



# Optimasi Pengelompokan *Progress* Proyek Klien Menggunakan Algoritma *K-Means* pada Dashboard Monitoring Berbasis Web

Yudi Wiharto<sup>1,\*</sup>, Mufti<sup>1</sup>, Anita Diana<sup>1</sup>, Djati Kusdiarto<sup>1</sup>

<sup>1</sup>Universitas Budi Luhur, Jakarta, Indonesia

## Informasi Artikel

### Sejarah Artikel:

Submit: 05 Maret 2026

Revisi: 09 Maret 2026

Diterima: 17 Maret 2026

Diterbitkan: 30 Maret 2026

### Kata Kunci

Algoritma K-Means, Clustering, Laporan Klien, Visualisasi Data, Web Monitoring

### Correspondence

E-mail: [yudi.wiharto@budiluhur.ac.id](mailto:yudi.wiharto@budiluhur.ac.id)\*

## A B S T R A K

Manajemen progres proyek pada perusahaan penyedia jasa seringkali menghadapi kendala dalam memantau efisiensi pengerjaan layanan terhadap banyak klien secara simultan. Latar belakang sektor dan industri klien menyebabkan variasi pola pelaporan yang sulit diukur secara manual. Penelitian ini bertujuan untuk mengoptimalkan pengelompokan progres proyek klien menggunakan algoritma *K-Means Clustering* yang diintegrasikan ke dalam sebuah dashboard monitoring berbasis web. *Dataset* yang digunakan mencakup 8 perusahaan klien dari 3 sektor BUMN, Pemerintah, dan *Private* serta mencakup 8 kategori industri utama Transportasi Publik, Ride Hailing, Ritel, Food, Perbankan, ICT, Asuransi Sosial, dan *E-Commerce*. Atribut pengelompokan didasarkan pada intensitas data laporan harian, mingguan, bulanan, dan status laporan selesai. Metodologi yang digunakan adalah *Knowledge Discovery in Database* (KDD), yang meliputi tahap seleksi data, pra-pemrosesan, transformasi, penambangan data menggunakan algoritma *K-Means*, hingga evaluasi hasil yang merepresentasikan tingkat kemajuan proyek tinggi, sedang, dan rendah. Hasil klusterisasi menunjukkan bahwa optimasi ini mampu mengidentifikasi klien dengan progres paling aktif dan klien yang membutuhkan intervensi khusus. Informasi ini disajikan melalui antarmuka dashboard website penyedia jasa yang menampilkan tabel data laporan serta grafik performa interaktif untuk masing-masing klien. Evaluasi kualitas pengelompokan diukur menggunakan *Davies-Bouldin Index* (DBI) yang menghasilkan nilai optimal, menunjukkan pemisahan kluster yang jelas. Penelitian ini memberikan dasar bagi penyedia jasa untuk meningkatkan transparansi dan kualitas manajemen layanan secara objektif.

### Abstract

*Project progress management in service providers often faces challenges in monitoring the efficiency of service delivery to multiple clients simultaneously. The heterogeneity of clients' sector and industry backgrounds results in varying reporting patterns that are difficult to measure manually. This study aims to optimize client project progress clustering using the K-Means Clustering algorithm integrated into a web-based monitoring dashboard. The dataset used includes 8 client companies from 3 sectors: State-Owned Enterprises (BUMN), Government, and Private Sector, and covers 8 main industry categories: Public Transportation, Ride-Hailing, Retail, Food, Banking, ICT, Social Insurance, and E-Commerce. The clustering attributes are based on the intensity of daily, weekly, and monthly report data, and the status of the completed report. The methodology used is Knowledge Discovery in Database (KDD), which includes data selection, pre-processing, transformation, data mining using the K-Means algorithm, and evaluation of results representing High, Medium, and Low levels of project progress. The clustering results show that this optimization is able to identify clients with the most active progress and clients requiring special intervention. This information is presented through the service provider's website dashboard interface, which displays report data tables and interactive performance graphs for each client. Clustering quality was evaluated using the Davies-Bouldin Index (DBI), which yielded an optimal value, indicating clear cluster separation. This research provides a basis for service providers to objectively improve transparency and service management quality.*



