

# Clustering Gaya Belajar Mahasiswa dengan Metode K-Means: Analisis VARK untuk Pengembangan Strategi Pembelajaran Adaptif

Tb Ai Munandar

Universitas Bhayangkara Jakarta Raya, Jakarta, Indonesia

Correspondence: e-mail: tbaimunandar@gmail.com

## Abstrak

Penelitian ini bertujuan memetakan gaya belajar mahasiswa menggunakan instrumen VARK (Visual, Auditory, Reading/Writing, Kinesthetic) melalui pendekatan *unsupervised learning*. Data diperoleh dari kuesioner mahasiswa, kemudian diproses melalui tahap pra-pemrosesan, meliputi ekstraksi kode jawaban, transformasi numerik dengan *one-hot encoding*, dan normalisasi. Algoritma K-Means Clustering digunakan untuk mengelompokkan mahasiswa berdasarkan pola jawaban, dengan jumlah klaster ditentukan sebanyak empat sesuai kerangka teoretis VARK. Hasil analisis menunjukkan terbentuknya empat klaster dengan karakteristik berbeda: Visual–Auditori, Auditori–Kinestetik, Reading/Writing, serta multimodal. Uji validitas menggunakan Silhouette Score, Davies–Bouldin Index, Calinski–Harabasz Index, dan Elbow Method menegaskan bahwa  $K=4$  merupakan konfigurasi optimal. Visualisasi dengan PCA serta distribusi proporsi VARK memperkuat keterpisahan antar klaster dan menunjukkan heterogenitas gaya belajar mahasiswa. Temuan ini memiliki implikasi praktis terhadap desain pembelajaran di perguruan tinggi. Setiap klaster menuntut strategi adaptif yang berbeda, misalnya penggunaan media visual, diskusi, praktik langsung, maupun variasi metode. Untuk penelitian selanjutnya, disarankan memperluas sampel, membandingkan dengan algoritma klasterisasi lain, serta mengintegrasikan data kuesioner dengan data perilaku belajar digital.

**Kata kunci:** VARK, Gaya Belajar, K-Means, Clustering, Pembelajaran Adaptif

## Abstract

This study aims to map students' learning styles using the VARK (Visual, Auditory, Reading/Writing, Kinesthetic) framework through an unsupervised learning approach. Data were collected from student questionnaires and pre-processed by extracting coded responses, transforming them into numerical variables via one-hot encoding, and applying normalization. The K-Means Clustering algorithm was then employed to group students based on response patterns, with the number of clusters set to four in accordance with the VARK theoretical framework. The results reveal four clusters with distinct characteristics: Visual–Auditory, Auditori–Kinesthetic, Reading/Writing, and Multimodal. Internal validation using the Silhouette Score, Davies–Bouldin Index, Calinski–Harabasz Index, and the Elbow Method confirmed that four clusters represent the optimal configuration. PCA visualization and the distribution of VARK preferences further support the separation among clusters while highlighting the heterogeneity of student learning styles. These findings have practical implications for the design of adaptive learning strategies in higher education. Each cluster requires differentiated approaches, such as the use of visual materials, discussions, hands-on practice, or a variety of methods for multimodal learners. Future studies are recommended to expand the sample size, compare alternative clustering algorithms, and integrate VARK questionnaire data with digital learning behavior to enrich the analysis.

**Keywords:** VARK, Learning Styles, K-Means, Clustering, Adaptive Learning

## 1. Pendahuluan

Perbedaan gaya belajar mahasiswa telah lama diakui sebagai salah satu faktor yang berpengaruh terhadap keberhasilan pembelajaran di perguruan tinggi. Mahasiswa tidak dapat dianggap homogen, karena setiap individu memiliki preferensi dalam menyerap, mengolah, dan merepresentasikan informasi. Apabila proses belajar hanya menggunakan pendekatan seragam, maka efektivitas pembelajaran tidak optimal karena sebagian mahasiswa tidak terakomodasi dengan baik [1]. Salah satu kerangka konseptual yang banyak digunakan untuk mengidentifikasi gaya belajar adalah VARK (Visual, Auditory, Reading/Writing, Kinesthetic) yang diperkenalkan oleh Fleming [2]. VARK menekankan bahwa mahasiswa dengan kecenderungan visual lebih responsif pada representasi grafis, mahasiswa auditori lebih terbantu dengan penjelasan lisan, mahasiswa reading/writing lebih menekankan teks dan catatan, sedangkan mahasiswa kinestetik lebih menyukai praktik langsung [3]. Kajian terbaru menegaskan bahwa meskipun terdapat perdebatan mengenai efektivitas penerapan model gaya belajar, VARK tetap banyak digunakan sebagai kerangka refleksi yang bermanfaat untuk merancang pengalaman belajar yang lebih personal [4]–[7].

