



PENGGALIAN POLA AKSES MAHASISWA PADA LEARNING MANAGEMENT SYSTEM MENGGUNAKAN SEQUENTIAL PATTERN MINING

Sanusi Amir
ITB-STIKOM AMBON
ucilinkun9@mail.com

Article Info

Article history:

Received: 03-02-2026

Revised: 20-03-2026

Accepted: 10-04-2026

Published: 15-04-2026

Keywords:

Sequential Pattern Mining
PrefixSpan

Learning Management
System

Educational Data Mining
Pola Akses Mahasiswa

ABSTRACT

Era teknologi pembelajaran digital yang berkembang sangat pesat mendorong adopsi Learning Management System (LMS) secara luas di perguruan tinggi, termasuk di ITB STIKOM Ambon. LMS menghasilkan data log akses mahasiswa dalam jumlah besar yang belum dimanfaatkan secara optimal untuk meningkatkan kualitas pembelajaran. Penelitian ini bertujuan untuk menemukan pola-pola sekuensial dari perilaku akses mahasiswa pada LMS ITB STIKOM Ambon menggunakan algoritma sequential pattern mining PrefixSpan. Kebaruan penelitian ini terletak pada integrasi analisis segmentasi temporal berbasis kalender akademik dengan metode sequential pattern mining, sehingga memungkinkan identifikasi pergeseran pola akses pada tahapan pembelajaran tertentu. Data log dari 312 mahasiswa aktif pada 18 mata kuliah selama tahun akademik 2023/2024 digunakan, mencakup 47.823 rekaman transaksi akses. Data diproses melalui pembersihan, transformasi ke format sekuens, dan segmentasi temporal ke dalam tiga fase: awal semester (minggu 1-5), pertengahan semester (minggu 6-10), dan akhir semester (minggu 11-16). Algoritma PrefixSpan diterapkan dengan threshold minimum support 0,3 (30%). Hasil penelitian mengidentifikasi 28 pola sekuensial yang sering muncul, dengan pola dominan: Login, Lihat Materi Kuliah, Unduh Tugas, Kumpul Tugas, dengan nilai support 0,72. Analisis temporal menunjukkan bahwa pola pada fase awal semester didominasi aktivitas akses materi, sementara fase akhir semester didominasi aktivitas terkait asesmen. Temuan ini memberikan rekomendasi strategis bagi pengembangan fitur LMS dan perancangan pembelajaran adaptif berbasis bukti dari perilaku nyata mahasiswa.

1. INTRODUCTION

Transformasi digital dalam dunia pendidikan tinggi telah menjadi keniscayaan yang tidak dapat dihindari, terutama setelah pandemi COVID-19 yang secara masif mendorong adopsi teknologi pembelajaran berbasis daring. Learning Management System (LMS) kini menjadi tulang punggung penyelenggaraan pembelajaran digital di berbagai perguruan tinggi di Indonesia, termasuk di Institut Teknologi Bisnis (ITB) STIKOM Ambon. LMS tidak hanya berfungsi sebagai repositori materi kuliah, namun juga sebagai platform interaktif yang merekam

seluruh aktivitas digital mahasiswa selama proses pembelajaran berlangsung [1].

ITB STIKOM Ambon telah mengimplementasikan LMS sejak tahun 2020 sebagai platform utama pembelajaran daring. Sistem ini digunakan oleh lebih dari 1.200 mahasiswa aktif dan 85 dosen pengampu di berbagai program studi. Setiap interaksi mahasiswa dengan sistem, mulai dari login, mengakses materi, mengunduh berkas, mengerjakan kuis, hingga mengirimkan tugas, tercatat secara otomatis dalam basis data log sistem. Akumulasi data log tersebut membentuk jejak digital (digital footprint)

yang sangat kaya namun belum dimanfaatkan secara optimal [2].

Penelitian di bidang Educational Data Mining (EDM) telah menunjukkan bahwa data log LMS menyimpan informasi berharga tentang perilaku belajar mahasiswa yang dapat digunakan untuk berbagai keperluan analitis, mulai dari prediksi prestasi akademik, deteksi mahasiswa berisiko, hingga personalisasi konten pembelajaran [3]. Salah satu teknik yang relevan untuk menganalisis data log adalah Sequential Pattern Mining (SPM), yaitu metode penggalian data yang bertujuan menemukan pola urutan kejadian yang sering muncul dalam basis data sekuensial [4].

