

Uncovering Learning Patterns in a Neural Computing Course: A Sequential Analytics Approach Applied to AI Education

Guillermo Sentoni¹  and Mariela Delauro¹ 

¹ Universidad Nacional de La Matanza, F. Varela 1903, Bs. As. Argentina
gsentoni@gmail.com

Abstract. This paper presents a sequential learning analytics framework applied to a fully online university course on neural computing, spanning topics from the Perceptron to foundational large-scale models. Teaching artificial intelligence, neural computing in particular, poses distinctive challenges in higher education: its content demands high mathematical maturity, and active computational practice plays a central role in building genuine understanding. The approach combines three articulated components: a semantically informed Finite State Machine that transforms interaction events into pedagogically meaningful states, exploratory trajectory clustering, and a Hidden Markov Model to infer latent cognitive modes without imposing categories a priori. Results show that active computational practice (PRACT) is the primary differentiator of effective trajectories, exhibiting the strongest positive marginal correlation with final grades (Spearman $\rho = 0.53$; $p = 0.063$). The Hidden Markov Model identifies four latent cognitive modes, of which Z2, characterized by regulated active practice, is the only mode significantly associated with academic performance. These findings have direct implications for the design, monitoring, and evaluation of AI courses at the university level.

Keywords: learning analytics, neural computing education, active practice, Hidden Markov Models, learning trajectories.

Descubriendo Patrones de Aprendizaje en un Curso de Computación Neuronal: Un Enfoque de Analíticas Secuenciales Aplicado a la Educación en IA

Resumen. Este trabajo presenta un marco secuencial de analítica del aprendizaje aplicado a un curso universitario completamente en línea sobre computación neuronal, que abarca temas desde el Perceptrón hasta modelos fundacionales a gran escala. La enseñanza de la inteligencia artificial, y de la computación neuronal en particular, plantea desafíos distintivos en la educación superior: su contenido exige elevada madurez matemática y la práctica computacional activa desempeña un papel central en la construcción de comprensión genuina. El enfoque combina tres componentes articulados: una Máquina de Estados Finitos semánticamente informada que transforma eventos de interacción en estados

pedagógicamente significativos, clustering exploratorio de trayectorias, y un Modelo Oculto de Markov para inferir modos cognitivos latentes sin imponer categorías a priori. Los resultados muestran que la práctica computacional activa (PRACT) es el principal diferenciador de las trayectorias efectivas, exhibiendo la tendencia positiva marginal más fuerte con las calificaciones finales (Spearman $\rho = 0,53$; $p = 0,063$). El Modelo Oculto de Markov identifica cuatro modos cognitivos latentes, de los cuales Z2, caracterizado por práctica activa regulada, es el único significativamente asociado con el rendimiento académico. Estos hallazgos tienen implicaciones directas para el diseño, el monitoreo y la evaluación de cursos de inteligencia artificial en el ámbito universitario.

Palabras clave: analíticas de aprendizaje, enseñanza de computación neuronal, práctica activa, Modelos Ocultos de Markov, trayectorias de aprendizaje.

1 Introducción

¿Qué patrones de comportamiento distinguen a quienes aprenden efectivamente y cómo se organizan temporalmente las acciones de los estudiantes en cursos de computación neuronal? Responder esta pregunta tiene valor tanto para el diseño instruccional como para el desarrollo de sistemas de alerta temprana en cursos de inteligencia artificial (IA). La enseñanza de IA en el nivel universitario enfrenta una complejidad inherentemente estructural: la distancia entre la comprensión conceptual de la teoría y la capacidad de implementarla y experimentar con ella computacionalmente. En cursos de computación neuronal, que abarcan desde el Perceptrón hasta arquitecturas Transformer y modelos generativos de gran escala, esta tensión es especialmente pronunciada. Dominar estos contenidos requiere no solo comprensión teórica sino habilidad para ejecutar, depurar y extender código en entornos de cómputo científico.