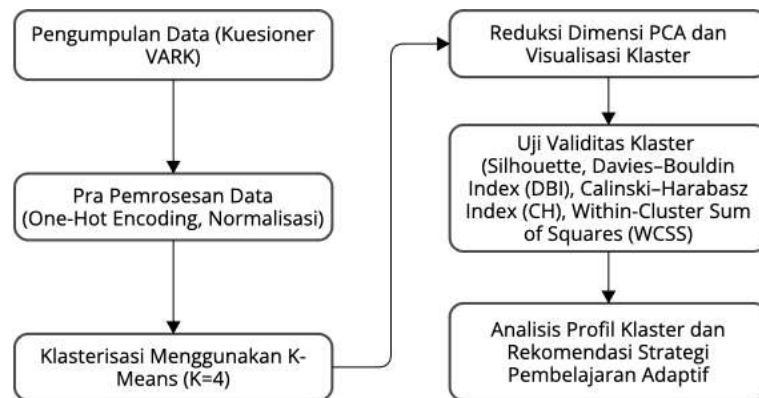
Beberapa penelitian sebelumnya menegaskan manfaat pemetaan gaya belajar berbasis VARK dalam desain pembelajaran adaptif. Chinnapun et al. [8] menemukan bahwa pengajaran berbasis VARK dapat meningkatkan capaian belajar biokimia medis. Bazán-Perkins et al. [9] menunjukkan adanya hubungan signifikan antara preferensi gaya belajar dan peningkatan hasil belajar mahasiswa kedokteran. Studi sistematis terbaru juga melaporkan bahwa pendekatan VARK masih menjadi acuan utama dalam penelitian gaya belajar di berbagai bidang kesehatan dan pendidikan tinggi [10], [11]. Namun demikian, sebagian besar penelitian terdahulu masih terbatas pada pendekatan deskriptif atau korelasional, sehingga tidak mampu menggali pola keterhubungan antar respon mahasiswa secara komprehensif. Kondisi ini menimbulkan masalah utama: bagaimana mengelompokkan mahasiswa berdasarkan data VARK dengan pendekatan yang lebih objektif, valid, dan mampu mengungkap struktur laten dalam data [12]–[15].

Untuk menjawab permasalahan tersebut, penelitian ini mengadopsi pendekatan unsupervised learning menggunakan algoritma K-Means Clustering. Algoritma ini populer dalam data mining karena kesederhanaan, kecepatan, dan kemampuannya dalam mengelompokkan data berukuran besar dengan variabel numerik [16]. Selain itu, K-Means dapat digabungkan dengan teknik reduksi dimensi seperti PCA untuk meningkatkan interpretabilitas hasil klasterisasi [17]. Validitas klaster kemudian dapat dievaluasi dengan berbagai metrik internal, seperti Silhouette Score [18], Davies–Bouldin Index [19], Calinski–Harabasz Index [20], dan Within-Cluster Sum of Squares (WCSS) melalui metode Elbow [21]. Berbagai studi terkini menegaskan keunggulan K-Means dalam aplikasi pendidikan, baik untuk evaluasi pembelajaran, analisis pola kehadiran, maupun penentuan profil mahasiswa [22], [23]. Dengan demikian, penerapan algoritma ini pada data VARK dipandang relevan dan potensial untuk menghasilkan pengelompokan gaya belajar yang lebih akurat dan dapat dipertanggungjawabkan [24].

Kontribusi utama penelitian ini adalah menghadirkan model pemetaan gaya belajar mahasiswa berbasis data yang mengintegrasikan kerangka konseptual VARK dengan analisis machine learning. Penelitian ini tidak hanya menghasilkan klaster gaya belajar yang sejalan dengan teori, tetapi juga memvalidasi struktur klaster secara empiris melalui metrik evaluasi. Inovasi lainnya adalah penyusunan rekomendasi strategi pembelajaran adaptif berdasarkan hasil klasterisasi, sehingga dosen dan institusi pendidikan memiliki dasar yang lebih kuat dalam merancang metode pengajaran diferensial. Dengan cara ini, penelitian ini diharapkan dapat memberikan kontribusi pada dua aspek: (1) memperkaya khazanah educational data mining melalui penerapan unsupervised learning dalam konteks gaya belajar, dan (2) memberikan solusi praktis untuk meningkatkan efektivitas pembelajaran di perguruan tinggi [25]–[28].

