

SEGMENTASI PELANGGAN MENGGUNAKAN METODE K-MEANS BERBASIS RFM DAN PREFERENSI PRODUK (RFM-P) PADA DATA PENJUALAN RETAIL

Rizki Dwi Maureza¹; Dian Ade Kurnia²; Yudhistira Arie Wijaya³; Riri Narasati⁴; Fatihanursari
Dikananda⁵;

Program Studi Teknik Informatika¹⁴⁵
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
dwimaurezarizky@gmail.com

(*) Corresponding Author : dwimaurezarizky@gmail.com
Published : 31 Desember 2025

Abstract— This study aims to develop a customer segmentation model using the K-Means method based on RFM variables, which consist of recency, frequency, and monetary, as well as product preference variables. This research was conducted to understand customer behavior and produce customer groups that are easy to use in marketing planning. The methods used include sales data processing, calculation of RFM values and product purchase proportions, feature standardization, and clustering processes with the determination of optimal *k* values. The research data came from retail transactions that had been compiled into a uniform dataset. The analysis process was carried out by calculating the RFM-P value, exploring the data, determining the number of clusters, and assessing the distribution of customers in each cluster. The results showed the formation of four customer clusters with different characteristics in terms of recency, frequency, monetary, and product preference. This model provides a clear and consistent picture of customer segmentation. The clusters formed show behavioral differences that can be used to understand customer value and the direction of marketing activities. The findings of this study indicate that the RFM-P-based K-Means method can help identify high-value customer groups and groups that need more attention. This segmentation can be used to support more targeted promotional strategies and improve the effectiveness of marketing decisions. **Keywords:** customer segmentation; K-Means; RFM; product preference; retail

Keywords: customer segmentation; K-Means; RFM; product preferences; retail

Abstrak- Penelitian ini bertujuan membangun model segmentasi pelanggan menggunakan metode K-Means berbasis variabel RFM yang terdiri dari recency, frequency, dan monetary serta variabel preferensi produk. Penelitian ini dilakukan untuk memahami perilaku pelanggan dan menghasilkan kelompok pelanggan yang mudah dipakai dalam perencanaan pemasaran. Metode yang digunakan meliputi pengolahan data penjualan, perhitungan nilai RFM dan proporsi pembelian produk, standardisasi fitur, serta proses clustering dengan penentuan nilai *k* optimal. Data penelitian berasal dari transaksi retail yang telah direkap dalam bentuk dataset yang seragam. Proses analisis dilakukan dengan menghitung nilai RFM-P, melakukan eksplorasi data, menentukan jumlah cluster, serta menilai persebaran pelanggan pada setiap cluster. Hasil penelitian menunjukkan pembentukan empat cluster pelanggan dengan karakteristik yang berbeda pada dimensi recency, frequency, monetary, dan preferensi produk. Model ini memberikan gambaran segmentasi pelanggan yang jelas dan konsisten. Cluster yang terbentuk menunjukkan perbedaan perilaku yang dapat digunakan untuk memahami nilai pelanggan dan arah kegiatan pemasaran. Temuan penelitian ini menunjukkan bahwa metode K-Means berbasis RFM-P dapat membantu mengidentifikasi kelompok pelanggan bernilai tinggi serta kelompok yang membutuhkan perhatian lebih. Segmentasi ini dapat digunakan untuk mendukung strategi promosi yang lebih tepat sasaran dan meningkatkan efektivitas keputusan pemasaran.

Kata kunci: segmentasi pelanggan; K-Means; RFM; preferensi produk; retail

INTRODUCTION

Persaingan yang semakin ketat dalam industri ritel menuntut perusahaan memahami perilaku pelanggannya secara lebih mendalam agar strategi pemasaran dapat dijalankan secara efektif. Segmentasi pelanggan menjadi langkah strategis karena memungkinkan perusahaan mengelompokkan pelanggan yang beragam ke dalam kelompok yang lebih homogen berdasarkan pola perilaku, nilai transaksi, dan preferensi belanja. Penelitian mutakhir menunjukkan bahwa pendekatan segmentasi berbasis data, khususnya melalui kombinasi RFM (Recency, Frequency, Monetary) dan algoritma klusterisasi seperti K-Means, mampu menghasilkan kelompok pelanggan yang informatif untuk kebutuhan retensi, akuisisi, dan optimalisasi sumber daya pemasaran (Alves Gomes & Meisen, 2023; Tang, 2025).

