

SEGMENTASI PELANGGAN PRIVATE GYM BERDASARKAN DATA BOOKING DENGAN ALGORITMA K-MEANS

Ahmad Rizky Ramadani¹⁾, Ahmad Faisol²⁾, Deddy Rudhistiar³⁾

^{1,2,3)}Program Studi Teknik Informatika, Fakultas Teknologi Industri, Institut Teknologi Nasional Malang
Jl. Raya Karanglo KM. 2, Tasikmadu, Kec. Lowokwaru, Kota Malang, Jawa Timur 65153
Email: ¹12218103@scholar.itn.ac.id, ²mzfai@lecturer.itn.ac.id, ³rudhistiar@lecturer.itn.ac.id

Abstract

The growth of the fitness industry has driven an increase in public interest in private gym services that offer a more personalized training experience. However, management faces challenges in understanding the diverse behavior of customers, making it difficult to appropriately target service and marketing strategies. This study aims to segment private gym customers based on booking data using the K-Means algorithm. The data used includes the number of booking sessions, training duration, and booking time. The research methodology includes data preprocessing, application of the K-Means algorithm to form customer segmentations, and evaluation of the results using the Elbow method to determine optimal k value and Silhouette Score to ensure the quality of clusters. The implementation is carried out on a web-based system using the Laravel framework, which displays segmentation results in tables and graphical visualizations. The study findings show that customers can be grouped into three main segments: active, passive, and potential customers. The clustering result is indicated have good result based on Silhouette Score testing result, which give 0.51 score for the clustering results. In conclusion, the application of the K-Means algorithm helps private gym management understand customer characteristics and formulate more effective, data-driven business strategies.

Keywords: Clustering, K-Means, Private Gym, Segmentation, Silhouette Score

Abstrak

Perkembangan industri kebugaran mendorong meningkatnya minat masyarakat terhadap layanan private gym yang menawarkan pengalaman berlatih yang lebih personal. Namun, tantangan yang dihadapi manajemen adalah memahami perilaku pelanggan yang beragam agar strategi pelayanan dan pemasaran dapat tepat sasaran. Studi ini bertujuan untuk mengelompokkan pelanggan private gym berdasarkan data booking menggunakan algoritma K-Means. Data yang digunakan meliputi jumlah sesi booking, durasi latihan, serta waktu pemesanan. Metode penelitian mencakup tahap pra-pemrosesan data, penerapan algoritma K-Means untuk membentuk kelompok pelanggan, serta menggunakan Elbow Method untuk menentukan nilai k yang optimal dan mengetahui kualitas cluster yang dihasilkan dengan Silhouette Score. Implementasi dilakukan pada sistem berbasis web menggunakan framework Laravel yang menampilkan hasil segmentasi dalam bentuk tabel dan visualisasi grafik. Hasil penelitian menunjukkan bahwa pelanggan dapat dikelompokkan menjadi tiga segmen utama, yaitu pelanggan aktif, pasif, dan potensial. Hasil clustering dapat diindikasikan baik berdasarkan pengujian kualitas hasil clustering dengan menggunakan metode silhouette score yang memberikan nilai 0.51. Kesimpulannya, penerapan algoritma K-Means mampu membantu manajemen private gym dalam memahami karakteristik pelanggan serta merumuskan strategi bisnis yang lebih efektif dan berbasis data.

Kata Kunci: Gym Privat, K-Means, Pengelompokan, Segmentasi, Silhouette Score

1. Pendahuluan

Seiring berkembangnya teknologi dan kesadaran masyarakat terhadap pola hidup sehat semakin meningkat, industri kebugaran juga berkembang pesat. Salah satunya adalah *private gym*, yaitu fasilitas kebugaran yang menerapkan sistem reservasi eksklusif untuk memberikan pengalaman berlatih yang lebih personal. Meskipun demikian, manajemen *private gym* menghadapi tantangan, salah satunya adalah memahami perilaku pelanggan yang beragam. Setiap pelanggan memiliki pola berbeda dalam frekuensi latihan, dan durasi sesi latihan [1].

Apabila pola perilaku pelanggan tidak dianalisis secara tepat, maka strategi pelayanan dan pemasaran yang diterapkan dapat menjadi tidak tepat sasaran dan kurang efektif. Karena itu, pendekatan berbasis data (*data-driven*



approach) memiliki peran penting dalam membantu manajemen untuk mengetahui pola perilaku pelanggan. Salah satu metode *unsupervised learning* yang dapat digunakan untuk mengelompokkan kumpulan data menjadi beberapa kelompok berdasarkan kemiripan karakteristik adalah *K-Means Clustering* [2]. Pada studi ini, peneliti memilih K-Means karena data digunakan bersifat numerik dan jumlah kelompok (*cluster*) yang akan dibentuk sudah diketahui dari awal.