## 2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksploratif dengan metode unsupervised learning, khususnya algoritma K-Means Clustering, untuk memetakan gaya belajar mahasiswa berdasarkan kerangka VARK (Visual, Auditory, Reading/Writing, Kinesthetic). Tujuan utama metode ini adalah mengidentifikasi kelompok mahasiswa dengan karakteristik belajar yang homogen, sehingga dapat dihasilkan rekomendasi strategi pembelajaran adaptif. Tahap penelitian dimulai dengan pengumpulan data, pra pemrosesan data, pengelompokan gaya belajar menggunakan algoritme k-means, reduksi dimensi berbasis PCA, uji validitas dan terakhir analisis profil klaster dan rekomendasi strategi pembelajaran adaptif. Gambar 1 memperlihatkan tahapan penelitian yang dilakukan



Gambar 1. Tahapan Penelitian

## 2.1 Data dan Instrumen

Data diperoleh melalui kuesioner VARK yang diadaptasi dari instrumen asli yang dikembangkan oleh Fleming [1]. Kuesioner terdiri dari sejumlah pertanyaan dengan empat pilihan jawaban yang mewakili kategori V, A, R, dan K. Responden adalah mahasiswa dari berbagai program studi yang mengisi kuesioner secara daring. Setiap respon mahasiswa menghasilkan vektor jawaban yang merepresentasikan distribusi preferensi belajar.

## 2.2 Tahap Pra-pemrosesan Data

Tahapan pengolahan data dilakukan dalam beberapa langkah. Pertama, seluruh jawaban kuesioner diekstrak menjadi kode (V), (A), (R), dan (K). Kedua, jawaban diubah ke bentuk numerik menggunakan teknik one-hot encoding, sehingga setiap responden memiliki representasi numerik yang dapat diproses oleh algoritma clustering. Ketiga, data dinormalisasi menggunakan StandardScaler untuk menyamakan skala antar variabel dan mencegah dominasi nilai tertentu. Proses pra-pemrosesan ini penting untuk menjaga akurasi hasil klasterisasi serta meningkatkan stabilitas algoritma.

## 2.3 Proses Klasterisasi

Metode utama yang digunakan adalah K-Means Clustering, yang bekerja dengan menginisialisasi sejumlah centroid kemudian mengelompokkan data berdasarkan kedekatan jarak Euclidean. Jumlah klaster (K) ditentukan sebanyak empat, sesuai dengan kerangka konseptual VARK. Algoritma kemudian mengiterasi proses assignment dan update centroid hingga mencapai konvergensi, yaitu kondisi ketika perpindahan anggota klaster sudah stabil. Selain itu, untuk mempermudah visualisasi hasil, dilakukan Principal Component Analysis (PCA) untuk mereduksi dimensi data ke dalam dua komponen utama.