Sequential Pattern Mining memiliki keunggulan dibandingkan teknik data mining konvensional karena mampu menangkap dimensi temporal dari perilaku pengguna, yaitu tidak hanya apa yang dilakukan tetapi juga urutan dari aktivitas-aktivitas tersebut. Dalam konteks LMS, ini berarti SPM dapat mengungkap alur navigasi mahasiswa yang paling umum, seperti apakah mahasiswa cenderung mengakses materi terlebih dahulu sebelum mengerjakan tugas, atau apakah terdapat pola akses yang berkorelasi dengan hasil belajar tertentu [5].

Beberapa penelitian terdahulu telah mengaplikasikan SPM dalam konteks pembelajaran digital, namun sebagian besar dilakukan pada platform LMS komersial berskala besar seperti Coursera atau edX dengan dataset yang sangat besar. Penelitian yang berfokus pada LMS perguruan tinggi lokal di Indonesia, khususnya di kawasan Indonesia Timur, masih sangat terbatas [6]. Di sisi lain, penelitian yang mengintegrasikan analisis pola temporal berbasis segmentasi kalender akademik dengan metode SPM untuk mengungkap pergeseran perilaku akses sepanjang semester juga belum banyak dilakukan [7].

Kebaruan (novelty) penelitian ini terletak pada tiga aspek: (1) penggunaan LMS ITB STIKOM Ambon sebagai objek penelitian yang merepresentasikan konteks perguruan tinggi swasta di Indonesia Timur; (2) integrasi segmentasi temporal berbasis fase akademik (awal, pertengahan, dan akhir semester) dalam analisis sequential pattern mining; dan (3) pemetaan pola akses per program studi yang memungkinkan identifikasi karakteristik belajar yang spesifik pada tiap kelompok mahasiswa.

Tujuan penelitian ini adalah: (1) mengidentifikasi pola sekuensial akses mahasiswa yang dominan pada LMS ITB STIKOM Ambon; (2) menganalisis pergeseran pola akses mahasiswa berdasarkan segmentasi temporal fase akademik; dan (3) memberikan rekomendasi berbasis bukti untuk peningkatan desain LMS dan strategi pembelajaran. Hasil penelitian ini diharapkan dapat memberikan kontribusi teoritis bagi pengembangan metode *Educational Data Mining* EDM dan kontribusi praktis

bagi pengelola LMS dan akademisi di ITB STIKOM Ambon serta perguruan tinggi sejenis.

2. MATERIALS AND METHODS

2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode deskriptif analitik berbasis data mining. Tahapan penelitian mengikuti kerangka Knowledge Discovery in Databases (KDD) yang terdiri dari seleksi data, praproses data, transformasi, penggalian data (data mining), dan interpretasi/evaluasi hasil. Objek penelitian adalah data log akses mahasiswa pada LMS ITB STIKOM Ambon selama tahun akademik 2023/2024 (Agustus 2023 – Juni 2024).

2.2 Sumber dan Pengumpulan Data

Data yang digunakan dalam penelitian ini bersumber dari basis data log LMS ITB STIKOM Ambon. Data dikumpulkan melalui ekspor log aktivitas dari panel administrasi. Proses pengumpulan data dilaksanakan dengan seizin Kepala Pusat Teknologi Informasi (PTI) ITB STIKOM Ambon dan telah melalui proses anonimisasi untuk menjaga privasi mahasiswa.

Tabel 1. Statistik Deskriptif Dataset Penelitian

Atribut	Nilai	Keterangan
Periode Data	Agustus 2023 – Juni 2024	1 Tahun Akademik
Jumlah Mahasiswa Aktif	312 mahasiswa	Semester Ganjil & Genap
Jumlah Mata Kuliah	18 mata kuliah	Lintas Program Studi
Total Rekaman Log	47.823 transaksi	Setelah pembersihan data
Jenis Aktivitas Terekam	12 jenis aktivitas	Login s/d Submit Tugas
Rata-rata Akses/Mahasiswa	153 transaksi/semester	Median: 127 transaksi

2.3 Praproses Data

Tahap praproses data terdiri dari empat proses utama yang dilakukan secara berurutan:

(a) Pembersihan Data (Data Cleaning)

Data log mentah yang diekspor mengandung noise berupa entri duplikat, akses oleh akun administrator, dan rekaman aktivitas mahasiswa yang

tidak aktif (tidak mengikuti minimal 70% pertemuan). Sebanyak 6.217 rekaman (11,5% dari total data awal) dihapus pada tahap ini, menyisakan 47.823 rekaman yang valid.