El aprendizaje es un proceso inherentemente secuencial (Winne y Hadwin, 1998; Hadwin et al., 2018). Sin embargo, la mayoría de los trabajos en analíticas de aprendizaje sigue dependiendo de métricas agregadas que borran la estructura temporal de la actividad estudiantil (Baker y Inventado, 2014; Romero y Ventura, 2010). El problema es especialmente agudo en cursos técnicos de alta densidad de interacción, donde la secuencia y la regulación de la práctica importan tanto como el volumen. Trabajos recientes han abordado esta brecha mediante análisis de trayectorias multi-canal (Gao et al., 2025) y técnicas de agrupamiento de secuencias de interacción en LMS (Villalobos et al., 2024). Estos trabajos confirman que la dimensión temporal del comportamiento estudiantil contiene información crítica, pero ninguno combina representación semántica de eventos con modelado latente de estados cognitivos, ni aborda el dominio específico de la computación neuronal, donde la práctica activa tiene un rol estructural que los indicadores de acceso no pueden capturar.

Este trabajo propone un marco de análisis secuencial aplicado a un curso universitario de computación neuronal completamente en línea. El marco combina tres componentes articulados: una Máquina de Estados Finitos (*Finite State Machine*, FSM) semánticamente informada que transforma eventos de bajo nivel del LMS en estados pedagógicamente significativos; clustering exploratorio de trayectorias; y un Modelo Oculto de Markov (*Hidden Markov Model*, HMM) para inferir modos cognitivos latentes sin imponer categorías a priori.

El marco permite realizar tres contribuciones: una representación secuencial del comportamiento estudiantil anclada en el diseño pedagógico de un curso de IA; evidencia de que integrar clustering con modelado latente de Markov captura la dinámica temporal del aprendizaje mejor que los enfoques descriptivos; e identificación empírica de cuatro modos cognitivos latentes con caracterización de cual predice el rendimiento académico.

2 Contexto: El Curso de Computación Neuronal

El estudio se sitúa en un curso universitario completamente en línea sobre computación neuronal artificial, dictado a través de la plataforma Moodle. El curso adopta el enfoque del aprendizaje neuronal como construcción y optimización de operadores parametrizados, organizando los contenidos en tres regímenes operatoriales:

- Operadores paramétricos globales: modelos lineales, Perceptrón, redes multicapa, retro-propagación del error.
- Operadores métricos locales: redes RBF, aprendizaje competitivo, mapas autoorganizados (SOM), cuantización vectorial (LVQ).
- Operadores dinámicos con estado: redes recurrentes (RNN), backpropagation a través del tiempo, LSTM y GRU.

El curso se organiza en tres unidades instruccionales secuenciales con evaluación diagnóstica inicial y evaluaciones sumativas por unidad. La práctica computacional se realiza a través de la consola CPIAE (Consola Python con Inteligencia Artificial Educativa), que permite ejecutar código Python en el navegador vía Pyodide con acceso a NumPy, Matplotlib y Pandas. Este contexto de cohorte reducida, alta densidad de interacción longitudinal y práctica computacional trazable a nivel de evento, define las condiciones de aplicación del marco analítico descrito a continuación (véase Tabla 1).

Tabla 1. Descripción del contexto y los datos analizados.

Variable	Descripción
Modalidad	Completamente en línea (Moodle)
Nivel académico	Universitario de grado
Estudiantes analizados	13 con actividad registrada (de 15 inscriptos)
Unidades instruccionales	Tres unidades secuenciales
Evaluaciones	Diagnóstico inicial y sumativas por unidad
Fuentes de datos	Logs de eventos Moodle, completitud de actividades, calificaciones
Estados FSM (v6)	NAV, REC, PRACT, QUIZ, EVAL, FB, OTHER
Entorno de práctica	Consola CPIAE (Pyodide + Python científico)
Total eventos secuenciales	$T = 2.546$

3 Metodología

3.1 Diseño analítico

El diseño sigue un enfoque observacional y orientado a datos. El pipeline analítico opera en cuatro etapas: recolección y consolidación de logs; transformación de eventos en estados pedagógicos mediante FSM; análisis descriptivo y clustering; e inferencia de modos cognitivos latentes mediante HMM. El orden no es arbitrario: cada etapa reduce la complejidad de la anterior y habilita la siguiente, de modo que la FSM prepara la entrada para el clustering y éste para el HMM. La Fig. 1 ilustra este pipeline.




