
**USER SEGMENTATION FOR DIGITAL TECHNOLOGY ADOPTION
ASSESSMENT USING RFM AND K-MEANS CLUSTERING : EVIDENCE
FROM PESONNAGO INTERNAL E-COMMERCE**

**Salma Azzahrah¹; Fresha Kharisma²; Ika Diah Candra Arifah³;
Hujatullah Fazlurrahman⁴**

Universitas Negeri Surabaya, Jawa Timur^{1,2,3,4}

Email : salma.23351@mhs.unesa.ac.id¹; freshakharisma@unesa.ac.id²;

Ikaarifah@unesa.ac.id³ Hujatullahfazlurrahman@unesa.ac.id⁴

ABSTRAK

Penelitian ini bertujuan mengidentifikasi tingkat adopsi teknologi digital dan menganalisis perilaku pengguna pada platform e-commerce internal PesonnaGo melalui pemanfaatan transaction log data. Penelitian menggunakan pendekatan kuantitatif eksploratif dengan metode *Recency-Frequency-Monetary* (RFM) Analysis yang diperluas melalui variabel Point Usage serta algoritma K-Means Clustering. Data penelitian diperoleh menggunakan teknik purposive sampling terhadap 8.888 transaksi berhasil yang kemudian diagregasi menjadi 5.007 pengguna unik selama periode November 2025 hingga Februari 2026. Pengolahan data dilakukan menggunakan Python (*scikit-learn*) pada lingkungan Google Colaboratory. Penentuan jumlah kluster dilakukan melalui *Elbow Method* dan *Silhouette Analysis*, sedangkan pengujian stabilitas model menggunakan *Adjusted Rand Index* (ARI). Hasil penelitian menunjukkan terbentuknya tiga kelompok pengguna, yaitu *High Adoption*, *Moderate Adoption*, dan *Low Adoption*. Kelompok *High Adoption* memiliki tingkat aktivitas tertinggi yang ditunjukkan oleh nilai *recency* terendah, *frequency* tertinggi, serta nilai *monetary* dan *point usage* terbesar dibandingkan kelompok lainnya. Selain itu, analisis korelasi Pearson menunjukkan hubungan positif yang sangat kuat antara nilai transaksi dan penggunaan poin ($r = 0,947$). Temuan penelitian mengindikasikan bahwa pendekatan *behavioral analytics* berbasis *transaction log data* mampu mengidentifikasi tingkat adopsi teknologi secara objektif serta memberikan dasar bagi pengembangan strategi personalisasi layanan dan optimalisasi program loyalitas pengguna.

Kata Kunci : *Digital Technology Adoption; User Behavior Analytics; RFM Analysis; K-Means Clustering; Transaction Log Data*

ABSTRACT

This study aims to identify the level of adoption of digital technology and analyze user behavior on PesonnaGo's internal e-commerce platform through the use of transaction log data. The research uses an exploratory quantitative approach with the Recency-Frequency-Monetary (RFM) Analysis method which is extended through the Point Usage variable and the K-Means Clustering algorithm. The research data was obtained using purposive sampling techniques on 8,888 successful transactions which were then aggregated into 5,007 unique users during the period of November 2025 to February 2026. Data processing is carried out using Python (scikit-learn) in the Google Colaboratory environment. The number of clusters was determined through the Elbow Method and Silhouette Analysis, while the model stability test was carried out using the Adjusted Rand Index (ARI). The results of the study showed the formation of three groups of users, namely High Adoption, Moderate Adoption, and Low Adoption. The High Adoption group had the highest level of activity as indicated by the lowest recency value, the highest frequency, and the largest monetary value and point usage compared to the other groups. In addition, Pearson's correlation analysis showed a very strong positive relationship between transaction value and point usage ($r = 0.947$). The findings of the study indicate that the behavioral analytics approach based on transaction log data is able to identify the level of technology adoption objectively and provides a basis for the development of service personalization strategies and optimization of user loyalty programs.

Keywords : Digital Technology Adoption; User Behavior Analytics; RFM Analysis; K-Means Clustering; Transaction Log Data

PENDAHULUAN

Transformasi digital telah mengubah cara organisasi membangun interaksi dengan para penggunanya, baik dalam konteks *business-to-consumer* (B2C) maupun pada lingkungan internal perusahaan. Perubahan tersebut mendorong lahirnya berbagai platform digital yang tidak hanya memfasilitasi aktivitas transaksi, tetapi juga mengintegrasikan proses pembelajaran, sistem penghargaan, dan layanan digital ke dalam satu ekosistem yang saling terhubung. Fenomena ini menunjukkan semakin luasnya implementasi konsep gamifikasi sebagai bagian dari strategi transformasi digital organisasi. Secara global, pasar perangkat lunak employee gamification diproyeksikan meningkat dari sekitar USD 1,2 miliar pada tahun 2025 menjadi lebih dari USD 2,6 miliar pada tahun 2035 dengan *compound annual growth rate* (CAGR) sebesar 8,3% (Industry Research Biz, 2026). Pertumbuhan tersebut menegaskan bahwa mekanisme penghargaan berbasis poin, *badges*, dan sistem penukaran hadiah telah menjadi komponen penting dalam pengembangan infrastruktur teknologi sumber daya manusia pada organisasi modern.

Implementasi konsep tersebut dapat dijumpai pada PesonnaGo, yaitu platform *internal e-commerce* yang dikembangkan oleh PT Pesonna Indonesia Jaya untuk mendukung ekosistem digital PT Pegadaian. Berbeda dengan marketplace komersial, platform ini dirancang sebagai media bagi karyawan untuk menukarkan poin yang diperoleh melalui penyelesaian program pembelajaran, pelatihan, maupun aktivitas pengembangan kompetensi lainnya. Model tersebut sejalan dengan penerapan *Incentives App* yang dimanfaatkan berbagai organisasi sebagai instrumen gamifikasi dalam mempercepat adopsi teknologi sekaligus mendukung proses manajemen perubahan (Unboxed Training & Technology, 2023). Dalam konteks ini, keberhasilan implementasi platform tidak hanya ditentukan oleh kelengkapan fitur yang tersedia, tetapi juga oleh tingkat partisipasi dan keberlanjutan penggunaan oleh karyawan sebagai pengguna utama (Wibowo & Aripin, 2025).

Meskipun demikian, data operasional PesonnaGo menunjukkan bahwa pola pemanfaatan platform masih bervariasi di antara pengguna. Selama periode November 2025 hingga Februari 2026 tercatat 8.888 transaksi berhasil, namun distribusi nilai *recency*, *frequency*, dan *monetary* memperlihatkan perbedaan perilaku transaksi yang cukup signifikan. Kondisi tersebut mengindikasikan bahwa tingkat keterlibatan pengguna terhadap platform belum merata sehingga diperlukan pendekatan yang mampu mengidentifikasi karakteristik setiap kelompok pengguna berdasarkan aktivitas transaksi aktual. Pendekatan semacam ini menjadi semakin penting karena sebagian besar penelitian mengenai adopsi teknologi masih bergantung pada

data persepsi yang diperoleh melalui survei menggunakan kerangka *Technology Acceptance Model* (TAM) maupun *Unified Theory of Acceptance and Use of Technology* (UTAUT). Walaupun kedua model tersebut telah digunakan secara luas, hasil pengukurannya masih berpotensi dipengaruhi oleh subjektivitas responden. Selain itu, penelitian longitudinal menunjukkan bahwa UTAUT mampu menjelaskan sekitar 70% variasi *behavioral intention*, tetapi hanya sekitar 50% variasi *actual use behavior* (Venkatesh et al., 2003). Temuan tersebut menunjukkan adanya kesenjangan antara niat menggunakan teknologi dengan perilaku penggunaan yang benar-benar terjadi.

Berdasarkan kondisi tersebut, penelitian ini mengusulkan pendekatan yang memanfaatkan transaction log data sebagai sumber utama dalam mengukur *use behavior* secara objektif. Analisis dilakukan dengan mengkombinasikan metode *Recency-Frequency-Monetary (RFM) Analysis* dan algoritma *K-Means Clustering* untuk mengidentifikasi pola perilaku pengguna. Secara konseptual, dimensi *recency* merepresentasikan keberlanjutan penggunaan (*use continuance*), *frequency* menggambarkan intensitas penggunaan aktual, sedangkan *monetary* pada penelitian ini direpresentasikan oleh jumlah poin yang ditukarkan sebagai indikator kedalaman keterlibatan (*depth of engagement*) pengguna terhadap fitur utama platform. Pemetaan tersebut didukung oleh penelitian Cao et al. (2021) yang mengintegrasikan kerangka RFM dalam kajian *post-adoption information system usage* untuk memprediksi penghentian penggunaan sistem. Berbeda dengan penerapan RFM yang umumnya digunakan sebagai alat segmentasi pelanggan pada bidang pemasaran, penelitian tersebut menempatkan RFM sebagai representasi perilaku penggunaan teknologi setelah implementasi sistem.