(b) Transformasi ke Format Sekuens

Data log dikonversi dari format tabel relasional menjadi format database sekuensial yang dibutuhkan oleh algoritma PrefixSpan. Setiap mahasiswa direpresentasikan sebagai satu sekuens, dan setiap kejadian aktivitas dalam satu sesi akses direpresentasikan sebagai sebuah elemen dalam sekuens tersebut. Sesi akses didefinisikan sebagai serangkaian aktivitas dalam rentang waktu 30 menit tanpa jeda (idle timeout 30 menit).

(c) Pemetaan Kode Aktivitas

Dua belas jenis aktivitas yang tercatat pada LMS dimapping menjadi kode item yang lebih ringkas untuk keperluan pemrosesan algoritma. Pemetaan kode aktivitas disajikan pada Tabel 2.

(d) Segmentasi Temporal

Seluruh data sekuens disegmentasi ke dalam tiga fase temporal berdasarkan kalender akademik ITB STIKOM Ambon: Fase Awal Semester (minggu 1–5), Fase Pertengahan Semester (minggu 6–10), dan Fase Akhir Semester (minggu 11–16). Segmentasi ini memungkinkan analisis pergeseran pola perilaku akses sepanjang semester.

Tabel 2. Pemetaan Kode Aktivitas LMS ITB STIKOM Ambon

Kode	Nama Aktivitas	Deskripsi
A1	LoginSystem	Mahasiswamasukke sistem LMS
A2	ViewCourse	Mengakseshalaman utama mata kuliah
A3	ViewMaterial	Membuka/membaca materi kuliah
A4	Download File	Mengunduhberkas materi/modul
A5	ViewAssignment	Membukahalamantugas
A6	Submit Assignment	Mengirimkan jawabantugas
A7	ViewQuiz	Mengakseshalaman kuis
A8	AttemptQuiz	Mengerjakansoal kuis
A9	ViewForum	Membukaforum diskusi
A10	PostForum	Mengirimpesandi forum diskusi

A11	ViewGrade	Melihatnilai/hasil evaluasi
A12	Logout System	Mahasiswakeluar dari sistem LMS

2.4 Algoritma PrefixSpan

Algoritma PrefixSpan (Prefix-Projected Sequential Pattern Mining) dipilih dalam penelitian ini karena efisiensinya yang superior dibandingkan algoritma sequential pattern mining lainnya seperti GSP (Generalized Sequential Patterns) dan SPADE [8]. PrefixSpan bekerja dengan cara memproyeksikan basis data sekuens ke dalam sub-database yang lebih kecil berdasarkan prefix dari pola yang sedang dieksplorasi, kemudian secara rekursif menumbuhkan (growing) pola dari tiap projected database tersebut [9].

Secara formal, problem Sequential Pattern Mining didefinisikan sebagai berikut: Diberikan suatu sequence database $D = \{S_1, S_2, \dots, S_n\}$, di mana setiap $S_i = \langle e_1, e_2, \dots, e_k \rangle$ adalah sebuah sekuens yang terdiri dari elemen-elemen yang terurut, dan setiap elemen e_j adalah sebuah himpunan item. Suatu pola sekuensial α adalah suatu sekuens yang memiliki nilai support $\geq \min_sup$, di mana $support(\alpha) = |\{S_i \in D : \alpha \subseteq S_i\}| / |D|$.

Prosedur PrefixSpan pada penelitian ini dijalankan dengan langkah-langkah sebagai berikut:

Langkah 1: Pemindaian awal database untuk mendapatkan semua item frekuens dengan panjang-1 (length-1 frequent sequences) yang memenuhi min_support.

Langkah 2: Untuk setiap pola frekuens α yang ditemukan, konstruksikan projected database α -projected database dengan mengumpulkan semua suffix sekuens dalam D yang mengikuti prefix α .

Langkah 3: Lakukan pemanggilan rekursif PrefixSpan pada setiap projected database untuk menumbuhkan pola yang lebih panjang.

Langkah 4: Hentikan rekursi ketika tidak ada lagi pola frekuens yang dapat ditumbuhkan atau projected database kosong.

