



## Analisis Pola Aktivitas Belajar Mahasiswa pada *Learning Management System* Menggunakan Teknik *Clustering*

Nurfaizah\*

Program Studi Sistem Informasi, Universitas Amikom Purwokerto, Indonesia

\*Penulis Korespondensi: [nurfaizah@amikompurwokerto.ac.id](mailto:nurfaizah@amikompurwokerto.ac.id)

**Abstract.** *The increasing use of Learning Management Systems (LMS) in higher education generates large amounts of student activity data that have the potential to provide deeper insights into learning processes. However, in practice, these data are still rarely analyzed systematically to understand variations in students' learning activity patterns, limiting their practical use in supporting teaching and learning. This study aims to explore students' learning activity patterns in an LMS using a clustering approach based on activity data. This research utilizes the publicly available Open University Learning Analytics Dataset (OULAD), focusing on a single course and a single academic term. LMS activity data were processed through data cleaning and feature extraction, followed by student clustering using the K-Means algorithm. The quality of the clustering results was evaluated using the Silhouette Score, and visual analysis was applied to support the interpretation of the results. The results indicate that students' learning activities can be grouped into two main patterns, namely a group of students with high learning activity and a group with lower or moderate activity levels. These findings highlight the existence of heterogeneous learning behaviors among students, even within the same learning context. The identified learning activity patterns provide an initial foundation for utilizing LMS data to monitor student engagement and to support the development of more responsive, data-driven learning approaches in higher education.*

**Keywords:** *Activity Patterns; K-Means; Learning Analytics; LMS Analytics; Student Clustering.*

**Abstrak.** Pemanfaatan Learning Management System (LMS) di pendidikan tinggi menghasilkan data aktivitas belajar mahasiswa yang berpotensi memberikan gambaran proses belajar secara lebih mendalam. Namun, dalam praktiknya, data tersebut masih jarang dianalisis secara sistematis untuk memahami variasi pola aktivitas belajar mahasiswa, sehingga pemanfaatannya dalam mendukung proses pembelajaran belum optimal. Penelitian ini bertujuan untuk menganalisis pola aktivitas belajar mahasiswa pada LMS menggunakan pendekatan clustering berbasis data aktivitas. Penelitian ini menggunakan dataset publik Open University Learning Analytics Dataset (OULAD) dengan membatasi analisis pada satu mata kuliah dan satu periode pembelajaran. Data aktivitas LMS diproses melalui tahap pembersihan, ekstraksi fitur aktivitas, dan pengelompokan mahasiswa menggunakan algoritma K-Means. Kualitas hasil clustering dievaluasi menggunakan Silhouette Score, serta divisualisasikan untuk mendukung interpretasi hasil. Hasil penelitian menunjukkan bahwa aktivitas belajar mahasiswa membentuk dua pola utama, yaitu kelompok mahasiswa dengan tingkat aktivitas belajar yang tinggi dan kelompok mahasiswa dengan aktivitas belajar yang lebih rendah atau moderat. Temuan ini menegaskan adanya variasi perilaku belajar mahasiswa meskipun berada dalam konteks pembelajaran yang sama. Hasil pemetaan pola aktivitas belajar ini dapat menjadi dasar awal bagi pemanfaatan data LMS dalam pemantauan keterlibatan mahasiswa serta pengembangan pendekatan pembelajaran yang lebih responsif dan berbasis data di pendidikan tinggi..