Fig. 1. Pipeline del estudio: FSM → Trayectorias → Clustering y análisis descriptivo → HMM.

3.2 Construcción de estados observables (FSM)

Los estados observables se definen a partir del diseño pedagógico del curso. La FSM incluye siete estados: navegación (NAV), consumo de recursos (REC), práctica computacional activa (PRACT), cuestionarios formativos (QUIZ), evaluación sumativa (EVAL), retroalimentación (FB) y otros (OTHER). Los eventos de Moodle se mapean mediante reglas semánticas basadas en el componente, el contexto de la actividad y la descripción del evento. Las interacciones con la consola CPIAE, identificadas por contextos que incluyen términos como "práctica", "consola", "python", nombres de arquitecturas, se asignan a PRACT, distinguiéndolas de EVAL y QUIZ. La Tabla 2 ilustra el pipeline de transformación con un fragmento real del log.

Tabla 2. Ejemplos de transformación log Moodle → estado FSM v6.

Hora	Contexto del evento	FSM	Regla semántica activada
26/08/25 10:50	video de la clase sincrónica unidad 1	REC	“video” en contexto → REC
27/08/25 19:45	práctica de subajuste y sobreajuste MLP	PRACT	“practica” en contexto → PRACT
31/08/25 12:08	cuestionario: evaluación unidad 1	EVAL	componente cuestionario + “submitted” → EVAL

3.3 Análisis de trayectorias y clustering

El objetivo del clustering es identificar perfiles conductuales típicos: grupos de estudiantes que comparten una distribución característica de actividad a lo largo de los siete estados FSM. A diferencia de describir cada trayectoria individualmente, el agrupamiento permite detectar patrones recurrentes y relacionarlos con el rendimiento académico de forma comparativa.

El clustering se aplica sobre las proporciones de los siete estados FSM por estudiante, normalizadas con norma L2, usando K-means con `n_init = 50` y semilla fija (`random_state = 42`). Se comparan soluciones con $K = 2, 3, 4$ y 5 mediante análisis de Silhouette. La selección de $K = 4$ y la interpretación de los clusters se reportan en la Sección 4.3.

3.4 Modelado latente con HMM

Se ajustó un modelo HMM categórico (CategoricalHMM, `hmmlearn`) a las secuencias FSM concatenadas de todos los estudiantes. La cohorte es reducida —15 estudiantes inscritos, de los cuales 13 registraron actividad en la plataforma y constituyen la muestra analizada— y característica de cursos altamente especializados. Los resultados deben interpretarse como evidencia exploratoria y requerirán replicación en otros contextos. El HMM se estima sobre el total de observaciones concatenadas T , no sobre el número de sujetos N : en la formulación Baum-Welch estándar, la potencia del modelo reside en la longitud de la secuencia (Rabiner, 1989). La distinción es crítica en analíticas secuenciales educativas, donde la densidad longitudinal determina la masa analítica disponible (Saqr et al., 2024) y no el tamaño de la cohorte. Con $T = 2.546$ eventos registrados, el corpus de este estudio supera ampliamente el umbral de convergencia del algoritmo Baum-Welch para cuatro estados, que típicamente se estabiliza entre las 500 y 800 observaciones. Esta robustez a nivel de eventos refuerza la confianza en los patrones identificados. La triangulación metodológica entre la FSM, el clustering y el Modelo Oculto de Markov (definido por las matrices de transición A y de emisión B) indica que esos patrones representan dinámicas subyacentes consistentes y no simples artefactos de la muestra. El modelo $\lambda = (\pi, A, B)$ fue estimado con 1.000 iteraciones y semilla fija (`random_state = 42`). Las secuencias latentes más probables se obtuvieron mediante el algoritmo de Viterbi.