Gym Zone merupakan salah satu *private gym* yang ada di Indonesia yang berdiri dibawah bendera PT. Gymzone Inovasi Indonesia sejak tahun 2024. Saat ini, pihak manajemen PT. Gymzone Inovasi Indonesia Didalam sistem yang berjalan saat ini, masih belum terdapat fitur yang dapat memberikan *output* berupa data pelanggan yang aktif, pasif dan potensial, sehingga pihak manajemen kesulitan untuk dapat menemukan pola perilaku pelanggannya. Oleh karena itu, penelitian ini dilandaskan berdasarkan kebutuhan manajemen PT. Gymzone Inovasi Indonesia yang membutuhkan sistem untuk dapat menampilkan kelompok pelanggan berdasarkan riwayat *booking*-nya.

Penelitian ini dilakukan untuk mengelompokkan pelanggan *private gym* menjadi tiga kategori, yaitu aktif, pasif, dan potensial dengan menganalisis data riwayat *booking* mereka menggunakan algoritma *K-Means*. Agar hasil pengelompokan ini mudah dipahami dan ditindaklanjuti, peneliti membangun sistem web dengan *framework* Laravel untuk menampilkannya secara visual dan interaktif. Pada akhirnya, temuan dari penelitian ini diharapkan bisa membantu manajemen *gym* dalam menentukan strategi pemasaran dan promosi yang lebih tepat dan efektif.

2. Metode

2.1 Data Mining

Salah satu bidang ilmu komputer yang saat ini banyak dimanfaatkan dalam beragam penelitian untuk menggali informasi dari data adalah *Data Mining*. Beberapa algoritma yang sering digunakan dalam *data mining*, yaitu *K-Means*, DBSCAN [3]. *Data mining* dapat digunakan untuk mengidentifikasi pola – pola tersembunyi dari kumpulan data yang besar atau bisa disebut sebagai *knowledge discovery*, karena bertujuan untuk menemukan pengetahuan atau wawasan baru yang sebelumnya tidak tampak [4].

2.2 Clustering

Clustering adalah salah satu teknik *data mining* yang termasuk ke dalam kategori *unsupervised learning*. Teknik ini dapat digunakan untuk menganalisis data dan mengkategorikannya ke dalam kelompok tertentu berdasarkan kemiripan karakteristiknya [4]. *Clustering* banyak digunakan ke dalam berbagai bidang untuk menemukan pola, segmentasi data, dan mengidentifikasi masalah.

2.3 Algoritma K-Means

Salah satu metode kecerdasan buatan yang bekerja dengan cara mengelompokkan data menjadi ke dalam beberapa bagian kelompok berdasarkan memiliki karakteristik serupa adalah algoritma *K-Means*. *K-Means* termasuk ke dalam *partitioning clustering*, yaitu algoritma yang dapat memisahkan data kedalam kelompok yang berbeda [5]. Algoritma *K-Means* bekerja dengan cara dengan membagi kelompok berdasarkan nilai K. Nilai K sendiri dapat ditentukan dari awal atau ditentukan melalui *elbow method*. Setelah itu ditentukan nilai *centroid* secara acak sebagai titik pusat dari masing – masing kelompok K. Selanjutnya data akan dibagi kedalam kelompok K berdasarkan *centroid* (nilai titik pusat) yang terdekat dengan menggunakan rumus *Euclidean Distance* [6].

Berikut merupakan tahapan dari algoritma *K-Means* :

1. Melakukan normalisasi data
2. Menentukan jumlah *cluster* atau nilai K.
3. Menentukan nilai *centroid* secara acak sebagai titik pusat masing – masing *cluster*.
4. Mengukur jarak setiap data terhadap *centroid* menggunakan persamaan berikut[5].

$$D_{(x,y)} = \sqrt{\sum_{i=0}^n (x_i - y_i)^2} \quad (1)$$

Penjelasan :

$D_{(x,y)}$ = Nilai jarak antara titik x dan y

x_i = Nilai atribut ke- i dari data

y_i = Nilai atribut ke- i dari *centroid*

n = Jumlah atribut

5. Melakukan tahap iterasi dengan menghitung jarak data terhadap *centroid* dengan persamaan (4)
6. Data dimasukkan kedalam masing – masing *cluster* berdasarkan jarak *centroid* terdekat dengan data tersebut.
7. Mengubah nilai *centroid* baru melalui rata – rata *cluster* yang sebelumnya dengan persamaan berikut [6]

$$C_k = \left(\frac{1}{n_k} \right) \sum d_i \quad (2)$$

Penjelasan :

C_k = *Centroid* cluster ke- k

n_k = Jumlah data pada *cluster* ke- k

d_i = Vektor data ke- i yang termasuk *cluster* ke- k

Jika nilai *centroid* baru tidak sama dengan *centroid* lama, maka Langkah 5-7 diulangi kembali. Apabila *centroid* yang

baru sudah sama, maka proses iterasi berhenti dan selesai dengan nilai *centroid* akhir yang terbaru.

