

Perbandingan Algoritma K-Means dan Hierarchical Clustering dalam Pengelompokan Prestasi Akademik Siswa

Hari Sampurno^{1*}, Muhammad Nashrullahil Wafi², Nurdin³

^{1,2,3}Fakultas Teknik, Universitas Malikussaleh

Jl. Kampus Unimal Bukit Indah, Blang Pulo, Kec. Muara Satu, Kota Lhokseumawe

¹hari.230170138@mhs.unimal.ac.id, ²muhammad.230170130@mhs.unimal.ac.id, ³nurdin@unimal.ac.id

*Penulis Korespondensi

ABSTRAK

Pengelompokan prestasi akademik merupakan salah satu strategi yang dapat membantu guru dan pihak sekolah dalam melakukan intervensi pembelajaran, seperti pemberian bimbingan tambahan atau penentuan strategi pengajaran yang lebih tepat. Penelitian ini bertujuan untuk membandingkan kinerja algoritma K-Means dan Hierarchical Clustering dalam mengelompokkan prestasi akademik siswa. Dataset yang digunakan terdiri dari 1.000 data siswa dengan tiga atribut nilai, yaitu Matematika, Membaca, dan Menulis, yang diperoleh dari sumber data publik. Tahapan penelitian meliputi proses preprocessing, normalisasi data menggunakan StandardScaler, penerapan algoritma clustering, serta visualisasi hasil menggunakan scatter plot dua dimensi dan dendrogram. Evaluasi kinerja model dilakukan menggunakan Silhouette Score untuk menilai kualitas pemisahan cluster. Hasil penelitian menunjukkan bahwa algoritma K-Means memperoleh skor Silhouette sebesar 0,406, sedangkan Hierarchical Clustering memperoleh skor 0,374. Nilai tersebut mengindikasikan bahwa K-Means menghasilkan struktur pengelompokan yang lebih baik dan lebih jelas dalam membedakan tingkat prestasi siswa menjadi tiga kategori: rendah, sedang, dan tinggi. Dengan demikian, K-Means dinilai lebih sesuai untuk analisis pengelompokan prestasi akademik pada dataset ini.

Article Info

Kata Kunci:

Clustering
K-Means
Hierarchical Clustering
Student Performance
Silhouette Score

Riwayat artikel:

Submit 3 Nov 2025
Revisi 13 Nov 2025
Diterima 29 Des 2025

1. PENDAHULUAN

Dalam peningkatan kualitas proses pembelajaran, ada peluang baru untuk menganalisis data pendidikan secara lebih sistematis. Clustering adalah salah satu pendekatan yang sering digunakan dalam analisis data pendidikan, yaitu teknik pengelompokan data tanpa label untuk mengidentifikasi pola atau karakteristik tertentu dalam data. Metode ini banyak dimanfaatkan untuk memahami variasi prestasi siswa serta mendukung guru dan sekolah dalam menentukan strategi intervensi akademik yang lebih tepat sasaran [1][2]. Berbagai penelitian sebelumnya di Indonesia memanfaatkan algoritma K-Means untuk mengelompokkan prestasi akademik siswa karena kemampuannya dalam menghasilkan kelompok yang jelas berdasarkan kemiripan nilai belajar [3][4]. Hasil penelitian tersebut menunjukkan bahwa metode ini mampu membagi siswa ke dalam kelompok prestasi tinggi, sedang, dan rendah, sehingga membantu sekolah dalam merancang program remedial, penentuan kelas, maupun evaluasi capaian pembelajaran.

Di sisi lain, algoritma Hierarchical Clustering juga sering digunakan dalam penelitian berbasis data pendidikan karena kemampuannya menghasilkan struktur hierarki berupa dendrogram yang memberikan gambaran menyeluruh mengenai hubungan antar data [5][6]. Pendekatan ini memungkinkan analisis yang lebih mendalam mengenai kemiripan antar siswa dan pola pembelajaran mereka. Namun, meskipun kedua algoritma ini banyak digunakan, sebagian besar penelitian sebelumnya hanya menerapkan satu algoritma clustering tanpa melakukan perbandingan kinerja secara kuantitatif menggunakan metrik evaluasi formal. Kesenjangan penelitian (*research gap*) muncul karena kurangnya studi yang secara langsung membandingkan kualitas pengelompokan dua algoritma

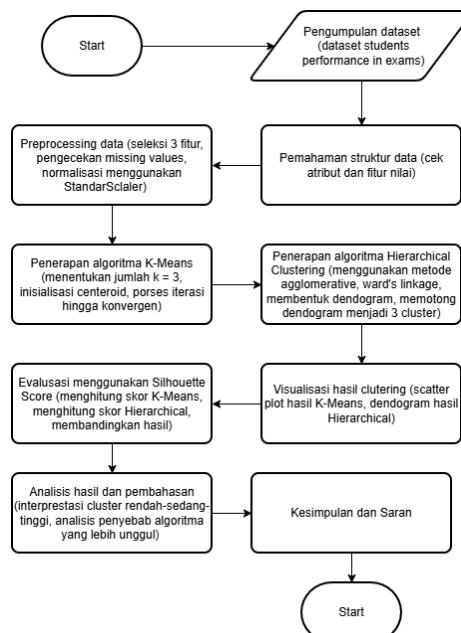
clustering populer tersebut dalam konteks prestasi akademik siswa [7]. Sebagian besar studi terdahulu lebih fokus pada penerapan satu metode tanpa melakukan validasi menggunakan metrik kuantitatif seperti Silhouette Score, Davies-Bouldin Index, atau Calinski-Harabasz Index. Padahal, penggunaan metrik evaluasi sangat penting untuk memastikan kualitas cluster yang terbentuk dan memberikan dasar pengambilan keputusan yang lebih objektif [8][9].