Fig. 2. Distribución de proporciones de estados FSM por estudiante. PRACT exhibe la mayor dispersión inter-individual.

El número de estados latentes K fue seleccionado mediante un procedimiento empírico incremental: se ajustaron modelos con $K = 2, 3, 4$ y 5 estados, evaluando en cada caso la interpretabilidad de los modos latentes resultantes y su capacidad para diferenciar patrones conductuales pedagógicamente significativos. $K = 4$ resultó ser el número mínimo de estados que permitió distinguir los cuatro modos cognitivos identificados. Para valores menores ($K = 2, 3$), modos conductualmente distintos colapsaban en un único estado latente. Para valores mayores ($K = 5$), los estados adicionales no aportaban interpretabilidad pedagógica diferencial. Este criterio de parsimonia interpretativa —el mínimo K que explica la estructura conductual observada— es coherente con el enfoque del learning analytics orientado a la legibilidad pedagógica del modelo (Osmanli, 2025).

La interpretación de los estados latentes se derivó post-hoc a partir de las matrices de emisión (B), los patrones de ocupación temporal y las correlaciones con el rendimiento académico, sin imponer etiquetas durante la estimación. Este enfoque interpretativo es coherente con las prácticas establecidas en el modelado de secuencias educativas con modelos de Markov (Helske et al., 2024).

4 Resultados

4.1 Distribución y variabilidad de estados observables

La Fig. 2 muestra la distribución de proporciones de estados FSM por estudiante. La Tabla 3 complementa con las estadísticas descriptivas. Navegación (NAV) y consumo de recursos (REC) dominan la actividad en términos de proporción media, pero exhiben dispersión relativamente limitada ($DE = 0.08$ y 0.09 , respectivamente). En contraste, la práctica computacional activa (PRACT) muestra variabilidad notablemente mayor (DE

= 0.12, RIC = 0.17), lo que anticipa que PRACT será el estado con mayor poder diferenciador en el análisis de rendimiento.

Tabla 3. Estadísticas descriptivas de las proporciones de estados FSM por estudiante.

Estado FSM	Media	Mediana	DE	RIC
NAV: Navegación	0.20	0.19	0.08	0.11
REC: Uso de recursos	0.26	0.25	0.09	0.13
PRACT: Práctica computacional activa	0.18	0.16	0.12	0.17
QUIZ: Cuestionarios formativos	0.11	0.10	0.06	0.08
EVAL: Evaluación sumativa	0.07	0.06	0.05	0.06

4.2 Correlaciones entre estados FSM y rendimiento académico

La Fig. 3 (heatmap de correlaciones de Spearman) muestra el patrón de forma inequívoca: la práctica computacional activa (PRACT) exhibe la tendencia positiva marginal más fuerte con la calificación final ($\rho = 0.53$, $p = 0.063$). En contraste, la navegación ($\rho = +0.13$, $p = 0.67$) y el consumo de recursos ($\rho = -0.35$, $p = 0.25$) muestran relaciones débiles o negativas. La Tabla 4 detalla los valores completos.




Fig. 3. Correlaciones de Spearman entre proporciones de estados FSM y calificación final. PRACT muestra la tendencia positiva marginal más fuerte ($\rho = 0.53$).

4.3 Clustering de trayectorias

El clustering se aplicó sobre las proporciones de los siete estados FSM por estudiante, normalizadas con norma L2. Se evaluaron soluciones con $K = 2, 3, 4$ y 5 mediante análisis de Silhouette con $n_{init} = 50$ y semilla fija ($random_state = 42$). $K = 4$ fue seleccionado (Silhouette = 0.315) porque es el mínimo que distingue cuatro perfiles conductuales pedagógicamente interpretables: valores menores colapsan modos conductualmente distintos en un mismo cluster, mientras que valores mayores no agregan interpretabilidad diferencial. La estabilidad de la solución fue verificada mediante múltiples inicializaciones, confirmando que los clusters no dependen de la condición inicial del algoritmo.