**Kata kunci:** Analisis LMS; Analisis Pembelajaran; K-Means; Pengelompokan Siswa; Pola Aktivitas.

### 1. LATAR BELAKANG

Pemanfaatan LMS di pendidikan tinggi semakin meluas seiring berkembangnya pembelajaran daring dan blended learning. LMS tidak hanya berfungsi sebagai media penyampaian materi, tetapi juga sebagai aplikasi perangkat lunak yang mendukung pengadministrasian, dokumentasi, pelacakan, pelaporan, serta penyampaian pembelajaran secara terstruktur, sekaligus merekam berbagai aktivitas mahasiswa seperti akses materi, diskusi, dan evaluasi pembelajaran. Aktivitas tersebut tersimpan dalam bentuk log LMS yang berpotensi memberikan gambaran rinci mengenai proses dan perilaku belajar mahasiswa

selama satu periode pembelajaran, serta memungkinkan pemantauan dan penilaian pencapaian tujuan pembelajaran mahasiswa secara sistematis (Kuzilek et al., 2017; Aljaloud et al., 2022; Purwoningsih et al., 2023).

Namun, dalam praktiknya, pemanfaatan data aktivitas LMS masih belum optimal. Evaluasi pembelajaran umumnya berfokus pada hasil akhir berupa nilai akademik, sementara pola aktivitas belajar mahasiswa yang terekam dalam LMS jarang dianalisis secara sistematis (Ginting, 2025). Akibatnya, dosen memiliki keterbatasan dalam memahami tingkat keterlibatan, konsistensi, dan variasi perilaku belajar mahasiswa, padahal pemahaman terhadap proses belajar tersebut penting untuk meningkatkan kualitas pembelajaran (Tresnawati et al., 2025).

Learning analytics hadir sebagai pendekatan untuk mengolah data LMS menjadi informasi yang bermakna melalui teknik analisis data dan machine learning. Salah satu metode yang banyak digunakan adalah clustering, yang memungkinkan pengelompokan mahasiswa berdasarkan kesamaan pola aktivitas belajar tanpa memerlukan label kelas tertentu (Zhang et al., 2023). Penelitian sebelumnya telah dilakukan menunjukkan bahwa teknik clustering mampu mengidentifikasi kelompok mahasiswa dengan karakteristik perilaku belajar yang berbeda (Lima et al., 2024).

Meskipun demikian, sebagian penelitian sebelumnya masih menggunakan pendekatan yang kompleks atau kurang menekankan interpretasi hasil, sehingga sulit diterapkan secara praktis dalam konteks pembelajaran sehari-hari. Selain itu, penelitian yang memanfaatkan dataset LMS terbuka dengan pendekatan yang sederhana dan mudah direplikasi masih relatif terbatas. Banyak studi lebih menitikberatkan pada prediksi kinerja akademik dibandingkan eksplorasi awal pola aktivitas belajar mahasiswa (Rita Awoliyi, 2023).

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk menganalisis pola aktivitas belajar mahasiswa pada LMS menggunakan teknik clustering. Dengan memanfaatkan dataset publik Open University Learning Analytics Dataset (OULAD) (Kuzilek et al., 2017) dan algoritma K-Means, penelitian ini berupaya mengidentifikasi kelompok mahasiswa dengan karakteristik aktivitas belajar yang berbeda. Hasil penelitian diharapkan dapat memberikan gambaran awal mengenai variasi perilaku belajar mahasiswa serta menjadi dasar pemanfaatan data LMS yang lebih efektif dalam mendukung proses pembelajaran di perguruan tinggi.

## **2. KAJIAN TEORITIS**

### **Learning Manajemen System**

Dalam penelitian ini, LMS diposisikan bukan sebagai objek teknologi, melainkan sebagai sumber data empiris untuk mengamati dinamika perilaku belajar mahasiswa secara longitudinal. LMS menyediakan seperangkat fungsi untuk pengelolaan konten pembelajaran, pengaturan aktivitas akademik, serta fasilitasi interaksi antara dosen dan mahasiswa dalam satu platform terpadu. Dalam kerangka ini, LMS diposisikan sebagai infrastruktur pembelajaran digital yang mendukung penyelenggaraan pembelajaran berbasis teknologi informasi secara terstruktur dan terdokumentasi (Kuzilek et al., 2017; Aljaloud et al., 2022).