Meskipun efektivitas kombinasi *RFM dan K-Means Clustering* telah banyak dibuktikan pada sektor ritel dan marketplace komersial (Robo, 2024; Sintaningrum & Wardhana, 2025; Wong et al., 2024), penelusuran terhadap literatur terdahulu memperlihatkan tiga kesenjangan yang melandasi urgensi penelitian ini. Pertama, secara metodologis, pengukuran adopsi teknologi selama ini masih didominasi pendekatan berbasis persepsi seperti TAM dan UTAUT, sementara pemanfaatan data perilaku aktual (transaction log data) sebagai indikator objektif *use behavior* masih jarang diterapkan, meskipun kesenjangan eksplanatif UTAUT antara *behavioral intention* dan *actual use behavior* telah lama diketahui (Venkatesh et al., 2003). Kedua, secara kontekstual, penerapan metodologi *RFM-K-Means* yang telah mapan pada konteks *business-to-consumer* (B2C) belum diuji penerapannya pada internal *corporate e-commerce* berbasis sistem reward pembelajaran karyawan, di mana karakteristik "nilai moneter" merepresentasikan poin hasil pembelajaran, bukan pengeluaran finansial konsumen sebagaimana lazim pada studi RFM terdahulu. Ketiga, secara praktis, literatur gamifikasi termasuk penerapan mekanisme reward berbasis poin seperti *Incentives App* (Unboxed Training & Technology, 2023), sebagian besar

masih bersifat deskriptif-konseptual atau bersumber dari laporan industri (Industry Research Biz, 2026), sehingga penelitian yang mengukur secara kuantitatif kekuatan hubungan antara intensitas penggunaan poin dan perilaku transaksi riil melalui pendekatan analitik berbasis kluster masih sangat terbatas. Ketiga kesenjangan inilah yang menjadi celah penelitian (research gap) yang diisi oleh studi ini, sekaligus menjadi dasar argumentasi bahwa penelitian ini layak dan relevan untuk disajikan.

Berdasarkan ketiga kesenjangan tersebut, penelitian ini menawarkan kebaruan (novelty) yang membedakannya secara signifikan dari penelitian-penelitian sebelumnya. Secara metodologis, penelitian ini mengusulkan pergeseran paradigma pengukuran adopsi teknologi digital, dari pendekatan konvensional berbasis persepsi (survei TAM/UTAUT) menuju pendekatan berbasis perilaku aktual (*behavioral analytics*) yang dioperasionalisasikan melalui transaction log data, sehingga konstruk adopsi teknologi dapat diukur secara objektif tanpa mediasi laporan diri pengguna yang rentan bias subjektivitas. Secara kontekstual, penelitian ini merupakan salah satu studi pertama yang menerapkan metodologi *RFM-K-Means* pada konteks internal *e-commerce* korporasi yang terintegrasi dengan sistem reward pembelajaran—sebuah konteks yang secara fundamental berbeda dari studi *RFM-K-Means* terdahulu yang umumnya berfokus pada *e-commerce* komersial *B2C* (Robo, 2024; Wong et al., 2024). Secara teoretis, penelitian ini memperluas jembatan konseptual antara literatur *business analytics* (*RFM*) dan literatur adopsi teknologi (UTAUT), yang sebelumnya hanya disinggung secara terbatas pada konteks sistem trading finansial (Cao et al., 2021), ke ranah platform digital internal korporasi yang belum banyak dieksplorasi. Kebaruan-kebaruan inilah yang menjadikan penelitian ini memberikan nilai tambah, baik bagi pengembangan literatur akademik maupun bagi praktik pengelolaan platform digital berbasis insentif di lingkungan organisasi.

Hasil segmentasi yang dihasilkan dalam penelitian ini, yaitu pengelompokan pengguna ke dalam kategori *High Adoption*, *Moderate Adoption*, dan *Low Adoption*, serta temuan mengenai hubungan antara penggunaan poin dan nilai transaksi, memberikan sejumlah implikasi praktis bagi pengelola platform. Pengguna yang termasuk dalam segmen *High Adoption* dapat menjadi fokus utama dalam strategi retensi melalui pemberian program loyalitas, penghargaan khusus, maupun manfaat eksklusif karena kelompok ini menunjukkan tingkat keterlibatan tertinggi terhadap platform. Di sisi lain, pengguna pada segmen *Moderate Adoption* memerlukan strategi peningkatan keterlibatan yang lebih terarah agar aktivitas penggunaan platform dapat meningkat dan berpotensi beralih ke kelompok dengan tingkat adopsi yang lebih tinggi. Sementara itu, segmen *Low Adoption* membutuhkan pendekatan yang lebih intensif, seperti edukasi mengenai manfaat dan fitur platform, serta penyempurnaan mekanisme insentif berbasis poin untuk mendorong peningkatan partisipasi pengguna. Dengan demikian, hasil

segmentasi ini dapat dimanfaatkan sebagai dasar dalam penyusunan strategi pengelolaan pengguna yang lebih tepat sasaran guna meningkatkan keterlibatan dan keberlanjutan penggunaan platform.

Oleh karena itu, pendekatan berbasis data yang diusulkan dalam penelitian ini tidak sekadar berfungsi sebagai instrumen diagnostik untuk memetakan tingkat adopsi teknologi, melainkan juga berpotensi menjadi landasan pengambilan keputusan manajerial (data-driven decision making) yang lebih tepercaya bagi pengelola PT Pesonna Indonesia Jaya. Jika kerangka segmentasi ini terbukti valid dan konsisten, pendekatan serupa berpeluang direplikasi secara berkala untuk memantau perubahan pola adopsi dari waktu ke waktu, sehingga strategi pengelolaan platform dapat terus disesuaikan dengan dinamika perilaku penggunanya, alih-alih hanya bertumpu pada evaluasi satu waktu yang bersifat statis.

TINJAUAN PUSTAKA DAN PENGEMBANGAN HIPOTESIS

Penelitian ini menggunakan pendekatan kuantitatif eksploratif-deskriptif dengan algoritma *unsupervised learning* berupa *K-Means Clustering*. Berbeda dengan penelitian konfirmatori yang menguji hubungan kausal melalui hipotesis statistik, pendekatan ini membentuk segmentasi pengguna berdasarkan pola yang muncul secara alami dalam data. Oleh karena itu, penelitian menggunakan proposisi (P1–P4) sebagai pedoman analisis yang dikonfirmasi melalui pendekatan *pattern matching* sesuai praktik penelitian *data mining* dan *behavioral analytics* (Sintaningrum & Wardhana, 2025).

Unified Theory of Acceptance and Use of Technology (UTAUT)

Unified Theory of Acceptance and Use of Technology (UTAUT) menjelaskan bahwa penggunaan teknologi dipengaruhi oleh *performance expectancy*, *effort expectancy*, *social influence*, dan *facilitating conditions* (Venkatesh et al., 2003). Penelitian ini berfokus pada konstruk *use behavior* karena merepresentasikan perilaku penggunaan teknologi yang benar-benar terjadi. Meskipun UTAUT mampu menjelaskan sebagian besar variasi *behavioral intention*, kemampuannya dalam menjelaskan *actual use behavior* masih lebih terbatas (Venkatesh et al., 2003). Selain itu, penggunaan data survei juga rentan terhadap bias persepsi. Oleh sebab itu, penelitian ini mengoperasionalkan *use behavior* melalui *transaction log data* agar pengukuran adopsi teknologi menjadi lebih objektif.