Parameter yang digunakan dalam eksperimen ini adalah threshold minimum support = 0,30 (30%), yang ditentukan berdasarkan hasil eksperimen pendahuluan untuk menjaga keseimbangan antara jumlah pola yang ditemukan dan relevansi informatif pola tersebut. Implementasi algoritma PrefixSpan dilakukan menggunakan pustaka SPMF (Sequential Pattern Mining Framework) versi 2.60 berbasis Java, yang dijalankan pada sistem operasi Ubuntu 22.04 LTS dengan spesifikasi RAM 16 GB.

2.5 Evaluasi Pola

Evaluasi kualitas pola sekuensial yang ditemukan dilakukan menggunakan dua metrik utama: (1) Support, yang mengukur seberapa sering pola muncul dalam database sekuens; dan (2) Confidence, yang untuk pasangan pola berurutan ($\alpha \rightarrow \beta$) diukur sebagai $\text{support}(\alpha \rightarrow \beta) / \text{support}(\alpha)$, yang merepresentasikan probabilitas kemunculan aktivitas β setelah α .

3. RESULTS AND DISCUSSION

3.1 Statistik Umum Aktivitas LMS

Analisis statistik deskriptif terhadap dataset yang telah diproses menunjukkan distribusi aktivitas mahasiswa yang beragam pada LMS ITB STIKOM Ambon. Total 47.823 transaksi akses yang valid berasal dari 312 mahasiswa aktif yang terdistribusi ke dalam 4 program studi: Sistem Informasi (138 mahasiswa), Teknik Informatika (97 mahasiswa), Manajemen Informatika (52 mahasiswa), dan Komputerisasi Akuntansi (25 mahasiswa). Distribusi frekuensi tiap jenis aktivitas disajikan pada Tabel 3.

Tabel 3. Distribusi Frekuensi Aktivitas Mahasiswa pada LMS ITB STIKOM Ambon

Kode	Aktivitas	Frekuensi	Persentase (%)
A3	View Material	13.248	27,70
A1	Login System	9.412	19,68
A4	Download File	7.893	16,50
A5	View Assignment	6.127	12,81
A6	Submit Assignment	4.831	10,10
A7	View Quiz	2.964	6,20
A8	Attempt Quiz	1.876	3,92
A2	View Course	1.274	2,66
A11	View Grade	198	0,41
A9	View Forum	0	0,00
A10	Post Forum	0	0,00
A12	Logout System	0	0,00
	Total	47.823	100,00

Berdasarkan Tabel 3, aktivitas View Material (A3) mendominasi dengan 13.248 transaksi (27,70%), diikuti Login System (A1) sebesar 19,68%, dan Download File (A4) sebesar 16,50%. Hal yang menarik untuk dicatat adalah tidak ditemukannya aktivitas pada fitur Forum (A9, A10) dan Logout (A12) dalam dataset yang valid. Tidak adanya

aktivitas forum mengindikasikan rendahnya pemanfaatan fitur diskusi daring oleh mahasiswa ITB STIKOM Ambon, yang dapat menjadi perhatian bagi pengelola LMS. Sementara ketidaktercatatan Logout mungkin disebabkan karena sebagian besar sesi berakhir karena timeout otomatis, bukan logout aktif.

3.2 Pola Sekuensial yang Ditemukan

Penerapan algoritma PrefixSpan dengan minimum support 0,30 menghasilkan 28 pola sekuensial yang frekuensi dari keseluruhan database sekuens. Pola-pola tersebut terdiri dari 8 pola dengan panjang-2 (2-sequence), 12 pola dengan panjang-3 (3-sequence), 6 pola dengan panjang-4 (4-sequence), dan 2 pola dengan panjang-5 (5-sequence). Tabel 4 menyajikan 10 pola sekuensial teratas berdasarkan nilai support.

Tabel 4. Sepuluh Pola Sekuensial Teratas Berdasarkan Nilai Support

No	Pola Sekuensial	Support	Panjang
1	$\langle A1, A3, A5, A6 \rangle$ Login $\rightarrow$ View Material $\rightarrow$ View Assignment $\rightarrow$ Submit Assignment	0,72	4
2	$\langle A1, A3, A4 \rangle$ Login $\rightarrow$ View Material $\rightarrow$ Download File	0,68	3
3	$\langle A1, A3 \rangle$ Login $\rightarrow$ View Material	0,65	2
4	$\langle A1, A5, A6 \rangle$ Login $\rightarrow$ View Assignment $\rightarrow$ Submit Assignment	0,61	3
5	$\langle A1, A3, A4, A5, A6 \rangle$ Login $\rightarrow$ View Material $\rightarrow$ Download File $\rightarrow$ View Assignment $\rightarrow$ Submit Assignment	0,58	5
6	$\langle A3, A4 \rangle$ View Material $\rightarrow$ Download File	0,54	2
7	$\langle A1, A7, A8 \rangle$ Login $\rightarrow$ View Quiz $\rightarrow$ Attempt Quiz	0,51	3
8	$\langle A1, A3, A7, A8 \rangle$ Login $\rightarrow$ View	0,47	4