Selain sebagai sarana pengelolaan pembelajaran, LMS menghasilkan data aktivitas pembelajaran sebagai konsekuensi dari interaksi pengguna dengan sistem. Data tersebut tersimpan dalam bentuk log sistem yang mencatat berbagai bentuk aktivitas, seperti frekuensi akses, jenis interaksi, serta intensitas keterlibatan mahasiswa dalam pembelajaran. Secara teoretis, data log LMS dapat dipandang sebagai representasi perilaku belajar mahasiswa dalam lingkungan pembelajaran digital, karena mencerminkan bagaimana mahasiswa memanfaatkan sumber belajar dan berinteraksi dengan aktivitas pembelajaran yang tersedia.

### **Learning Analytics**

Dalam kajian analitik pendidikan, pemanfaatan data pembelajaran digital dibahas dalam kerangka learning analytics. Dalam konteks penelitian ini, learning analytics digunakan sebagai kerangka eksploratif untuk mengungkap struktur laten perilaku belajar mahasiswa berbasis data aktivitas. Pendekatan ini menempatkan data aktivitas pembelajaran sebagai objek analisis utama, dengan tujuan memperoleh pemahaman yang lebih mendalam mengenai dinamika pembelajaran yang berlangsung di lingkungan digital (Kharis & Zili, 2022).

Salah satu aspek penting dalam learning analytics adalah analisis pola aktivitas belajar mahasiswa. Pola aktivitas belajar merujuk pada keteraturan dan karakteristik perilaku mahasiswa yang terbentuk dari kombinasi intensitas interaksi, konsistensi keterlibatan, serta jenis aktivitas pembelajaran yang dilakukan. Dalam perspektif teoretis, pola aktivitas belajar dapat digunakan untuk menggambarkan variasi strategi belajar mahasiswa, tanpa harus bergantung pada indikator hasil belajar seperti nilai akademik semata. Oleh karena itu, analisis pola aktivitas belajar dipandang sebagai pendekatan eksploratif untuk memahami proses belajar secara lebih holistik.

### **K-Means**

K-Means dipilih karena kesesuaiannya dengan tujuan eksploratif penelitian ini, yaitu memetakan kemiripan pola aktivitas belajar tanpa asumsi label performa akademik. Tujuan

utama algoritma ini adalah membentuk cluster yang memiliki tingkat kemiripan tinggi di dalam cluster dan perbedaan yang jelas antar cluster, sehingga pola laten dalam data dapat diidentifikasi secara eksploratif (Ahmed et al., 2020). Secara matematis, K-Means meminimalkan fungsi objektif within-cluster sum of squares (WCSS), yang mengukur jarak total antara setiap data dan pusat cluster (centroid).

$$J = \sum_{k=1}^K \sum_{x_i \in C_k} \|x_i - \mu_k\|^2$$

K menyatakan jumlah cluster,  $x_i$  adalah data ke- $i$ ,  $C_k$  merupakan cluster ke- $k$ , dan  $\mu_k$  adalah centroid cluster (Ahmed et al., 2020). Perhitungan jarak umumnya menggunakan Euclidean distance, sehingga skala fitur sangat memengaruhi hasil clustering dan normalisasi data menjadi prasyarat penting sebelum penerapan algoritma ini. Secara konseptual, algoritma K-Means bekerja melalui tahapan iteratif yang meliputi penentuan jumlah cluster, inisialisasi centroid awal, pengalokasian data ke cluster dengan centroid terdekat, serta pembaruan centroid berdasarkan rata-rata data dalam setiap cluster. Proses ini diulang hingga mencapai kondisi konvergen, yaitu ketika tidak terjadi perubahan signifikan pada posisi centroid atau keanggotaan cluster. Prosedur iteratif ini menjadikan K-Means efektif untuk analisis eksploratif, meskipun sensitif terhadap inisialisasi awal dan pemilihan jumlah cluster (Junthopas & Wongoutong, 2025).