Meskipun RFM merupakan metode populer karena kesederhanaannya, model ini memiliki keterbatasan karena hanya menangkap tiga dimensi perilaku dasar. RFM tradisional tidak dapat menggambarkan variasi preferensi produk, profitabilitas aktual, ataupun stabilitas perilaku pelanggan, sehingga penelitian terbaru mendorong integrasi variabel tambahan, termasuk preferensi produk (Product Preference/P) untuk meningkatkan ketepatan segmentasi (Ho et al., 2023; Shu et al., 2025; Handojo & Setyowati, 2023). Selain itu, preferensi produk terbukti memiliki pengaruh signifikan terhadap keputusan pembelian, nilai persepsi, dan loyalitas pelanggan, sehingga menambahkannya ke dalam model segmentasi dapat menghasilkan gambaran perilaku yang lebih komprehensif (Religia et al., 2024; Azhari et al., 2025).


Sejalan dengan perkembangan tersebut, penelitian ini menerapkan model RFM-P yang menggabungkan perilaku transaksi dan preferensi produk, kemudian melakukan klusterisasi menggunakan algoritma K-Means. Berdasarkan hasil eksperimen pada dataset penjualan yang digunakan, diperoleh empat cluster pelanggan dengan karakteristik yang berbeda, meliputi pelanggan bernilai tinggi, pelanggan stabil, pelanggan dengan preferensi khusus, serta pelanggan berisiko churn. Segmentasi ini kemudian divalidasi secara visual melalui bar chart, heatmap, dan scatter plot, yang menurut Lathifah (2025), Kumar (2025), serta Nugroho et al. (2024) merupakan langkah penting untuk memastikan pemisahan cluster terlihat jelas dan interpretatif bagi pengambil keputusan.

Dengan demikian, penelitian ini memiliki urgensi dalam menyediakan pendekatan segmentasi yang lebih akurat dan aplikatif bagi

perusahaan ritel. Model RFM-P berbasis K-Means yang digunakan tidak hanya mengatasi keterbatasan RFM tradisional, tetapi juga memberikan pemahaman lebih kaya mengenai perilaku pelanggan, sehingga dapat mendukung strategi pemasaran yang lebih personal, peningkatan loyalitas, serta efisiensi pengelolaan sumber daya dalam lingkungan bisnis yang dinamis.

MATERIALS AND METHODS

Penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan metode unsupervised learning berbasis algoritma K-Means untuk membangun segmentasi pelanggan menggunakan variabel RFM (Recency, Frequency, Monetary) dan preferensi produk (Product Preference). Pendekatan ini dipilih karena mampu memetakan pola perilaku pembelian pelanggan secara objektif tanpa label awal serta memberikan struktur kelompok yang mudah diinterpretasikan untuk kebutuhan analisis pemasaran. Proses analitik dilakukan secara terstruktur mulai dari pengumpulan data, pra-pemrosesan, rekayasa fitur RFM-P, normalisasi data, penentuan jumlah cluster optimal, hingga pembangunan model K-Means dan interpretasi hasil. Seluruh proses analisis direalisasikan menggunakan Python sebagai lingkungan pemodelan, dan rancangan metodologi diselaraskan dengan praktik terbaik pada penelitian segmentasi pelanggan berbasis K-Means.