Recency-Frequency-Monetary (RFM) Analysis

Recency-Frequency-Monetary (RFM) Analysis merupakan metode yang mengukur perilaku pengguna berdasarkan tiga dimensi utama, yaitu *recency*, *frequency*, dan *monetary*. Pendekatan ini banyak digunakan untuk segmentasi pelanggan karena mampu memanfaatkan data transaksi yang tersedia tanpa memerlukan survei tambahan (Wong et al., 2024; Robo, 2024). Namun, RFM konvensional memiliki keterbatasan dalam menangkap seluruh variasi

perilaku pengguna. Oleh karena itu, penelitian ini menggunakan *extended* RFM dengan menambahkan variabel *Point Usage* sebagaimana pengembangan yang disarankan dalam penelitian sebelumnya (Cao et al., 2021). Selain sebagai metode segmentasi, RFM juga digunakan sebagai representasi *use behavior* dalam konteks adopsi teknologi.

K-Means Clustering

K-Means Clustering merupakan algoritma unsupervised learning yang mengelompokkan data berdasarkan tingkat kemiripan karakteristik menggunakan jarak *Euclidean* (IBM, 2025; MacQueen, 1967). Algoritma ini banyak digunakan karena sederhana dan efisien untuk mengolah data berukuran besar. Meskipun demikian, hasil pengelompokan dipengaruhi oleh pemilihan centroid awal dan jumlah kluster yang harus ditentukan sebelumnya, sehingga diperlukan evaluasi menggunakan *Elbow Method* dan *Silhouette Analysis* (Rousseeuw, 1987). Dalam penelitian ini, *K-Means* digunakan untuk mengidentifikasi kelompok pengguna PesonnaGo berdasarkan kemiripan skor RFM dan *Point Usage*.

Sintesis Penelitian Terdahulu dan Kesenjangan Penelitian

Literatur terdahulu menunjukkan bahwa penelitian yang berkaitan dengan topik ini dapat dikelompokkan ke dalam tiga tema utama yang saling berhubungan, tetapi belum terintegrasi secara komprehensif. Tema pertama membahas penerapan *Recency-Frequency-Monetary* (RFM) Analysis yang dikombinasikan dengan *K-Means Clustering* untuk segmentasi pelanggan pada lingkungan *e-commerce*. Wong et al. (2024) memanfaatkan kombinasi RFM, *K-Means*, dan *Hierarchical Clustering* untuk mengelompokkan pelanggan berdasarkan data transaksi pada ekosistem big data. Robo (2024) menunjukkan bahwa pendekatan tersebut mampu menghasilkan sepuluh segmen pelanggan, seperti *Champions* dan *Hibernating*, yang mendukung penyusunan strategi pemasaran secara lebih tepat sasaran. Sementara itu, Sintaningrum dan Wardhana (2025) mengembangkan *extended* RFM dengan membandingkan beberapa algoritma *clustering* pada dataset transaksi berskala besar dan memperoleh tiga kluster optimal dengan *Silhouette Score* sebesar 0,65. Walaupun berbagai penelitian tersebut membuktikan efektivitas kombinasi RFM dan *K-Means*, penerapannya masih didominasi oleh konteks *business-to-consumer* (B2C) sehingga implementasinya pada platform *internal corporate e-commerce* berbasis sistem penghargaan masih belum banyak dikaji.

Tema kedua berfokus pada penelitian adopsi teknologi yang menggunakan kerangka *Unified Theory of Acceptance and Use of Technology* (UTAUT) sebagai dasar analisis (Venkatesh et al., 2003). Meskipun model ini telah menjadi salah satu pendekatan yang paling luas digunakan, sejumlah penelitian menyoroti keterbatasannya karena bergantung pada data persepsi yang dikumpulkan melalui survei. Konsekuensinya, hasil pengukuran rentan terhadap bias subjektivitas responden dan belum sepenuhnya mampu menggambarkan perilaku

penggunaan teknologi yang benar-benar terjadi (Wibowo & Aripin, 2025). Adapun tema ketiga membahas pemanfaatan gamifikasi melalui sistem poin dan penghargaan sebagai mekanisme untuk meningkatkan keterlibatan pengguna sekaligus mempercepat adopsi teknologi, baik pada lingkungan organisasi maupun pasar konsumen (Unboxed Training & Technology, 2023). Namun demikian, sebagian besar bukti yang tersedia masih berasal dari kajian konseptual maupun laporan industri (Industry Research Biz, 2026; Market Growth Reports, 2026), sehingga penelitian empiris yang menghubungkan penggunaan poin dengan perilaku transaksi aktual berbasis transaction log data masih relatif terbatas.

Upaya menghubungkan ketiga tema tersebut mulai terlihat pada penelitian Cao et al. (2021) yang mengintegrasikan kerangka RFM ke dalam kajian *post-adoption information system usage* untuk memprediksi penghentian penggunaan sistem *mobile trading*. Penelitian tersebut menunjukkan bahwa metrik RFM dapat digunakan sebagai representasi perilaku penggunaan teknologi setelah tahap adopsi. Meskipun demikian, objek penelitiannya masih terbatas pada sistem perdagangan finansial yang digunakan pelanggan eksternal, sehingga belum merepresentasikan karakteristik platform digital internal organisasi.

Berdasarkan sintesis tersebut, penelitian ini mengidentifikasi tiga kesenjangan utama. Pertama, dari sisi metodologis, pengukuran adopsi teknologi masih didominasi oleh pendekatan berbasis persepsi, sedangkan pemanfaatan transaction log data sebagai indikator objektif use behavior belum banyak diterapkan. Kedua, dari sisi konteks penelitian, implementasi metode RFM–K-Means pada *internal corporate e-commerce* dengan mekanisme penghargaan berbasis poin hasil pembelajaran masih sangat terbatas, terutama karena dimensi *monetary* dalam lingkungan tersebut merepresentasikan nilai poin yang ditukarkan, bukan pengeluaran finansial pengguna. Ketiga, dari sisi praktis, masih sedikit penelitian yang menganalisis hubungan antara penggunaan poin dan nilai transaksi menggunakan pendekatan *behavioral analytics* berbasis data aktual. Oleh sebab itu, penelitian ini berupaya mengisi kesenjangan tersebut dengan mengkombinasikan metode RFM–K-Means untuk mengukur tingkat adopsi teknologi pada platform internal *corporate e-commerce* yang mengintegrasikan sistem penghargaan berbasis poin pembelajaran.

Kerangka konseptual penelitian disusun menggunakan *process-based framework* yang menggambarkan alur analisis secara sistematis sebagaimana ditunjukkan pada gambar 1. Tahapan pertama diawali dengan pemanfaatan *transaction log data* sebagai sumber data utama. Data tersebut kemudian diolah melalui perhitungan variabel *Recency*, *Frequency*, *Monetary*, dan *Point Usage* pada setiap pengguna. Selanjutnya, seluruh variabel distandarisasi sebelum diproses menggunakan algoritma *K-Means Clustering*. Penentuan jumlah kluster terbaik dilakukan melalui kombinasi *Elbow Method* dan *Silhouette Analysis*. Setelah proses clustering

selesai, karakteristik masing-masing kelompok dianalisis berdasarkan nilai rata-rata *recency*, *frequency*, *monetary*, dan *point usage*, kemudian diinterpretasikan menjadi tiga kategori tingkat adopsi teknologi, yaitu *High Adoption*, *Moderate Adoption*, dan *Low Adoption*. Hasil segmentasi tersebut selanjutnya menjadi dasar dalam penyusunan implikasi manajerial.

Secara konseptual, penelitian ini mengintegrasikan tiga landasan teori utama. Konstruksi *use behavior* dalam UTAUT menjadi dasar untuk menjelaskan perilaku penggunaan teknologi, sedangkan RFM digunakan sebagai bentuk operasionalisasi perilaku tersebut melalui data transaksi aktual. Sementara itu, *K-Means Clustering* berperan sebagai metode analisis untuk mengidentifikasi kelompok pengguna yang memiliki karakteristik serupa. Integrasi ketiga konsep tersebut menghasilkan kerangka analisis yang memungkinkan pengukuran adopsi teknologi dilakukan secara lebih objektif melalui pendekatan *behavioral analytics* berbasis *transaction log data*.

Sebagaimana telah dijelaskan pada catatan metodologis di bagian sebelumnya, penelitian ini tidak menggunakan hipotesis statistik formal sebagai dasar analisis. Sebagai gantinya, disusun serangkaian proposisi penelitian yang berfungsi sebagai pedoman dalam menginterpretasikan hasil analisis. Validasi terhadap proposisi tersebut dilakukan melalui pendekatan *pattern matching*, yaitu dengan membandingkan kesesuaian antara pola empiris yang dihasilkan dari proses clustering dengan pernyataan konseptual yang telah dirumuskan sebelumnya.