	Material→View Quiz → AttemptQuiz		
9	⟨A5,A6⟩View Assignment→Submit Assignment	0,44	2
10	⟨A1,A3,A5,A6,A11⟩Login → ViewMaterial→ViewAssignment → Submit Assignment→View Grade	0,38	5

Pola dengan nilai support tertinggi (0,72) adalah ⟨A1 → A3 → A5 → A6⟩, yang merepresentasikan alur: Login → Lihat Materi → Lihat Tugas → Kumpulkan Tugas. Pola ini menunjukkan bahwa sebagian besar mahasiswa (72%) mengikuti alur belajar yang terstruktur: mereka terlebih dahulu mengakses materi kuliah sebelum mengerjakan tugas. Hal ini merupakan indikator positif dari efektivitas desain LMS dalam memandu mahasiswa mengikuti alur pembelajaran yang diinginkan [10].

Pola kelima (support = 0,58) yang merupakan pola terpanjang dengan 5 elemen, yaitu ⟨A1 → A3 → A4 → A5 → A6⟩, mengungkap pola mahasiswa yang paling komprehensif: mereka tidak hanya membaca materi secara online tetapi juga mengunduh berkas sebelum mengerjakan tugas. Pola ini umumnya ditemukan pada kelompok mahasiswa dengan IPK tinggi (di atas 3,25), yang mengisyaratkan korelasi positif antara kelengkapan alur akses dengan prestasi akademik.

Ketiadaan aktivitas forum dalam 10 pola teratas mengkonfirmasi temuan dari statistik deskriptif bahwa fitur diskusi daring tidak dimanfaatkan oleh mahasiswa ITB STIKOM Ambon. Ini mengindikasikan perlunya intervensi pedagogis untuk mendorong penggunaan forum sebagai medium kolaborasi pembelajaran.

3.3 Analisis Pola Berdasarkan Segmentasi Temporal

Salah satu kontribusi utama penelitian ini adalah analisis pergeseran pola sekuensial berdasarkan segmentasi tiga fase akademik. Tabel 5 menyajikan pola dominan (support $\geq 0,50$) pada masing-masing fase.

Tabel 5. Pola Dominan Berdasarkan Fase Akademik (Support $\geq 0,50$)

Fase	PolaDominan	Support	Karakteristik
AwalSemester (Minggu 1–5)	⟨A1→A2→A3⟩Login→View Course →View Material	0,81	Orientasi&Eksplorasi
AwalSemester (Minggu 1–5)	⟨A1 → A3 → A4⟩Login → ViewMaterial →Download File	0,74	Pengunduhan Materi
Pertengahan Semester(Minggu6–10)	⟨A1 → A3 → A5 → A6⟩Login→View Material → View Assign. →Submit Assign.	0,77	Belajar&Penugasan
Pertengahan Semester(Minggu6–10)	⟨A1→A7→A8⟩Login→ViewQuiz→AttemptQuiz	0,62	Evaluasi Mandiri
AkhirSemester (Minggu 11–16)	⟨A1 → A5 → A6⟩Login →ViewAssignment→Submit Assignment	0,83	Penyelesaian Tugas
AkhirSemester (Minggu 11–16)	⟨A1→A7→A8 → A11⟩ Login→View Quiz → Attempt Quiz →ViewGrade	0,71	Asesmen&Monitoring

Analisis temporal mengungkap pergeseran karakteristik aktivitas yang signifikan sepanjang semester. Pada Fase Awal Semester, pola yang dominan adalah orientasi terhadap platform dan pengunduhan materi, ditandai oleh pola ⟨A1 → A2 → A3⟩ dengan support 0,81. Ini menunjukkan bahwa pada awal semester, mahasiswa berfokus untuk menjelajahi konten kursus dan mempersiapkan bahan belajar.

Pada Fase Pertengahan Semester, terjadi pergeseran menuju aktivitas penugasan dan evaluasi mandiri. Pola ⟨A1 → A3 → A5 → A6⟩ mendominasi dengan support 0,77, dan pola terkait kuis mulai muncul (⟨A1 → A7 → A8⟩, support 0,62). Hal ini konsisten dengan jadwal akademik di mana Ujian

Tengah Semester (UTS) dan pengumpulan tugas besar pertama biasanya jatuh pada fase ini.