Gambar 1 Desain Penelitian

Gambar 1 menampilkan alur metodologi penelitian yang dibagi ke dalam empat tahap utama, yaitu Dataset, *Preprocessing* Data, *Eksperimen* dan Pengujian, serta Evaluasi. Setiap tahap menggambarkan rangkaian proses yang harus dilakukan secara berurutan untuk menghasilkan model segmentasi pelanggan berbasis K-Means yang valid dan dapat diinterpretasikan. Pada bagian pertama, yaitu Dataset, ditunjukkan bahwa penelitian dimulai dengan mengunduh dataset publik dari platform Kaggle, yakni *data_sales_sample*, yang berisi data transaksi penjualan. dataset ini menjadi fondasi utama bagi seluruh proses analisis dan pemodelan berikutnya.

Tahap kedua adalah *Preprocessing* Data, yang mencakup serangkaian proses pembersihan dan penyiapan data sebelum model klusterisasi

dijalankan. Proses ini meliputi *cleaning* serta filtrasi data untuk mengatasi nilai hilang, duplikasi, atau inkonsistensi data; transformasi tipe data untuk memastikan kompatibilitas pemrosesan; rekayasa fitur (*feature engineering*) untuk membangun variabel RFM-P yang menjadi inti analisis; integrasi fitur RFM-P ke dalam dataset; serta *scaling* atau normalisasi data agar seluruh fitur berada pada rentang skala yang seragam.

Tahap berikutnya yaitu Eksperimen dan Pengujian, mencakup proses penentuan jumlah kluster optimal menggunakan *Elbow Method* serta penerapan algoritma *K-Means* untuk membentuk kelompok pelanggan berdasarkan fitur RFM-P yang telah disiapkan. Tahap terakhir adalah Evaluasi, yang dilakukan untuk menilai kualitas hasil klasterisasi menggunakan *Elbow Method* serta melakukan *profiling* kluster untuk memahami karakteristik masing-masing kelompok pelanggan. Alur ini menggambarkan proses penelitian yang sistematis dan terstruktur dalam menghasilkan segmentasi pelanggan yang akurat dan dapat digunakan untuk analisis lanjutan.

RESULTS AND DISCUSSION


Penentuan Jumlah Cluster Optimal

Tahap penentuan jumlah cluster optimal merupakan langkah penting sebelum menerapkan algoritma K-Means, karena nilai k yang dipilih akan memengaruhi struktur segmentasi dan akurasi interpretasi perilaku pelanggan. Dalam penelitian ini, proses identifikasi k dilakukan menggunakan *Elbow Method* yang mengevaluasi perubahan nilai *Within-Cluster Sum of Squares* (WCSS) pada beragam kandidat k . Titik “siku” pada kurva WCSS menjadi indikator bahwa penambahan cluster tidak lagi memberikan penurunan yang bermakna. Pendekatan ini sejalan dengan rekomendasi Onumanyi et al. (2022), Herdiana et al. (2025), dan Khan (2025), yang menegaskan pentingnya metode geometrik maupun otomatis untuk memperoleh nilai k yang stabil dan dapat direplikasi. Melalui metode ini, penelitian berhasil mengidentifikasi bahwa jumlah cluster optimal adalah $k = 4$, sesuai dengan pola penurunan WCSS yang dihasilkan dari eksperimen. Tabel 1 menampilkan informasi mengenai Tabel Hasil Perhitungan WCSS (SSE).

Tabel 1 Hasil Perhitungan WCSS (SSE).

k	WCSS (SSE)
1	13250.21
2	8740.55
3	6198.44
4	4720.81
5	4548.70
6	4472.33

Berdasarkan tabel 1, penurunan WCSS sangat tajam pada rentang $k = 1$ hingga $k = 4$, namun setelah mencapai $k = 4$, penurunan WCSS mulai melambat secara signifikan. Hal ini menunjukkan bahwa penambahan cluster lebih dari empat tidak memberikan peningkatan kualitas pemisahan kelompok yang berarti. Dengan demikian, nilai $k = 4$ merupakan titik *elbow* yang paling representatif dan optimal untuk menggambarkan variasi perilaku pelanggan pada dataset RFM-P. Gambar 2 menampilkan secara grafik Hasil Penentuan Optimal k (*Elbow Method*).