### **Penelitian Terdahulu**

Berbagai penelitian terdahulu, termasuk dalam konteks pendidikan tinggi di Indonesia, telah menerapkan teknik clustering untuk menganalisis data aktivitas LMS. Hasil penelitian tersebut menunjukkan bahwa mahasiswa dapat dikelompokkan ke dalam beberapa kategori berdasarkan pola aktivitas belajar, seperti mahasiswa dengan tingkat keterlibatan tinggi, mahasiswa dengan kecenderungan belajar mandiri, dan mahasiswa dengan aktivitas belajar rendah (Ikhsan, 2021; Adam et al., 2025). Temuan ini menguatkan pandangan bahwa perilaku belajar mahasiswa bersifat heterogen dan dapat dianalisis melalui pendekatan clustering berbasis data aktivitas.


Namun demikian, sebagian penelitian terdahulu masih menempatkan clustering sebagai alat pendukung analisis prediktif atau menggunakan pendekatan yang relatif kompleks, sehingga aspek interpretasi pola aktivitas belajar belum menjadi fokus utama. Selain itu, pemanfaatan dataset LMS terbuka dengan pendekatan analisis yang sederhana dan mudah

direplikasi masih relatif terbatas, khususnya dalam studi yang berorientasi pada pemetaan awal perilaku belajar mahasiswa (Ardianti et al., 2024) (Rita Awoliyi, 2023).

Berdasarkan kajian teoretis dan penelitian sebelumnya, analisis pola aktivitas belajar mahasiswa menggunakan teknik clustering berbasis data LMS memiliki dasar konseptual yang kuat dalam bidang learning analytics. Kerangka teoritis ini menjadi landasan bagi penelitian untuk mengeksplorasi variasi pola aktivitas belajar mahasiswa melalui pendekatan clustering yang sederhana dan interpretatif, sebagai langkah awal dalam memahami proses belajar mahasiswa di lingkungan pembelajaran digital.

### 3. METODE PENELITIAN

Penelitian ini menggali pola perilaku belajar mahasiswa yang bersifat laten berdasarkan data aktivitas pembelajaran digital. Metode unsupervised learning digunakan agar pengelompokan mahasiswa dapat dilakukan tanpa memerlukan label kelas tertentu. Adapun tahap penelitiannya seperti pada gambar 1 berikut.



**Gambar 1.** Tahap Penelitian.

Populasi penelitian mencakup seluruh mahasiswa yang aktivitas belajarnya terekam dalam Open University Learning Analytics Dataset (OULAD). Sampel ditentukan secara purposive dengan membatasi data pada satu mata kuliah dan satu periode pembelajaran guna menjaga konsistensi konteks pembelajaran. Data diperoleh melalui teknik dokumentasi dengan memanfaatkan dataset publik OULAD yang berisi log aktivitas mahasiswa pada LMS, sedangkan instrumen penelitian berupa data aktivitas mahasiswa dan metadata aktivitas pembelajaran.

Analisis data dilakukan melalui preprocessing, ekstraksi fitur, dan clustering. Data dibersihkan dan disaring sesuai kriteria sampel, kemudian aktivitas LMS diintegrasikan per mahasiswa untuk membentuk fitur numerik yang merepresentasikan karakteristik aktivitas belajar. Data yang telah diekstraksi dinormalisasi sebelum dilakukan pengelompokan menggunakan algoritma K-Means. Kualitas hasil clustering dievaluasi menggunakan Silhouette Score, dan karakteristik setiap kelompok mahasiswa dianalisis melalui profil cluster.

Proses analisis data dilakukan menggunakan bahasa pemrograman Python pada lingkungan Google Colaboratory dengan dukungan pustaka *pandas*, *numpy*, *scikit-learn*, dan *matplotlib*. Model penelitian ini menempatkan data aktivitas LMS sebagai input utama, proses clustering sebagai inti analisis, dan pola aktivitas belajar mahasiswa sebagai luaran untuk memahami variasi perilaku belajar mahasiswa di pendidikan tinggi.

