

Segmentasi Pelanggan dengan Model LRFM Menggunakan Particle Swarm Optimization dan Fuzzy C-Means

Syelvya Julianti^{a1}, I Made Widiartha^{a2}, Made Agung Raharja^{a3}, Luh Gede Astuti^{a4}

^aProgram Studi Informatika, Universitas Udayana
Bali, Indonesia

¹syelvia06@email.com

²madewidiartha@unud.ac.id

³made.agung@unud.ac.id

⁴madewidiartha@unud.ac.id

Abstract

Increasing business competition encourages companies to utilize e-commerce and better understand customer behavior through customer segmentation. This study combines the LRFM model with Fuzzy C-Means (FCM) and Particle Swarm Optimization (PSO), where PSO optimizes the initial cluster centers to improve FCM clustering performance. The research process includes LRFM calculation, data normalization, PSO parameter tuning, clustering, and evaluation using the Partition Coefficient (PC), Partition Entropy (PE), and Davies–Bouldin Index (DBI). The best PSO parameters were 50 particles, an inertia weight of 0.7, $C_1 = 1.5$, and $C_2 = 1.0$. The optimal result was obtained with two clusters, achieving PC = 0.845, PE = 0.267, and DBI = 0.613. The clustering identified lost customers with low activity and transaction value, recommended for a let-go strategy, and core customers with high activity and contribution, recommended for an enforced strategy.

Keywords: Customer Segmentation, LRFM, Fuzzy C-Means, Particle Swarm Optimization

1. Introduction

Persaingan bisnis yang semakin ketat mendorong pelaku usaha untuk terus berinovasi, salah satunya melalui penerapan e-commerce. Berdasarkan analisis RedSeer, Indonesia diprediksi menjadi kontributor utama pertumbuhan pasar e-commerce di Asia Pasifik dengan peningkatan nilai pasar mencapai US\$137,5 miliar pada tahun 2025 [1]. Pertumbuhan tersebut menyebabkan persaingan bisnis semakin kompetitif sehingga perusahaan perlu memperhatikan pelanggan sebagai aspek penting dalam memperoleh keuntungan. Oleh karena itu, segmentasi pelanggan diperlukan untuk memahami karakteristik pelanggan dan menentukan strategi pemasaran yang tepat.


Segmentasi pelanggan dapat dilakukan menggunakan model LRFM yang terdiri dari Length, Recency, Frequency, dan Monetary. Model ini dikembangkan dari model RFM dengan menambahkan variabel Length untuk mengukur lamanya hubungan pelanggan dengan bisnis sehingga mampu memberikan analisis loyalitas pelanggan yang lebih baik [2]. Dengan model LRFM, perusahaan dapat memahami perilaku pelanggan secara lebih menyeluruh berdasarkan durasi hubungan, waktu transaksi terakhir, frekuensi transaksi, dan total pengeluaran pelanggan.

Dalam proses segmentasi pelanggan, metode Fuzzy C-Means dipilih karena mampu menghasilkan pengelompokan yang lebih fleksibel melalui derajat keanggotaan setiap data [3]. Namun, Fuzzy C-Means memiliki kelemahan yaitu sensitif terhadap pusat kluster awal sehingga mudah terjebak pada optimum lokal [4]. Untuk mengatasi permasalahan tersebut, digunakan metode Particle Swarm Optimization (PSO) sebagai optimasi pusat kluster awal. PSO dipilih karena memiliki waktu komputasi yang lebih cepat dan biaya komputasi yang lebih rendah dibandingkan beberapa algoritma optimasi lainnya [5].

Beberapa penelitian terdahulu telah menerapkan model LRFM menggunakan algoritma K-Means maupun Fuzzy C-Means untuk segmentasi pelanggan [6], [7]. Namun, penggunaan K-Means hanya menghasilkan keanggotaan tunggal pada setiap pelanggan, sedangkan penelitian yang menggunakan Fuzzy C-Means belum mengoptimalkan penentuan pusat kluster awal sehingga masih berpotensi menghasilkan kualitas kluster yang kurang optimal [7]. Selain itu, penelitian lain masih menggunakan model RFM sehingga belum memanfaatkan variabel Length yang mampu memberikan analisis loyalitas pelanggan secara lebih komprehensif [8]. Oleh karena itu, penelitian ini mengusulkan segmentasi pelanggan berdasarkan model LRFM menggunakan metode Fuzzy C-Means dan Particle Swarm Optimization.