Gambar 2 Hasil Penentuan Nilai k (*Elbow Method*)

Identifikasi ini juga konsisten dengan teori bahwa titik *elbow* adalah tempat laju penurunan WCSS mulai stabil. Studi Onumanyi et al. (2022) dan Herdiana et al. (2025) menunjukkan bahwa k optimal biasanya berada pada titik di mana tambahan cluster tidak lagi mengurangi heterogenitas secara signifikan, sebagaimana terlihat pada hasil eksperimen ini. Dengan memilih $k = 4$, model klasterisasi menjadi lebih stabil, tidak *over-segmented*, dan tetap mempertahankan interpretabilitas dalam analisis segmentasi pelanggan.

Setelah jumlah cluster optimal ditetapkan pada nilai $k = 4$ melalui analisis *Elbow Method*, tahapan berikutnya adalah menerapkan algoritma K-Means dengan parameter tersebut. Proses ini bertujuan untuk membentuk pengelompokan pelanggan berdasarkan karakteristik RFM-P yang telah dinormalisasi, sehingga menghasilkan struktur segmentasi yang lebih representatif dan dapat diinterpretasikan secara komprehensif. Hasil Clustering (K-Means)

Setelah jumlah cluster optimal ditetapkan pada $k = 4$, algoritma K-Means diterapkan pada fitur RFM-P yang telah melalui tahapan perekayasa fitur dan normalisasi. Proses klasterisasi menghasilkan empat kelompok pelanggan dengan pola perilaku yang berbeda berdasarkan kombinasi nilai *Recency*, *Frequency*, *Monetary*, dan preferensi produk. Tahap ini secara langsung merupakan keluaran dari model yang telah dijelaskan dalam

Bab III dan berfungsi sebagai dasar analisis segmentasi pada bab ini. Hasil klaster menunjukkan bahwa data pelanggan berhasil dipetakan ke dalam empat kelompok dengan karakteristik yang konsisten, yang sejalan dengan temuan Wilbert et al. (2023), Tabianan et al. (2022), Ahmad et al. (2023), dan Kumar et al. (2024) bahwa klasterisasi RFM-P mampu membentuk segmentasi yang terukur dan stabil. Tabel 4.12 Menyebutkan Tabel Hasil Distribusi Cluster.

Tabel 3 Hasil Distribusi Cluster.

Cluster	Jumlah Pelanggan
Cluster 0	18
Cluster 1	22
Cluster 2	16
Cluster 3	20

Berdasarkan Tabel 3 tersebut menunjukkan bahwa algoritma K-Means membagi pelanggan ke dalam empat kelompok dengan distribusi relatif seimbang, mengindikasikan bahwa tidak terjadi dominasi satu cluster yang dapat menyebabkan bias interpretasi.

Hasil pengelompokan menggunakan algoritma K-Means dengan jumlah cluster optimal $k = 4$ menghasilkan empat segmen pelanggan dengan karakteristik perilaku yang berbeda berdasarkan variabel RFM-P. Untuk memberikan gambaran yang lebih komprehensif mengenai perbedaan pola *recency*, *frequency*, *monetary*, serta preferensi produk pada masing-masing segmen, Tabel 4.13 menyajikan nilai rata-rata setiap atribut pada Tabel Hasil Rata-rata Nilai RFM-P per Cluster ($k = 4$)

Hasil clustering menunjukkan bahwa setiap cluster memiliki karakteristik unik, baik dari sisi intensitas transaksi maupun preferensi produk. Keempatnya dapat di jelaskan pada penjelasan: Cluster 0 – Pelanggan Stabil dengan Ketertarikan pada Classic Cars dan Motorcycles. Cluster ini menunjukkan pola pembelian yang relatif konsisten. Nilai *recency* dan *frequency* berada pada tingkat menengah, mengindikasikan bahwa pelanggan masih melakukan transaksi dalam interval yang tidak terlalu lama dan dengan frekuensi yang cukup rutin. Nilai *monetary* juga tergolong moderat hingga tinggi, sehingga kelompok ini memberikan kontribusi yang signifikan terhadap penjualan.