Pengembangan Proposisi Penelitian

P1. Data transaksi pengguna PesonnaGo diperkirakan menunjukkan keragaman pada dimensi *recency*, *frequency*, dan *monetary*, sehingga memungkinkan terbentuknya kelompok pengguna yang memiliki karakteristik berbeda melalui penerapan algoritma *K-Means Clustering*. Proposisi ini didasarkan pada berbagai penelitian terdahulu yang menunjukkan bahwa variasi perilaku transaksi pada data riil umumnya mampu membentuk struktur klaster yang bermakna dalam analisis berbasis RFM (Wong et al., 2024; Robo, 2024).

P2. Proses penentuan jumlah klaster menggunakan *Elbow Method* dan *Silhouette Analysis* diperkirakan menghasilkan struktur segmentasi yang tidak hanya memiliki kualitas statistik yang baik, tetapi juga mudah diinterpretasikan untuk kebutuhan pengambilan keputusan manajerial. Berdasarkan temuan empiris sebelumnya, jumlah klaster yang relatif terbatas, yaitu sekitar tiga hingga empat kelompok, dinilai mampu memberikan keseimbangan antara akurasi hasil segmentasi dan kemudahan interpretasi. Proposisi ini mengacu pada penelitian Sintaningrum dan Wardhana (2025), yang memperoleh tiga klaster optimal dalam studi segmentasi berbasis RFM pada dataset berskala besar.

P3. Kelompok pengguna yang memiliki karakteristik *recency* lebih rendah, *frequency* lebih tinggi, serta nilai *monetary* dan *point usage* yang lebih besar secara keseluruhan diperkirakan merepresentasikan tingkat adopsi teknologi digital yang lebih tinggi dibandingkan kelompok lainnya. Dasar konseptual proposisi ini mengacu pada konstruk *use behavior* dalam kerangka UTAUT (Venkatesh et al., 2003), yang dalam penelitian ini dioperasionalisasikan melalui dimensi RFM. Penentuan kategori tingkat adopsi dilakukan berdasarkan kombinasi seluruh dimensi secara simultan, bukan melalui peringkat pada masing-masing indikator secara terpisah, karena algoritma *K-Means Clustering* membentuk klaster berdasarkan kedekatan jarak Euclidean terhadap centroid dengan mempertimbangkan seluruh variabel input secara bersamaan.

P4. Nilai transaksi (*monetary*) diperkirakan memiliki hubungan positif yang kuat dengan penggunaan poin (*point usage*). Hubungan tersebut mengindikasikan bahwa mekanisme insentif berbasis poin berpotensi meningkatkan aktivitas transaksi sekaligus mendukung tingkat adopsi teknologi digital pada platform internal e-commerce PesonnaGo. Proposisi ini didukung oleh berbagai kajian mengenai gamifikasi yang menunjukkan bahwa sistem poin dan penghargaan berperan sebagai pendorong utama dalam meningkatkan keterlibatan pengguna terhadap suatu sistem (Unboxed Training & Technology, 2023).

Keempat proposisi tersebut tidak dievaluasi melalui pengujian hipotesis inferensial. Sebaliknya, proses konfirmasi dilakukan dengan membandingkan kesesuaian pola empiris yang diperoleh dari hasil analisis terhadap pola yang diperkirakan dalam setiap proposisi. Evaluasi tersebut mempertimbangkan profil rata-rata masing-masing klaster pada seluruh dimensi RFM dan *Point Usage* secara bersamaan, serta koefisien korelasi antara *monetary* dan *point usage*. Pendekatan ini sesuai dengan karakteristik penelitian eksploratif berbasis data mining, yang menitikberatkan validitas temuan pada konsistensi pola empiris dan kekuatan interpretasi teoritis dibandingkan pada pengujian hipotesis statistik formal.

METODE PENELITIAN

Metode adalah suatu cara kerja yang dapat digunakan untuk memperoleh sesuatu. Sedangkan metode penelitian dapat diartikan sebagai tata cara kerja di dalam proses penelitian, baik dalam pencarian data ataupun pengungkapan fenomena yang ada (Zulkarnaen, W., et al., 2020). Penelitian ini menggunakan pendekatan kuantitatif dengan desain *eksploratif-deskriptif* untuk menganalisis tingkat adopsi teknologi digital berdasarkan data transaksi aktual. Karakter eksploratif diwujudkan melalui algoritma *unsupervised learning*, yaitu *K-Means Clustering*, yang menemukan pola dan struktur data tanpa label kategori yang ditentukan sebelumnya (MacQueen, 1967), sementara karakter deskriptif tercermin dari upaya mendeskripsikan karakteristik setiap segmen berdasarkan nilai *Recency*, *Frequency*, *Monetary*, dan *Point Usage*.

Berbeda dengan penelitian konfirmatori, kategori tingkat adopsi (*High, Moderate, Low Adoption*) tidak ditetapkan sejak awal, melainkan terbentuk secara alami dari proses *clustering* berdasarkan kemiripan karakteristik data, sehingga penelitian ini tidak berorientasi pada pengujian hubungan kausal antarvariabel, melainkan pada identifikasi pola perilaku yang muncul dari data empiris.

Subjek, Objek, dan Sampel Penelitian

Objek penelitian adalah PesonnaGo, sebuah platform *internal e-commerce* yang dikembangkan oleh PT Pesonna Indonesia Jaya untuk mendukung ekosistem digital di lingkungan PT Pegadaian. Platform ini digunakan oleh karyawan untuk menukarkan poin yang diperoleh melalui penyelesaian program pembelajaran, pelatihan, maupun aktivitas pengembangan kompetensi lainnya. Populasi penelitian meliputi seluruh karyawan PT Pegadaian yang terdaftar sebagai pengguna PesonnaGo. Sampel ditentukan menggunakan teknik *purposive sampling*, yaitu hanya pengguna yang melakukan sedikitnya satu transaksi berhasil selama periode November 2025 hingga Februari 2026. Teknik ini dipilih karena perhitungan *Recency-Frequency-Monetary* (RFM) mensyaratkan adanya riwayat transaksi sebagai dasar pembentukan variabel *recency*, *frequency*, dan *monetary*. Dengan demikian, pengguna yang belum pernah melakukan transaksi tidak dapat diikutsertakan dalam proses analisis.

Unit analisis penelitian adalah pengguna, bukan transaksi. Sebanyak 8.888 transaksi berhasil terlebih dahulu diagregasi berdasarkan National Identity Karyawan (NIK) sebagai identitas unik pengguna. Proses tersebut menghasilkan satu profil RFM untuk setiap pengguna yang kemudian digunakan sebagai masukan pada algoritma *K-Means Clustering*. Hasil agregasi menghasilkan 5.007 pengguna unik dengan rata-rata 1,78 transaksi selama periode observasi. Nilai tersebut konsisten dengan hasil segmentasi yang menunjukkan rentang *frequency* antara 1,19 hingga 2,34 transaksi sehingga mendukung validitas proses agregasi data. Penggunaan teknik *purposive sampling* menjadi salah satu keterbatasan penelitian ini karena hasil yang diperoleh hanya merepresentasikan kelompok pengguna aktif PesonnaGo. Oleh sebab itu, temuan penelitian belum dapat digeneralisasikan kepada seluruh karyawan PT Pegadaian, terutama pengguna yang belum pernah memanfaatkan platform, yang secara konseptual dapat dikategorikan sebagai non-adopter.

Penelitian ini menggunakan pendekatan *unsupervised learning*, sehingga konsep variabel berbeda dengan penelitian konfirmatori. Analisis tidak membedakan variabel independen maupun dependen, melainkan menggunakan empat variabel masukan (*input features*), yaitu *Recency*, *Frequency*, *Monetary*, dan *Point Usage* sebagai dasar pembentukan klaster. Adapun variabel keluaran (*outcome label*) berupa Segmen Adopsi Teknologi diperoleh

secara otomatis melalui proses clustering. Definisi operasional setiap variabel disajikan pada Tabel 1.