2. Metode Penelitian

Gambar 1 menunjukkan alur penelitian yang dimulai dari tahap pengumpulan data, dilanjutkan dengan *preprocessing* data yang meliputi proses *cleaning* data, transformasi data, pembentukan fitur LRFM, dan normalisasi data. Selanjutnya, dilakukan proses segmentasi pelanggan menggunakan metode PSO dan FCM, yang mencakup penentuan jumlah kluster, tuning parameter PSO, penentuan pusat kluster awal menggunakan PSO, klusterisasi dengan FCM, serta evaluasi kluster. Tahap akhir dari penelitian ini adalah pengembangan sistem.



Gambar 1. Alur Penelitian

2.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data riwayat penjualan Brazil e-commerce yang diperoleh dari Kaggle, dengan *dataset* yang digunakan meliputi *dataset* customer, orders, dan order item. Jumlah data pada *dataset* customer sebanyak 5010 baris, sedangkan *dataset* orders dan order item masing-masing memiliki 14985 baris data.

2.2. Pra-pemrosesan Data

Dalam penelitian ini, tahapan *preprocessing* terdiri dari *data cleaning*, transformasi data, pembentukan fitur, dan normalisasi data. *Data cleaning* dilakukan untuk menghapus data duplikat dan data tidak lengkap pada *dataset* customers, order item, dan orders agar kualitas data meningkat [9]. Selanjutnya dilakukan transformasi data dengan menggabungkan ketiga tabel tersebut sesuai kebutuhan penelitian [10]. Setelah itu dilakukan pembentukan fitur berdasarkan model LRFM untuk menggambarkan pola pembelian pelanggan. Tahap terakhir adalah normalisasi data menggunakan metode MinMaxScaler pada fitur length, recency, frequency, dan monetary agar memiliki rentang nilai antara 0 hingga 1.

2.3. Penentuan Jumlah Kluster

Dalam proses klusterisasi, penentuan jumlah kluster merupakan tahap penting karena pada metode Fuzzy C-Means jumlah kluster ditentukan secara acak. Oleh karena itu, penelitian ini menggunakan


Koefisien Silhouette untuk menentukan jumlah kluster yang optimal. Nilai koefisien berada pada rentang -1 hingga 1, dimana nilai yang mendekati 1 menunjukkan bahwa jumlah kluster yang digunakan sudah optimal [11].

2.4. Tuning Parameter PSO

Pemilihan parameter PSO merupakan tahap penting karena dapat mempengaruhi kualitas solusi dan kecepatan konvergensi algoritma. Dalam penelitian ini dilakukan tuning parameter dengan metode grid search pada jumlah partikel, bobot inersia, serta nilai koefisien akselerasi C1 dan C2 berdasarkan kajian penelitian sebelumnya. Jumlah partikel dipilih pada rentang 20, 30, 40, dan 50 karena dinilai mampu menjaga keseimbangan antara kualitas solusi dan efisiensi komputasi [12], [13]. Selanjutnya, bobot inersia digunakan untuk mengatur keseimbangan antara eksplorasi dan eksploitasi, sehingga penelitian ini menggunakan rentang nilai 0,4; 0,5; 0,6; 0,7; 0,8; 0,9 [14], [15]. Selain itu, parameter C1 dan C2 berperan dalam mengatur pengaruh personal best dan global best pada proses pencarian solusi, sehingga digunakan variasi nilai 0,5; 1,0; 1,5; 2,0; 2,5 sesuai rekomendasi beberapa penelitian sebelumnya [16], [17].

2.5. Penentuan Pusat Kluster Awal dengan PSO


Gambar 2 menunjukkan alur algoritma PSO untuk menentukan pusat kluster awal pada metode FCM. Proses dimulai dengan menentukan parameter seperti jumlah kluster, jumlah partikel, iterasi maksimum, bobot inersia, serta nilai C1 dan C2, kemudian dilakukan inialisasi posisi dan *velocity* partikel secara acak. Selanjutnya dihitung nilai *fitness* menggunakan fungsi objektif FCM untuk menentukan *pbest* dan *gbest*. Partikel kemudian diperbarui melalui proses *update velocity* dan posisi hingga iterasi maksimum tercapai, sehingga diperoleh pusat kluster awal yang optimal untuk proses klusterisasi FCM.