Selain itu, pemanfaatan dataset pendidikan publik yang tersedia secara terbuka masih jarang dilakukan dalam penelitian lokal. Sementara penggunaan dataset seperti *Students Performance in Exams* memungkinkan eksperimen yang lebih terstandarisasi dan dapat direplikasi oleh peneliti lain. Dengan demikian, penelitian yang melakukan analisis komparatif antara K-Means dan Hierarchical Clustering menggunakan dataset terstandar menjadi penting untuk memberikan gambaran menyeluruh mengenai performa kedua algoritma tersebut dalam mengelompokkan prestasi akademik siswa.

Berdasarkan latar belakang ini, penelitian ini bertujuan untuk membandingkan kinerja algoritma K-Means dan Hierarchical Clustering dalam mengelompokkan prestasi akademik siswa berdasarkan nilai membaca, menulis, dan matematika. Perbandingan dilakukan melalui evaluasi kuantitatif menggunakan Silhouette Score untuk mengetahui algoritma mana yang menghasilkan kualitas cluster lebih baik. Hasil penelitian ini diharapkan dapat membantu proses pembuatan sistem pendukung keputusan di bidang pendidikan, terutama yang berkaitan dengan pemetaan prestasi, pengelompokan kelas, dan identifikasi siswa yang membutuhkan pendampingan belajar tambahan [10][11].

2. METODE PENELITIAN

Untuk membandingkan kinerja dua algoritma pembelajaran tidak diawasi—K-Means Clustering dan Hierarchical Clustering—penelitian ini menggunakan kedua pendekatan deskriptif dan metode eksperimen komputasi. Tujuan utama penelitian adalah untuk mengetahui algoritma yang mampu menghasilkan pengelompokan prestasi akademik siswa dengan kualitas pemisahan cluster yang lebih baik berdasarkan nilai akademik mereka. Dataset yang digunakan merupakan data publik “*Students Performance in Exams*” yang diambil dari platform Kaggle, dengan total 1.000 baris data siswa dan delapan atribut. Penelitian ini hanya memfokuskan pengelompokan pada tiga atribut nilai akademik, yaitu nilai Matematika, Membaca, dan Menulis, karena ketiganya merepresentasikan kemampuan inti siswa dalam bidang literasi dan numerasi. Tahapan penelitian meliputi beberapa langkah utama yaitu, pengumpulan dan pemilihan dataset, pra-pemrosesan data yang mencakup seleksi fitur, pengecekan *missing values*, dan normalisasi menggunakan StandardScaler, penerapan algoritma K-Means Clustering dengan jumlah cluster $K = 3$, penerapan algoritma Hierarchical Clustering menggunakan metode *agglomerative* dan *ward's linkage*, visualisasi hasil dalam bentuk scatter plot dan dendrogram, evaluasi hasil pengelompokan menggunakan Silhouette Score, analisis hasil dan penarikan kesimpulan. Alur lengkap tahapan penelitian ditunjukkan pada Gambar 1, yang menggambarkan seluruh proses mulai dari pengumpulan data hingga penilaian akhir.



Gambar 1. Penelitian dimulai dengan pengumpulan dataset dan preprocessing, penerapan algoritma, evaluasi hasil, hingga analisis dan kesimpulan.

2.1 Dataset dan Prapemrosesan

Dalam penelitian ini, dataset publik Students Performance in Exams yang bersumber dari platform Kaggle. Dataset ini berisi 1.000 data siswa dengan delapan atribut, yaitu jenis kelamin, ras/etnis, tingkat pendidikan orang tua, makan siang, kursus persiapan ujian serta, serta tiga nilai akademik: nilai matematika, nilai membaca, dan nilai menulis. Setiap baris merepresentasikan satu siswa sehingga dataset ini relevan digunakan untuk menganalisis prestasi akademik secara individual. Dalam penelitian ini, hanya tiga atribut numerik digunakan, yaitu nilai Matematika, Membaca, dan Menulis, karena ketiganya merupakan indikator langsung dari kemampuan akademik inti siswa dan menjadi dasar rasional untuk tujuan pengelompokan. Atribut non-numerik tidak digunakan karena fokus penelitian bukan pada karakteristik demografis, melainkan pada pengelompokan prestasi belajar. Tahap prapemrosesan data dilakukan untuk memastikan bahwa data siap digunakan oleh algoritma clustering. Langkah-langkah prapemrosesan meliputi: Pertama Seleksi Atribut, hanya tiga kolom nilai digunakan: nilai matematika, nilai membaca, dan nilai menulis. Pemilihan ini dilakukan untuk fokus pada performa akademik utama dan menghindari gangguan variabel kategorikal. Kedua, Pengecekan missing values dataset diperiksa dari kemungkinan nilai kosong. Dataset Kaggle ini tidak memiliki missing values sehingga tidak diperlukan proses imputasi data. Ketiga Normalisasi Data, normalisasi dilakukan menggunakan metode StandardScaler, karena setiap fitur memiliki standar deviasi 1 dan rata-rata 0. Langkah ini penting karena algoritma K-Means dan Hierarchical Clustering sensitif terhadap perbedaan skala antar fitur. Keempat Penentuan Jumlah Cluster, jumlah cluster ditetapkan sebanyak tiga kelompok, yaitu rendah, sedang, dan tinggi, berdasarkan tujuan penelitian untuk memetakan tingkatan prestasi siswa secara lebih terstruktur. Tahap prapemrosesan ini memastikan bahwa data berada dalam kondisi optimal sebelum diproses oleh algoritma clustering, sehingga hasil pengelompokan dapat lebih akurat dan tidak bias oleh skala fitur tertentu.