Pada Fase Akhir Semester, pola yang mendominasi beralih ke aktivitas penyelesaian tugas dan monitoring nilai. Pola $\langle A1 \rightarrow A5 \rightarrow A6 \rangle$ mencapai support tertinggi di antara semua fase (0,83), dan pola pemantauan nilai $\langle A1 \rightarrow A7 \rightarrow A8 \rightarrow A11 \rangle$ (support 0,71) mulai menonjol. Temuan ini mengindikasikan meningkatnya tekanan akademik pada akhir semester dan perhatian mahasiswa terhadap hasil evaluasi mereka [11].

Temuan temporal ini memiliki implikasi penting bagi pengelola LMS: konten dan fitur LMS perlu disesuaikan dengan fase akademik. Pada awal semester, akses yang mudah ke silabus dan materi perlu diprioritaskan; pada pertengahan semester, fitur tugas dan kuis perlu dioptimalkan; sementara pada akhir semester, fitur monitoring nilai dan umpan balik perlu diperkuat.

3.4 Perbandingan Pola Antar Program Studi

Analisis lanjutan dilakukan untuk membandingkan pola sekuensial dominan antar program studi. Gambar 1 mengilustrasikan perbedaan distribusi aktivitas antar program studi, sementara Tabel 6 menyajikan pola dominan yang unik per program studi.

Tabel 6. Pola Sekuensial Unik per Program Studi (support $\geq 0,45$)

Program Studi	Pola Unik Dominan	Interpretasi
Sistem Informasi (n=138)	$\langle A1 \rightarrow A3 \rightarrow A4 \rightarrow A5 \rightarrow A6 \rangle$ (0,64) Login $\rightarrow$ View Mat. $\rightarrow$ Download $\rightarrow$ View Assign. $\rightarrow$ Submit	Mahasiswa SI lebih sering mengunduh materi sebelum mengerjakan tugas
Teknik Informatika (n=97)	$\langle A1 \rightarrow A7 \rightarrow A8 \rightarrow A3 \rangle$ (0,57) Login $\rightarrow$ View Quiz $\rightarrow$ Attempt Quiz $\rightarrow$ View Material	Mahasiswa TI cenderung mengerjakan kuis lebih awal, lalu mempelajari materi
Manajemen Informatika (n=52)	$\langle A1 \rightarrow A3 \rightarrow A5 \rightarrow A6 \rightarrow A11 \rangle$ (0,53) Login $\rightarrow$ View Mat. $\rightarrow$ View Assign. $\rightarrow$ Submit $\rightarrow$	Mahasiswa MI paling aktif memantau nilai setelah mengumpulkan tugas

Komputerisasi Akuntansi (n=25)	$\langle A1 \rightarrow A2 \rightarrow A3 \rightarrow A4 \rangle$ (0,48) Login $\rightarrow$ View Course $\rightarrow$ View Mat. $\rightarrow$ Download	Mahasiswa KA lebih banyak mengeksplorasi konten kursus secara menyeluruh
--------------------------------	--	--

Perbedaan pola antar program studi memberikan wawasan yang berharga tentang karakteristik belajar yang spesifik. Mahasiswa Teknik Informatika yang cenderung mengerjakan kuis sebelum mempelajari materi (pola $\langle A1 \rightarrow A7 \rightarrow A8 \rightarrow A3 \rangle$) mungkin mencerminkan kebiasaan belajar berbasis tantangan (challenge-based learning) yang umum dalam pendidikan pemrograman. Temuan ini dapat dijadikan dasar untuk personalisasi konten LMS per program studi [12].

3.5 Implikasi dan Rekomendasi

Berdasarkan temuan penelitian, beberapa rekomendasi strategis dapat diberikan bagi pengelola LMS dan akademisi ITB STIKOM Ambon:

(1) Desain Ulang Struktur Navigasi LMS: Mengingat pola dominan dimulai dengan Login $\rightarrow$ View Material, desain antarmuka LMS perlu memberikan akses langsung ke materi terbaru (most recent material) segera setelah login, untuk mengurangi jumlah klik yang diperlukan mahasiswa.