Gambar 2. Flowchart Pusat Kluster Awal dengan PSO

2.6. Klasterisasi dengan Fuzzy C-Means

Gambar 3 menunjukkan alur proses klasterisasi menggunakan metode FCM dengan pusat klaster awal dari hasil PSO. Proses dimulai dengan menentukan parameter seperti jumlah klaster, parameter *fuzziness*, iterasi maksimum, dan toleransi konvergensi, kemudian dilakukan perhitungan derajat keanggotaan dan pembaruan pusat klaster secara berulang. Selanjutnya dihitung perubahan pusat klaster hingga nilai perubahan lebih kecil dari toleransi konvergensi atau mencapai maksimum iterasi, sehingga diperoleh hasil klasterisasi akhir.



Gambar 3. Flowchart Klasterisasi dengan FCM

2.7. Evaluasi Klaster

Evaluasi klaster dalam penelitian menggunakan tiga metode evaluasi, yaitu Davies Bouldin Indeks (DBI), Partition Coefficient (PC), dan Partition Entropy (PE). DBI digunakan untuk mengukur kualitas klaster dengan nilai terbaik mendekati 0, PC digunakan untuk menilai kejelasan pembagian klaster dengan nilai terbaik mendekati 1, sedangkan PE digunakan untuk mengukur tingkat kekaburan klaster dengan nilai terbaik mendekati 0.

2.8. Analisis Segmentasi Pelanggan

Dalam analisis segmentasi pelanggan, dilakukan perhitungan nilai rata-rata untuk setiap fitur LRFM pada masing-masing klaster, kemudian dibandingkan dengan rata-rata global seluruh data. Jika nilai rata-rata fitur pada klaster lebih tinggi dari rata-rata global maka diberi tanda panah ke atas (↑), sedangkan jika lebih rendah diberi tanda panah ke bawah (↓).

2.9. Pengembangan Sistem


Pengembangan sistem dalam penelitian ini berupa pembuatan *website* menggunakan flask dan menggunakan *framework* Flask yang bernama SegemenXpert. SegmenXpert terdiri dari lima fitur, yaitu

dashboard, fitur pengelolaan data pelanggan, proses klusterisasi, penyajian hasil klusterisasi, dan penyajian hasil segmentasi pelanggan.

3. Hasil dan Pembahasan

3.1. Penentuan Jumlah Kluster


Nilai *Silhouette Score* untuk jumlah kluster pada rentang 2 hingga 10 ditunjukkan pada Gambar 4. Hasil pengujian menunjukkan bahwa jumlah kluster sebanyak 2 memperoleh nilai *Silhouette Score* tertinggi, yaitu sebesar 0,593. Oleh karena itu, jumlah kluster optimal ditetapkan sebanyak dua karena memiliki nilai *Silhouette Score* yang paling tinggi dan paling mendekati 1 dibandingkan jumlah kluster lainnya, sehingga menunjukkan kualitas kluster yang paling baik untuk dataset yang digunakan dalam penelitian ini.




Gambar 4. Jumlah Kluster Optimal Berdasarkan Nilai Silhouette

3.2. Tuning Parameter PSO


Proses penentuan parameter terbaik dilakukan menggunakan metode *grid search* dengan menguji 600 kombinasi parameter PSO. Pada setiap kombinasi, PSO digunakan untuk menghasilkan pusat kluster awal yang selanjutnya menjadi input dalam proses klusterisasi menggunakan FCM. Parameter terbaik dipilih berdasarkan nilai fungsi objektif PSO yang paling kecil. Hasil pengujian menunjukkan bahwa kombinasi parameter terbaik adalah $n_particles = 50$, $w_inertia = 0,70$, $C1 = 1,50$, dan $C2 = 1,00$, dengan nilai fungsi objektif sebesar 57,280197. Kombinasi parameter tersebut menghasilkan solusi terbaik karena mampu memberikan nilai fungsi objektif paling kecil dibandingkan kombinasi parameter lainnya, sehingga menghasilkan pusat kluster awal yang lebih optimal untuk proses klusterisasi FCM.