Keempat variabel masukan dipetakan ke dalam konstruk use behavior pada kerangka UTAUT (Venkatesh et al., 2003). Dimensi *recency* merepresentasikan keberlanjutan penggunaan (*use continuance*), *frequency* mencerminkan intensitas penggunaan aktual, sedangkan *monetary* dan *point usage* menggambarkan tingkat keterlibatan (*depth of engagement*) pengguna terhadap fitur utama platform. Berbeda dengan model RFM konvensional, penelitian ini menambahkan variabel Point Usage untuk merepresentasikan karakteristik sistem penghargaan berbasis poin yang diterapkan pada PesonnaGo. Penambahan variabel tersebut mengacu pada pengembangan konsep *extended* RFM yang dikemukakan oleh Cao et al. (2021). Sementara itu, Segmen Adopsi Teknologi tidak ditentukan sebelum analisis dilakukan. Kategori tersebut dihasilkan dari proses *K-Means Clustering* berdasarkan pola yang terbentuk dalam data transaksi, kemudian diinterpretasikan secara *post-hoc* menggunakan karakteristik rata-rata *Recency*, *Frequency*, *Monetary*, dan *Point Usage* pada masing-masing klaster.

Penelitian ini memanfaatkan data sekunder yang berasal dari lingkungan internal organisasi, yaitu transaction log data yang secara otomatis direkam oleh sistem PesonnaGo. Proses pengumpulan data dilakukan menggunakan teknik dokumentasi (*documentary technique*) melalui ekstraksi data transaksi dari basis data internal untuk periode November 2025 sampai Februari 2026. Data yang diperoleh meliputi identitas pengguna (User ID/NIK), waktu terjadinya transaksi (*timestamp*), jumlah atau nilai poin yang ditransaksikan, serta status keberhasilan setiap transaksi. Seluruh informasi yang dianalisis berasal dari sistem operasional platform sehingga penelitian ini tidak melibatkan pengumpulan data primer, seperti penyebaran kuesioner maupun pelaksanaan wawancara. Pendekatan tersebut dipilih karena data perilaku aktual (*behavioral data*) dinilai mampu merepresentasikan tingkat adopsi teknologi secara lebih objektif dibandingkan data persepsi yang diperoleh melalui survei (Venkatesh et al., 2003; Wibowo & Aripin, 2025).

Karena penelitian menggunakan data berbentuk log transaksi digital, tidak diperlukan instrumen pengukuran psikometrik. Seluruh proses pengolahan dan analisis data dilakukan menggunakan bahasa pemrograman Python pada lingkungan komputasi *Google Collaboratory* (Bisong, 2019). Beberapa pustaka (*library*) dimanfaatkan sesuai fungsinya, yaitu *pandas* dan *numpy* untuk pengelolaan serta manipulasi data, *matplotlib* dan *seaborn* untuk penyajian visualisasi, sedangkan *scikit-learn* digunakan dalam proses standardisasi data melalui *StandardScaler*, penerapan algoritma *K-Means Clustering*, dan evaluasi kualitas hasil pengelompokan menggunakan *silhouette score* (Pedregosa et al., 2011).

Pengolahan data dilaksanakan secara bertahap melalui tujuh langkah utama. Tahap pertama diawali dengan proses ekstraksi dan pembersihan data, yang meliputi penghapusan data duplikat, penanganan nilai yang hilang (*missing values*), serta penyaringan transaksi dengan status berhasil. Tahap kedua adalah melakukan agregasi data pada tingkat pengguna menggunakan User ID/NIK sebagai identitas unik melalui fungsi `groupby()`. Selanjutnya, pada tahap ketiga dihitung variabel *Recency*, *Frequency*, *Monetary*, dan *Point Usage* sesuai dengan rumusan yang disajikan pada Tabel 1. Tahap keempat berupa standardisasi seluruh variabel menggunakan *StandardScaler* (*Z-score normalization*). Proses ini diperlukan karena setiap variabel memiliki satuan dan rentang nilai yang berbeda, sehingga standardisasi mencegah variabel dengan skala yang lebih besar memberikan pengaruh yang berlebihan terhadap perhitungan jarak Euclidean. Tahap kelima adalah menjalankan algoritma K-Means dengan metode inisialisasi `k-means++`, sementara jumlah kluster (*k*) diuji pada rentang 2 hingga 10. Setelah itu, tahap keenam dilakukan untuk menentukan jumlah kluster terbaik melalui kombinasi *Elbow Method* dan *Silhouette Analysis*. Tahap terakhir adalah menginterpretasikan hasil clustering sekaligus memberikan label pada kluster akhir berdasarkan karakteristik rata-rata (*centroid*) dari keempat variabel yang dianalisis secara multivariat dan simultan.

Analisis data dilakukan melalui beberapa tahapan yang saling terintegrasi untuk mengidentifikasi pola perilaku pengguna serta mengukur tingkat adopsi teknologi pada platform PesonnaGo. Tahap pertama menggunakan *Recency-Frequency-Monetary* (RFM) Analysis untuk mentransformasikan data transaksi menjadi variabel numerik pada tingkat pengguna. Berbeda dengan model RFM konvensional, penelitian ini menambahkan variabel *Point Usage* sebagai dimensi keempat guna merepresentasikan intensitas pemanfaatan mekanisme penghargaan berbasis poin.

Proses segmentasi pengguna dilakukan menggunakan algoritma *K-Means Clustering* sebagai metode analisis utama. Algoritma ini mengelompokkan pengguna berdasarkan kedekatan jarak Euclidean terhadap centroid, kemudian memperbarui posisi centroid secara iteratif hingga diperoleh hasil yang konvergen (MacQueen, 1967; IBM, 2025). Sebelum proses clustering dilakukan, jumlah kluster optimal ditentukan menggunakan *Elbow Method* dengan mengevaluasi perubahan nilai *Within-Cluster Sum of Squares* (WCSS) pada beberapa alternatif nilai *k*. Titik elbow dipilih ketika penurunan WCSS mulai melambat sehingga penambahan jumlah kluster tidak lagi memberikan peningkatan yang berarti.

Selanjutnya, kualitas hasil pengelompokan dievaluasi menggunakan *Silhouette Analysis*. Nilai *Silhouette Score* yang berada pada rentang -1 hingga 1 digunakan untuk mengukur tingkat kesesuaian setiap observasi terhadap kluster yang ditempatinya (Rousseeuw, 1987). Penentuan jumlah kluster akhir tidak hanya mempertimbangkan nilai *Silhouette Score* tertinggi, tetapi juga

memperhatikan keseimbangan antara kualitas segmentasi dan kemudahan interpretasi hasil untuk kebutuhan pengambilan keputusan manajerial (*parsimony*). Selain melakukan segmentasi, penelitian ini juga menerapkan analisis korelasi Pearson untuk mengidentifikasi arah dan kekuatan hubungan antara *variabel Monetary* dan *Point Usage*. Interpretasi koefisien korelasi mengacu pada konvensi umum, di mana nilai $|r| \geq 0,70$ menunjukkan hubungan yang sangat kuat.

Keandalan hasil clustering dievaluasi melalui tiga tahapan validasi. Validasi pertama dilakukan secara internal menggunakan *Elbow Method* dan *Silhouette Analysis* untuk menilai kualitas pembentukan klaster. Tahap berikutnya berupa validasi konseptual melalui pendekatan *pattern matching*, yaitu membandingkan karakteristik setiap klaster dengan proposisi penelitian yang telah dirumuskan. Selanjutnya, stabilitas model diuji dengan menjalankan algoritma *K-Means Clustering* sebanyak 20 kali menggunakan inisialisasi centroid yang berbeda pada setiap iterasi. Konsistensi hasil pengelompokan kemudian diukur menggunakan *Adjusted Rand Index* (ARI), mengingat algoritma K-Means sensitif terhadap pemilihan centroid awal (Kaufman & Rousseeuw, 1990).