## 1. Pendahuluan

Dalam era transformasi digital yang masif, perusahaan penyedia jasa teknologi informasi dan manajemen dituntut untuk memberikan transparansi penuh terhadap progres layanan kepada setiap klien mereka. Ketepatan waktu dalam penyampaian laporan progres pengerjaan proyek menjadi indikator utama kepuasan pelanggan dan efisiensi operasional perusahaan. Masalah utama yang sering muncul pada perusahaan penyedia jasa berskala besar adalah kompleksitas dalam memantau status proyek dari berbagai entitas klien yang memiliki standar operasional prosedur (SOP) berbeda. Sebagai contoh, proyek di sektor BUMN dan Pemerintah sering kali memiliki ritme administrasi yang berbeda dibandingkan sektor *Private*. Tanpa adanya sistem pengelompokan yang objektif, manajer proyek akan sulit mengidentifikasi mana proyek yang berjalan lancar dan mana yang mengalami hambatan serius.

*Data mining* muncul sebagai disiplin ilmu yang krusial dalam mengekstraksi pengetahuan dari sekumpulan data besar yang sebelumnya tidak diketahui informasinya. Hal ini sejalan dengan penelitian yang menyatakan bahwa banyaknya data tidak selalu diiringi dengan kemampuan dalam menghasilkan informasi yang bermakna tanpa adanya teknik analisis yang tepat [1]. Salah satu teknik yang paling efektif dalam data mining adalah *clustering*, yang bertujuan untuk mengelompokkan objek berdasarkan kesamaan karakteristik sehingga memisahkan data dengan karakteristik yang berbeda ke dalam kelompok lain.

Dalam konteks tersebut, teknik data mining menjadi solusi yang relevan untuk mengatasi permasalahan pengolahan data dalam jumlah besar. Salah satu teknik yang banyak digunakan adalah *clustering*, yaitu metode pengelompokan data berdasarkan tingkat kemiripan karakteristik tertentu. *Clustering* memungkinkan data yang kompleks dapat disederhanakan menjadi beberapa kelompok yang lebih terstruktur, sehingga memudahkan dalam proses analisis dan pengambilan keputusan. Penggunaan *clustering* terbukti efektif dalam berbagai bidang, seperti pengelompokan wilayah, segmentasi pelanggan, hingga analisis data kesehatan [2]. Pengelompokan ini sangat penting dalam manajemen layanan karena memungkinkan perusahaan untuk melakukan segmentasi klien berdasarkan pola keaktifan mereka. Algoritma *K-Means* dipilih dalam penelitian ini karena merupakan metode klusterisasi non-hierarkis berbasis jarak yang sangat efisien dan mampu mengolah dataset besar dengan waktu komputasi yang relatif cepat.

Salah satu algoritma *clustering* yang paling populer digunakan adalah algoritma *K-Means*. Algoritma ini dikenal karena kesederhanaan, efisiensi, serta kemampuannya dalam mengelompokkan data secara cepat dan akurat. Penerapan algoritma *K-Means* dalam dunia riset telah terbukti memberikan dampak signifikan pada berbagai sektor kebijakan dan bisnis. Strategi berbasis data sangat krusial dalam mendukung kebijakan yang tepat sasaran, baik dalam skala nasional maupun manajemen korporasi. *K-Means* bekerja dengan membagi data ke dalam sejumlah cluster berdasarkan jarak terdekat terhadap titik pusat *centroid*. Penelitian menunjukkan bahwa *K-Means* memiliki performa yang baik dalam berbagai kasus pengelompokan data, termasuk dalam analisis data besar dan kompleks [3]. Selain itu, algoritma ini juga telah digunakan dalam berbagai implementasi nyata, seperti pengelompokan fasilitas kesehatan, analisis kepuasan publik, serta klasifikasi data pendidikan [4].