Gambar 5. Grafik Pengaruh Jumlah Partikel



Gambar 6.1. Grafik Pengaruh Bobot Inersia



Gambar 6.2. Grafik Pengaruh C1



Gambar 6.3. Grafik Pengaruh C2


3.3. Hasil Implementasi dan FCM dengan Inisialisasi PSO

Pengujian algoritma FCM-PSO dilakukan sebanyak 10 kali *running* dengan jumlah klaster optimal yang telah ditentukan sebelumnya yaitu 2 klaster. Parameter yang digunakan pada proses ini adalah nilai *fuzziness* $w = 2.0$, kriteria konvergensi 0,00001, jumlah partikel PSO sebanyak 50, maksimum iterasi 100, $w_{inertia} = 0,7$, $C1 = 1,5$, dan $C2 = 1,0$. Proses pada setiap *running* terdiri dari dua tahap, yaitu

PSO terlebih dahulu untuk menghasilkan posisi pusat kluster awal yang mendekati solusi optimal, kemudian dilanjutkan dengan FCM untuk memperhalus hasil klasterisasi hingga konvergen. Hasil dari seluruh 10 *running* dapat dilihat pada Tabel 1.

Tabel 1. Hasil Pengujian 10 Kali Running

Run	Obj PSO	Iterasi	Obj Awal FCM	Obj Akhir FCM
1	57.280198	3	57.280198	57.280196
2	58.973530	10	58.973530	57.280196
3	57.280196	1	57.280196	57.280196
4	59.443549	8	59.443549	57.280196
5	57.636811	8	57.636811	57.280196
6	57.954707	9	57.954707	57.280196
7	57.399162	7	57.399162	57.280196
8	57.308297	8	57.308297	57.280196
9	57.417374	8	57.417374	57.280196
10	57.280222	4	57.280222	57.280196



Gambar 7. Visualisasi Posisi Pusat Kluster Awal dan Akhir FCM-PSO

Berdasarkan Tabel 4.7, seluruh 10 *running* menghasilkan nilai fungsi objektif akhir yang sama yaitu 57,280196 dengan rata-rata iterasi FCM sebanyak 6,6 iterasi. Hal ini menunjukkan bahwa metode FCM-PSO mampu menghasilkan proses klasterisasi yang stabil dan konsisten. Stabilitas tersebut ditunjukkan oleh konsistensi nilai fungsi objektif akhir pada seluruh *running*, yang mengindikasikan bahwa PSO secara konsisten menemukan pusat kluster awal yang mendekati solusi optimal. *Running* ke-3 dipilih sebagai hasil terbaik berdasarkan nilai objektif awal PSO dan efisiensi iterasi. Berdasarkan Gambar 7, posisi pusat kluster awal hasil inisialisasi PSO dan pusat kluster akhir hasil FCM menunjukkan pergeseran yang sangat kecil. Hal ini menunjukkan bahwa pusat kluster awal yang dihasilkan PSO sudah berada dekat dengan posisi akhir sehingga FCM hanya memerlukan sedikit iterasi untuk mencapai konvergensi.

3.4. Evaluasi Klaster

Hasil evaluasi metode yang digunakan dalam penelitian ini berupa evaluasi klaster menggunakan DBI, PC, dan PE. Evaluasi kualitas klaster dilakukan pada jumlah klaster 2 hingga 10, hasil pengujian menunjukkan bahwa jumlah klaster 2 memberikan nilai evaluasi terbaik, yaitu DBI sebesar 0,613, PC sebesar 0,845, dan PE sebesar 0,267. Nilai DBI sebesar 0,613 merupakan yang terendah dibandingkan jumlah klaster lainnya, sehingga menunjukkan bahwa klaster yang terbentuk memiliki tingkat kekompakan dalam klaster (*intra-cluster*) dan pemisahan antar klaster (*inter-cluster*) yang paling baik. Meskipun tidak terdapat batas nilai baku yang menyatakan suatu DBI tergolong baik, semakin kecil nilai DBI maka semakin baik kualitas klaster yang dihasilkan. Selain itu, nilai PC sebesar 0,845 merupakan nilai tertinggi yang menunjukkan bahwa sebagian besar data memiliki derajat keanggotaan yang dominan pada satu klaster, sedangkan nilai PE sebesar 0,267 merupakan nilai terendah yang menunjukkan tingkat ketidakpastian keanggotaan data yang rendah. Ketiga metrik tersebut memberikan hasil yang konsisten sehingga dapat disimpulkan bahwa jumlah klaster yang paling optimal dalam penelitian ini adalah dua klaster.