Penelitian ini tidak menerapkan pengujian hipotesis statistik secara konfirmatori karena menggunakan pendekatan eksploratif berbasis unsupervised learning, sehingga tidak menetapkan variabel dependen sebelum proses analisis dilakukan. Sebagai penggantinya, penelitian mengembangkan empat proposisi yang diverifikasi melalui pendekatan *pattern matching*, yaitu dengan membandingkan pola empiris yang dihasilkan dari proses clustering dengan proposisi yang telah dirumuskan sebelumnya (Sintaningrum & Wardhana, 2025). Proposisi pertama (P1) menyatakan bahwa variasi pada dimensi recency, frequency, dan monetary memungkinkan terbentuknya beberapa kelompok pengguna yang berbeda. Proposisi kedua (P2) menyebutkan bahwa jumlah klaster yang ditentukan melalui *Elbow Method* dan *Silhouette Analysis* mampu menghasilkan segmentasi yang memiliki kualitas statistik yang baik sekaligus mudah diinterpretasikan. Proposisi ketiga (P3) mengemukakan bahwa pengguna dengan nilai recency rendah, frequency tinggi, serta nilai monetary dan point usage yang tinggi cenderung menunjukkan tingkat adopsi teknologi yang lebih tinggi. Sementara itu, proposisi keempat (P4) menyatakan adanya hubungan positif yang kuat antara Monetary dan Point Usage, yang mengindikasikan bahwa mekanisme penghargaan berbasis poin berkontribusi terhadap peningkatan aktivitas transaksi dan adopsi teknologi. Verifikasi terhadap keempat proposisi tersebut dilakukan pada bagian Hasil dan Pembahasan melalui analisis karakteristik setiap klaster serta interpretasi hasil korelasi Pearson.

HASIL PENELITIAN DAN DISKUSI

Analisis Deskriptif Data Penelitian

Penelitian ini menggunakan data transaksi pengguna pada platform e-commerce internal PesonnaGo selama periode November 2025 hingga Februari 2026. Setelah dilakukan proses agregasi pada tingkat pengguna, diperoleh 5.007 pengguna unik dengan total 8.888 transaksi berhasil. Berdasarkan hasil pengolahan data, rata-rata frekuensi transaksi yang dilakukan pengguna selama periode observasi adalah 1,78 transaksi per pengguna. Nilai tersebut menunjukkan bahwa sebagian besar pengguna hanya melakukan satu hingga dua transaksi selama empat bulan pengamatan.

Berdasarkan Gambar 2, aktivitas transaksi pengguna menunjukkan pola yang berfluktuasi sepanjang periode penelitian. Jumlah transaksi tertinggi terjadi pada November dan Desember 2025 dengan volume yang relatif sama, yaitu sekitar 3.700 transaksi pada masing-masing bulan. Selanjutnya, jumlah transaksi mengalami penurunan pada Januari 2026 sebelum kembali meningkat pada Februari 2026. Pola tersebut mengindikasikan bahwa intensitas penggunaan PesonnaGo dipengaruhi oleh aktivitas pengguna yang tidak berlangsung secara konstan selama periode penelitian. Kondisi ini diduga berkaitan dengan siklus program pembelajaran dan pelatihan karyawan yang menjadi sumber akumulasi poin pada platform.

Sebelum dilakukan proses segmentasi menggunakan algoritma *K-Means Clustering*, penelitian ini terlebih dahulu melakukan analisis statistik deskriptif terhadap empat variabel utama, yaitu *Recency*, *Frequency*, *Monetary*, dan *Point Usage*. Ringkasan hasil statistik deskriptif disajikan pada Tabel 2. Variabel *Monetary* dan *Point Usage* telah ditransformasi menggunakan fungsi logaritma natural ($\log 1p$) untuk mengurangi tingkat kemencengan distribusi data sehingga lebih sesuai digunakan dalam proses clustering.

Berdasarkan Tabel 2, variabel *Recency* memiliki nilai rata-rata sebesar 76,57 hari dengan standar deviasi 30,60 hari. Temuan ini menunjukkan adanya perbedaan tingkat aktivitas yang cukup besar antar pengguna, di mana sebagian pengguna masih melakukan transaksi hingga mendekati akhir periode pengamatan, sedangkan sebagian lainnya sudah tidak bertransaksi dalam jangka waktu yang relatif lama. Pada variabel *Frequency*, rata-rata frekuensi transaksi tercatat sebesar 1,78 transaksi dengan standar deviasi 0,97 dan rentang nilai antara 1 hingga 8 transaksi. Hasil tersebut mencerminkan karakteristik PesonnaGo sebagai platform internal organisasi yang digunakan secara lebih terbatas dibandingkan marketplace komersial. Di sisi lain, variabel *Monetary* memiliki nilai rata-rata sebesar 13,63 (SD = 0,61), sedangkan *Point Usage* memiliki rata-rata 13,55 (SD = 0,58). Kemiripan nilai rata-rata maupun standar deviasi pada kedua variabel tersebut mengindikasikan adanya kecenderungan pola yang searah

antara nilai transaksi dan penggunaan poin. Indikasi tersebut selanjutnya diperkuat melalui hasil analisis hubungan antar variabel yang dibahas pada subbagian berikutnya.

Penentuan Jumlah Kluster Optimal

Penentuan jumlah kluster dilakukan menggunakan kombinasi *Elbow Method* dan *Silhouette Analysis* sebagai dua pendekatan yang saling melengkapi dalam proses evaluasi hasil clustering. *Elbow Method* dimanfaatkan untuk mengidentifikasi jumlah kluster yang mampu menjelaskan keragaman data secara optimal melalui analisis perubahan nilai *Within-Cluster Sum of Squares* (WCSS), sedangkan *Silhouette Analysis* digunakan untuk menilai kualitas pemisahan antar kluster berdasarkan tingkat kesamaan objek dalam kelompok yang sama. Melalui kombinasi kedua metode tersebut, jumlah kluster yang dipilih diharapkan tidak hanya memiliki kualitas pengelompokan yang memadai secara statistik, tetapi juga menghasilkan segmentasi yang sederhana, mudah diinterpretasikan, dan dapat digunakan sebagai dasar penyusunan strategi pengelolaan pengguna secara lebih efektif.

Berdasarkan hasil *Elbow Method* pada Gambar 3, nilai *Within Cluster Sum of Squares* (WCSS) mengalami penurunan yang signifikan hingga jumlah kluster mencapai tiga. Setelah titik tersebut, penurunan WCSS cenderung melambat sehingga penambahan jumlah kluster tidak lagi memberikan peningkatan kualitas yang berarti. Temuan ini menunjukkan bahwa tiga kluster telah mampu merepresentasikan variasi karakteristik pengguna secara memadai.

Hasil *Silhouette Analysis* pada Gambar 4 menunjukkan bahwa nilai *Silhouette Score* tertinggi diperoleh pada $k = 8$ sebesar 0,363. Namun demikian, nilai *Silhouette Score* pada $k = 3$ sebesar 0,356 hanya berbeda 0,007 dari nilai maksimum. Selisih yang sangat kecil tersebut menunjukkan bahwa kualitas pengelompokan menggunakan tiga kluster tetap berada pada kategori yang baik. Oleh karena itu, penelitian ini menetapkan tiga kluster sebagai model akhir karena dinilai mampu memberikan keseimbangan antara kualitas statistik dan kemudahan interpretasi.

Menurut Kaufman dan Rousseeuw (1990), nilai *Silhouette Score* sebesar 0,356 berada pada kategori struktur kluster yang cukup terbentuk meskipun masih terdapat kemungkinan terjadinya tumpang tindih antar kluster. Dengan demikian, segmentasi pengguna yang dihasilkan dalam penelitian ini lebih merepresentasikan kecenderungan perilaku pengguna dibandingkan batas klasifikasi yang bersifat mutlak.

Hasil Segmentasi Pengguna Menggunakan K-Means Clustering

Setelah jumlah kluster optimal ditetapkan sebanyak tiga kelompok, proses segmentasi dilakukan menggunakan algoritma *K-Means Clustering* dengan empat variabel masukan, yaitu *Recency*, *Frequency*, *Monetary*, dan *Point Usage*. Hasil segmentasi menunjukkan bahwa setiap

klaster memiliki karakteristik perilaku transaksi yang berbeda sebagaimana ditunjukkan pada Tabel 3.

Berdasarkan hasil pengelompokan yang disajikan pada Tabel 3, terbentuk tiga klaster pengguna dengan karakteristik perilaku yang berbeda. Klaster 0 memiliki tingkat keterlibatan paling tinggi, yang ditunjukkan oleh nilai Recency paling rendah sebesar 17,80 hari serta nilai Frequency, Monetary, dan Point Usage yang paling tinggi dibandingkan klaster lainnya. Karakteristik tersebut menunjukkan bahwa pengguna dalam kelompok ini lebih aktif dan konsisten dalam memanfaatkan platform, sehingga diklasifikasikan sebagai segmen High Adoption. Temuan ini sejalan dengan konsep use behavior dalam kerangka UTAUT yang menyatakan bahwa tingginya intensitas dan keberlanjutan penggunaan merupakan indikator tingkat adopsi teknologi yang lebih tinggi (Venkatesh et al., 2003).