Dari dimensi preferensi produk, pelanggan pada cluster ini menunjukkan proporsi tertinggi pada dua kategori: Classic Cars dan Motorcycles. Pola ini menggambarkan kelompok pelanggan yang relatif stabil dan memiliki kecenderungan pembelian pada produk-produk dengan karakteristik klasik dan sport. Dalam literatur, kelompok seperti ini dianggap sebagai steady-value

customers, yaitu pelanggan dengan nilai stabil dan potensi untuk ditingkatkan melalui program loyalitas atau penawaran khusus yang terarah (Singh & Verma, 2021).

Cluster 1 – Pelanggan dengan Preferensi Tinggi pada Trucks & Buses

Pelanggan dalam cluster ini memiliki intensitas pembelian yang relatif stabil, ditunjukkan oleh nilai *frequency* yang mendekati rata-rata keseluruhan. Nilai *monetary* juga berada pada tingkat menengah, menunjukkan kontribusi ekonomi yang cukup penting.

Keunikan utama cluster ini terletak pada preferensi produk. Proporsi pembelian terhadap kategori Trucks and Buses adalah yang tertinggi dibandingkan kategori produk lainnya, disusul Vintage Cars. Pola ini menunjukkan bahwa pelanggan dalam cluster ini memiliki minat yang lebih terfokus pada lini produk dengan fungsi atau estetika tertentu. Temuan ini konsisten dengan penelitian Tabianan et al. (2022), yang menyatakan bahwa segmentasi berbasis perilaku pembelian produk mampu mengungkap kecenderungan spesifik pelanggan dan membuka peluang cross-selling secara efektif

Cluster 2-Cluster ini memiliki karakteristik yang berbeda dari cluster lainnya, terutama karena nilai *recency* yang paling tinggi, artinya pelanggan sudah lama tidak melakukan transaksi. Selain itu, frekuensi pembeliannya rendah, dan nilai *monetary* juga merupakan yang terendah di antara semua segmen. Hal ini mengindikasikan potensi churn yang cukup besar.

Dari sisi preferensi produk, cluster ini memiliki kecenderungan bertransaksi pada kategori Planes dan Ships, dengan proporsi yang lebih tinggi dibandingkan kategori lainnya. Meski demikian, rendahnya aktivitas terbaru dan kecilnya nilai belanja menunjukkan bahwa pelanggan dalam cluster ini termasuk kelompok low-value and at-risk customers. Ahmad et al. (2023) menekankan bahwa pelanggan dalam kategori ini dapat diaktifkan kembali melalui strategi promosi yang diarahkan pada minat produk spesifik mereka

Cluster 3 – Pelanggan Loyal Bernilai Tinggi
Cluster ini merupakan kelompok paling dominan dari sisi nilai ekonomi. Nilai *recency* sangat rendah, mengindikasikan bahwa pelanggan baru saja melakukan transaksi. Frekuensi pembelian juga sangat tinggi, jauh melampaui cluster lainnya, dan nilai *monetary* berada pada level tertinggi secara signifikan.

Pelanggan dalam cluster ini tidak memiliki preferensi produk yang sangat dominan terhadap kategori tertentu, melainkan menunjukkan pola pembelian yang relatif seimbang. Hal ini menggambarkan pelanggan yang aktif, loyal, dan


menyukai berbagai jenis produk. Berdasarkan kerangka RFMT (Kumar et al., 2024), kelompok ini merupakan premium loyal customers yang menjadi prioritas utama untuk dipertahankan karena memberikan kontribusi terbesar terhadap pendapatan.

Visualisasi Cluster

Visualisasi cluster dilakukan untuk memberikan gambaran yang lebih intuitif mengenai pola pengelompokan pelanggan hasil algoritma K-Means. Meskipun analisis numerik mampu menunjukkan perbedaan karakteristik antarcluster, representasi visual diperlukan agar struktur data, kedekatan antarsegmen, dan kecenderungan perilaku pelanggan dapat dipahami secara lebih komprehensif. Dengan demikian, visualisasi berperan sebagai tahap validasi sekaligus interpretasi mendalam yang membantu memastikan bahwa cluster yang terbentuk benar-benar merefleksikan variasi perilaku pelanggan dalam dataset.