3.5. Analisis Segmentasi Pelanggan

Tabel 2. Hasil Perhitungan Setiap Klaster

Klaster	L		R		F		M	
0	0.0929	↓	0.3456	↑	0.0166	↓	0.0243	↓
1	0.6907	↑	0.0562	↓	0.3014	↑	0.2288	↑
Rata – rata global	0.5305		0.1338		0.2251		0.1740	

Setelah dilakukan klasterisasi menggunakan FCM dengan jumlah 2 klaster, diperoleh klaster 0 sebanyak 287 data dan klaster 1 sebanyak 784 data. Selanjutnya dilakukan perhitungan rata-rata fitur LRFM pada setiap klaster dan dibandingkan dengan rata-rata global untuk menentukan karakteristik masing-masing klaster pada tabel 2. Hasil analisis menunjukkan bahwa klaster 0 memiliki karakteristik $L \downarrow R \uparrow F \downarrow M \downarrow$ yang menandakan pelanggan cenderung tidak aktif dengan nilai transaksi rendah, sehingga dikategorikan sebagai *lost customer* kategori *uncertain new customers* dengan strategi pemasaran berupa *let-go strategy*. Sementara itu, klaster 1 memiliki karakteristik $L \uparrow R \downarrow F \uparrow M \uparrow$ yang menunjukkan pelanggan aktif dengan kontribusi transaksi tinggi, sehingga dikategorikan sebagai *core customer* kategori *including high value loyal customers* dengan strategi pemasaran berupa *enforced strategy*.

3.6. Pengembangan Sistem

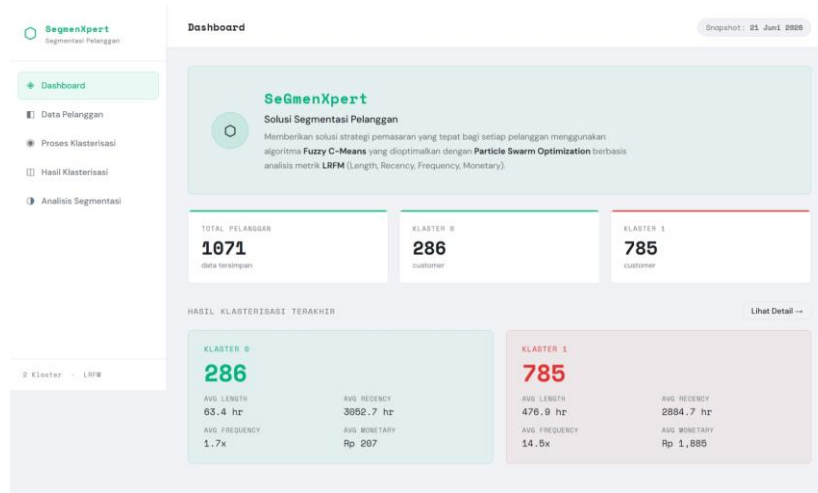
Model klasterisasi yang telah dibuat kemudian dikembangkan dalam bentuk *website* yang bernama SegemenXpert menggunakan *framework* Flask untuk melakukan klasterisasi dan memberikan strategi pemasaran bagi setiap pelanggan.

a. Dashboard

Gambar 8 adalah tampilan menu *dashboard* yang terdapat penjelasan mengenai SegmenXpert, jumlah pelanggan, jumlah klaster 0, jumlah klaster 1, dan hasil klasterisasi terakhir.

b. Data Pelanggan

Gambar 9 adalah fitur data pelanggan yang terdiri dari *form input* data pelanggan dan tabel yang berisi baris data pelanggan yang telah *diinputkan*. Adapun kolom atau *input* yang dilakukan, yaitu berupa id pelanggan, tanggal pertama transaksi, tanggal terakhir transaksi, jumlah transaksi, dan total belanja. Data tersebutlah yang selanjutnya akan memasuki tahap *preprocessing* data.