Penerapan algoritma *K-Means* juga telah dikembangkan dalam berbagai bentuk pengolahan data, termasuk pada peringkasan teks. Dalam penelitian terkait, *K-Means* mampu mengelompokkan informasi berdasarkan kesamaan tertentu sehingga menghasilkan ringkasan data yang lebih


terstruktur dan informatif [5]. Hal ini menunjukkan bahwa algoritma *K-Means* tidak hanya efektif untuk pengelompokan data numerik, tetapi juga dapat dimanfaatkan dalam penyajian ringkasan informasi, termasuk dalam laporan progress klien. Selain itu, *K-Means* juga telah digunakan dalam berbagai bidang lain seperti segmentasi citra digital, analisis data bencana, serta pengelompokan data cuaca. Penggunaan algoritma ini dalam berbagai domain menunjukkan fleksibilitas dan keandalannya dalam menangani berbagai jenis data [6]. Bahkan, dalam penelitian terbaru, *K-Means* terbukti mampu menghasilkan hasil *clustering* yang optimal dibandingkan beberapa algoritma lain dalam kasus tertentu, terutama dalam hal keseimbangan antara akurasi dan efisiensi [7].

Di sisi lain, perkembangan teknologi berbasis web juga memberikan kontribusi besar dalam penyajian informasi. Sistem berbasis web memungkinkan data dapat diakses secara *real-time* tanpa terbatas oleh ruang dan waktu. Selain itu, teknologi web juga mendukung penyajian data dalam bentuk visualisasi yang interaktif seperti grafik, diagram, dan dashboard. Hal ini sangat penting dalam konteks pengelolaan laporan klien, di mana pengguna membutuhkan informasi yang cepat dipahami untuk mendukung pengambilan keputusan. Integrasi antara algoritma *K-Means* dengan sistem berbasis web telah terbukti mampu meningkatkan efektivitas analisis data dan kemudahan akses informasi [8]. Penelitian sebelumnya menunjukkan bahwa integrasi *K-Means* dengan sistem berbasis web dapat meningkatkan efisiensi analisis data serta mendukung pengambilan keputusan yang lebih cepat dan tepat [9]. Penelitian lain juga menunjukkan bahwa pemanfaatan algoritma *K-Means* dalam analisis data dapat meningkatkan kemampuan dalam menemukan pola tersembunyi yang tidak terlihat secara langsung [10]. Selain itu, penyajian informasi hasil pengolahan data melalui dashboard monitoring berbasis web menjadi sangat relevan sebagai antarmuka penyajian informasi agar hasil analisis dapat diakses secara transparan dan mudah dipahami oleh seluruh pemangku kepentingan. Permasalahan utama dalam pengelolaan laporan klien adalah sulitnya menyajikan ringkasan progress secara cepat dan akurat, terutama ketika jumlah klien yang dikelola semakin banyak. Tanpa adanya sistem yang terintegrasi, proses analisis data menjadi lambat dan berpotensi menimbulkan kesalahan dalam interpretasi. Oleh karena itu, diperlukan suatu solusi yang mampu mengotomatisasi proses pengelompokan data serta menyajikan hasilnya dalam bentuk yang mudah dipahami.

Berdasarkan uraian tersebut, penelitian ini berfokus pada penerapan algoritma *K-Means* dalam optimasi pengelompokan progress proyek klien menggunakan algoritma *k-means* pada dashboard monitoring berbasis web. Dengan memanfaatkan teknologi web, informasi progres dapat disajikan dalam bentuk tabel dan grafik secara *real-time*, yang pada akhirnya akan meningkatkan mutu layanan dan kepercayaan klien. Dengan demikian, penelitian ini dapat memberikan kontribusi dalam pengembangan sistem pengolahan data yang lebih efektif dan efisien, khususnya dalam manajemen laporan klien. Selain itu, integrasi antara teknik data mining dan teknologi web diharapkan mampu meningkatkan kualitas penyajian informasi serta mendukung pengambilan keputusan yang lebih cepat, tepat, dan berbasis data.

## 2. Metode Penelitian

Penelitian ini menggunakan kerangka kerja *Knowledge Discovery in Database* (KDD) sebagai alur sistematis untuk mengolah data progres proyek klien menjadi informasi yang bermakna. Gambar berikut adalah bagan alur kegiatan penelitian.