2.2 Algoritma K-Means

K-Means adalah salah satu algoritma pembelajaran tanpa pengawasan yang paling banyak digunakan untuk tugas pengelompokan data. Algoritma ini membagi data ke dalam sejumlah cluster berdasarkan kedekatan jarak antara titik data dan centroid (pusat cluster). Proses K-Means secara umum meliputi tiga tahap utama, yaitu: (1) menentukan centroid awal secara acak, (2) menghitung jarak setiap data ke centroid menggunakan metrik jarak (umumnya Euclidean Distance), dan (3) memperbarui posisi centroid berdasarkan rata-rata anggota cluster hingga mencapai kondisi konvergen, yaitu ketika perubahan posisi centroid sangat kecil atau tidak berubah lagi [12].

K-Means dikenal sebagai algoritma yang efisien karena memiliki kompleksitas komputasi yang relatif rendah serta mampu menangani dataset berukuran besar dengan performa yang stabil [13]. Selain efisiensi, K-Means juga banyak digunakan dalam penelitian akademik karena sifatnya yang mudah diimplementasikan dan interpretasinya yang sederhana terhadap data numerik. Beberapa penelitian lain juga menunjukkan bahwa K-Means bekerja optimal pada data yang memiliki kecenderungan distribusi berbentuk bulat (spherical clusters). Meskipun demikian, Nilai K (jumlah cluster) sangat bergantung pada kinerja K-Means serta inisialisasi centroid awal [14]. Centroid yang kurang tepat dapat menyebabkan algoritma terjebak pada solusi lokal sehingga hasil pengelompokan kurang optimal. Untuk mengatasi hal tersebut, beberapa penelitian merekomendasikan penggunaan metode inisialisasi k-means++, yang terbukti mengurangi kesalahan inisialisasi dan meningkatkan stabilitas hasil cluster.

Untuk mewakili kategori prestasi rendah, sedang, dan tinggi, dalam penelitian ini, jumlah cluster ditetapkan sebesar K = 3. Data dikumpulkan menggunakan library scikit-learn di platform Google Colab untuk melakukan pengelompokan dinormalisasi menggunakan StandardScaler sebelum diimplementasikan pada algoritma K-Means agar perbedaan skala antar atribut tidak memengaruhi hasil pengelompokan.

2.3 Algoritma Hierarchical Clustering

Algoritma pembelajaran tidak terlihat yang membentuk struktur pengelompokan bertingkat (hierarki) berdasarkan tingkat kemiripan antar objek. Proses ini dapat dilakukan melalui dua pendekatan, yaitu agglomerative (bottom-up) dan divisive (top-down). Dalam penelitian ini, setiap subjek dianggap sebagai satu cluster pada awalnya, kemudian cluster-cluster yang memiliki kemiripan tertinggi secara bertahap digabungkan hingga seluruh data membentuk satu cluster besar [15].

Penggabungan cluster dilakukan melalui metode Ward's linkage, yang meminimalkan variansi total dalam setiap langkah proses. Ward's linkage dikenal efektif dalam menghasilkan cluster yang lebih homogen karena mempertimbangkan kuadrat selisih jarak antar titik data sehingga distribusi cluster lebih stabil dan terstruktur [16]. Struktur hubungan antar objek divisualisasikan melalui dendrogram, yang menunjukkan bagaimana cluster terbentuk dari tahap awal hingga tahap akhir. Visualisasi dendrogram membantu peneliti memahami pola kemiripan data serta menentukan titik pemotongan (cut-off) yang paling sesuai untuk menghasilkan jumlah cluster tertentu [17]. Untuk keperluan perbandingan dengan algoritma K-Means dalam penelitian ini, dendrogram dipotong pada tingkat tertentu sehingga menghasilkan tiga cluster, sesuai kategori prestasi rendah, sedang, dan tinggi [18]. Pemotongan dendrogram ini bertujuan untuk memastikan bahwa hasil Hierarchical Clustering dapat dibandingkan secara langsung dengan hasil K-Means dalam evaluasi kuantitatif menggunakan Silhouette Score.

2.4 Evaluasi Hasil Clustering

Evaluasi kualitas cluster pada penelitian ini dilakukan dengan metrik Skor Silhouette, yaitu ukuran yang digunakan untuk mengevaluasi kesesuaian suatu objek dengan cluster yang tepat. Tidak seperti metode lain yang membutuhkan ground truth, Silhouette Score cocok digunakan dalam penelitian unsupervised learning karena hanya bergantung pada jarak antar data dan struktur cluster yang terbentuk [19].

Silhouette Score mempertimbangkan dua komponen jarak, yaitu:

1. $a(i)$ = rata-rata jarak antara titik i dan anggota cluster lainnya.
2. $b(i)$ = jarak rata-rata antara titik i dan anggota kelompok terdekat.

Nilai Silhouette Score dihitung menggunakan persamaan berikut:

$$S(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (1)$$

Interpretasi nilai Silhouette Score adalah sebagai berikut:

- 1 0.71 – 1.00 : struktur cluster yang sempurna
- 2 0.51 – 0.70 : struktur cluster yang efektif
- 3 0.26 – 0.50 : struktur cluster cukup, cluster mungkin saling tumpang tindih
- 4 0.00 – 0.25 : struktur cluster lemah
- 5 < 0.00 : banyak data ditempatkan pada cluster yang salah