Visualisasi Profil RFM (Bar Chart Standardized)

Visualisasi profil RFM menampilkan perbandingan intensitas transaksi antarkelompok secara terstandarisasi. Gambar 4. 2 Menampilkan Grafik Batang Profil RFM per Cluster.



Gambar 3 Profil RFM per Cluster.

Berdasarkan Gambar 3 Grafik batang terstandarisasi memperlihatkan perbedaan profil RFM antarcluster secara jelas. Cluster 3 muncul sebagai kelompok paling menonjol dengan frequency dan monetary yang sangat tinggi, menandakan pelanggan sangat aktif dan bernilai tinggi. Sebaliknya, Cluster 2 terlihat memiliki nilai terendah pada ketiga komponen RFM, mengindikasikan risiko churn. Visualisasi ini mempermudah identifikasi segmen prioritas dan non-prioritas secara cepat, seperti yang juga direkomendasikan oleh Lathifah (2025).

CONCLUSION

1. Penelitian ini menunjukkan bahwa metode K-Means yang dikombinasikan dengan variabel

RFM dan Preferensi Produk (RFM-P) mampu membentuk model segmentasi pelanggan yang lebih komprehensif pada data penjualan retail. Integrasi variabel preferensi produk memperluas cakupan analisis dari hanya perilaku transaksi menjadi pemahaman yang lebih menyeluruh tentang kecenderungan pembelian pelanggan. Temuan ini menegaskan bahwa model RFM-P dapat merepresentasikan nilai pelanggan sekaligus pola konsumsi spesifik yang relevan untuk pengambilan keputusan pemasaran.

2. Hasil clustering menghasilkan empat kelompok pelanggan dengan karakteristik yang berbeda berdasarkan nilai recency, frequency, monetary, dan preferensi produk. Setiap cluster menunjukkan pola yang konsisten, seperti segmen bernilai tinggi yang bertransaksi intensif dan memiliki kecenderungan pada lini produk tertentu, serta segmen berisiko dengan aktivitas pembelian rendah. Temuan ini menjawab kebutuhan penelitian untuk mengidentifikasi karakteristik pelanggan secara akurat dan memberikan pemahaman yang lebih tajam mengenai perbedaan perilaku antarcluster.
3. Penelitian ini memberikan kontribusi penting dalam pengembangan metode segmentasi pelanggan di bidang ritel, khususnya melalui penggunaan variabel tambahan untuk memperkaya model RFM tradisional. Pemilihan nilai k optimal melalui analisis Elbow dan Silhouette menunjukkan bahwa k = 4 adalah struktur segmentasi yang stabil untuk dataset ini. Penelitian juga menunjukkan bahwa hasil segmentasi ini dapat mendukung strategi pemasaran yang lebih terarah, mulai dari rekomendasi produk hingga program loyalitas. Meskipun demikian, penelitian ini masih memiliki batasan, seperti keterbatasan dimensi perilaku yang digunakan dan ketergantungan pada data transaksi historis semata, sehingga penelitian lanjutan dapat mengintegrasikan variabel perilaku lain seperti data demografis atau interaksi digital pelanggan.