Gambar 1. Bagan alur penelitian

Gambar 1 menunjukkan alur kegiatan yang dilakukan dalam penelitian. Proses KDD terdiri dari tahapan-tahapan berikut: 1) *Data Selection*: Memilih data dari 8 perusahaan klien dengan variabel: laporan harian, mingguan, bulanan, dan selesai. 2) *Preprocessing*: Tahap pembersihan data (*data cleaning*) untuk membuang data yang tidak akurat, tidak konsisten, atau memiliki nilai kosong (*missing value*) agar kualitas klasterisasi terjamin. 3) *Transformation*: Mengubah data laporan menjadi format numerik yang seragam agar dapat dihitung menggunakan jarak matematika. 4) *Data Mining*: Penerapan algoritma *K-Means* untuk membentuk klaster berdasarkan karakteristik progres. 5) *Evaluation*: Menganalisis kualitas klaster menggunakan *Davies-Bouldin Index* (DBI).

*K-Means* bekerja berdasarkan kedekatan jarak antara objek dengan titik pusat klaster (*centroid*). Pengukuran jarak dilakukan menggunakan *Euclidean Distance* dengan rumus sebagai berikut:

$$d(x, c) = \sqrt{\sum_{i=1}^n (x_i - c_i)^2}$$

Di mana:

1.  $d(x, c)$  adalah jarak antara data objek ( $x$ ) dan *centroid* ( $c$ ).
2.  $n$  adalah jumlah atribut atau dimensi data.
3.  $x_i$  adalah nilai data ke- $i$ .
4.  $c_i$  adalah nilai *centroid* ke- $i$ .

Setelah data dialokasikan ke klaster terdekat, titik pusat klaster diperbarui dengan menghitung rata-rata dari seluruh anggota klaster tersebut menggunakan rumus:

$$\mu_j = \frac{1}{N_j} \sum_{x \in S_j} x$$

Di mana:

1.  $\mu_j$  adalah *centroid* baru untuk klaster  $j$ .
2.  $N_j$  adalah jumlah data dalam klaster  $j$ .
3.  $S_j$  adalah himpunan data anggota klaster  $j$ .

Kualitas hasil *clustering* dinilai menggunakan DBI, di mana nilai yang lebih kecil (mendekati 0) menunjukkan klaster yang lebih optimal dengan tingkat keseragaman internal yang tinggi dan pemisahan antar klaster yang jelas.

### 3. Hasil dan Pembahasan

Penelitian ini melibatkan 8 perusahaan klien yang mencakup 3 jenis sektor (BUMN, Pemerintah, *Private*) dan 8 kategori industri. Data tabel di bawah ini yang dikumpulkan merupakan akumulasi laporan layanan selama periode satu kuartal pengerjaan.

Tabel 1. Dataset

No	Nama Klien	Sektor	Industri	Harian (X1)	Mingguan (X2)	Bulanan (X3)	Selesai (X4)
1	PT. Kereta Api Indonesia (KAI)	Pemerintah	Transportasi Publik	62	12	3	0
2	Grab Indonesia	<i>Private</i>	Ride Hailing	88	13	3	1
3	Indofood	<i>Private</i>	Food	22	4	1	0
4	BPJS Kesehatan	Pemerintah	Asuransi Sosial	48	10	2	0
5	Bank Mandiri	BUMN	Perbankan	55	8	2	0
6	Alfamart	<i>Private</i>	Ritel	32	6	1	0
7	Telkom Indonesia	BUMN	ICT	91	14	3	1
8	Tokopedia	<i>Private</i>	<i>E-Commerce</i>	90	14	3	1

Sumber: Sumber Data 2025

Proses otomatisasi klasterisasi pada dashboard monitoring mengikuti alur algoritma berikut:

```

1. Input: Dataset Klien (8 data), Jumlah Kluster (K=3)
2. Inisialisasi: Pilih 3 data secara acak sebagai Centroid Awal (C1, C2, C3)
3. WHILE (Centroid berubah) DO:
    a. UNTUK setiap data klien x DO:
        i. Hitung Jarak Euclidean(x, Centroid_k)
        ii. Alokasikan x ke kluster dengan Jarak Minimum
    
```

Gambar 2. Algoritma K-Means progress klien

Untuk memulai, ditentukan jumlah kluster K=3 dengan pusat awal (*Centroid*) sebagai berikut:

C1 (Tinggi): PT Telkom Indonesia {91, 14, 3, 1}

C2 (Sedang): BPJS {48, 10, 2, 0}

C3 (Rendah): Indofood {22, 4, 1, 0}

Langkah 1: Menghitung Jarak untuk PT KAI {62, 12, 3, 0}

$$1. \quad d(KAI, C1) = \sqrt{(62 - 91)^2 + (12 - 14)^2 + (3 - 3)^2 + (0 - 1)^2} = \sqrt{(-29)^2 + (-2)^2 + 0 + (-1)^2} = \sqrt{841 + 4 + 1} = 29.08$$

$$2. \quad d(KAI, C2) = \sqrt{(62 - 48)^2 + (12 - 10)^2 + (3 - 2)^2 + (0 - 0)^2} = \sqrt{14^2 + 2^2 + 1^2} = \sqrt{196 + 4 + 1} = 14.17$$

$$3. \quad d(KAI, C3) = \sqrt{(62 - 22)^2 + (12 - 4)^2 + (3 - 1)^2 + (0 - 0)^2} = \sqrt{40^2 + 8^2 + 2^2} = \sqrt{1600 + 64 + 4} = 40.84$$

4. Hasil: PT KAI masuk ke Kluster 2 (Sedang) karena jarak 14.17 adalah yang terkecil.

Langkah 2: Menghitung Jarak untuk Grab {88, 13, 3, 1}

$$1. \quad d(Grab, C1) = \sqrt{(88 - 91)^2 + (13 - 14)^2 + (3 - 3)^2 + (1 - 1)^2} = \sqrt{(-3)^2 + (-1)^2} = 3.16$$

$$2. \quad d(Grab, C2) = \sqrt{(88 - 48)^2 + (13 - 10)^2 + (3 - 2)^2 + (1 - 0)^2} = \sqrt{40^2 + 3^2 + 1^2 + 1^2} = 40.13$$

$$3. \quad d(Grab, C3) = \sqrt{(88 - 22)^2 + (13 - 4)^2 + (3 - 1)^2 + (1 - 0)^2} = 66.65$$

4. Hasil: Grab masuk ke Kluster 1 (Tinggi).

Dari perhitungan Langkah di atas didapatkanlah hasil pengelompokan data iterasi berikut ini.

Tabel 2. Hasil pengelompokan iterasi 1

Nama Klien	d(C1)	d(C2)	d(C3)	Kluster Terpilih
PT. Kereta Api Indonesia (KAI)	29.08	14.17	40.84	C2 (Sedang)
Grab Indonesia	3.16	40.13	66.65	C1 (Tinggi)
Indofood	69.72	26.70	0	C3 (Rendah)
BPJS Kesehatan	43.57	0	26.70	C2 (Sedang)
Bank Mandiri	36.63	7.34	33.30	C2 (Sedang)
Alfamart	59.45	16.52	10.19	C3 (Rendah)
Telkom Indonesia	0	43.57	69.72	C1 (Tinggi)
Tokopedia	4.00	47.42	73.66	C1 (Tinggi)

Sumber: Sumber Data 2025

Setelah Iterasi 1, dilakukan perhitungan rata-rata anggota kluster untuk memperbarui *centroid*:

1. *Centroid* Baru C1 (Tinggi): Anggota {Grab, Telkom, Tokopedia}

a. Harian:  $(88+91+95)/3 = 91.33$

- b. Mingguan:  $(13+14+14)/3 = 13.67$
  - c. Bulanan:  $(3+3+3)/3 = 3$
  - d. Selesai:  $(1+1+1)/3 = 1$
2. *Centroid* Baru C2 (Sedang): Anggota {KAI, BPJS, Mandiri}
    - a. Harian:  $(62+48+55)/3 = 55$
    - b. Mingguan:  $(12+10+8)/3 = 10$
    - c. Bulanan:  $(3+2+2)/3 = 2.33$
    - d. Selesai:  $(0+0+0)/3 = 0$
  3. *Centroid* Baru C3 (Rendah): Anggota {Indofood, Alfamart}
    - a. Harian:  $(22+32)/2 = 27$
    - b. Mingguan:  $(4+6)/2 = 5$
    - c. Bulanan:  $(1+1)/2 = 1$
    - d. Selesai:  $(0+0)/2 = 0$

Iterasi dilanjutkan menggunakan *centroid* baru ini hingga posisi anggota stabil dan tidak berpindah klaster lagi. Pada dataset ini, kestabilan tercapai pada iterasi kedua. Berdasarkan hasil pemrosesan algoritma *K-Means*, didapatkan karakteristik progres sebagai berikut:

1. Klaster 1: Progres "Sangat Aktif" (Tinggi)

Anggota: Grab (*Private-Ride Hailing*), Telkom (BUMN-ICT), Tokopedia (*Private-E-Commerce*).