2.5 Lingkungan Penelitian

Eksperimen penelitian ini dilakukan di lingkungan komputasi berbasis cloud Google Colab, yang mendukung eksekusi notebook Python dengan kemampuan GPU/CPU yang stabil. Google Colab dipilih karena menyediakan akses komputasi yang memadai tanpa memerlukan instalasi lokal serta mendukung reproduktifitas penelitian. Penelitian dijalankan menggunakan Python 3.10 dengan spesifikasi runtime standar Google Colab, yaitu CPU Intel Xeon virtual dan memori sekitar 12 GB RAM. Untuk mendukung proses pengolahan data, visualisasi, serta implementasi algoritma clustering, beberapa library yang digunakan pertama, pandas dan numpy digunakan untuk manipulasi dataset, pembersihan data, seleksi atribut, serta pengolahan nilai numerik. Kedua, matplotlib dan seaborn dimanfaatkan untuk visualisasi hasil penelitian, termasuk grafik sebar (scatter plot), visualisasi hasil clustering, serta grafik evaluasi. Ketiga, scikit-learn berperan dalam implementasi algoritma K-Means, Agglomerative Hierarchical Clustering, normalisasi menggunakan StandardScaler, dan perhitungan metrik evaluasi Silhouette Score. Lingkungan komputasi ini memastikan bahwa seluruh tahapan mulai dari prapemrosesan hingga evaluasi dapat dijalankan secara konsisten dan dapat direplikasi oleh peneliti lain.

3. HASIL DAN DISKUSI

3.1 Deskripsi Hasil Clustering

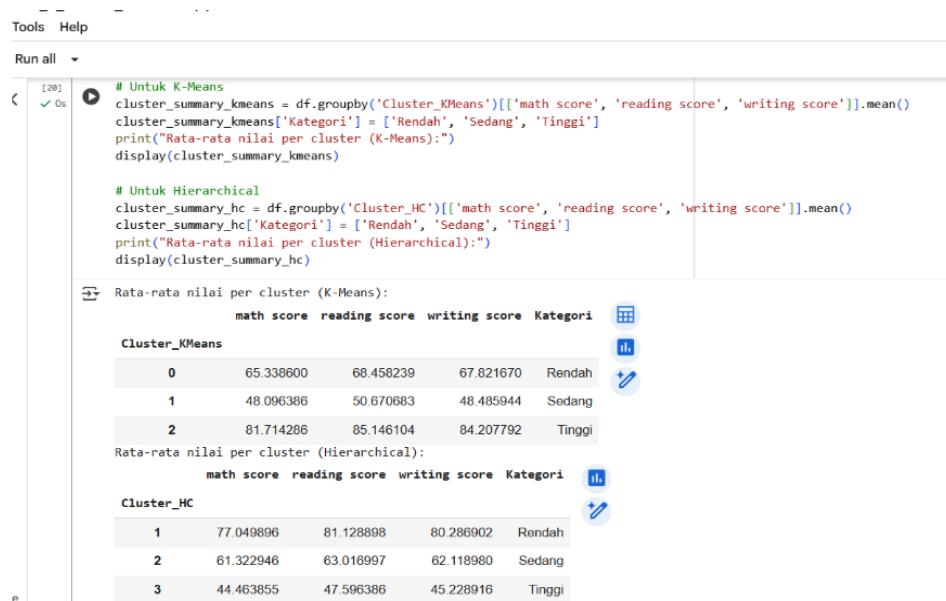
Penelitian ini menggunakan dua algoritma unsupervised learning, yaitu K-Means dan Kelompokan Hierarki untuk mengelompokkan prestasi akademik siswa berdasarkan tiga nilai utama: membaca, menulis, dan matematika. Jumlah cluster ditetapkan sebanyak tiga, yang mewakili kategori prestasi rendah, sedang, dan tinggi. Setelah dilakukan proses pengelompokan, kedua algoritma menghasilkan pembagian cluster yang berbeda dari segi penomoran, namun tetap menunjukkan pola yang searah dalam mengelompokkan siswa berdasarkan performa akademiknya. Untuk memperoleh interpretasi yang lebih terstruktur, nilai rata-rata setiap atribut dihitung pada masing-masing cluster. Nilai rata-rata ini menjadi dasar untuk menentukan kategori cluster, di mana cluster dengan nilai tertinggi dikategorikan sebagai Prestasi Tinggi, cluster nilai menengah sebagai Prestasi Sedang, dan cluster nilai terendah sebagai Prestasi Rendah.

Tabel 1. Algoritma K-Means dan Hierarchical Clustering Rata-rata Nilai Per Cluster

Algoritma	Cluster	Rata-Rata Matematika	Rata-Rata Membaca	Rata-Rata Menulis	Kategori
K-Means	0	65.34	68.46	67.82	Rendah
K-Means	1	48.10	50.67	48.49	Sedang
K-Means	2	81.71	85.15	84.21	Tinggi
Hierarchical	1	77.05	81.13	80.29	Tinggi
Hierarchical	2	61.32	63.02	62.12	Sedang
Hierarchical	3	44.46	47.60	45.23	Rendah

Berdasarkan Tabel 1, terlihat bahwa K-Means menghasilkan cluster dengan nilai tertinggi pada Cluster 2, yaitu rata-rata 81.71 (Matematika), 85.15 (Membaca), dan 84.21 (Menulis). Dengan demikian, cluster ini dikategorikan sebagai Prestasi Tinggi. Algoritma Hierarchical Clustering juga menghasilkan tiga kelompok, namun

dengan label penomoran yang berbeda. Pada algoritma ini, Cluster 1 merupakan kelompok dengan nilai tertinggi, sedangkan Cluster 3 merupakan kelompok dengan nilai terendah. Perbedaan penomoran label ini umum terjadi pada algoritma unsupervised, karena setiap algoritma mengelompokkan data tanpa referensi kelas sehingga penamaan cluster tidak mencerminkan urutan tingkatan. Namun, pola yang dihasilkan kedua algoritma tetap konsisten dalam membedakan siswa berprestasi tinggi, sedang, dan rendah.