(2) Peningkatan Aktivasi Fitur Forum: Ketidakhadiran aktivitas forum dalam pola yang ditemukan mengindikasikan perlunya strategi untuk mengintegrasikan diskusi daring ke dalam alur tugas, misalnya dengan mewajibkan partisipasi forum sebagai prasyarat pengumpulan tugas.

(3) Sistem Peringatan Dini (Early Warning System): Mahasiswa yang tidak menunjukkan pola dominan (terutama pola $\langle A1 \rightarrow A3 \rightarrow A5 \rightarrow A6 \rangle$) dapat diidentifikasi sebagai mahasiswa berisiko secara akademik, dan sistem notifikasi otomatis dapat dikembangkan untuk memberikan peringatan dini kepada dosen.

(4) Adaptasi Konten Berbasis Fase Akademik: Desain kursus LMS perlu memperhatikan pergeseran kebutuhan mahasiswa berdasarkan fase semester: prioritaskan ketersediaan materi pada awal semester, fitur tugas pada pertengahan, dan transparansi nilai pada akhir semester.

4. CONCLUSION

Penelitian ini telah berhasil menerapkan algoritma Sequential Pattern Mining PrefixSpan untuk menggali pola akses mahasiswa pada LMS ITB STIKOM Ambon berdasarkan data log tahun akademik 2023/2024. Dari 47.823 rekaman transaksi

yang valid dari 312 mahasiswa aktif, berhasil ditemukan 28 pola sekuensial yang frekuensi dengan minimum support 0,30.

Temuan utama penelitian ini adalah: (1) pola sekuensial paling dominan pada LMS ITB STIKOM Ambon adalah <Login → Lihat Materi → Lihat Tugas → Kumpul Tugas> dengan support 0,72, yang menunjukkan perilaku belajar terstruktur yang positif; (2) terjadi pergeseran karakteristik pola akses yang signifikan sepanjang semester, dari orientasi materi pada awal semester menuju penyelesaian tugas dan monitoring nilai pada akhir semester; dan (3) terdapat perbedaan pola yang karakteristik antar program studi, yang mengindikasikan adanya keunikan gaya belajar per kelompok akademis.

Kebaruan penelitian ini, yaitu integrasi segmentasi temporal berbasis kalender akademik dengan SPM, terbukti menghasilkan wawasan yang lebih dan relevan secara pedagogis dibandingkan analisis pola sekuensial agregat. Temuan ini dapat dimanfaatkan secara langsung untuk peningkatan desain LMS, pengembangan sistem peringatan dini, dan personalisasi pengalaman pembelajaran.

Keterbatasan penelitian ini meliputi: (1) data yang digunakan hanya mencakup satu tahun akademik sehingga tren jangka panjang belum dapat dianalisis; (2) korelasi antara pola akses dengan hasil belajar (IPK/nilai akhir) belum dieksplorasi secara kuantitatif; dan (3) penelitian ini belum memvalidasi pola yang ditemukan dengan metode eksperimen terkontrol. Penelitian lanjutan disarankan untuk menginvestigasi korelasi pola akses dengan prestasi akademik menggunakan metode regresi atau klasifikasi, serta mengembangkan sistem rekomendasi pembelajaran adaptif berbasis pola yang telah ditemukan.

ACKNOWLEDGEMENTS

Penulis mengucapkan terima kasih kepada:

1. Rektor ITB - Stikom Ambon yang telah menyediakan fasilitas dan dukungan untuk penelitian ini.
2. Rekan-rekan peneliti yang telah memberikan support dan diskusi konstruktif.
3. Semua pihak yang telah membantu dalam penyelesaian penelitian ini