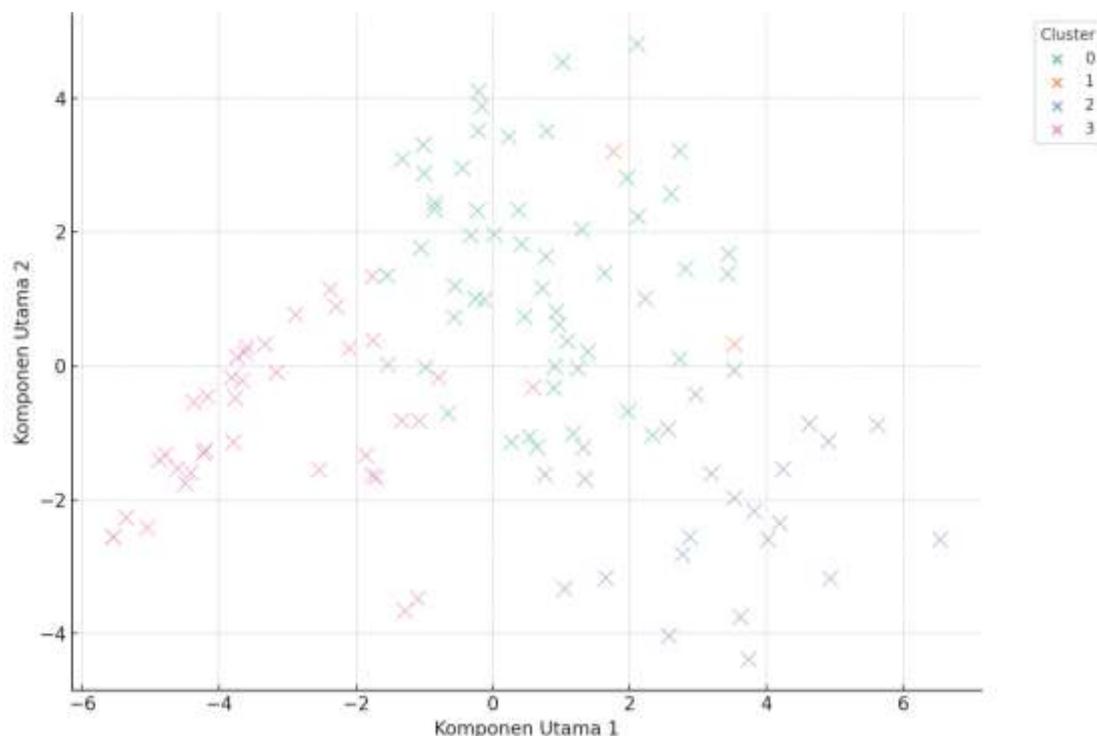
## 2.4 Uji Validitas Klaster

Validitas hasil klasterisasi diuji menggunakan empat metrik internal. Pertama, Silhouette Score untuk mengukur tingkat kohesi intra-kluster dan separasi antar-kluster. Kedua, Davies–Bouldin Index (DBI) untuk menilai tingkat kemiripan antar-kluster, di mana nilai lebih rendah menunjukkan pemisahan yang lebih baik. Ketiga, Calinski–Harabasz Index (CH) yang membandingkan variansi antar-kluster dengan variansi dalam-kluster. Keempat, Within-Cluster Sum of Squares (WCSS) yang divisualisasikan dengan Elbow Method untuk menentukan titik optimal jumlah klaster. Kombinasi keempat metrik ini digunakan untuk mengevaluasi robustitas hasil pengelompokan.

## 3. Hasil dan Pembahasan

Data penelitian ini bersumber dari kuesioner gaya belajar berbasis VARK (Visual, Auditory, Reading/Writing, Kinesthetic) yang diisi oleh mahasiswa dari berbagai wilayah di Indonesia. Ada 120 responden yang mengisi kuesioner gaya belajar yang disebarluaskan. Setiap respon jawaban diekstrak menjadi kode (V), (A), (R), atau (K). Tahap awal pra-pemrosesan melibatkan konversi jawaban ke bentuk numerik menggunakan one-hot encoding, kemudian normalisasi dengan StandardScaler agar setiap variabel memiliki skala yang setara. Proses ini krusial untuk memastikan algoritma klasterisasi tidak bias terhadap perbedaan skala data, sehingga pola yang muncul benar-benar mewakili perbedaan preferensi belajar mahasiswa.

Metode analisis yang digunakan adalah K-Means Clustering dengan jumlah klaster ditentukan sebanyak empat. Penetapan ini tidak hanya berlandaskan pertimbangan teoretis, yaitu empat dimensi utama dalam model VARK, tetapi juga diperkuat melalui evaluasi validitas klaster. Hasil klasterisasi menunjukkan distribusi mahasiswa yang tidak seimbang: Cluster 0 beranggotakan 53 mahasiswa, Cluster 3 beranggotakan 39 mahasiswa, Cluster 2 terdiri atas 24 mahasiswa, dan Cluster 1 hanya 2 mahasiswa. Struktur hasil pengelompokan divisualisasikan dengan Principal Component Analysis (PCA) dua dimensi yang ditampilkan pada Gambar 2. Terlihat bahwa keempat klaster membentuk kelompok yang relatif terpisah, meskipun terdapat sejumlah individu yang berada di wilayah peralihan antar klaster, mencerminkan adanya variasi gaya belajar yang tumpang tindih.