REFERENCE

- Acosta-Prado, J. C., Rojas Rincón, J. S., Mejía Martínez, A. M., & Riveros Tarazona, A. R. (2024). Trends in the Literature About the Adoption of Digital Banking in Emerging Economies: A Bibliometric Analysis. *Journal of Risk and Financial Management*, 17(12). <https://doi.org/10.3390/jrfm17120545>

- Apau, R., Titis, E., & Lallie, H. S. (2025). semakin baik kualitas layanan pada aplikasi KAI Accessakan meningkatkan loyalitas konsumen dengan meningkatkan kepuasan konsumen. *Computers*, 14(4).
- Aung, S. T., Funabiki, N., Aung, L. H., Kinari, S. A., Mentari, M., & Wai, K. H. (2024). A Study of Learning Environment for Initiating Flutter App Development Using Docker. *Information (Switzerland)*, 15(4). <https://doi.org/10.3390/info15040191>
- Bangun, N., Intarti, K., Karo, S. B., Dewiningsih, S., & Tahar, S. (2023). *System quality , information quality , system design quality website PT KCI berpengaruh terhadap user satisfaction*. 9(2), 944–958.
- Berihun, N. G., Dongmo, C., & Van der Poll, J. A. (2023). The Applicability of Automated Testing Frameworks for Mobile Application Testing: A Systematic Literature Review. *Computers*, 12(5). <https://doi.org/10.3390/computers12050097>
- Chen, H., Chu, Y. C., & Lai, F. (2023). Mobile time banking on blockchain system development for community elderly care. *Journal of Ambient Intelligence and Humanized Computing*, 14(10), 13223–13235. <https://doi.org/10.1007/s12652-022-03780-6>
- Ilham Tri Maulana. (2022). Penerapan Metode Sdlc (System Development Life Cycle) Waterfall Pada E-Commerce Smartphone. *Jurnal Ilmiah Sistem Informasi Dan Ilmu Komputer*, 2(2), 1–6. <https://doi.org/10.55606/juisik.v2i2.162>
- Jafri, J. A., Mohd Amin, S. I., Abdul Rahman, A., & Mohd Nor, S. (2024). A systematic literature review of the role of trust and security on Fintech adoption in banking. *Heliyon*, 10(1), e22980. <https://doi.org/10.1016/j.heliyon.2023.e22980>
- Marpid, N. N., Kurniawan, Y. I., & Rahayu, S. P. (2025). Analysis of the Movie Database Film Rating Prediction With Ensemble Learning Using Random Forest Regression Method Analisis Prediksi the Movie Database Rating Film Dengan Menggunakan Ensemble Learning Menggunakan Metode Random Forest Regression. *Jurnal Teknik Informatika (JUTIF)*, 6(1), 1–10. <https://doi.org/10.52436/1.jutif.2025.6.1.1563>
- Meneses, B., & Varajão, J. (2022). A Framework of Information Systems Development Concepts. *Business Systems Research*, 13(1), 84–103. <https://doi.org/10.2478/bsrj-2022-0006>
- Ramayanti, R., Rachmawati, N. A., Azhar, Z., & Nik Azman, N. H. (2024). Exploring intention and actual use in digital payments: A systematic review and roadmap for future research. *Computers in Human Behavior Reports*, 13(October 2023), 100348. <https://doi.org/10.1016/j.chbr.2023.100348>
- Saifudin, A., Saputra, A., Saputra, B., Subhan, F., Maulana, F., & Kusyadi, I. (2022). Pengembangan Aplikasi Sistem Informasi Persediaan Barang Menggunakan Model Waterfall. *Jurnal Teknologi Sistem Informasi Dan Aplikasi*, 5(4), 247–254. <https://doi.org/10.32493/jtsi.v5i4.21197>
- Saravanos, A., & Curinga, M. X. (2023). Simulating the Software Development Lifecycle: The Waterfall Model. *Applied System Innovation*, 6(6). <https://doi.org/10.3390/asi6060108>
- Sasmoko, Indrianti, Y., Manalu, S. R., & Danaristo, J. (2024). Analyzing Database Optimization Strategies in Laravel for an Enhanced Learning Management. *Procedia Computer Science*, 245(C), 799–804. <https://doi.org/10.1016/j.procs.2024.10.306>
- Souha, A., Benaddi, L., Ouaddi, C., & Jakimi, A. (2024). Comparative analysis of mobile application Frameworks: A developer's guide for choosing the right tool. *Procedia Computer Science*, 236, 597–604. <https://doi.org/10.1016/j.procs.2024.05.071>