2.4 Normalisasi Data

Salah satu metode normalisasi data yang diterapkan oleh peneliti adalah *min-max normalization*. *Min-Max Normalization* adalah metode yang dilakukan untuk merubah nilai suatu data menjadi rentang antara 0 hingga 1. Berikut merupakan persamaan untuk menghitung *MinMax Normalization* [7]

$$X^i = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3)$$

Penjelasan :

X = Nilai asli dari suatu fitur

X^i = Nilai ke- i hasil normalisasi

X_{min} = Nilai terkecil dari fitur tersebut pada seluruh data

X_{max} = Nilai terbesar dari fitur tersebut pada seluruh data

2.5 Evaluasi Silhouette Score

Peneliti menggunakan metode *silhouette score* untuk dapat menilai kualitas hasil *clustering*. *Silhouette Score* digunakan untuk mengukur seberapa baik setiap data dimasukkan kedalam masing – masing *cluster*-nya dengan mempertimbangkan kedekatan antar data dalam satu *cluster* (*cohesion*) dan jarak antar *cluster* yang berbeda (*separation*) [8]. Nilai silhouette score dihitung dengan persamaan berikut [8].

$$s(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (4)$$

Penjelasan :

$s(i)$ = Nilai *silhouette score* berada pada rentang $-1 \leq s(i) \leq 1$

$a(i)$ = Rata – rata jarak antara data ke- i dengan seluruh data lain dalam cluster yang sama

$b(i)$ = Rata – rata jarak minimum antara data ke- i dengan seluruh data dalam cluster lain

Rentang nilai $s(i)$ memiliki penjelasan sebagai berikut.

$s(i)$ mendekati 1, artinya data berada pada *cluster* yang tepat dan terpisah dengan baik dari *cluster* lain.

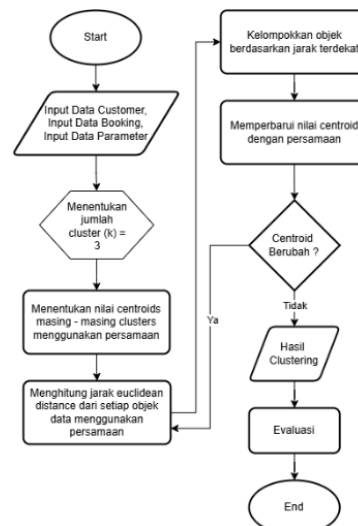
$s(i)$ mendekati 0, artinya data berada dibatas antara 2 *cluster*.

$s(i)$ mendekati -1, artinya data menempati *cluster* yang salah.

2.6 Sistem Informasi

Sistem informasi merupakan sistem yang terintegrasi dengan beberapa komponen dan berisikan untuk fungsi mengolah, menyimpan, dan mendistribusikan informasi yang dibutuhkan oleh pengguna. Seluruh komponen tersebut berfungsi untuk mengorganisasikan jaringan komunikasi strategis, mengelola proses transaksi rutin, serta menyediakan landasan substantif bagi pengambilan keputusan strategis baik untuk kebutuhan internal maupun eksternal organisasi [10].

2.7 Diagram Alir Algoritma K-Means

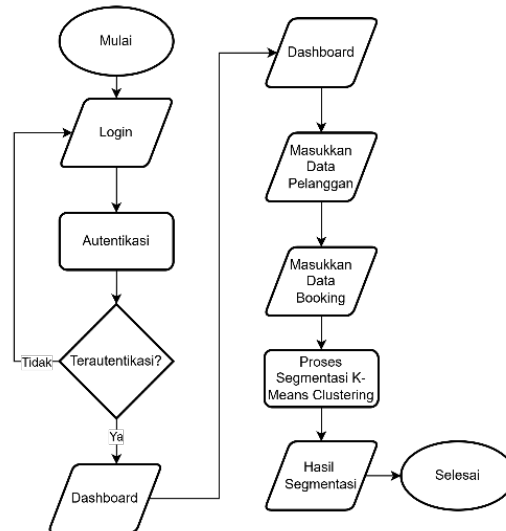


Gambar 1. Flowchart Metode K-Means

Algoritma *K-Means* dimulai dengan memasukkan data *customer*, *booking* dan *parameter* yang akan digunakan. Kemudian menentukan nilai k atau jumlah berapa banyak kelompok yang diharapkan. Nilai k pada studi ini sudah

diketahui dari awal, karena data ingin dibagi menjadi 3 kelompok, yaitu aktif, pasif dan potensial. Selanjutnya menentukan nilai centroid untuk masing – masing cluster secara acak. Lalu menggunakan persamaan *euclidian distance* untuk menghitung jarak antara data dan *centroid*. Lalu menentukan kelompok masing – masing data berdasarkan jarak terdekatnya dengan *centroid*. Nilai centroid diperbarui secara iteratif hingga nilai *centroid* stabil tidak ada perubahan. Setelah itu, hasil clustering dievaluasi dengan metode *silhouette score* sebelum ditampilkan kedalam bentuk grafik [5].