#### **4. HASIL DAN PEMBAHASAN**

##### **Hasil**

##### ***Deskripsi Dataset Penelitian***

Analisis pada penelitian ini dilakukan menggunakan subset data dari Open University Learning Analytics Dataset (OULAD) yang telah diseleksi berdasarkan satu mata kuliah dan satu periode pembelajaran untuk menjaga konsistensi konteks. Setelah melalui tahap preprocessing dan penyaringan data, dataset akhir yang digunakan dalam analisis terdiri dari 378 mahasiswa yang memiliki aktivitas terekam secara lengkap pada LMS.

Data aktivitas mahasiswa tersebut berasal dari 180.982 baris log interaksi LMS, yang kemudian diagregasi pada tingkat mahasiswa sehingga setiap mahasiswa direpresentasikan oleh satu vektor fitur aktivitas belajar. Fitur yang digunakan dalam penelitian ini mencakup *total\_clicks*, *num\_active\_days*, *num\_sites\_visited*, dan *num\_events*, yang merepresentasikan intensitas, konsistensi, dan keragaman aktivitas belajar mahasiswa selama satu periode pembelajaran.

##### ***Evaluasi Jumlah Cluster Menggunakan Silhouette Score***

Penentuan jumlah cluster optimal dilakukan dengan mengevaluasi kualitas hasil clustering menggunakan Silhouette Score pada beberapa konfigurasi jumlah cluster, yaitu  $K=2$  hingga  $K=8$ . Silhouette Score digunakan untuk mengukur tingkat kohesi intra-cluster dan separasi antar-cluster, di mana nilai yang lebih tinggi menunjukkan struktur cluster yang lebih baik.

Hasil evaluasi menunjukkan bahwa nilai Silhouette Score tertinggi diperoleh pada  $K=2$  dengan nilai 0,3446, sebagaimana disajikan pada Tabel 1. Ketika jumlah cluster ditingkatkan menjadi  $K=3$  dan  $K=4$ , nilai Silhouette Score menurun masing-masing menjadi 0,2518 dan 0,2184, serta terus menurun hingga berada pada kisaran 0,1598–0,1765 untuk  $K \geq 5$ . Pola ini menunjukkan bahwa penambahan jumlah cluster cenderung mengurangi kualitas pemisahan antar cluster.

Berdasarkan hasil tersebut, konfigurasi dengan dua cluster memberikan struktur pengelompokan yang paling stabil dan optimal. Oleh karena itu, pada penelitian ini jumlah cluster yang digunakan dalam analisis selanjutnya ditetapkan sebanyak dua cluster ( $K = 2$ ).

**Tabel 1.** Nilai Silhouette Score untuk Berbagai Jumlah Cluster.

Jumlah Cluster (K)	Silhouette Score
2	0,3446
3	0,2518
4	0,2184
5	0,1755
6	0,1747
7	0,1765
8	0,1598