Gambar 2. Visualisasi Klaster Mahasiswa Berdasarkan PCA (K=4)

Profil gaya belajar pada setiap klaster kemudian dianalisis berdasarkan distribusi proporsi kode VARK. Hasilnya menunjukkan bahwa masing-masing klaster memiliki karakteristik dominan yang berbeda. Cluster 0 cenderung pada kombinasi Visual–Auditori, mengindikasikan preferensi kuat terhadap media grafis dan penjelasan verbal. Cluster 3 didominasi oleh kecenderungan Auditori–Kinestetik, yang berarti mahasiswa dalam kelompok ini lebih optimal dengan diskusi, praktik, dan pengalaman langsung. Cluster 2 relatif menonjol pada aspek Reading/Writing, menunjukkan preferensi terhadap teks, catatan, dan aktivitas menulis. Sementara itu, Cluster 1 yang kecil memperlihatkan pola multimodal, yaitu fleksibilitas menggunakan berbagai gaya belajar. Distribusi ini divisualisasikan dalam Gambar 3, yang memperlihatkan proporsi VARK di setiap klaster secara lebih jelas.



Gambar 3. Distribusi Gaya Belajar (VARK) per Kluster

Temuan mengenai distribusi gaya belajar ini menegaskan heterogenitas preferensi belajar mahasiswa. Tidak semua mahasiswa dapat dilayani dengan metode pembelajaran yang sama, karena tiap klaster menampilkan kebutuhan yang berbeda. Keberadaan klaster multimodal, walaupun kecil, menunjukkan adanya kelompok mahasiswa dengan fleksibilitas tinggi dalam menerima berbagai bentuk stimulus pembelajaran. Hal ini menjadi indikator bahwa strategi pembelajaran adaptif perlu dirancang secara diferensial, agar semua tipe mahasiswa memperoleh kesempatan belajar yang optimal.

Validitas hasil klasterisasi diuji dengan sejumlah metrik internal: Silhouette Score, Davies–Bouldin Index (DBI), Calinski–Harabasz Index (CH), serta Within-Cluster Sum of Squares (WCSS) melalui metode Elbow. Nilai evaluasi pada rentang  $K=2$  hingga  $K=8$  disajikan pada Tabel 1. Data dalam tabel menunjukkan bahwa  $K=4$  menghasilkan nilai Silhouette yang relatif tinggi (0,0769), DBI yang lebih rendah (2,6548), serta nilai CH yang cukup kompetitif (7,4173). Selain itu, nilai WCSS pada  $K=4$  sudah mulai menunjukkan perlambatan penurunan, yang mengindikasikan keberadaan titik tekukan atau elbow. Dengan kata lain, pemilihan empat klaster didukung baik secara konseptual maupun empiris.

Tabel 1. Hasil Uji Validitas Internal Klaster ( $K=2$ – $8$ )

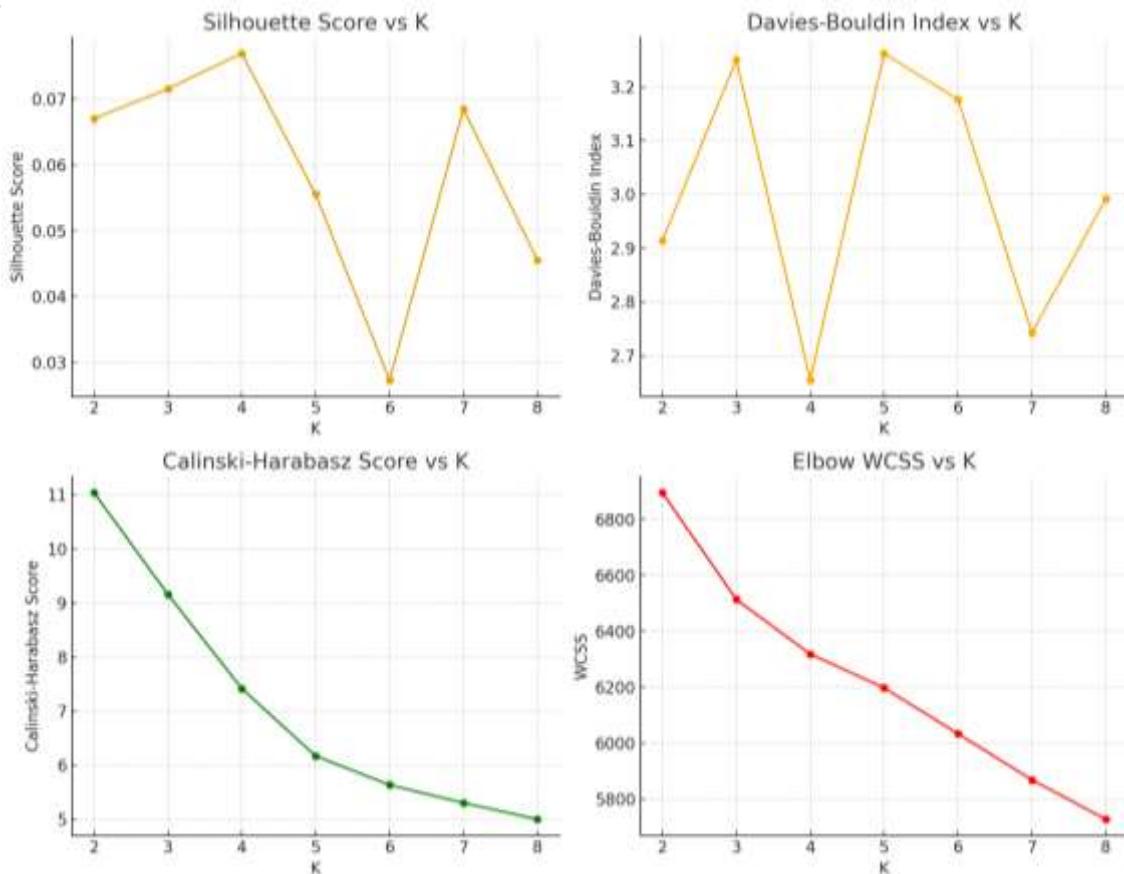
Jumlah - k	Silhouette	Davies-Bouldin	Calinski-Harabasz	WCSS
2	0.067	2.9144	11.0364	6895.9146
3	0.0716	3.2503	9.1599	6514.2604
4	0.0769	2.6548	7.4173	6318.6553
5	0.0555	3.2621	6.1717	6197.9489
6	0.0274	3.1766	5.6361	6033.8223
7	0.0685	2.7426	5.3043	5869.182
8	0.0456	2.9913	5.0036	5728.1187