Sebaliknya, Klaster 1 menunjukkan tingkat aktivitas yang paling rendah, ditandai dengan nilai Frequency, Monetary, dan Point Usage yang lebih rendah dibandingkan klaster lainnya. Meskipun nilai Recency pada kelompok ini sedikit lebih baik dibandingkan Klaster 2, secara keseluruhan tingkat keterlibatannya tetap berada pada posisi terendah sehingga dikategorikan sebagai segmen Low Adoption. Sementara itu, Klaster 2 memiliki karakteristik yang berada di antara kedua kelompok tersebut dan diklasifikasikan sebagai segmen Moderate Adoption. Hasil segmentasi ini menunjukkan bahwa tingkat adopsi teknologi pada pengguna PesonnaGo tidak bersifat seragam, sehingga setiap kelompok memerlukan pendekatan dan strategi pengelolaan yang disesuaikan dengan karakteristik perilaku masing-masing pengguna.

Hasil Uji Stabilitas Clustering

Untuk menguji konsistensi hasil pengelompokan, penelitian ini melakukan uji stabilitas terhadap model K-Means Clustering. Pengujian dilakukan dengan menjalankan kembali algoritma sebanyak 20 kali menggunakan nilai random state yang berbeda pada setiap iterasi, kemudian tingkat kesesuaian hasil klaster dievaluasi menggunakan Adjusted Rand Index (ARI) sebagaimana disajikan pada Tabel 4. Hasil pengujian menunjukkan nilai ARI rata-rata sebesar 0,9998 dengan standar deviasi 0,0008, yang sangat mendekati nilai maksimum teoretis sebesar 1,000. Temuan tersebut menunjukkan bahwa struktur tiga klaster yang terbentuk memiliki tingkat stabilitas yang sangat tinggi dan dapat direproduksi secara konsisten meskipun proses pengelompokan diawali dengan inisialisasi centroid yang berbeda. Dengan demikian, sensitivitas algoritma K-Means terhadap pemilihan centroid awal sebagaimana dikemukakan oleh Kaufman dan Rousseeuw (1990) tidak memberikan pengaruh yang signifikan terhadap keandalan hasil segmentasi dalam penelitian ini.

Analisis Hubungan Antarvariabel

Hasil analisis korelasi Pearson yang ditampilkan pada Gambar 5 menunjukkan bahwa hubungan paling kuat terjadi antara variabel Monetary dan Point Usage, dengan koefisien korelasi sebesar $r = 0,947$. Nilai tersebut termasuk dalam kategori hubungan positif yang sangat kuat ($|r| \geq 0,7$), yang mengindikasikan bahwa peningkatan penggunaan poin cenderung diikuti oleh peningkatan nilai transaksi yang dilakukan pengguna. Selain itu, variabel Frequency juga menunjukkan hubungan positif dengan Monetary ($r = 0,32$) dan Point Usage ($r = 0,41$). Sebaliknya, variabel Recency memiliki hubungan negatif dengan ketiga variabel tersebut, yang menunjukkan bahwa pengguna yang lebih aktif bertransaksi cenderung memiliki nilai Recency yang lebih rendah. Secara keseluruhan, pola hubungan antar variabel ini mengindikasikan bahwa Recency, Frequency, Monetary, dan Point Usage saling berkaitan dan secara bersama-sama dapat merepresentasikan tingkat keterlibatan (*user engagement*) pengguna dalam memanfaatkan platform.

Hasil analisis menunjukkan bahwa seluruh proposisi penelitian memperoleh dukungan dari temuan empiris yang dihasilkan. Proposisi P1 terkonfirmasi karena terdapat perbedaan yang jelas pada nilai Recency, Frequency, Monetary, dan Point Usage antar klaster, sehingga menunjukkan bahwa data pengguna memiliki karakteristik yang cukup beragam untuk membentuk segmentasi yang bermakna. Proposisi P2 juga mendapatkan dukungan, meskipun nilai Silhouette Score pada model tiga klaster berada pada kategori sedang. Namun demikian, nilai Adjusted Rand Index (ARI) sebesar 0,9998 menunjukkan bahwa struktur segmentasi yang terbentuk sangat stabil dan konsisten. Selanjutnya, Proposisi P3 terkonfirmasi dengan kuat karena Klaster 0 secara bersamaan memiliki performa terbaik pada seluruh dimensi yang digunakan dalam analisis, sedangkan perbedaan karakteristik antara Klaster 1 dan Klaster 2 menegaskan pentingnya melakukan interpretasi berdasarkan kombinasi beberapa variabel, bukan hanya satu dimensi secara terpisah. Sementara itu, Proposisi P4 juga terkonfirmasi melalui hasil korelasi Pearson yang menunjukkan hubungan positif sangat kuat antara Point Usage dan Monetary ($r = 0,947$), sehingga mengindikasikan bahwa mekanisme insentif berbasis poin memiliki peran penting dalam mendorong aktivitas transaksi pengguna pada platform.

Pembahasan dan Interpretasi Temuan

Temuan penelitian ini menunjukkan bahwa pendekatan *behavioral analytics* yang memanfaatkan *transaction log data* mampu memberikan gambaran yang lebih objektif mengenai tingkat adopsi teknologi dibandingkan pendekatan yang hanya mengandalkan persepsi pengguna, seperti *Technology Acceptance Model* (TAM) dan *Unified Theory of Acceptance and Use of Technology* (UTAUT) (Venkatesh et al., 2003). Hasil segmentasi juga menunjukkan bahwa karakteristik pengguna pada kelompok *High Adoption* memiliki kemiripan

dengan kategori champions yang banyak ditemukan dalam penelitian segmentasi pelanggan pada lingkungan e-commerce komersial (Robo, 2024). Temuan tersebut mengindikasikan bahwa kombinasi metode *RFM Analysis* dan *K-Means Clustering*, yang telah banyak digunakan dalam konteks *business-to-consumer* (B2C), juga dapat diterapkan secara efektif pada platform *corporate e-commerce internal* (Cao et al., 2021). Selain itu, hubungan yang sangat kuat antara *Point Usage* dan *Monetary* memberikan bukti empiris bahwa sistem penghargaan berbasis poin tidak hanya berfungsi sebagai fitur pendukung, tetapi juga berperan sebagai instrumen strategis dalam mendorong aktivitas transaksi pengguna (Unboxed Training & Technology, 2023). Di sisi lain, nilai *Adjusted Rand Index* (ARI) sebesar 0,9998 menunjukkan bahwa hasil segmentasi yang diperoleh memiliki tingkat stabilitas yang sangat tinggi. Temuan ini memperkuat interpretasi terhadap nilai *Silhouette Score* yang berada pada kategori moderat, sehingga dapat disimpulkan bahwa model clustering tetap menghasilkan pengelompokan yang andal dan konsisten meskipun batas antar kluster belum sepenuhnya terpisah secara tegas.

Implikasi Penelitian

Secara teoretis, penelitian ini memperluas operasionalisasi konstruk *use behavior* berbasis data log transaksi sebagai pelengkap TAM/UTAUT, sekaligus memperluas penerapan RFM–K-Means ke konteks internal *corporate e-commerce* yang masih terbatas dalam literatur. Secara praktis, hasil segmentasi memberi dasar bagi PT Pesonna Indonesia Jaya dan PT Pegadaian untuk mempertahankan pengguna *High Adoption* melalui program loyalitas, mendorong *Moderate Adoption* melalui kampanye keterlibatan terarah, dan memberikan edukasi bagi *Low Adoption* guna mendukung keberlanjutan pemanfaatan platform.

KESIMPULAN

Temuan penelitian menunjukkan bahwa kombinasi *Recency-Frequency-Monetary* (*RFM*) *Analysis* dan *K-Means Clustering* mampu mengidentifikasi tingkat adopsi teknologi digital pada platform PesonnaGo secara objektif berdasarkan transaction log data. Analisis terhadap 8.888 transaksi yang diagregasi menjadi 5.007 pengguna unik menghasilkan tiga segmen, yaitu *High Adoption*, *Moderate Adoption*, dan *Low Adoption*, dengan model segmentasi terbukti sangat stabil (ARI = 0,9998). Korelasi Pearson turut menemukan hubungan positif yang sangat kuat antara *Point Usage* dan *Monetary* ($r = 0,947$), mengindikasikan bahwa sistem insentif berbasis poin berkontribusi meningkatkan aktivitas transaksi sekaligus adopsi teknologi. Temuan ini memperkuat pemanfaatan data perilaku aktual sebagai indikator *use behavior* yang melengkapi model berbasis persepsi seperti TAM dan UTAUT, sekaligus memperluas penerapan metode *RFM–K-Means* pada konteks internal corporate e-commerce yang masih terbatas dalam literatur.