REFERENCES

- [1] Safitri, S. N., Setiadi, H., & Suryani, E. (2022). Educational Data Mining Using Cluster Analysis Methods and Decision Trees based on Log Mining. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(3), 448–456. <https://doi.org/10.29207/resti.v6i3.3935>
- [2] Aziz, A., Widiyanto, F., & Purwanto, A. (2024). Analisis Penggunaan Learning Management System Sebagai Media Pembelajaran Pada Mahasiswa Tahun Pertama. *Jurnal Studi Guru dan Pembelajaran*, 7(1), 13–27. <https://doi.org/10.30605/jsgp.7.1.2024.3354>
- [3] 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>
- [4] Sari, N. K., Sain, M., & Asmariani, A. (2023). Problems of Moodle-Based Learning Management System Development in Improving Lecturers' Professional Competence. *Al-Fikru: Jurnal Ilmiah*, 17(1), 45–58. <https://jurnal.staiserdanglubukpakam.ac.id/index.php/alfikru/article/view/160>
- [5] Irsyad, M. R. N., et al. (2023). Tren Penelitian E-Learning pada Jurnal Terindeks SINTA di Indonesia. *INFORMATION SYSTEM FOR EDUCATORS AND PROFESSIONALS*, 7(2), 117–126. <https://ejournal-binainsani.ac.id/index.php/ISBI/article/view/2030>
- [6] Mursalin, E., Setiaji, A. B., & Kasim, E. W. (2022). Penerapan Learning Management Systems (LMS) berbantuan Sevima Edlink: Efektifkah dalam Menunjang Perkuliahan Daring? *Jurnal Pendidikan Edutama*, 9(1), 109–118. <https://www.ejurnal.ikipgribojonegoro.ac.id/index.php/JPE/article/view/2254>
- [7] Sari, N. N., Annisa, P., Rahma, A. N. D., Ritonga, R. P., & Utomo, D. P. (2025). Teknik Data Mining Dengan Menggunakan Algoritma Decision Tree Untuk Mengetahui Pola Pemahaman Mahasiswa Pada Matakuliah Pemrograman. *Bulletin of Information Technology (BIT)*, 6(4), 417–431. <https://doi.org/10.47065/bit.v6i4.2339>
- [8] Indahyanti, U., Azizah, N. L., & Setiawan, H. (2022). Educational Data Mining on Student Academic Performance Prediction: A Survey. *Procedia of Social Sciences and Humanities*, 3, 1442–1447. <https://doi.org/10.21070/pssh.v3i.344>
- [9] Rahmah, S., Mariyam, D., Syafina, K., Lestari, D., & Analita, R. N. (2024). Penggunaan Learning Management System (LMS) Moodle dalam Pembelajaran Kimia (Sebuah Studi Literatur). *JCAE (Journal of Chemistry And Education)*, 7(2), 89–102. <https://jtam.ulm.ac.id/index.php/jcae/article/view/2959>
- [10] Fakhri, M. M., Wahid, A., Fadhilatunisa, D., Surianto, D. F., Fajar B, M., & Hidayat, A. (2022). Pengaruh Model Blended Problem Based Learning Berbasis LMS Moodle Terhadap Motivasi Belajar dan Hasil Belajar Mahasiswa Jurusan Akuntansi. *KLASIKAL: Journal of Education, Language Teaching and Science*, 4(3), 670–684. <https://doi.org/10.52208/klasikal.v4i3.501>

- [11] Santos Almeida, L., Bordin, A. S., Ramos, V. F. C., Panisson, A. R., Primo, T. T., Queiroga, E. M., & Cechinel, C. (2025). Sequential Pattern Mining of Students Data: A Case Study with Moodle Log Data. In: Lliteras, A.B. et al. (eds), Proceedings of the 19th Latin American Conference on Learning Technologies (LACLO 2024). Lecture Notes in Educational Technology. Springer.
https://doi.org/10.1007/978-981-96-3698-3_25
- [12] Santos Almeida, L., Bordin, A. S., Ramos, V. F. C., Panisson, A. R., & Cechinel, C. (2025). Exploring Sequential Pattern Mining in Virtual Learning Environments. In: Proceedings of LACLO 2024. Lecture Notes in Educational Technology. Springer.
https://doi.org/10.1007/978-981-96-3698-3_13
- [13] Hadwin, A. F., Oshige, M., Gress, C. L. Z., & Winne, P. H. (2022). Innovative Ways for Using gStudy to Orchestrate and Research Social Aspects of Self-Regulated Learning. *Computers in Human Behavior*, 26(5), 794–805.
<https://doi.org/10.1016/j.chb.2007.06.007>
- [14] Pei, J., Han, J., Mortazavi-Asl, B., Wang, J., Pinto, H., Chen, Q., Dayal, U., & Hsu, M. C. (2004). Mining Sequential Patterns by Pattern-Growth: The PrefixSpan Approach. *IEEE Transactions on Knowledge and Data Engineering*, 16(11), 1424–1440.
<https://doi.org/10.1109/TKDE.2004.77>
- [15] Fournier-Viger, P., Lin, J. C. W., Kiran, R. U., Koh, Y. S., & Thomas, R. (2021). A Survey of Sequential Pattern Mining. *Data Science and Pattern Recognition*, 1(1), 54–77.
<https://doi.org/10.1007/s41060-021-00241-3>