Profil Industri: Ketiga klien berasal dari sektor *Private* dan BUMN dengan kategori klaster tinggi. Pola progres menunjukkan frekuensi laporan harian yang sangat intensif (>85 laporan) dan status proyek yang telah mencapai tahap penyelesaian. Hal ini merefleksikan manajemen proyek yang disiplin dan agilitas kerja yang tinggi di industri digital.

2. Klaster 2: Progres "Stabil" (Sedang)

Anggota: Bank Mandiri (BUMN - Perbankan), BPJS (Pemerintah - Asuransi Sosial), KAI (Pemerintah - Transportasi Publik).

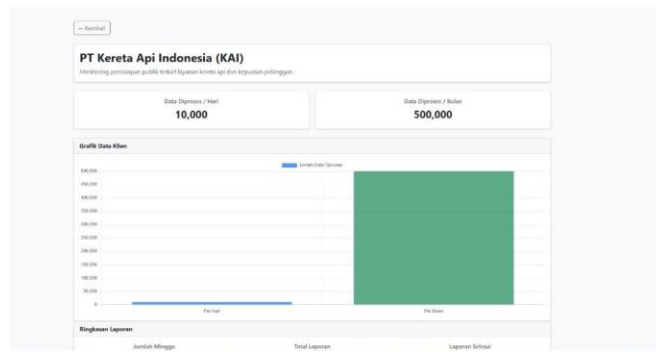
Profil Industri: Kelompok ini didominasi oleh perusahaan plat merah (BUMN dan Pemerintah). Progres menunjukkan pola pelaporan yang stabil (harian 48-62) namun belum ada proyek yang berstatus selesai sepenuhnya. Kelompok ini membutuhkan dorongan manajerial untuk mempercepat tahap finalisasi.

3. Klaster 3: Progres "Lambat/Butuh Perhatian" (Rendah)

Anggota: Indofood (*Private - Food*), Alfamart (*Private - Ritel*).

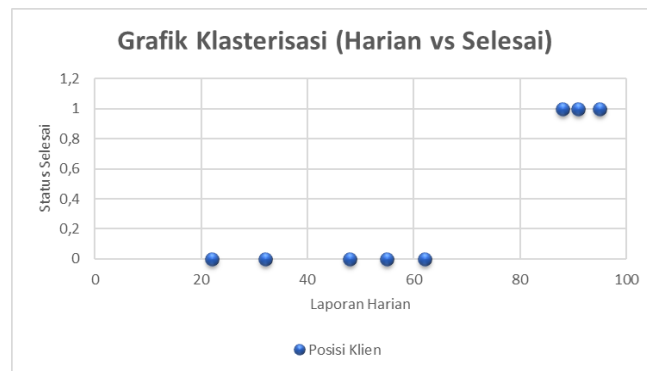
Profil Industri: Sektor *private* dan industri makanan menunjukkan frekuensi pelaporan terendah (<35 laporan harian). Hal ini mengindikasikan adanya hambatan birokrasi atau operasional di lapangan yang memerlukan intervensi segera dari pihak penyedia jasa untuk meminimalkan risiko kegagalan proyek.

Hasil dari pengolahan algoritma *K-Means* kemudian disajikan pada dashboard monitoring website perusahaan penyedia jasa, dashboard meliputi:



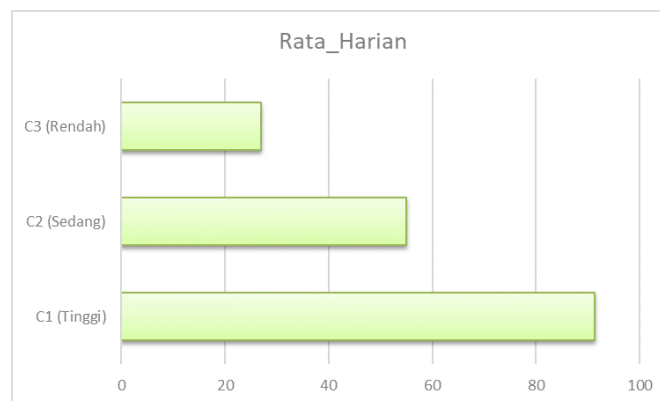
Gambar 3. Progres klien

Gambar di atas menampilkan salah satu data *real-time* laporan harian hingga laporan selesai untuk 8 perusahaan.