Tabla 4. Correlaciones de Spearman entre proporciones de estados FSM y calificación final.

Estado FSM	ρ de Spearman	p-valor	Interpretación
NAV: Navegación	+0.13	0.67	Sin relación significativa
REC: Uso de recursos	-0.35	0.25	Sin relación significativa
PRACT: Práctica activa	+0.53	0.063	Tendencia positiva marginal
QUIZ: Cuestionarios	+0.32	0.29	Sin relación significativa
EVAL: Evaluación	+0.32	0.29	Sin relación significativa

La Fig. 4 muestra la proyección PCA de las trayectorias de los 13 estudiantes, coloreadas por cluster. Los cuatro grupos reflejan configuraciones conductuales bien diferenciadas. En un extremo, el cluster de mayor rendimiento concentra estudiantes con alta proporción de PRACT y QUIZ, cuyas trayectorias forman secuencias REC→PRACT→EVAL típicas de un ciclo de aprendizaje completo. En el otro extremo, el cluster de bajo rendimiento agrupa trayectorias dominadas por NAV y OTHER, sin práctica regulada sostenida. Entre ambos, los clusters intermedios capturan perfiles de transición: lectores intensivos que no llegan a la práctica, y navegadores dispersos con actividad fragmentada. La separación visual en el espacio PCA, que concentra el 96% de la varianza en dos componentes, confirma que los clusters capturan estructura real y no artefactos de muestra pequeña.




Fig. 4. Proyección PC1-PC2 de las trayectorias FSM coloreadas por pertenencia al cluster $K = 4$.

4.4 Modos cognitivos latentes inferidos por el HMM

El HMM identifica cuatro modos cognitivos latentes (Z0–Z3). La Tabla 5 sintetiza su caracterización, derivada post-hoc a partir de las probabilidades de emisión, la posición temporal promedio y la relación con el rendimiento académico. Cada modo se distingue tanto por lo que emite (su FSM dominante) como por cuándo aparece en la trayectoria, dimensión temporal que un análisis de proporciones agregadas no puede capturar. Las Tablas 6 y 7 presentan las matrices del modelo estimado.

Tabla 5. Síntesis de los cuatro modos cognitivos latentes identificados por el HMM.

Modo	Denominación	FSM dominante	Fase temporal	Relación con rendimiento
Z0	Lector / explorador de recursos	REC	Temprana	Baja
Z1	Navegador superficial	NAV	Temprana-media	Media
Z2	Aprendiz activo regulado	PRACT/QUIZ	Media-tardía	Alta
Z3	Pasivo / difuso	OTHER	Tardía	Media-baja

Los cuatro modos describen roles cognitivos diferenciados. Z0 (Lector / explorador de recursos) domina la fase temprana: el estudiante consume materiales con alta probabilidad de emitir REC ($B[Z0 \rightarrow REC] = 0.731$) y poca actividad práctica. Z1 (Navegador superficial) combina navegación y actividad difusa, sin foco en la práctica ni en la evaluación. Z3 (Pasivo / difuso) aparece tardíamente y emite predominantemente OTHER ($B[Z3 \rightarrow OTHER] = 0.729$), lo que refleja interacción sin estructura pedagógica reconocible. Entre los cuatro modos, Z2, el Aprendiz activo regulado, emerge como el único asociado significativamente al rendimiento académico. Solo Z2 emite estados PRACT con alta probabilidad ($B[Z2 \rightarrow PRACT] = 0.401$) y aparece predominantemente en la fase media-tardía. Es también el único modo con correlación positiva significativa con la calificación final. Los estudiantes con mayor ocupación temporal en Z2 obtienen resultados académicos significativamente mejores. Ninguno de estos modos fue definido a priori: emergieron del proceso de estimación del HMM sobre 2.546 eventos de interacción registrados (véase Tabla 6).

Tabla 6. Matriz de transición A del HMM.