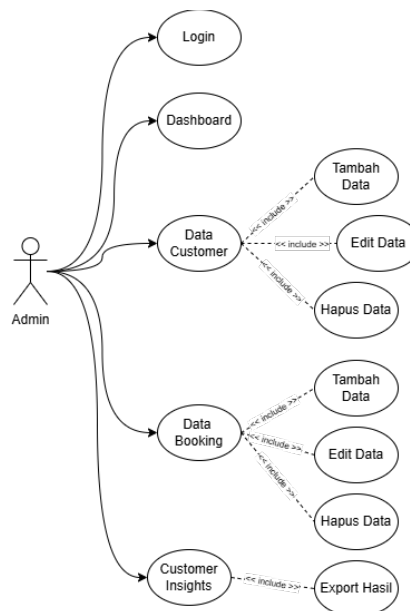
2.8 Flowchart Sistem



Gambar 2. Alur Sistem

Proses alur sistem segmentasi pelanggan dimulai dari login dan diautentikasi. Apabila tidak terautentikasi, admin diarahkan kembali ke *login page*. Apabila terautentikasi, maka akan diarahkan ke *dashboard*. Setelah itu proses dapat dilanjutkan dengan memasukkan data pelanggan, dan data *booking*. Setelah data terisi, maka proses segmentasi *K-Means clustering* sudah bisa dilakukan cukup dengan mengakses menu yang sudah disediakan. Setelah proses clustering selesai, user akan diberikan hasil segmentasi dalam bentuk representasi grafik, selain itu user juga akan diberikan hasil dari *silhouette score* dari hasil *clustering* tersebut.

2.9 Use Case Diagram



Gambar 3. Use Case Diagram

Use case diagram sistem dirancang untuk menggambarkan hubungan antara entitas dan fungsionalitas sistem yang tersedia. Aktor utama yang terlibat adalah admin yang berperan sebagai pengguna sistem. Sebelum dapat mengakses sistem, admin terlebih dahulu diwajibkan melakukan login sebagai proses autentikasi. Saat proses autentikasi berhasil, admin diarahkan menuju dashboard sebagai pusat navigasi. Dari dashboard tersebut, admin dapat melakukan pengelolaan

data *customer* yang meliputi penambahan data baru, perubahan data yang telah tersimpan, serta penghapusan data yang tidak diperlukan. Selain itu, admin juga memiliki akses terhadap pengelolaan data booking dengan fungsi yang serupa, yaitu menambah, mengedit, dan menghapus data *booking*. Sistem ini juga dilengkapi dengan fitur customer 9 insights yang digunakan untuk menyajikan analisis data customer. Hasil dari analisis tersebut dapat diekspor dalam format tertentu guna mendukung kebutuhan strategi bisnis dan promosi.

3. Hasil dan Pembahasan

3.1 Datasets

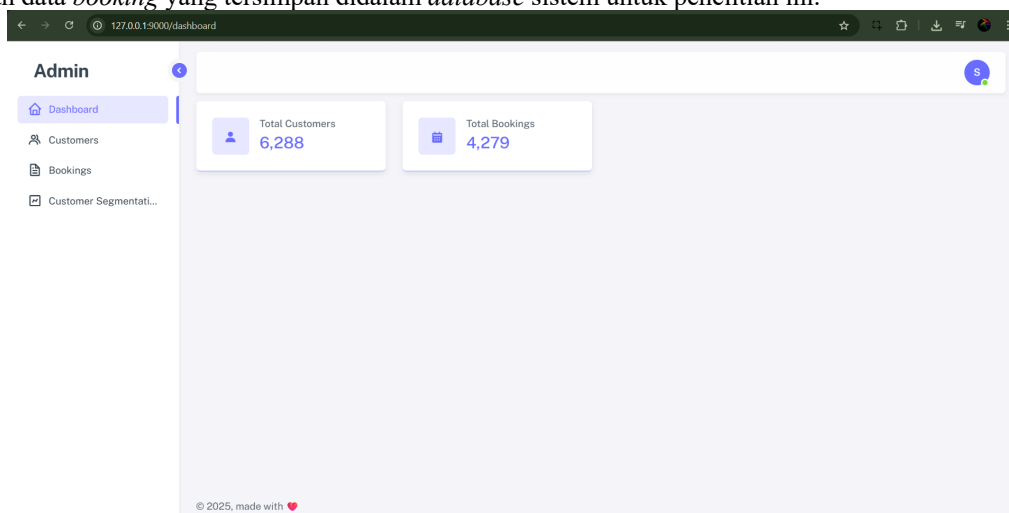
Studi ini menggunakan *Dataset* yang meliputi data transaksi *booking* pada periode Desember 2024 sampai Agustus 2025, yang terdiri dari 6288 data *customers* dan 4280 data *booking*. *Dataset* yang digunakan telah dilakukan proses normalisasi dan *pre-processing* terlebih dahulu. Tahapan *pre-processing* yang dilakukan yaitu melakukan *filtering* data dengan hanya menggunakan data *booking* yang memiliki status *On Going*, *Check In* dan *Done*. Hal ini bertujuan agar data yang digunakan adalah data *booking* aktif saja. Kemudian dilanjutkan dengan menghitung nilai frekuensi *booking* berdasarkan banyaknya jumlah *booking* yang dilakukan *customer*, *recency_days* berdasarkan hari terakhir *booking* yang dihitung sejak tanggal saat ini dan *total_sessions* berdasarkan akumulasi total sesi yang telah dilakukan oleh *customer* dari data *booking* berdasarkan kolom *date_start*, *time_start*, dan *time_end* pada tabel *booking*. Setelah itu tahapan *pre-processing* yang dilakukan adalah dengan melakukan normalisasi data, yaitu mengubah nilai dari variabel yang akan digunakan menjadi rentang nilai antara 0 hingga 1. Sehingga terdapat 3 variabel yang akan digunakan sebagai parameter *K-Means*, yaitu *recency days*, *frequency*, dan *total sessions*. Berikut adalah *dataset* yang sudah dinormalisasi yang ditunjukkan pada tabel 1.

