metode bagging untuk optimalisasi. Setelah penambahan bagging akurasi random forest dan CFS Subset Evaluator menjadi 92.2141%. Untuk detail hasil pengujian ditunjukkan pada Tabel 9.

Tabel 9. Pengujian Random Forest + CFS Subset Evaluator.

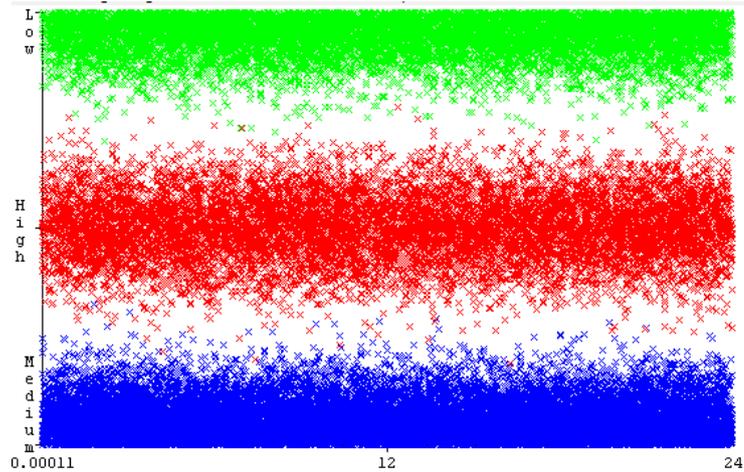
Akurasi	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area
92.2141%	0.922	0.05	0.922	0.922	0.922	0.877	0.947	0.907

Dari beberapa langkah pengujian, ditemukan beberapa poin penting dalam perilaku pemain video game yang berpengaruh pada tingkat retensi pemain diantaranya adalah perilaku yang paling menentukan tingkat retensi pemain videogame adalah seberapa sering seseorang memainkan video game. Rutinitas ini lebih penting jika dibandingkan dengan lama bermain dalam satu waktu. Hal ini ditunjukkan pada gambar 1.



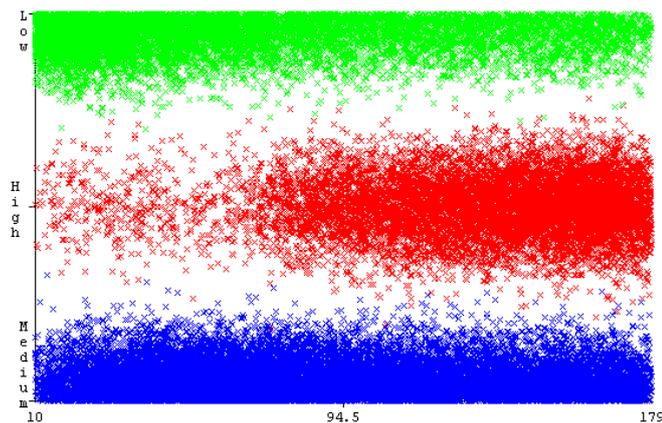
Gambar 1. Sebaran fitur SessionsPerWeek

Gambar 1 menunjukkan sebaran pemain dengan tingkat retensi tinggi memiliki lebih banyak sesi bermain dalam satu minggu. Lamanya permainan sesi dalam satu waktu tidak menjadi perilaku yang berpengaruh dalam menentukan tingkat retensi pemain. Hal ini ditunjukkan pada Gambar 2 yang menggambarkan bahwa sebaran perilaku lama bermain dalam satu waktu hampir merata di setiap tingkatan retensi



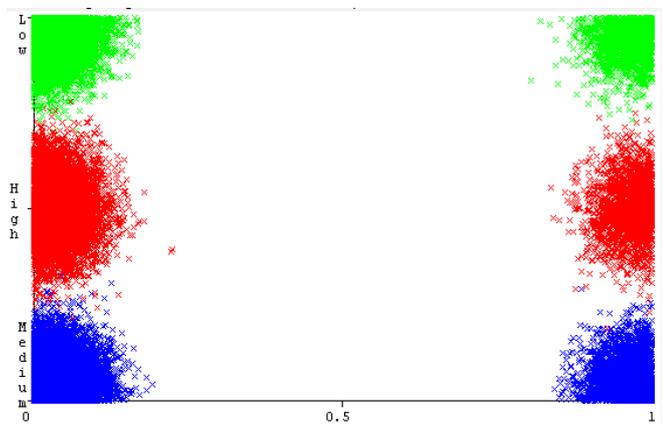
Gambar 2. Sebaran fitur PlayTimeHours

Selain itu, rata-rata durasi pemain memainkan video game pada setiap sesi juga sangat berpengaruh. Pada Gambar 3 ditunjukkan bahwa pemain dengan rata-rata durasi bermain tinggi di setiap sesi adalah pemain dengan retensi yang tinggi



Gambar 3. Sebaran fitur SessionsPerWeek

Temuan yang menarik adalah, perilaku melakukan pembelian dalam video game tidak terlalu berpengaruh dalam pengelompokan tingkat retensi pemain video game. Hal ini ditunjukkan dari meratanya sebaran data seperti yang ditunjukkan pada Gambar 4.