The screenshot shows a Google Colab interface with the following code and results:

```
# Untuk K-Means
cluster_summary_kmeans = df.groupby('Cluster_KMeans')[['math score', 'reading score', 'writing score']].mean()
cluster_summary_kmeans['Kategori'] = ['Rendah', 'Sedang', 'Tinggi']
print("Rata-rata nilai per cluster (K-Means):")
display(cluster_summary_kmeans)

# Untuk Hierarchical
cluster_summary_hc = df.groupby('Cluster_HC')[['math score', 'reading score', 'writing score']].mean()
cluster_summary_hc['Kategori'] = ['Rendah', 'Sedang', 'Tinggi']
print("Rata-rata nilai per cluster (Hierarchical):")
display(cluster_summary_hc)

Rata-rata nilai per cluster (K-Means):
math score    reading score    writing score    Kategori
Cluster_KMeans
0            65.338600      68.458239      67.821670    Rendah
1            48.096386      50.670683      48.485944    Sedang
2            81.714286      85.146104      84.207792    Tinggi

Rata-rata nilai per cluster (Hierarchical):
math score    reading score    writing score    Kategori
Cluster_HC
1            77.049896      81.128898      80.286902    Rendah
2            61.322946      63.016997      62.118980    Sedang
3            44.463855      47.596386      45.228916    Tinggi
```

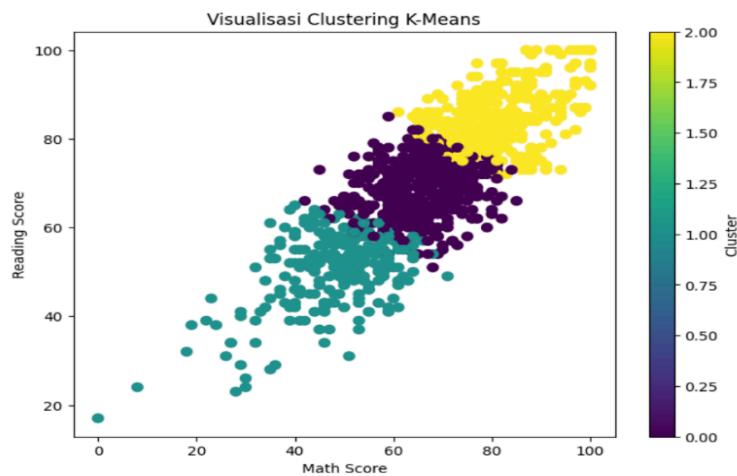
Gambar 2. Program Hasil Clustering Hierarki dan Algoritma K-Means Clustering di Google Colab

Secara keseluruhan, hasil pengelompokan menunjukkan bahwa algoritma K-Means dan Pengelompokan Hierarki memiliki kecenderungan yang serupa untuk memisahkan siswa berdasarkan prestasi akademiknya. Meskipun kedua algoritma menghasilkan penomoran cluster yang berbeda, perbedaan tersebut tidak berdampak pada interpretasi kategori prestasi karena penentuan label—rendah, sedang, atau tinggi—ditetapkan berdasarkan nilai rata-rata setiap atribut, bukan berdasarkan urutan label cluster yang dibuat otomatis oleh algoritma.

K-Means menunjukkan kemampuan pengelompokan yang lebih tegas, terlihat dari perbedaan rata-rata nilai antar cluster yang lebih jelas, terutama pada kelompok berprestasi tinggi dan rendah. Pola pemisahan nilai antarkelompok yang lebih kontras ini mengindikasikan bahwa K-Means mampu menangkap struktur data yang cenderung terdistribusi secara relatif merata di ruang fitur, sehingga menghasilkan pemisahan cluster yang lebih baik. Di sisi lain, Hierarchical Clustering tetap memberikan hasil pengelompokan yang konsisten, namun variasi rata-rata nilai antarkluster tampak lebih berdekatan dibandingkan dengan hasil K-Means. Hal ini dapat terjadi karena proses penggabungan bertahap pada metode agglomerative yang dapat menyebabkan beberapa cluster memiliki komposisi nilai yang lebih heterogen. Meskipun demikian, Hierarchical Clustering memberikan kelebihan dalam bentuk representasi dendrogram yang menunjukkan struktur hierarki dan hubungan kedekatan antar data, sehingga tetap relevan untuk analisis komprehensif.

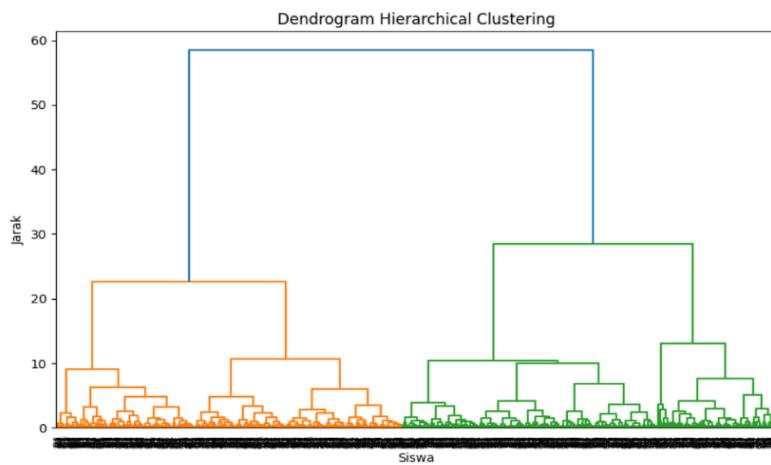
3.2 Visualisasi Hasil Clustering

Visualisasi hasil pengelompokan untuk algoritma pengelompokan hierarki dan K-Means dilakukan untuk memberikan pemahaman yang lebih baik tentang pola pengelompokan yang terbentuk. Visualisasi ini dibuat menggunakan dua variabel, yaitu nilai Matematika (math score) dan nilai Membaca (reading score), dengan warna yang berbeda untuk setiap cluster. Pemilihan dua variabel ini bertujuan untuk mempermudah representasi hasil pengelompokan dalam bentuk diagram dua dimensi (2D) sehingga pola pemisahan antar cluster dapat diamati secara langsung.