### ***Hasil Pengelompokan Mahasiswa Menggunakan K-Means***

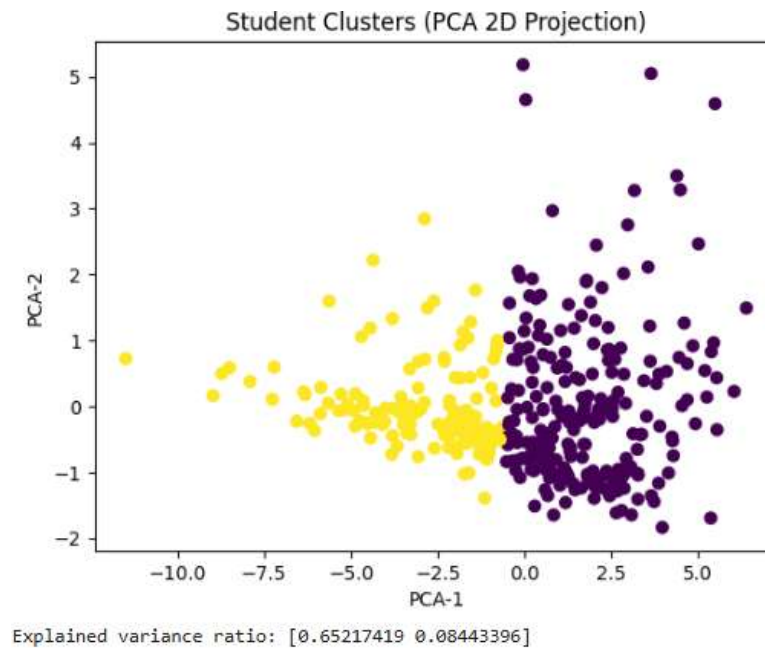
Berdasarkan hasil evaluasi jumlah cluster optimal, algoritma K-Means diterapkan dengan jumlah cluster  $K=2$  pada data aktivitas belajar mahasiswa. Proses clustering menghasilkan dua kelompok mahasiswa yang berbeda berdasarkan kemiripan pola aktivitas belajar pada LMS.

Hasil pengelompokan menunjukkan bahwa Cluster 0 terdiri dari 237 mahasiswa, sedangkan Cluster 1 terdiri dari 141 mahasiswa. Distribusi ini menunjukkan bahwa mahasiswa dalam satu mata kuliah dan periode pembelajaran yang sama tidak menunjukkan pola aktivitas yang seragam, melainkan terbagi ke dalam dua kelompok utama dengan karakteristik aktivitas belajar yang berbeda.

Distribusi mahasiswa pada masing-masing cluster menunjukkan bahwa 62,7% mahasiswa (237 dari 378) tergolong ke dalam cluster aktivitas tinggi, sedangkan 37,3% mahasiswa (141 dari 378) berada pada cluster aktivitas lebih rendah/moderat.

### ***Principal Component Analysis (PCA)***

Untuk memvisualisasikan hasil clustering dalam bentuk dua dimensi, dilakukan reduksi dimensi data aktivitas belajar mahasiswa menggunakan PCA. Proyeksi PCA menghasilkan dua komponen utama, yaitu PCA-1 dan PCA-2, yang digunakan untuk menampilkan struktur pengelompokan mahasiswa secara visual, sebagaimana ditunjukkan pada Gambar 2.



**Gambar 2.** PCA Student Clusters.

Hasil analisis menunjukkan bahwa PCA-1 menjelaskan 65,2% variasi data, sedangkan PCA-2 menjelaskan 8,4% variasi data. Dengan demikian, dua komponen PCA secara kumulatif menjelaskan sekitar 73,6% variasi total data aktivitas belajar mahasiswa, sehingga visualisasi dua dimensi ini cukup representatif untuk menggambarkan struktur clustering.

Visualisasi menunjukkan pemisahan dua cluster yang relatif jelas, terutama sepanjang sumbu PCA-1. Meskipun terdapat sedikit tumpang tindih antar cluster di sekitar pusat distribusi, struktur dua kelompok utama tetap dapat diamati dengan jelas, yang konsisten dengan hasil evaluasi Silhouette Score.

**Karakteristik Cluster Berdasarkan Fitur Aktivitas LMS**

Karakteristik masing-masing cluster dianalisis berdasarkan nilai rata-rata fitur aktivitas LMS yang digunakan sebagai input clustering, yaitu total\_clicks, num\_active\_days, num\_sites\_visited, dan num\_events. Ringkasan profil aktivitas belajar mahasiswa pada masing-masing cluster disajikan pada Tabel 2.