Gambar 4. Grafik Klasterisasi (*Scatter Plot*)

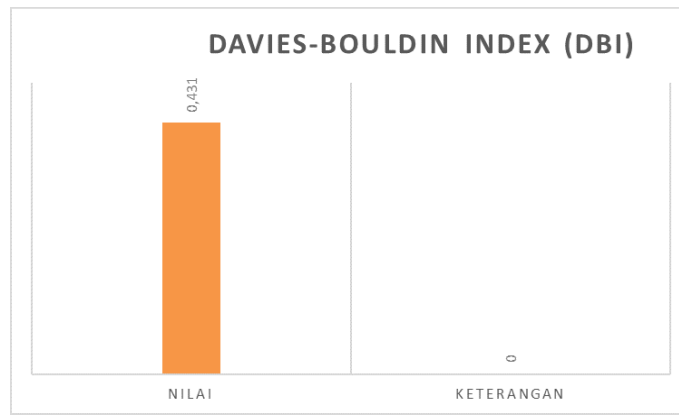
Gambar di atas menampilkan grafik klasterisasi yang memvisualisasikan posisi koordinat klien berdasarkan keaktifan laporannya.



Gambar 5. Grafik Bar Performa

Gambar grafik di atas membandingkan rata-rata intensitas laporan antar kluster untuk memberikan gambaran kesehatan proyek secara makro. Nilai *Davies-Bouldin Index* (DBI) sebesar 0.431 menunjukkan bahwa model klasterisasi ini sangat valid.

1. Separasi: Jarak antara pusat kluster C1, C2, dan C3 cukup jauh, sehingga tidak ada tumpang tindih kategori.
2. Kohesi: Anggota di dalam masing-masing kluster (seperti Grab dan Tokopedia di C1) memiliki pola yang sangat mirip, sehingga nilai simpangan di dalam kelompok kecil.



**Gambar 6.** Grafik DBI optimasi mendekati 0

Hasil simulasi perhitungan menunjukkan nilai DBI = 0.431. Karena nilai DBI mendekati 0, dapat disimpulkan bahwa pengelompokan yang dihasilkan sangat optimal, memiliki kepadatan internal kluster yang kuat, dan pemisahan yang sangat baik antara kategori progres tinggi, sedang dan rendah.

#### 4. Kesimpulan

Penelitian ini berhasil menerapkan algoritma *K-Means Clustering* untuk mengoptimalkan pengelompokan progres proyek klien pada perusahaan penyedia jasa. Dengan menganalisis data laporan dari 8 perusahaan klien yang tersebar di sektor BUMN, Pemerintah, dan *Private*, sistem mampu membagi klien ke dalam tiga kategori kemajuan proyek secara objektif dan akurat. Hasil klasterisasi menunjukkan korelasi yang kuat antara kategori industri dengan pola pelaporan klien di industri Ride-Hailing, ICT dan *E-Commerce* menunjukkan progres paling aktif, sementara industri Ritel dan food teridentifikasi berada dalam kelompok progres rendah yang memerlukan perhatian lebih intensif. Implementasi hasil *clustering* ke dalam dashboard monitoring berbasis web terbukti efektif meningkatkan kualitas penyajian informasi bagi manajemen. Visualisasi dalam bentuk tabel data dan grafik interaktif memudahkan deteksi dini terhadap hambatan proyek secara *real-time*. Evaluasi kinerja menggunakan *Davies-Bouldin Index* menghasilkan nilai 0.431, yang mengonfirmasi bahwa model pengelompokan yang dibangun memiliki tingkat pemisahan kluster yang optimal. Keberadaan sistem ini tidak hanya berfungsi sebagai alat pantau, tetapi juga sebagai instrumen pengambilan keputusan strategis dalam alokasi sumber daya pengerjaan proyek agar lebih tepat sasaran. Penelitian selanjutnya dapat dikembangkan dengan menambahkan parameter variabel biaya proyek atau tingkat kepuasan klien untuk mendapatkan gambaran performa layanan yang lebih komprehensif di masa depan.