Gambar 3. Visualisasi Hasil Clustering Menggunakan Algoritma K-Means

Pada visualisasi K-Means, setiap cluster tampak terpisah cukup jelas, terutama antara kelompok berprestasi tinggi dan rendah. Hal ini menunjukkan bahwa K-Means mampu memetakan data ke dalam ruang fitur yang lebih terstruktur, sehingga pemisahan antar cluster terlihat lebih kuat. Penyebaran titik data yang cenderung membentuk kelompok padat juga menggambarkan bahwa K-Means bekerja secara optimal pada data dengan distribusi yang relatif konveks.



Gambar 4. Visualisasi Hasil Dendrogram Algoritma Hierarchical Clustering

Pada visualisasi Hierarchical Clustering, pola pemisahan cluster tetap terlihat, namun batas antar cluster tampak lebih tumpang tindih dibandingkan K-Means. Hal ini sesuai dengan karakteristik metode agglomerative, di mana penggabungan cluster dilakukan secara bertahap sehingga beberapa kelompok mungkin memiliki komposisi nilai yang lebih beragam. Meskipun demikian, struktur cluster yang terbentuk masih mampu membedakan kelompok siswa berprestasi tinggi, sedang, dan rendah.

Meskipun visualisasi hanya menggunakan dua variabel, data asli memiliki tiga fitur (Matematika, Membaca, dan Menulis). Oleh karena itu, representasi visual 2D tidak sepenuhnya menggambarkan kompleksitas struktur cluster di ruang tiga dimensi. Namun, visualisasi ini tetap memberikan indikasi awal mengenai kualitas pemisahan cluster dan mendukung hasil evaluasi kuantitatif yang dilakukan menggunakan Silhouette Score. Dari kedua visualisasi tersebut, terlihat bahwa K-Means menghasilkan pemisahan cluster yang lebih tegas, sedangkan Hierarchical Clustering menunjukkan beberapa area tumpang tindih. Hasil ini konsisten dengan analisis numerik dan nilai evaluasi yang dibahas pada subbab selanjutnya.

3.3 Evaluasi Hasil Clustering (Silhouette Score)

Evaluasi kualitas pengelompokan dalam penelitian ini dilakukan menggunakan metrik Silhouette Score, yaitu ukuran yang menunjukkan seberapa baik suatu data berada pada cluster yang tepat dibandingkan dengan cluster lain. Metrik ini sangat sesuai untuk penelitian berjenis unsupervised learning, karena tidak memerlukan label kelas dan hanya bergantung pada jarak antar data dalam ruang fitur. Nilai Silhouette berada dalam rentang -1 hingga 1 , di

mana nilai yang lebih besar dari 1 menunjukkan bahwa objek berada di cluster yang sangat sesuai dan jauh dari cluster lainnya, dan nilai yang lebih rendah menunjukkan bahwa objek berada pada batas antara dua cluster. Nilai negatif mengindikasikan bahwa objek lebih mirip dengan cluster lain sehingga kemungkinan ditempatkan di cluster yang salah. Pada penelitian ini, Silhouette Score dihitung untuk kedua algoritma menggunakan data yang telah dinormalisasi

3.3.1 Hasil Evaluasi

Dua algoritma, Hierarchical Clustering dan K-Means, diuji dengan data yang telah dinormalisasi. Hasil perhitungan Skor Silhouette untuk kedua algoritma tersebut ditunjukkan pada Tabel 2 dan Gambar 5 berikut.

Tabel 2. Perbandingan Nilai Silhouette Score Hierarchical dan K-Means

Algoritma	Silhouette Score	Interpretasi
K-Means	0.406	Baik
Hierarchical Clustering	0.374	Cukup Baik

```
[16] ✓ 0s
from sklearn.metrics import silhouette_score

score_kmeans = silhouette_score(scaled_data, df['Cluster_KMeans'])
score_hc = silhouette_score(scaled_data, df['Cluster_HC'])

print("Silhouette Score K-Means:", score_kmeans)
print("Silhouette Score Hierarchical:", score_hc)

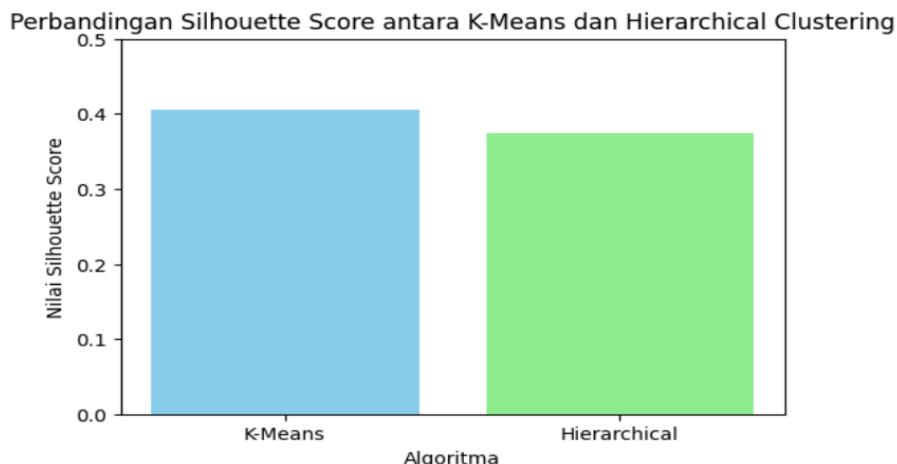
Silhouette Score K-Means: 0.40599504065325176
Silhouette Score Hierarchical: 0.37368405585398173
```

Gambar 5. Hasil Silhouette Score

Karena memperoleh nilai Silhouette yang lebih tinggi, K-Means menghasilkan struktur cluster yang lebih baik daripada Clustering Hierarchical. Perbedaan nilai ini menunjukkan kemampuan K-Means untuk membentuk cluster yang lebih terpisah dan lebih kompak (homogen dalam cluster) dan (heterogen antar cluster). Sedangkan Dengan nilai yang sedikit lebih rendah, klasifikasi hierarkis menunjukkan bahwa ada beberapa titik data yang berada cukup dekat dengan cluster lain sehingga pemisahan antar cluster kurang optimal.