Gambar 4. Sebaran fitur PlayTimeHours

KESIMPULAN

Penelitian ini memberikan literatur dengan menyediakan pemahaman yang lebih mendalam tentang perilaku yang mempengaruhi retensi pemain. Diantaranya, usia, pilihan genre, dan lokasi tidak teralalu berpengaruh pada tingkat retensi pemain. Pemain yang melakukan pembelian dalam game belum tentu pemain yang memiliki tingkat retensi tinggi. Dari penelitian ini juga ditemukan bahwa banyak nya sesi bermain lebih penting dari lamanya bermain dalam satu sesi. Beberapa informasi ini diharapkan dapat menjadi acuan bagi pengembang video game dalam menyusun strategi pemasaran.

Penelitian ini juga telah membuat sebuah model klasifikasi tingkat retensi pemain video game guna mengelompokkan pengguna agar pengembang dapat menerapkan strategi pemasaran yang paling sesuai untuk masing-masing kategori pemain video game.

REFERENSI

- Darmawan, D., Arifin, S., & Purwanto, F. (2020). Studi Tentang Persepsi Nilai, Kepuasan Dan Retensi Pelanggan Kapal Penyeberangan Ujung - Kamal. *Jurnal Baruna Horizon*, 3(1), 198–209. <https://doi.org/10.52310/jbhorizon.v3i1.39>
- Delfiantriso, A., & Sroyer, S. (2020). Analisis Potensi Pemanfaatan Teknologi Internet Dalam Menunjang Kehidupan Sosial Ekonomi Masyarakat Kabupaten Mimika. *JURNAL KRITIS (Kebijakan, Riset, Dan Inovasi)*, 4(1), 1–17. <http://ejournal.stiejb.ac.id/index.php/jurnal-kritis/article/view/104>
- Karmakar, B., Liu, P., Mukherjee, G., Che, H., & Dutta, S. (2022). Improved retention analysis in freemium role-playing games by jointly modelling players' motivation, progression and churn. *Journal of the Royal Statistical Society. Series A: Statistics in Society*, 185(1), 102–133. <https://doi.org/10.1111/rssa.12730>
- Moesarofah, M. (2021). Analisis Karakteristik Retensi Mahasiswa di Perguruan Tinggi. *Didaktis: Jurnal Pendidikan Dan Ilmu Pengetahuan*, 21(1). <https://doi.org/10.30651/didaktis.v21i1.7005>
- Siahaya, S., Alfonso, P. V., & Aunalal, Z. I. (2023). Analisis Pengaruh Pelayanan Karyawan Yang Berorientasi Pelanggan Terhadap Kepuasan Pelanggan Dan Dampaknya Terhadap Retensi Pelanggan (Studi Empiris Pada Salon Kecantikan Di Kota Ambon). *Jurnal Administrasi Terapan*, 2(1), 60–67.
- Sinambela, E. A., Retnowati, E., Ernawati, E., Lestari, U. P., & Munir, M. (2022). Pengaruh Kualitas Layanan Dan Citra Perusahaan Terhadap Retensi Pelanggan Bengkel Resmi Honda Surabaya. *Jurnal Baruna Horizon*, 5(1), 17–25. <https://doi.org/10.52310/jbhorizon.v5i1.73>
- Subarkah, W. P., Santoso, A., & Widhianingrum, W. (2023). A Study of Player Behavior And Social Influences to Purchase Intention Mobile Legends: Bang Bang In-Game Item. *Journal of Entrepreneurship & Business*, 4(3), 138–158. <https://doi.org/10.24123/jeb.v4i3.5639>
- We are Social. (2023). The Changing World of Digital in 2023. In *We are Social*. <https://wearesocial.com/id/blog/2023/01/the-changing-world-of-digital-in-2023-2/>
- We are Social. (2024). *Digital 2024 Report*.
- Wijman T, Chen F, Buijsman M, Wagner M, Elliott R, Reis T, Gu T, Kuzuhara T, Simon L I, Koh R, Georgiou S, & Zhou D. (2023). *Global Games Market Report August 2023. August*.