Tabel 1. Normalized Datasets Customer Booking dan Nilai Parameter

No	Customer	Recency Days	Frequency	Total Sessions
1	Celsius Wijaya	0,91	0,08	0,09
2	Bryan Jutanzah	0,16	0,13	0,25
3	Ruang Mimpi	1,00	0,00	0,00
4	mariam	0,08	0,03	0,04
5	Fionna A	0,21	0,01	0,00
6	Teddy Wijaya harlim	0,65	0,20	0,27
7	Nusa Harum	0,14	0,04	0,07
8	Zuhdiya Nila Kaloka	0,10	0,08	0,09
9	Muhammad Nur	0,99	0,01	0,02
10	Sandifadli sopandi	0,97	0,03	0,04
...
1419	Riyan Setiawan	0,00	0,01	0,00

3.2 Implementasi Sistem

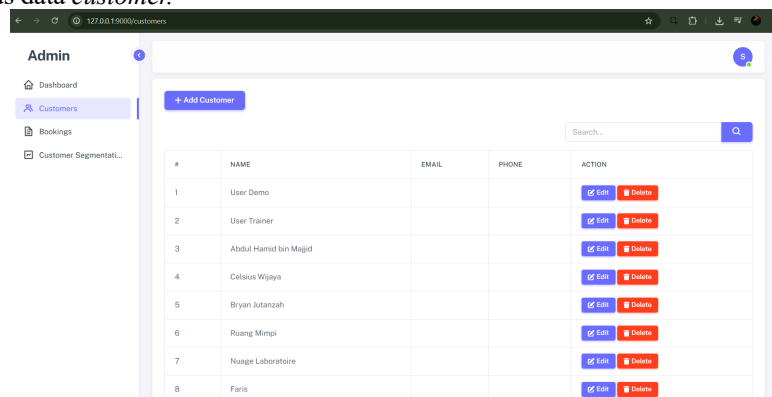
Gambar 4 menunjukkan halaman beranda dari sistem, yang didalamnya memuat informasi terkait jumlah data *customer* dan data *booking* yang tersimpan didalam *database* sistem untuk penelitian ini.



Gambar 4. Halaman *Dashboard*

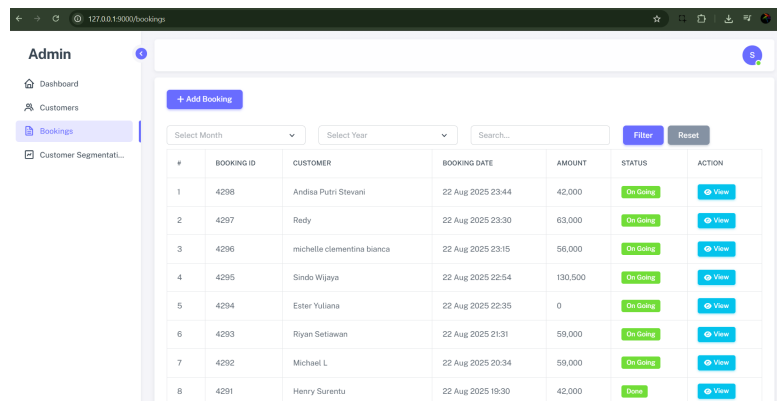
Gambar 5 menunjukkan tampilan web daftar *customer*, dimana didalamnya memuat informasi terkait nama, email

dan nomor telepon *customer*. Terdapat beberapa aksi yang dapat dilakukan, yaitu *edit* untuk mengubah data *customer* dan *delete* untuk menghapus data *customer*.