**Tabel 2.** Profil Rata-rata Fitur Aktivitas Belajar Mahasiswa per Cluster.

Cluster	Jumlah Mahasiswa	Total Clicks (Rata-rata)	Hari Aktif (Rata-rata)	Situs Dikunjungi (Rata-rata)	Jumlah Event (Rata-rata)
0	237	2448,79	121,83	78,55	671,01
1	141	483,20	36,87	38,98	155,69

Hasil analisis menunjukkan bahwa Cluster 0 memiliki nilai rata-rata yang lebih tinggi pada seluruh fitur aktivitas LMS dibandingkan Cluster 1. Mahasiswa pada Cluster 0 menunjukkan intensitas interaksi LMS yang lebih tinggi, konsistensi hari aktif yang lebih

panjang, serta keragaman aktivitas pembelajaran yang lebih luas. Sebaliknya, Cluster 1 menunjukkan tingkat aktivitas LMS yang relatif lebih rendah pada seluruh dimensi yang dianalisis.

Perbedaan karakteristik numerik antar cluster ini selaras dengan hasil visualisasi PCA, di mana mahasiswa pada Cluster 0 cenderung berada pada nilai PCA-1 yang lebih tinggi, sedangkan mahasiswa pada Cluster 1 berada pada nilai PCA-1 yang lebih rendah. Berdasarkan karakteristik tersebut, kedua cluster dapat diberi label operasional sebagai cluster aktivitas tinggi (Cluster 0) dan cluster aktivitas lebih rendah/moderat (Cluster 1). Pemberian label ini bersifat deskriptif dan digunakan untuk memudahkan pelaporan hasil penelitian.

## **Pembahasan**

Hasil penelitian menunjukkan bahwa mahasiswa memiliki pola aktivitas belajar yang beragam dalam memanfaatkan sistem pembelajaran daring, meskipun berada dalam mata kuliah dan periode pembelajaran yang sama. Temuan ini menegaskan bahwa proses belajar tidak berlangsung secara seragam, melainkan dipengaruhi oleh perbedaan tingkat keterlibatan dan kebiasaan belajar masing-masing mahasiswa. Sebagian mahasiswa menunjukkan keterlibatan yang tinggi dan konsisten dalam mengikuti aktivitas pembelajaran, sementara sebagian lainnya berinteraksi secara lebih terbatas, yang menggambarkan variasi alami dalam perilaku belajar mahasiswa.

Dalam konteks pemanfaatan data pembelajaran, pemetaan pola aktivitas belajar tersebut memberikan gambaran awal yang penting bagi dosen dan pengelola pembelajaran untuk memahami proses belajar mahasiswa secara lebih menyeluruh. Informasi mengenai perbedaan pola keterlibatan ini dapat dimanfaatkan sebagai bahan refleksi dalam merancang strategi pembelajaran yang lebih responsif terhadap kebutuhan mahasiswa. Namun demikian, penelitian ini difokuskan pada tahap pemetaan pola aktivitas belajar, sehingga pengembangan bentuk intervensi pembelajaran atau sistem pembelajaran yang lebih adaptif masih menjadi peluang penelitian selanjutnya.

## **5. KESIMPULAN DAN SARAN**

Penelitian ini bertujuan untuk menganalisis pola aktivitas belajar mahasiswa pada LMS menggunakan pendekatan clustering berbasis data aktivitas. Berdasarkan hasil analisis terhadap data log LMS dari OULAD, penelitian ini menemukan bahwa aktivitas belajar mahasiswa membentuk dua pola utama yang berbeda, yaitu kelompok mahasiswa dengan tingkat aktivitas belajar yang tinggi dan kelompok mahasiswa dengan aktivitas belajar yang

lebih rendah atau moderat. Temuan ini menunjukkan bahwa meskipun mahasiswa berada dalam mata kuliah dan periode pembelajaran yang sama, perilaku belajar mereka tidak bersifat homogen, melainkan menunjukkan variasi yang jelas dan terukur berdasarkan data aktivitas LMS.

Penelitian selanjutnya disarankan untuk melibatkan lebih banyak mata kuliah, periode pembelajaran yang berbeda, serta mengombinasikan data aktivitas LMS dengan data hasil belajar atau data temporal agar pemahaman terhadap pola belajar mahasiswa menjadi lebih mendalam.