Gambar 8. Fitur Dashboard

#	ID PELANGGAN	TGL PERTAMA	TGL TERAKHIR	JML TRANSAKSI	TOTAL BELANJA	AKSI
1	CUST-001	2017-01-11	2018-07-18	18x	# 1,700	Edit Hapus
2	f54a9f9e6b351c431402b8401e051999	2017-01-23	2018-07-31	25x	# 2,236	Edit Hapus
3	f59c3b73fe7833bf53a1be19a0f17c81	2017-07-05	2018-08-13	17x	# 1,635	Edit Hapus

Gambar 9. Fitur Data Pelanggan


c. Proses Klasterisasi

Gambar 10 adalah fitur proses klasterisasi yang dilakukan dengan menekan tombol "Jalankan Proses Klasterisasi". Setelah menekan tombol tersebut maka proses klasterisasi akan berjalan di belakang sistem dengan menentukan pusat kluster awal menggunakan algoritma PSO, lalu pusat kluster tersebut digunakan sebagai inisialisasi dalam algoritma Fuzzy C-Means untuk melakukan proses pengelompokan data ke dalam sejumlah kluster yang telah ditentukan. Proses klasterisasi ditunggu dengan waktu beberapa detik.

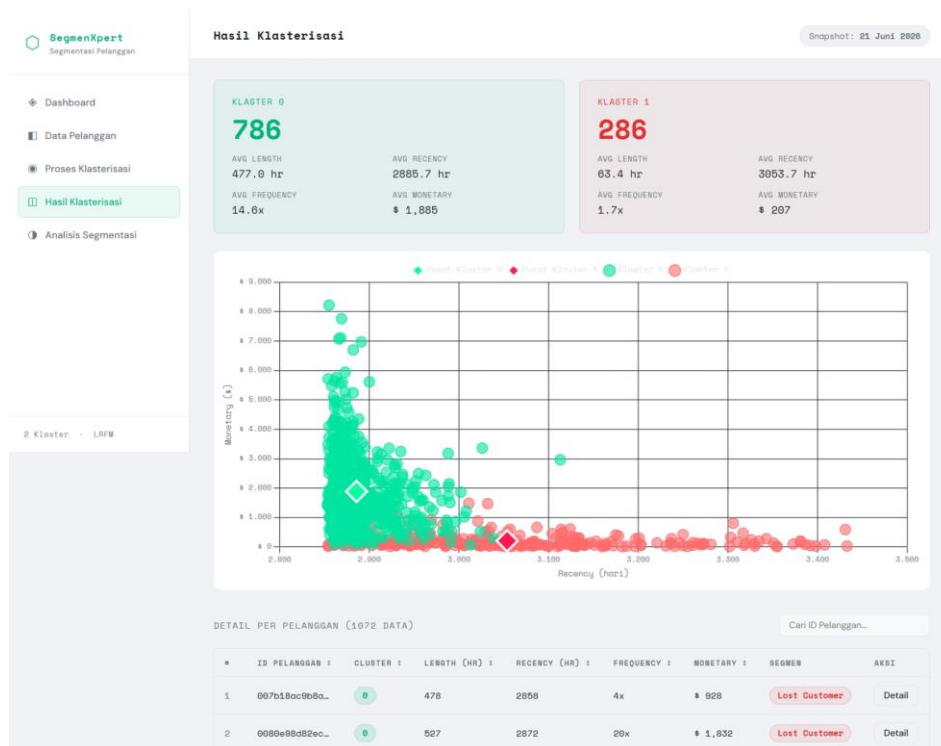
d. Analisis Segmentasi

Gambar 12 adalah fitur Analisis Segmentasi berupa hasil perhitungan rata-rata fitur, rata-rata global, dan hasil simbolnya yang merupakan hasil perbandingan rata-rata fitur dengan global. Selain itu, terdapat informasi hasil segmentasi dan kategori pelanggan sekaligus program strategi dan aktivitas

pemasaran setiap segmen. Setelah mendapat hasil segmentasi, hasilnya disimpan dengan tombol “Simpan Hasil Segmentasi” untuk menyimpan data hasil segmen bagi setiap data pelanggan.