Gambar 4 memperlihatkan pola bahwa Silhouette Score mencapai kestabilan pada  $K=4$ , DBI menurun pada titik yang sama, CH meningkat cukup signifikan, dan kurva WCSS menunjukkan titik elbow yang jelas. Kombinasi ini memperlihatkan bahwa jumlah klaster empat merupakan konfigurasi optimal, sehingga hasil klasterisasi memiliki kekuatan statistik untuk dipertanggungjawabkan. Dengan demikian, penggunaan  $K=4$  tidak hanya sesuai dengan teori VARK, tetapi juga memperoleh justifikasi kuat dari sisi validitas internal.

Hasil pengujian ini memperkuat keyakinan bahwa metode K-Means dapat digunakan secara efektif untuk mengidentifikasi pola gaya belajar mahasiswa. Keberhasilan klasterisasi dalam membentuk kelompok yang terstruktur menunjukkan bahwa mahasiswa memang memiliki preferensi belajar yang dapat dipetakan dengan jelas. Fakta bahwa klasterisasi empiris konsisten dengan kerangka VARK memperlihatkan bahwa pendekatan unsupervised learning ini mampu mengungkap pola teoretis yang sudah lama diakui dalam literatur pendidikan, sekaligus memberikan cara baru untuk mengujinya secara kuantitatif.

Implikasi praktis dari hasil penelitian ini sangat penting bagi strategi pembelajaran adaptif. Mahasiswa dengan dominasi Visual–Auditori lebih efektif difasilitasi dengan kombinasi bahan visual (grafik, video, diagram) dan penjelasan lisan. Mahasiswa dengan preferensi Auditori–Kinestetik akan lebih berkembang melalui diskusi, praktik, dan simulasi. Kelompok Reading/Writing lebih optimal melalui penyediaan literatur, modul, dan tugas menulis. Sementara itu, kelompok multimodal memerlukan variasi metode agar semua kecenderungannya terakomodasi. Dengan cara ini, hasil klasterisasi dapat diterjemahkan langsung ke dalam strategi pengajaran yang kontekstual di perguruan tinggi.

Secara keseluruhan, penelitian ini menunjukkan bahwa penerapan K-Means Clustering pada instrumen VARK bukan sekadar latihan statistik, tetapi memberikan kontribusi nyata dalam ranah pendidikan. Analisis klaster menghasilkan peta gaya belajar mahasiswa yang dapat menjadi landasan bagi dosen dalam merancang pembelajaran adaptif. Dengan memanfaatkan hasil ini, pendekatan pengajaran dapat diarahkan untuk meningkatkan efektivitas, relevansi, dan pengalaman belajar mahasiswa secara keseluruhan.