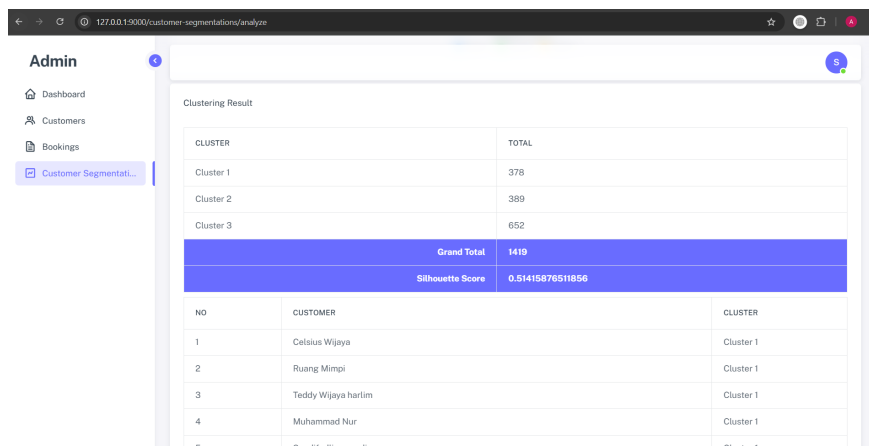
Gambar 5. Halaman *List Customers*

Pada gambar 6 terdapat halaman web data *booking* yang telah dilakukan oleh *customer*. Didalamnya memuat informasi terkait Id *Booking*, *customer*, tanggal *booking*, nominal *booking* dan status *booking*. Data yang ditampilkan adalah data keseluruhan tetapi juga disediakan filter yang dapat digunakan untuk menampilkan data berdasarkan bulan dan tahun *booking*, serta pencarian nama *customer*.

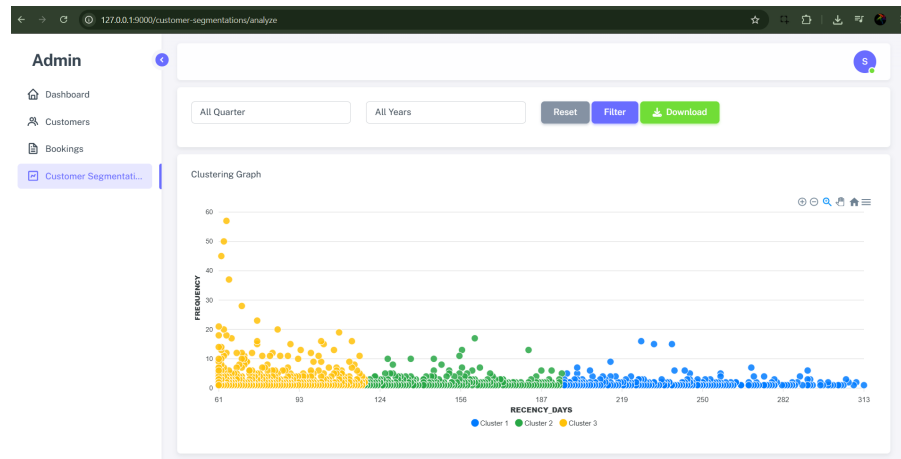


Gambar 6. Tampilan Halaman Data *Bookings*

Pada gambar 7 ditunjukkan halaman proses *clustering* yang menggunakan algoritma *K-Means*, lalu hasilnya ditampilkan dalam bentuk tabel. Kemudian pada gambar 8 ditampilkan halaman segmentasi pelanggan dalam bentuk grafik *scatter plot* dari data hasil proses *clustering* sebelumnya dan pelanggan terbagi ke dalam 3 kelompok, yaitu *cluster 1* yang bisa disebut pelanggan pasif karena memiliki ciri ciri frekuensi rendah, *recency* tinggi, *cluster 2* yang bisa disebut sebagai pelanggan potensial, dan *cluster 3* pelanggan aktif karena memiliki frekuensi dan *recency days* yang tinggi.



Gambar 7. Halaman Proses *Clustering*



Gambar 8. Halaman Segmentasi Pelanggan

Pada gambar 8 ditunjukkan halaman hasil *clustering* yang divisualisasikan dalam bentuk grafik *scatter* dengan data semua periode. Terlihat pada kolom Y-Axis adalah nilai frekuensi dan kolom X-Axis adalah nilai dari *recency days*/hari terakhir *booking*. Cluster ke-1 memiliki indikasi warna biru, *cluster* ke-2 memiliki indikasi warna hijau, dan *cluster* ke-3 memiliki indikasi warna kuning. Setiap *cluster* yang dihasilkan berada pada kelompoknya masing – masing.

3.3 Hasil Clustering

Proses *clustering* seluruh periode memberikan hasil yang ditunjukkan pada tabel 2 dimana, cluster 1 dengan jumlah sebanyak 378 *customer*, untuk cluster 2 sebanyak 389 *customer*, dan cluster 3 sebanyak 652 *customer*.

Tabel 2. Hasil Clustering

No	Customer	Cluster
1	Celsius Wijaya	1
2	Ruang Mimpi	1
3	Teddy Wijaya Harlim	1
4	Muhammad Nur	1
5	Sandifadli sopandi	1
6	Bahar Ficky	1
7	Faiz Almath	1
8	Hafizh Tanjung	1
9	Orvin Jairus	1
10	Jamil	1
...
1419	Tangsel Foodies	2

3.4 Pengujian Blackbox

Pengujian blackbox dilakukan dengan tujuan untuk menguji fungsionalitas dari perangkat lunak berjalan sesuai harapan peneliti dan memberikan *output* yang sesuai. Pada tabel 3 ditunjukkan kesimpulan dari pengujian yang dilakukan dengan beberapa skenario pengujian.