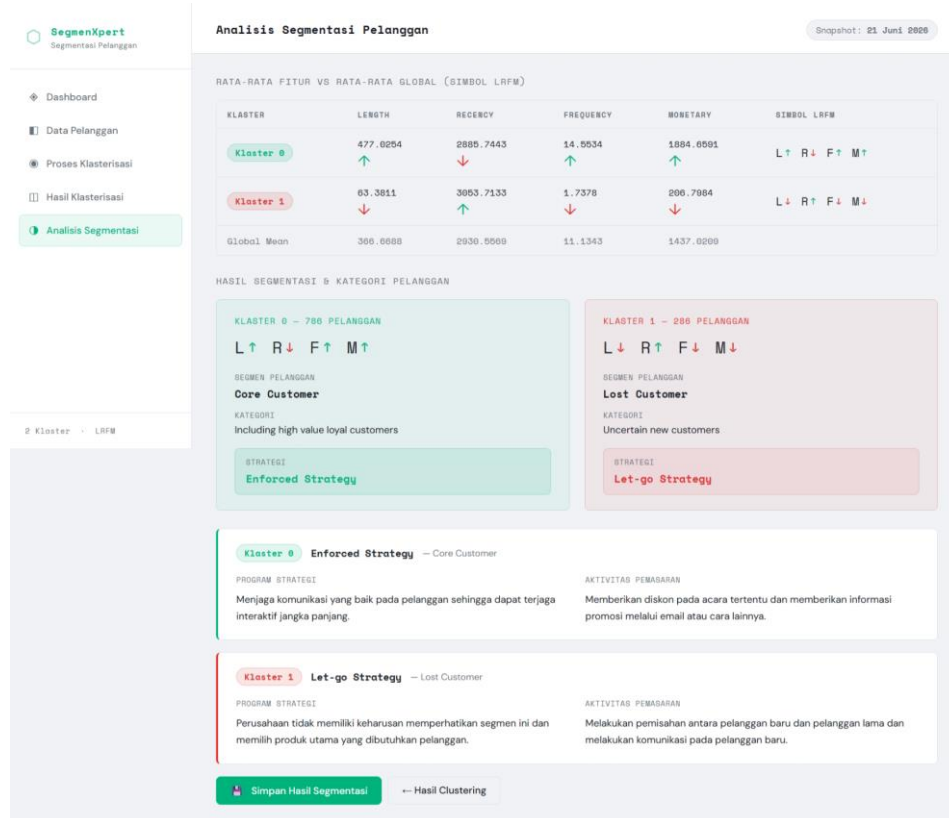
Gambar 10. Fitur Proses Klusterisasi



Gambar 11. Fitur Hasil Segmentasi

e. Analisis Segmentasi

Gambar 12 adalah fitur Analisis Segmentasi berupa hasil perhitungan rata-rata fitur, rata-rata global, dan hasil simbolnya yang merupakan hasil perbandingan rata-rata fitur dengan global. Selain itu, terdapat informasi hasil segmentasi dan kategori pelanggan sekaligus program strategi dan aktivitas pemasaran setiap segmen. Setelah mendapat hasil segmentasi, hasilnya disimpan dengan tombol “Simpan Hasil Segmentasi” untuk menyimpan data hasil segmen bagi setiap data pelanggan.



Gambar 12. Analisis Segmentasi Pelanggan

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, diperoleh kesimpulan bahwa parameter terbaik PSO untuk inisialisasi pusat kluster diperoleh melalui proses tuning hyperparameter dengan kombinasi jumlah partikel 50, bobot inersia 0,7, nilai C1 sebesar 1,5, dan C2 sebesar 1,0. Selanjutnya, hasil evaluasi menunjukkan bahwa jumlah kluster terbaik adalah 2 dengan nilai DBI sebesar 0,613, PC sebesar 0,845, dan PE sebesar 0,267 yang menunjukkan kualitas kluster yang baik. Berdasarkan hasil segmentasi LRFM menggunakan metode FCM-PSO, kluster 0 termasuk segmen *lost customer* kategori *uncertain new customers* dengan strategi pemasaran *let-go strategy*, sedangkan kluster 1 termasuk segmen *core customer* kategori *including high value loyal customers* dengan strategi pemasaran *enforced strategy*.

References

- [1] R. S. Dewi, Surjanti, Widowati, B. S. Eko, and E. Pangestuti, "The Role of Mediators in ASEAN Trade Disputes in Consumer Protection Law Perspective," in *Proceedings of the International Seminar on Business, Education and Science*, 2022, pp. 241–251.
- [2] Martono and M. Syafrullah, "Pengklasteran dan Segmentasi Karakteristik Donatur Sedekah Daring Dengan Teknik Penambangan Data," *Jurnal Inovtek Polbeng Seri Informatika*, vol. 4, no. 1, pp. 366–380, 2024.
- [3] D. L. Aditya and F. Devi, "Comparative Study of Fuzzy C-Means and K-Means Algorithm for Grouping Customer Potential in Brand Limback," *Jurnal Riset Informatika*, vol. 3, no. 4, pp. 327–334, 2021.
- [4] N. Sa'diyah, A. A. Supianto, and C. Dewi, "Implementasi Algoritme Fuzzy C-Means dengan Particle Swarm Optimization (FCMP SO) untuk Pengelompokan Proses Berpikir Siswa dalam