Gambar 4. Evaluasi Validitas Klaster (K=2–8)

#### 4. Kesimpulan

Penelitian ini membuktikan bahwa metode unsupervised learning dengan algoritma K-Means Clustering dapat digunakan secara efektif untuk memetakan gaya belajar mahasiswa berdasarkan instrumen VARK. Hasil analisis menghasilkan empat klaster dengan karakteristik dominan yang berbeda, yaitu Visual–Auditori, Auditori–Kinestetik, Reading/Writing, serta satu klaster multimodal. Validitas internal yang diuji menggunakan Silhouette Score, Davies–Bouldin Index, Calinski–Harabasz Index, dan Elbow Method menunjukkan bahwa jumlah klaster empat merupakan konfigurasi optimal, sekaligus konsisten dengan kerangka konseptual VARK. Temuan ini menegaskan pentingnya pemetaan gaya belajar sebagai dasar dalam mengembangkan strategi pembelajaran adaptif yang lebih responsif terhadap keragaman mahasiswa.

Untuk penelitian mendatang, terdapat beberapa peluang pengembangan yang dapat dilakukan. Pertama, memperluas ukuran sampel dan konteks institusi agar hasil analisis lebih representatif dan dapat digeneralisasikan. Kedua, membandingkan performa K-Means dengan algoritma clustering lainnya, seperti Hierarchical Clustering atau DBSCAN, guna memperoleh gambaran komparatif atas keunggulan masing-masing metode. Ketiga, mengintegrasikan data kuesioner VARK dengan data perilaku belajar mahasiswa, misalnya interaksi dalam Learning Management System atau capaian akademik, untuk memperkaya model analisis. Dengan arah tersebut, penelitian selanjutnya diharapkan mampu menghasilkan temuan yang lebih komprehensif, sekaligus memberikan landasan yang kuat bagi pengembangan sistem pembelajaran adaptif berbasis data di perguruan tinggi.

#### Daftar Pustaka

- [1] E. El-Saftawy et al., “Influence of applying VARK learning styles on enhancing teaching skills,” BMC Medical Education, 2024. doi: <https://doi.org/10.1186/s12909-024-05979-x>
- [2] N. D. Fleming and C. Mills, “Not Another Inventory, Rather a Catalyst for Reflection,” To Improve the Academy, vol. 11, pp. 137–155, 1992. Doi : <https://doi.org/10.1002/j.2334-4822.1992.tb00213.x>