3.3.2 Analisis Hasil Evaluasi

Nilai Skor Silhouette untuk algoritma K-Means adalah 0.406, sedangkan nilai Clustering Hierarchical adalah 0.374. Hasil evaluasi dapat dilihat pada Tabel 2 dan Gambar 5. Nilai silhouette yang lebih tinggi menunjukkan bahwa sebagian besar titik data pada K-Means berada dalam cluster yang tepat dan lebih jauh dari cluster terdekat, menunjukkan kemampuan mereka untuk menghasilkan struktur cluster yang lebih optimal dan jelas dibandingkan dengan hierarki clustering. Hasil ini konsisten dengan visualisasi sebaran data pada scatter plot. Pada hasil visualisasi K-Means, kelompok siswa tampak terpisah dengan lebih tegas dan batas antar cluster relatif jelas. Sementara itu, pada Hierarchical Clustering terlihat adanya tumpang tindih antar cluster, terutama pada nilai menengah. Hal ini disebabkan oleh sifat dasar metode agglomerative yang menggabungkan cluster secara bertahap tanpa proses iterasi berulang seperti pada K-Means, sehingga beberapa titik data cenderung masuk ke cluster yang kurang tepat.



Gambar 6. Benchmarking Hierarchical Clustering dan Silhouette Score K-Means

Oleh karena itu, dapat disimpulkan bahwa dari segi kualitas pengelompokan, K-Means lebih baik dalam mengelompokkan siswa berdasarkan tingkat prestasi akademik. Selain menghasilkan nilai Silhouette yang lebih tinggi, K-Means juga memiliki proses komputasi yang lebih cepat dan efisien untuk dataset berukuran menengah, seperti Dataset Prestasi Siswa. Efisiensi ini membuat K-Means lebih sesuai untuk digunakan pada analisis prestasi akademik siswa dalam skala data yang lebih besar, seperti data sekolah tingkat kota atau provinsi. Sementara itu, Hierarchical Clustering tetap bermanfaat untuk memberikan gambaran struktur hierarki melalui dendrogram, namun kurang optimal dalam menghasilkan cluster yang terpisah secara tegas pada dataset ini.

4. KESIMPULAN

Tujuan dari penelitian ini adalah untuk menganalisis dan membandingkan kinerja dua algoritma pengelompokan, yaitu K-Means dan Pengelompokan Hierarki, dalam mengelompokkan prestasi akademik siswa berdasarkan tiga nilai utama: membaca, menulis, dan matematika. Berdasarkan hasil pengolahan data, kedua algoritma ini mampu membentuk tiga cluster, masing-masing mewakili kategori prestasi rendah, sedang, dan tinggi. Namun, struktur cluster yang dihasilkan menunjukkan perbedaan kualitas pemisahan antar kelompok.

Berdasarkan evaluasi menggunakan Skor Silhouette, algoritma K-Means memberikan hasil pengelompokan yang lebih baik, dengan tingkat kohesi cluster yang lebih tinggi dan jarak antar cluster yang lebih kecil. Nilai-nilai ini menunjukkan bahwa algoritma K-Means memberikan hasil pengelompokan yang lebih baik. Visualisasi hasil clustering juga mendukung temuan ini, di mana penyebaran data pada K-Means tampak lebih terstruktur dan menunjukkan batas antar cluster yang lebih jelas dibandingkan Hierarchical Clustering. Selain kualitas pengelompokan yang lebih unggul, K-Means juga memiliki kelebihan dari sisi efisiensi komputasi. Proses iteratif yang dimiliki K-Means membuatnya lebih sesuai diterapkan pada dataset berukuran menengah hingga besar, seperti dataset prestasi akademik siswa. Sementara itu, Hierarchical Clustering tetap memberikan kelebihan dalam bentuk dendrogram yang memudahkan analisis struktur hierarki, namun kurang optimal dalam menghasilkan cluster yang terpisah secara tegas pada dataset ini. Secara keseluruhan, penelitian ini menyimpulkan bahwa algoritma K-Means lebih efisien untuk menggabungkan data tentang prestasi akademik siswa. Hasil ini dapat digunakan untuk membangun sistem yang mendukung keputusan pendidikan, seperti sistem pemantauan prestasi, penetapan program perbaikan, atau pemetaan kemampuan siswa untuk membuat strategi pembelajaran yang lebih tepat sasaran.

Untuk melanjutkan penelitian ini, beberapa rekomendasi yang dapat dipertimbangkan yaitu, menggunakan algoritma clustering lain seperti DBSCAN, Gaussian Mixture Model (GMM), atau Fuzzy C-Means untuk melihat perbandingan performa yang lebih komprehensif, menggunakan dataset dengan jumlah yang lebih besar atau dataset dari institusi pendidikan lain untuk menguji konsistensi hasil, menambahkan fitur tambahan seperti data kehadiran siswa, latar belakang sosial, atau hasil tes psikologi belajar untuk melihat pengaruh variabel lain terhadap pengelompokan prestasi, menerapkan metode validasi tambahan, seperti Index Davis-Bouldin atau Calinski-Harabasz agar evaluasi cluster lebih kuat.