Penelitian ini memiliki beberapa keterbatasan, yaitu hanya mencakup pengguna yang telah melakukan transaksi berhasil selama periode pengamatan, menggunakan satu objek penelitian, serta memanfaatkan variabel yang terbatas pada data transaksi. Di samping itu, nilai Silhouette Score yang berada pada kategori sedang menunjukkan bahwa kualitas pemisahan kluster masih dapat ditingkatkan. Oleh karena itu, penelitian selanjutnya disarankan menggunakan periode observasi yang lebih panjang, mengintegrasikan data perilaku aktual dan data persepsi melalui pendekatan mixed methods, mengeksplorasi algoritma clustering alternatif, menambahkan variabel seperti karakteristik demografis dan data interaksi pengguna, serta menguji model pada berbagai platform digital internal organisasi untuk meningkatkan kualitas segmentasi dan generalisasi hasil penelitian.

DAFTAR PUSTAKA

- Bisong, E. (2019). Google Colaboratory. In *Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners* (pp. 59–64). Apress. https://doi.org/10.1007/978-1-4842-4470-8_7
- Cao, Y., Kim, J., & Sarkar, S. (2021). Predicting Mobile Trading System Discontinuance: The Role of Attention. *Electronic Commerce Research and Applications*, 45, 101025. <https://doi.org/10.1016/j.elerap.2020.101025>
- IBM. (2025). What is K-Means Clustering? IBM. <https://www.ibm.com/think/topics/k-means-clustering>. Diakses tanggal 27 Juni 2026.
- Industry Research Biz. (2026). Employee Gamification Software Market Trends. Industry Research Biz. <https://www.industryresearch.biz/market-reports/employee-gamification-software-market-114973>. Diakses tanggal 27 Juni 2026.
- Kaufman, L., & Rousseeuw, P. J. (1990). *Finding Groups in Data: An Introduction to Cluster Analysis*. John Wiley & Sons. <https://doi.org/10.1002/9780470316801>
- MacQueen, J. (1967). Some Methods for Classification and Analysis of Multivariate Observations. In L. M. Le Cam & J. Neyman (Eds.), *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability* (Vol. 1, pp. 281–297). University of California Press.
- Market Growth Reports. (2026). What are the Top 17 Employee Gamification Software Companies in 2026? Market Growth Reports. <https://www.marketgrowthreports.com/blog/employee-gamification-software-companies-108>. Diakses tanggal 27 Juni 2026.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-Learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Robo, A. (2024). The Application of Customers Segmentation Using RFM Analysis Method and K-Means Clustering to Improve Marketing Strategy. *International Journal of Information System and Technology (IJISTECH)*, 8(3). <https://ijistech.org/ijistech/index.php/ijistech/article/view/370>
- Rousseeuw, P. J. (1987). Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis. *Journal of Computational and Applied Mathematics*, 20(1), 53–65. [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- Sintaningrum, P., & Wardhana, A. (2025). Intelligent Customer Segmentation: Unveiling Consumer Patterns with Machine Learning. *Journal of Umm Al-Qura University for Engineering and Architecture*. <https://doi.org/10.1007/s43995-025-00180-7>

- Unboxed Training and Technology. (2023). Examples of Gamification in the Workplace. Unboxed Training and Technology. <https://unboxedtechnology.com/blog/examples-of-gamification-in-the-workplace/>. Diakses tanggal 27 Juni 2026.
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425–478.
- Wibowo, R., & Aripin, Z. (2025). Antecedents of Data Analytics Adoption: A Systematic Literature Review from 2018–2024. PMC. <https://pmc.ncbi.nlm.nih.gov/articles/PMC12640482/>
- Wong, C.-G., Tong, G.-K., & Haw, S.-C. (2024). Exploring Customer Segmentation in E-Commerce Using RFM Analysis with Clustering Techniques. *Journal of Telecommunications and the Digital Economy*, 12(3), 97–125. <https://doi.org/10.18080/jtde.v12n3.978>
- Zulkarnaen, W., Fitriani, I., & Yuningsih, N. (2020). Pengembangan Supply Chain Management Dalam Pengelolaan Distribusi Logistik Pemilu Yang Lebih Tepat Jenis, Tepat Jumlah Dan Tepat Waktu Berbasis Human Resources Competency Development Di KPU Jawa Barat. *Jurnal Ilmiah MEA (Manajemen, Ekonomi, & Akuntansi)*, 4(2), 222–243. <https://doi.org/10.31955/mea.vol4.iss2.pp222-243>.

GAMBAR, GRAFIK DAN TABEL



Gambar 1. Kerangka Konseptual
Sumber : Data Diolah Peneliti (2026)




Gambar 2. Tren Transaksi Bulanan Pengguna PesonnaGo Periode November 2025–Februari 2026
Sumber : Data Sekunder Diolah Peneliti Menggunakan Python (Google Colaboratory) (2026)

Tabel 1. Variabel dan definisi operasional

Variabel	Definisi Operasional	Satuan	Formula/Cara Hitung
<i>Recency (R)</i>	Jumlah hari sejak transaksi terakhir pengguna hingga akhir periode observasi (28 Februari 2026)	Hari	$R = \text{Tanggal akhir observasi} - \text{Tanggal transaksi terakhir pengguna}$
<i>Frequency(F)</i>	Jumlah total transaksi berhasil yang dilakukan pengguna selama periode observasi	Jumlah transaksi	$F = \text{COUNT (transaksi berhasil per User ID)}$
<i>Monetary(M)</i>	Total nilai/poin transaksi yang dihasilkan pengguna selama periode observasi	Poin	$M = \text{SUM (nilai transaksi per User ID)}$
<i>Point Usage</i>	Total volume poin yang digunakan pengguna dalam transaksi penukaran selama periode observasi	Poin	$\text{Point Usage} = \text{SUM (poin terpakai per User ID)}$
Segmen Adopsi (<i>outcome</i>)	Label kategorikal hasil <i>clustering</i> yang merepresentasikan tingkat adopsi teknologi digital	Kategorikal (<i>High/Moderate/Low</i>)	Hasil pelabelan <i>post-hoc</i> terhadap <i>output</i> K-Means Clustering

Sumber : Data Diolah Peneliti (2026)




Gambar 3. Hasil Elbow Method

Sumber : Data Sekunder Diolah Peneliti Menggunakan Python (Google Colaboratory) (2026)

Tabel 2. Statistik Deskriptif Variabel Penelitian (N = 5.007)

Variabel	Mean	Std. Deviation	Minimum	Maximum
Recency	76.57	30.60	1.00	115.00
Frequency	1.78	0.97	1.00	8.00
Monetary	13.63	0.61	11.51	15.71
Point Usage	13.55	0.58	10.31	15.25

Sumber : Data Sekunder Diolah Peneliti Menggunakan Python (Google Colaboratory) (2026)




Gambar 4. Hasil Silhouette Analysis

Sumber : Data Sekunder Diolah Peneliti Menggunakan Python (Google Colaboratory) (2026)

Tabel 3. Profil Klaster Pengguna PesonnaGo

	Recency	Frequency	Monetary	Point Usage	Segment
Cluster					
0	17.80	2.34	14.19	14.11	High Adoption
1	84.62	1.19	12.94	12.86	Low Adoption
2	87.92	1.95	13.86	13.78	Moderate Adoption

Sumber : Data Sekunder Diolah Peneliti Menggunakan Python (Google Colaboratory) (2026)



Gambar 5. Matriks Korelasi Variabel Penelitian

Sumber : Data Sekunder Diolah Peneliti Menggunakan Python (Google Colaboratory) (2026)

Tabel 4. Hasil Uji Stabilitas Clustering (Adjusted Rand Index)

Metrik	Nilai
Rata-rata ARI (Average ARI)	0,9998
Standar reviasi ARI	0,0008
Jumlah eksekusi ulang	20 kali

Sumber : Data Sekunder Diolah Peneliti Menggunakan Python (Google Colaboratory) (2026)