- Proses Belajar,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 4, no. 6, pp. 1625–1632, 2020, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [5] N. P. Rahmasari, I. Fibriani, and W. Cahyadi, “ANALISIS PERBANDINGAN METODE PARTICLE SWARM OPTIMIZATION DAN METODE ALGORITMA GENETIKA UNTUK OPTIMASI RUTE FIBER TO THE HOME PADA PERUMAHAN BERNADY LAND SLAWU JEMBER,” *Jurnal Arus Elektro Indonesia*, vol. 7, no. 1, pp. 29–34, 2021.
- [6] I. Karima and A. Rahman, “Implementasi Metode Fuzzy Mamdani dalam Pengambilan Keputusan Rekomendasi Jumlah Produksi,” 2024. [Online]. Available: <https://jurnal.citanusantara.id/index.php/inokom>
- [7] M. I. Hidayah and R. Sulaiman, “Analisis Sentimen Twitter terhadap Calon Gubernur DKI Jakarta 2024 Menggunakan Logika Fuzzy Mamdani,” *Jurnal Ilmiah Matematika*, vol. 13, no. 3, pp. 342–349, 2025.
- [8] A.-Y. Al-Yasir, M. Afdal, Z. Zarnelly, and A. Marsal, “Analisis Loyalitas Pelanggan Business To Business Berdasarkan Model RFM Menggunakan Algoritma Fuzzy C-Means,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 1, pp. 359–365, Jan. 2024, doi: 10.57152/malcom.v4i1.1163.
- [9] Y. Raharja, A. S. Fitriani, and R. Dijaya, “KLASIFIKASI TINGKAT PARTISIPASI PEMILU BERDASARKAN SEKTOR INDUSTRI MENGGUNAKAN ALGORITMA NAÏVE BAYES,” *Jurnal Tekinkom (Teknik Informasi dan Komputer)*, vol. 7, no. 1, pp. 135–143, 2024.
- [10] C. M. Sidiq, A. Faqih, and G. Dwilestari, “ALGORITMA DECISION TREE C4. 5 DIGUNAKAN UNTUK MENGLASIFIKASIKAN DATA STROKE,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 2, pp. 1869–1874, 2024.
- [11] D. Ayu, I. C. Dewi, and K. Pramita, “Analisis Perbandingan Metode Elbow dan Silhouette pada Algoritma Clustering K-Medoids dalam Pengelompokan Produksi Kerajinan Bali,” *JURNAL MATRIX*, vol. 9, no. 3, pp. 102–109, 2019.
- [12] G. Papazoglou and P. Biskas, “Review and Comparison of Genetic Algorithm and Particle Swarm Optimization in the Optimal Power Flow Problem,” Feb. 01, 2023, *MDPI*. doi: 10.3390/en16031152.
- [13] A. P. Piotrowski, J. J. Napiorkowski, and A. E. Piotrowska, “Population size in Particle Swarm Optimization,” *Swarm Evol. Comput.*, vol. 58, Nov. 2020, doi: 10.1016/j.swevo.2020.100718.
- [14] S. Ramadhani *et al.*, “Sensitivity Analysis of Parameter Control in Leukemia Classification Using Variable-Length Particle Swarm Optimization Sunway Medical Centre,” vol. 16, no. 2, pp. 58–71, 2025, doi: 10.31849/digitalzone.v16i2.
- [15] Y. Zhang, “Elite archives-driven particle swarm optimization for large scale numerical optimization and its engineering applications,” *Swarm Evol. Comput.*, vol. 76, p. 101212, 2023, doi: <https://doi.org/10.1016/j.swevo.2022.101212>.
- [16] D. Tarekegn Nigatu, T. Gemechu Dinka, and S. Lulseged Tilahun, “Convergence analysis of particle swarm optimization algorithms for different constriction factors,” *Front. Appl. Math. Stat.*, vol. 10, 2024, doi: 10.3389/fams.2024.1304268.
- [17] U. Kruthika and S. Paneerselvam, “Improved Adaptive PSO-based Gain Tuning for PID Controllers in Utility Boilers,” in *Procedia Computer Science*, Elsevier B.V., 2023, pp. 183–192. doi: 10.1016/j.procs.2023.12.073.