- [3] V. Clinton-Lisell, "Is it really a neuromyth? A meta-analysis of the learning styles hypothesis," *Front. Psychol.*, vol. 15, 2024. Available: <https://doi.org/10.3389/fpsyg.2024.1428732>
- [4] R. A. Cabual, "Learning Styles and Preferred Learning Modalities in the New Normal" *Open Access Library Journal*, Vol. 8 No. 4, 2021. doi: <https://doi.org/10.4236/oalib.1107305>
- [5] I. Zrudlo, "Why the learning styles myth appeals and how to persuade believers otherwise" *Teaching and Teacher Education*, vol. 132, 2023. doi: <https://doi.org/10.1016/j.tate.2023.104266>
- [6] N. Ferrer-Valdivia et al., "Learning Styles in undergraduate dentistry students: a systematic review," *J Japanese Dental Science Review* Vol. 61, 2025. Doi : <https://doi.org/10.1016/j.jdsr.2025.03.004>
- [7] A. R. Sayed et al., "Exploring the VAK model to predict student learning styles based on learning activity", *Intelligent Systems with Applications*, Vol.25, 2025. Doi : <https://doi.org/10.1016/j.iswa.2025.200483>
- [8] D. Chinnapun et al., "Enhancing Learning in Medical Biochemistry by Teaching Based on VARK Learning Style for Medical Students," *Advances in Medical Education and Practice*, Vol. 15, 2024. Doi : <https://doi.org/10.2147/AMEP.S472532>
- [9] J. R. Bazán-Perkins et al., "Relationship between the learning gains and learning style preferences among students from the school of medicine and health sciences" *BMC Med. Educ.*, 25 71 (2025). DOI : <https://doi.org/10.1186/s12909-024-06554-0>
- [10] R. Pashler, M. McDaniel, D. Rohrer, and R. Bjork, "Learning Styles: Concepts and Evidence," *Psychol. Sci. Public Interest*, vol. 9, no. 3, pp. 105–119, 2008. doi: <https://doi.org/10.1111/j.1539-6053.2009.01038.x>
- [11] M. Durán Pincay and Y. Durán Pincay, "VARK learning styles in Medical Education: a systematic review", *Salud, Ciencia y Tecnología*, vol. 4, p. .594, Sep. 2024, doi: <https://doi.org/10.56294/saludcyt2024.594>
- [12] A. Y. Obeng et al., "Consequential effects of using competing perspectives to predict learning style in e-learning systems", *Cogent Education*, 10(1), 2023. <https://doi.org/10.1080/2331186X.2023.2218960>
- [13] W. A. Prastyabudi et al., "Segmenting the Higher Education Market: An Analysis of Admissions Data Using K-Means Clustering" *Procedia Computer Science*, vol. 234, 95-105, 2024. Doi : <https://doi.org/10.1016/j.procs.2024.02.156>
- [14] R. Liu, "Data Analysis of Educational Evaluation Using K-Means," *Comput. Intell. Neurosci.*, vol. 2022, 2022. doi: <https://doi.org/10.1155/2022/3762431>
- [15] P. M. Newton, "How Common Is Belief in the Learning Styles Neuromyth, and Does It Matter? A Pragmatic Systematic Review" *Front. Educ.*, vol. 5, 2020. doi: <https://doi.org/10.3389/feduc.2020.602451>
- [16] C. Ding and X. He, "K-means Clustering via Principal Component Analysis," in *Proc. ICML*, 2004, pp. 225–232. doi: <https://doi.org/10.1145/1015330.1015408>
- [17] B. Sinaga, "Multivariate Data Analysis for Customer Segmentation Using Principal Component Analysis and K-Means Clustering ", *Info Sains*, vol. 15, no. 01, pp. 283–291, Aug. 2025. Available : <https://ejournal.seaninstitute.or.id/index.php/InfoSains/article/view/7192>
- [18] P. J. Rousseeuw, "Silhouettes: A graphical aid to the interpretation and validation of cluster analysis" *Journal of Computational and Applied Mathematics*, vol. 20, pp. 53–65, 1987. doi: [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- [19] D. L. Davies and D. W. Bouldin, "A Cluster Separation Measure," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-1, no. 2, pp. 224-227, April 1979, doi: <https://doi.org/10.1109/TPAMI.1979.4766909>
- [20] Caliński, T., & Harabasz, J. "A dendrite method for cluster analysis", *Communications in Statistics*, 3(1), 1–27, 1974. Doi: <https://doi.org/10.1080/03610927408827101>
- [21] E. du Plooy et al., "Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement" *Heliyon*, vol. 10, no. 1, 2024. doi: <https://doi.org/10.1016/j.heliyon.2024.e39630>
- [22] E. G. Rincón-Flores et al., "Improving the learning-teaching process through adaptive learning strategy", *Smart Learn. Environ.* 11, 27 (2024). <https://doi.org/10.1186/s40561-024-00314-9>
- [23] V. Mirata et al., "Rincon-Flores, E.G., Castano, L., Guerrero Solis, S.L. et al. Role of organisational readiness and stakeholder acceptance: an implementation framework of adaptive learning for higher education", *Education Tech Research Dev* 71, 1567–1593 (2023). <https://doi.org/10.1007/s11423-023-10248-7>
- [24] Shi, P., Liu, W. Adaptive learning oriented higher educational classroom teaching strategies. *Sci Rep* 15, 15661 (2025). <https://doi.org/10.1038/s41598-025-00536-y>

- [25] D. Hooshyar, X. Weng, P.J. Sillat, K. Tammets, M. Wang, R. Hämäläinen, "The effectiveness of personalized technology-enhanced learning in higher education: A meta-analysis with association rule mining", Computers & Education, vol. 223, 2024. doi: <https://doi.org/10.1016/j.compedu.2024.105169>
- [26] Sumarlin, dan D. Anggraini, "Data Mining Pendidikan: Prediksi Gaya Belajar Mahasiswa Teknik Menggunakan Machine Learning", JTIIK, vol. 12, no. 3, pp. 563–572, Jun. 2025, doi: <https://doi.org/10.25126/jtiik.2025129190>
- [27] S R. Liu, "Data Analysis of Educational Evaluation Using K-Means Clustering Method", Computational Intelligence and Neuroscience, July 2022, DOI : <https://doi.org/10.1155/2022/3762431>
- [28] I. Gligoreea, M. Cioca, R. Oancea, A-T. Gorski, H. Gorski, P. Tudorache, "Adaptive Learning Using Artificial Intelligence in e-Learning: A Literature Review", Education Sciences. 2023; 13(12):1216. <https://doi.org/10.3390/educsci13121216>