REFERENSI

- [1] M. Habibullah Arief and M. Kholila Fadhil, “Educational Data Mining for Student Academic Performance Analysis,” 2024. [Online]. Available: <https://doi.org/10/25047/jtit.v11i2.5627>.
- [2] M. Faisal, N. Nurdin, F. Fajriana, and Z. Fitri, “Information and Communication Technology Competencies Clustering For Students For Vocational High School Students Using K-Means Clustering Algorithm,” *Int. J. Eng. Sci. Inf. Technol.*, vol. 2, no. 3, pp. 111–120, 2022, doi: 10.52088/ijest.v2i3.318.

-
- [3] R. Awalia, "Penerapan Metode K-Means Clustering untuk Pengelompokan Prestasi Siswa menggunakan Orange Data Mining: Studi Kasus di MTs Muhammadiyah Tallo Makassar," *Mechatronics Journal in Professional & Entrepreneur*, vol.6, no.2, 2024.
 - [4] V. V. Romanuke, "Random Centroid Initialization For Improving Centroid-Based Clustering," *Decision Making: Applications in Management and Engineering*, vol. 6, no. 2, pp. 734–746, 2023, doi: 10.31181/dmame622023742.
 - [5] N. Bili *et al.*, "Penerapan Algoritma K-Means Clustering Untuk Pengelompokan Performa Siswa Pada Pembelajaran Bahasa Indonesia(Studi Kasus: SD INPRES WAINGAPU 3) Application Of The K-Means Clustering Algorithm For Grouping Student Performance In Indonesia Language Learning (Case Study: SD INPRES WAINGAPU 3)," *Universitas Kristen Wira Wacana Sumba Fakultas Sains dan Teknologi SATI: Sustainable Agricultural Technology Innovation*, 2024.
 - [6] E. Palumbo, M. Vandenhirtz, A. Ryser, I. Daunhawer, and J. E. Vogt, "From Logits to Hierarchies: Hierarchical Clustering made Simple," Oct. 2024, [Online]. Available: <http://arxiv.org/abs/2410.07858>.
 - [7] Nurdin, C. C. Pradita, and Fadlysyah, "Implementasi Data Mining Untuk Menganalisis Kategori Kompetisi Mahasiswa Menggunakan Algoritma Apriori," *SISFO J. Ilm. Sist. Inf.*, vol. 7, no. 1, pp. 28–45, 2023.
 - [8] M. Sholeh and D. Andayati, "Penerapan Metode Clustering dengan Algoritma K-Means Pada Pengelompokan Indeks Prestasi Akademik Mahasiswa," *SKANIKA: Sistem Komputer dan Teknik Informatika*, vol. 6, no. 1, pp. 51–60, 2023.
 - [9] K. Aoyama and K. Saito, "Accelerating spherical K-means clustering for large-scale sparse document data," Nov. 2024, [Online]. Available: <http://arxiv.org/abs/2411.11300>.
 - [10] H. Jowhari, "Hierarchical Clustering via Local Search," May 2024, [Online]. Available: <http://arxiv.org/abs/2405.15983>.
 - [11] A. Hidayat *et al.*, "Analisis Perancangan Sistem Informasi pada Perpustakaan Institut Teknologi Mitra Gama," *FORMAT: Jurnal Ilmiah Teknik Informatika*, vol. 14, no.2, pp. 136-155, 2025 .
 - [12] N. Nurdin, Fajriana, R. Meiyanti, Adelia, and M. Maulita, "Clustering and Mapping of Agricultural Production Based on Geographic Information System Using K-Medoids Algorithm," *J. Artif. Intell. Technol.*, vol. 5, pp. 116–124, 2025, doi: 10.37965/jait.2025.0633.
 - [13] R. Dila, S. Defit, and S. Arlis, "Analisis Algoritma K-Means Clustering Dalam Pengelompokan Prestasi Belajar Siswa Menengah Atas (SMA)," *Bulletin Of Computer Science Research Media Online*, vol. 5, no. 5, pp. 1113–1119, 2025, doi: 10.47065/bulletincsr.v5i5.751.
 - [14] R. Khairuna, Nurdin, and Ar Razi, "Analisis Perbandingan Algoritma K-Means Dan K-Medoids Untuk Klusterisasi Teks Ulasan Pada Aplikasi Cookpad," *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 445–458, 2025, doi: 10.36341/rabit.v10i2.6131.
 - [15] V. Cohen-Addad, V. Kanade, F. Mallmann-Trenn, and C. Mathieu, "Hierarchical Clustering: Objective Functions and Algorithms," Apr. 2021, [Online]. Available: <http://arxiv.org/abs/1704.02147>.
 - [16] F. Rahmawati, S. Imanuel Fallo, P. Studi Matematika, and F. Leibniz, "Hierarchical Agglomerative Clustering Dengan Metode Ward Untuk Pemetaan Pasar Tenaga Kerja Pascapandemi Di Jawa Tengah: Pendekatan Machine Learning Berbasis Klasterisasi," *Jurnal Matematika*, 2022.
 - [17] A. Fadliana and F. Rozi, "Penerapan Metode Agglomerative Hierarchical Clustering Untuk Klasifikasi Kabupaten/Kota Di Provinsi Jawa Timur Berdasarkan Kualitas Pelayanan Keluarga Berencana," *Cauchy: Jurnal Matematika Murni Dan Aplikasi*, vol. 4, no. 1, pp. 32–40, 2020.
 - [18] Z. Fitri, Safriana, and Nurdin, "Computational thinking-based informatics material recommendation system for vocational school students with the content-based filtering method," *Edelweiss Appl. Sci. Technol.*, vol. 8, no. 6, pp. 4765–4777, 2024, doi: 10.55214/25768484.v8i6.3028.
 - [19] P. J. Rousseeuw, "Silhouettes: a graphical aid to the interpretation and validation of cluster analysis," *Journal of Computational and Applied Mathematics*, vol. 8, pp. 53-65, 2021.