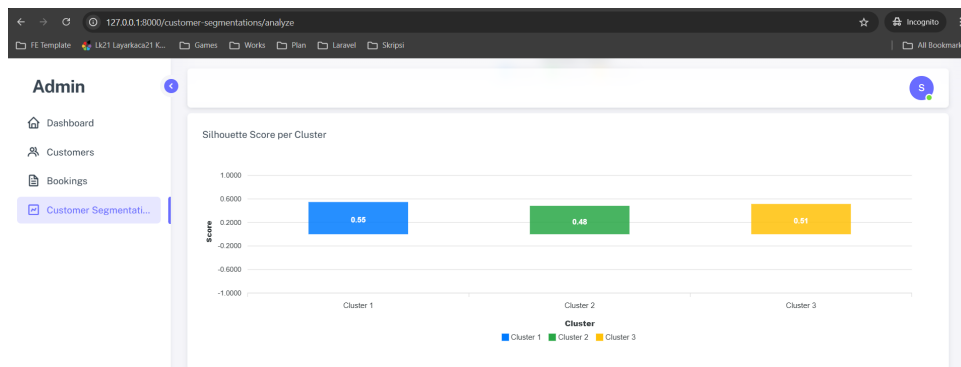
Tabel 3. Tabel Hasil Pengujian Blackbox

No	Fitur	Skenario Uji	Hasil yang Diharapkan	Hasil Uji	Kesimpulan
1	Login	Memasukkan kredensial dengan benar	Username = superadmin Password = 123456	Kredensial terdaftar dalam sistem dan mengarahkan ke halaman <i>dashboard</i>	Sukses
2	Customer	Menambahkan data customer	Nama = 'Budi' Email = 'budi@gmail.com' Password = '123456'	Sistem mengalihkan admin ke halaman data <i>customer</i>	Sukses
3	Booking	Menambahkan	Customer = 'Budi'	Sistem	Sukses

		data booking	Price = 28000 Tanggal = '20-10-2025' Sesi Mulai = '07:00' Sesi Berakhir = '07:30'	mengalihkan admin ke halaman data <i>booking</i>	
4	Proses Clustering	Melakukan filter Periode bulan dan tahun	Bulan = Juli – September Tahun = 2025	Sistem memberikan hasil <i>clustering</i> sesuai dengan <i>filter</i> yang dipilih	Sukses
5	Segmentasi Pelanggan	Melakukan filter Periode bulan dan tahun	Bulan = Juli – September Tahun = 2025	Sistem dapat menampilkan grafik segmentasi pelanggan berdasarkan hasil <i>clustering</i>	Sukses
7	Export Hasil Clustering	Melakukan export excel terhadap hasil <i>clustering</i>	Download file hasil <i>clustering</i> dalam bentuk excel	Sistem dapat memberikan keluaran hasil <i>clustering</i> dalam bentuk file <i>excel</i>	Sukses

3.5 Pengujian Algoritma K-Means

Peneliti melakukan uji kualitas dari hasil *clustering* menggunakan metode *silhouette score*. Pada studi ini, data yang digunakan sebanyak 6288 data *customer* dan 4280 data *booking* pada periode Desember 2024 – Agustus 2025. *Silhouette score* memberikan nilai 0.51 dari keseluruhan data tersebut setelah dilakukan proses *clustering*. Nilai tersebut dapat mengindikasikan bahwa hasil *clustering* tergolong baik. *Cluster* yang dihasilkan cukup jelas terpisah dan sebagian besar data cocok dengan *cluster*-nya tetapi masih bisa ditingkatkan lagi lebih lanjut.



Gambar 9. Pengujian *Silhouette Score*

CLUSTER	TOTAL
Cluster 1	378
Cluster 2	383
Cluster 3	658
Grand Total	1419
Silhouette Score	0.51

NO	CUSTOMER	REGENCY DAYS	FREQUENCY	TOTAL SESSIONS	CLUSTER
1	Celsius Wijaya	314	6	13	Cluster 1
2	Ruang Mimpi	336	1	1	Cluster 1
3	Teddy Wijaya harlim	249	16	32	Cluster 1

Gambar 10. Nilai *Silhouette Score*

Peneliti juga melakukan validasi hasil kualitas *clustering* dengan menggunakan metode *silhouette score* secara manual, sehingga didapatkan nilai *silhouette score* dari hasil *clustering* seperti yang ditunjukkan pada tabel 4 dan tabel 5. Kemudian dilakukan perhitungan nilai rata – rata *silhouette score* dari masing – masing *cluster* dan didapatkan nilai *silhouette score* akhir adalah 0.51. Sehingga dapat disimpulkan bahwa nilai *silhouette score* yang diberikan oleh sistem dan perhitungan secara manual memiliki hasil yang sama dan nilai yang diberikan oleh sistem dapat dinyatakan valid.