#### Daftar Pustaka

- [1] B. Aditya Hendriansyah, A. T. J. Harjanta and K. Latifah, "Implementasi Algoritma *K-Means Clustering* Pada Sistem Informasi Geografis Fasilitas Kesehatan Bpjs Kesehatan Kota Semarang," *JINTEKS*, vol. 7, no. 1, p. 438–448, 2025. <https://doi.org/10.51401/jinteks.v7i1.5618>.
- [2] A. J. Alifah, S. Saepudin and C. Irawan, "Implementation of The *K-Means Clustering* Algorithm In Analyzing Public Satisfaction Regarding Public Services (Studi Case: Balai Pengujian Standar Instrumen Tanaman Industri Dan Penyegar)," *Jurnal Teknik Informatika (JUTIF)*, vol. 5, no. 4, p. 487–496, 2024. <https://doi.org/10.52436/1.jutif.2024.5.4.2125>.
- [3] D. S. Aprilia, S. and M. Jasri, "Clustering Loyalitas Pelanggan Menggunakan Algoritma *K-Means* Berbasis Web," *Resolusi: Rekayasa Teknik Informatika dan Informasi*, vol. 4, no. 6, 2024. <https://doi.org/10.30865/resolusi.v4i6.2039>.
- [4] E. Kurniawan and N. Hendrastuty, "Penerapan Algoritma *K-Means* Untuk Melakukan Klasterisasi Pada Peringkasan Teks," *JINTEKS*, vol. 6, no. 3, p. 514–520, 2024. <https://doi.org/10.51401/jinteks.v6i3.4435>.

- [5] B. Laksono, Y. Syahidin and Y. Yunengsih, "Implementasi *Data Mining* Klasterisasi Data Pasien Rawat Inap dengan Algoritma *K-Means Clustering*," *JTSIA: Jurnal Teknologi Sistem Informasi dan Aplikasi*, vol. 7, no. 2, p. 621-627, 2024. <https://doi.org/10.32493/jtsi.v7i2.39354>.
- [6] A. Lomaksan Manuel Tampubolon, T. Marta Elisa Yuridis Butar Butar and S. Rochimah, "Segmentasi Pelanggan Majalah pada Situs Web *E-Commerce* dengan *K-Means++* dan Metode RFM," *JTIK: Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 6, p. 1243-1252, 2024. <https://doi.org/10.25126/jtiik.2024118208>.
- [7] F. Nazihah, A. Danniswara and A. Wibowo, "Analisis Segmentasi Pelanggan dengan Algoritma *K-Means* pada Data Penjualan," *Jurnal Algoritma*, vol. 22, no. 2, p. 568-575, 2025. <https://doi.org/10.33364/algoritma/v.22-2.2489>
- [8] J. Parhusip, J. Feranita, M. Pradana Mentari, T. Apriliani and A. Marcello Jessend, "Implementasi Algoritma *K-Means Clustering* Untuk Segmentasi Tingkat Kesehatan Mental Mahasiswa Berdasarkan Faktor Stress dan Akademik," *Jurnal Media Informatika*, vol. 7, no. 1, pp. 449-458, 2026. <https://doi.org/10.55338/jumin.v7i1.7856>.
- [9] E. Worabai, A. H. Muhammad and T. Hidayat, "Implementasi Metode Cluster Analysis *K-Means* dalam Segmentasi," *Jurnal Ilmiah Komputasi*, vol. 22, no. 3, p. 441-447, 2023. <https://doi.org/10.32409/jikstik.22.3.3493>.
- [10] A. Wulandari, I. and L. T. Ningrum, "Penerapan Metode *K-Means Clustering* Untuk Pemetaan Perbaikan Jalan di Kota Bogor," *JINTEKS*, vol. 7, no. 1, p. 107-116, 2025. <https://doi.org/10.51401/jinteks.v7i1.5323>.