## DAFTAR REFERENSI

- Adam, A., Farell, G., Marta, R., & Asmara, D. (2025). Learning analytics terhadap perilaku akses digital mahasiswa pada learning management system Universitas Negeri Padang. *Jurnal*, 9, 30623–30630.
- Ahmed, M., Seraj, R., & Islam, S. M. S. (2020). The k-means algorithm: A comprehensive survey and performance evaluation. *Electronics*, 9(8), 1–12. <https://doi.org/10.3390/electronics9081295>
- Aljaloud, A. S., Uliyan, D. M., Alkhalil, A., Elrhman, M. A., Alogali, A. F. M., Altameemi, Y. M., Altamimi, M., & Kwan, P. (2022). A deep learning model to predict student learning outcomes in LMS using CNN and LSTM. *IEEE Access*, 10, 85255–85265. <https://doi.org/10.1109/ACCESS.2022.3196784>
- Ardianti, M., Nurhayati, O. D., & Warsito, B. (2024). Model prediksi kinerja siswa berdasarkan data log LMS menggunakan ensemble machine learning. *JST (Jurnal Sains dan Teknologi)*, 12(3), 562–571. <https://doi.org/10.23887/jstundiksha.v12i3.59816>
- Ginting, S. (2025). EduTIK: Jurnal Pendidikan Teknologi Informasi dan Komunikasi. *EduTIK: Jurnal Pendidikan Teknologi Informasi dan Komunikasi*, 2(5), 773.
- Ikhsan, E. (2021). Penerapan K-means clustering dari log data Moodle untuk menentukan perilaku peserta pada pembelajaran daring. *Sistemasi*, 10(2), 414. <https://doi.org/10.32520/stmsi.v10i2.1285>
- Junthopas, W., & Wongoutong, C. (2025). Pre-determining the optimal number of clusters for k-means clustering using the parameters package in R and distance metrics. *Applied Sciences*, 15(21), 1–20. <https://doi.org/10.3390/app152111372>
- Kharis, S. A. A., & Zili, A. H. A. (2022). Learning analytics dan educational data mining pada data pendidikan. *Jurnal Riset Pembelajaran Matematika Sekolah*, 6(1), 12–20. <https://doi.org/10.21009/jrpms.061.02>
- Kuzilek, J., Hlosta, M., & Zdrahal, Z. (2017). Data descriptor: Open University learning analytics dataset. *Scientific Data*, 4, 1–8. <https://doi.org/10.1038/sdata.2017.171>
- Lima, G. D. O., Costa, J. A. R., Araújo, R. D., & Dorça, F. A. (2024). Exploring the relationship between students engagement and self-regulated learning: A case study using OULAD dataset and machine learning techniques. *Proceedings*, 1154–1165. <https://doi.org/10.5753/sbie.2023.234344>

- Purwoningsih, T., Inayanto, W., & Yunus, M. (2023). Exploring learning analytics in e-learning: A comprehensive analysis of student characteristics and behavior. *Jurnal Pendidikan Terbuka dan Jarak Jauh*, 24(2), 50–74. <https://doi.org/10.33830/ptjj.v24i2.5055.2023>
- Siemens, G., & Baker, R. S. J. D. (2012). Learning analytics and educational data mining: Towards communication and collaboration. *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK 2012)*, 252–254. <https://doi.org/10.1145/2330601.2330661>
- Tresnawati, D., Septiana, Y., & Hidayatno, F. R. (2025). Pengukuran keterlibatan pelajar menggunakan learning analytics dan metode Kanban. *Jurnal Algoritma*, 22(2), 847–857. <https://doi.org/10.33364/algoritma/v.22-2.2369>
- Zhang, J., Qiu, F., Wu, W., Wang, J., Li, R., Guan, M., & Huang, J. (2023). E-learning behavior categories and influencing factors of STEM courses: A case study of the Open University learning analytics dataset (OULAD). *Sustainability*, 15(10). <https://doi.org/10.3390/su15108235>