Tabel 4. Tabel Pengujian Manual *Silhouette Score*

No	customer	a(i)	b(i)	silhouette_score
1	Celsius Wijaya	0,242649	0,561297	0,567699
2	Ruang Mimpi	0,296198	0,640546	0,537585
3	Teddy Wijaya harlim	0,340118	0,432999	0,214507
4	Muhammad Nur	0,283877	0,628119	0,548052
5	Sandifadli sopandi	0,270839	0,61261	0,557894
6	Bahar Ficky	0,280024	0,624327	0,551478
7	Faiz Almath	0,272203	0,616144	0,558215
8	Hafizh Tanjung	0,119569	0,415253	0,712059
9	Orvin Jairus	0,104355	0,331678	0,685372
10	Jamil	0,260812	0,604497	0,568547
...
1419	Dony Cahyanto	0,139235	0,152783	0,088675

Tabel 5. Tabel Nilai *Silhouette Score*

C1	C2	C3	Overall
0.55	0.48	0.51	0.51

4. Kesimpulan dan Saran

Setelah tahap pengujian *blackbox* dan hasil yang diberikan, dapat disimpulkan bahwa sistem dapat bekerja sesuai fungsinya dan skenario yang sudah dirancang sebelumnya. Sistem dapat memberikan *output cluster* yang representatif dan sesuai dengan kebutuhan. Pengujian *silhouette score* yang telah dilakukan menghasilkan nilai 0.51, ini berarti hasil *cluster* yang diberikan tergolong baik, tetapi masih berpotensi untuk dapat ditingkatkan lebih lanjut agar hasil yang diberikan dapat lebih baik dan lebih akurat. Sistem juga dapat merepresentasikan hasil ke dalam bentuk grafik dengan baik, dan dapat memberikan informasi yang bisa sangat berguna bagi manajemen untuk kedepannya. Hasil *cluster* juga dapat diekspor kedalam bentuk excel dan dapat dimanfaatkan lebih lanjut untuk kebutuhan manajemen dalam menyusun strategi promosi dan pemahaman terkait perilaku pelanggan. Saran peneliti untuk penelitian berikutnya terhadap pengembangan sistem ini, yaitu meningkatkan kualitas sistem dengan melakukan penyempurnaan terhadap proses normalisasi data atau melakukan pengembangan lebih lanjut terhadap hasil *cluster* yang sudah dapat dihasilkan. Sistem ini juga dapat dikembangkan lebih lanjut untuk mengelompokkan masing – masing *cluster* kedalam kelompok lain lagi, sehingga dapat memberikan wawasan baru terhadap pelanggan berdasarkan data *booking* yang sudah dilakukan.

Daftar Pustaka

- [1] A. Bukowski, "Kilo," 28 03 2025. [Online]. Available: <https://usekilo.com/how-to-use-personalization-to-keep-more-gym-members/>. [Accessed 03 09 2025].
- [2] B. Rahmat, U. Narimawati, A. Afandi, S. Priadana and H. Erlangga, "Pengaruh Kualitas Pelayanan dan Strategi Pemasaran Terhadap Minat Beli Konsumen OTOBento.," *JIIP-Jurnal Ilmiah Ilmu Pendidikan*, vol. 5, no. 4, pp. 1118-1122, 2022.
- [3] R. Adha, N. Nurhaliza, U. Soleha and M. , "Perbandingan Algoritma DBSCAN dan K-Means Clustering untuk," *Jurnal Sains, Teknologi dan Industri*, vol. 18, pp. 206 - 211, 2021.
- [4] N. Nugroho and F. D. Adhinata, "Penggunaan Metode K-Means dan K-Means++ Sebagai," *TEKNIKA*, vol. 11, no. 3, pp. 170-179, 2022.
- [5] A. Febrianto, S. Achmadi and A. P. Sasmito, "PENERAPAN METODE K-MEANS UNTUK CLUSTERING PENGUNJUNG," *JATI*, vol. 5, no. 3, pp. 61-70, 2021.
- [6] A. D. Cahyani, A. Faisol and D. Rudhistiar, "SISTEM PEMETAAN DAN KLASTERISASI TPS DI KOTA MALANG DENGAN ALGORITMA K-MEANS++," *JTST*, vol. 06, no. 1, pp. 1-9, 2025.
- [7] I. Permana and F. N. Salisah, "Pengaruh Normalisasi Data Terhadap Performa Hasil Klasifikasi Algoritma Backpropagation," *IJRSE: Indonesian Journal of Informatic Research and Software Engineering*, vol. 2, no. 1, pp. 67-72, 2022.
- [8] A. R. Lashiyanti, I. R. Munthe and F. A. Nasution, "Optimisasi Klasterisasi Nilai Ujian Nasional dengan Pendekatan Algoritma K-Means, Elbow, dan Silhouette," *Jurnal Ilmu Komputer dan Sistem Informasi (JIKOMSI)*, vol. 6, no. 1, pp. 14-20, 2023.
- [9] M. Nurrohman, M. and P. Sukmasetya, "Sistem Klasterisasi Volume Sampah Organik di Kota Magelang," *TEMATIK (Jurnal Teknologi Informasi Komunikasi)*, vol. 10, no. 1, pp. 146-153, 2023.
- [10] A. Selay, G. D. Andgha, M. A. Alfarizi, M. I. Bintang, W. M. N. Falah, M. Encep and M. Khaira, "SISTEM INFORMASI PENJUALAN," *Karimah Tauhid*, vol. 2, no. 1, pp. 232-237, 2023.