A →	Z0	Z1	Z2	Z3
Z0	0.821	0.129	0.051	0.000
Z1	0.000	0.454	0.097	0.448
Z2	0.031	0.130	0.796	0.043
Z3	0.341	0.569	0.090	0.000

La lectura conjunta de ambas matrices permite una interpretación dinámica de los modos. Z2 no solo emite los estados cognitivamente más ricos (PRACT + QUIZ), sino

que además exhibe la mayor auto-persistencia del modelo ($A[Z2 \rightarrow Z2] = 0.796$): una vez que el estudiante ingresa al modo de práctica activa regulada, tiende fuertemente a permanecer en él. En contraste, Z3 es altamente inestable: con probabilidad 0.569 transita hacia Z1 y con probabilidad 0.341 hacia Z0. Esto refleja que el modo pasivo/difuso no consolida dinámicas de aprendizaje profundo. La correlación de Spearman entre la proporción de tiempo en Z2 y la calificación final es $\rho = 0.599$ ($p = 0.030$), la única significativa del modelo, mientras que Z0 ($\rho = -0.261$), Z1 ($\rho = -0.045$) y Z3 ($\rho = -0.126$) muestran correlaciones nulas o negativas (véase Tabla 7).

Tabla 7. Matriz de emisión B del HMM.

B →	OTHER	NAV	REC	QUIZ	EVAL	FB	PRACT
Z0	0.071	0.116	0.731	0.000	0.000	0.000	0.083
Z1	0.396	0.537	0.000	0.060	0.000	0.000	0.007
Z2	0.035	0.008	0.018	0.412	0.063	0.063	0.401
Z3	0.729	0.065	0.168	0.000	0.000	0.000	0.037

Desde el punto de vista de la teoría del aprendizaje autorregulado, esta estructura es coherente: Z2 encapsula la secuencia preparación–acción–verificación ($REC \rightarrow PRACT \rightarrow EVAL/FB$) que caracteriza los ciclos cognitivos eficaces (Winne y Hadwin, 1998). La alta auto-persistencia de Z2 sugiere que la práctica activa regulada no es un estado esporádico sino una dinámica sostenida, lo que refuerza su rol como modo cognitivo estructurante del éxito académico en cursos de IA.

En conjunto, los tres niveles de análisis convergen en un hallazgo único y consistente: la práctica computacional activa regulada —capturada por el estado PRACT a nivel observable, por el cluster de alta práctica a nivel descriptivo, y por el modo Z2 a nivel latente— es el único predictor significativo del rendimiento académico en este curso. Esta convergencia, obtenida a partir de métodos analíticamente independientes, minimiza la posibilidad de que el resultado sea un artefacto de la muestra y fortalece la base empírica de las implicaciones pedagógicas que se desarrollan a continuación (véase Tabla 8).

Tabla 8. ρ de Spearman entre proporción de tiempo en cada modo latente y calificación final.

Modo latente	ρ de Spearman	p-valor	Lectura
Z0	-0.261	0.389	Negativo, no significativo
Z1	-0.045	0.884	Nulo
Z2	+0.599	0.030	Positivo, significativo
Z3	-0.126	0.681	Nulo

5 Discusión e implicaciones para la enseñanza de IA

Del análisis emergen tres hallazgos articulados con implicaciones directas para la enseñanza de IA en el nivel superior.




Fig. 5. Proporción promedio del estado latente Z2 por cluster de trayectoria. Los clusters de mayor rendimiento académico presentan mayor ocupación de Z2, cerrando la cadena explicativa FSM → Clusters → HMM → Rendimiento.

En primer lugar, la tendencia positiva marginal entre práctica computacional activa y rendimiento ($\rho = 0.53$, $p = 0.063$) refuerza el valor del paradigma learning by doing en cursos técnicos de IA (Koedinger et al., 2016). En el contexto del curso analizado, donde los estudiantes trabajan con diversos operadores neuronales en un entorno Python interactivo, la práctica no es una actividad auxiliar sino el medio principal de construcción del conocimiento. El tiempo instruccional debería orientarse a maximizar oportunidades de práctica computacional regulada, con secuencias que integren recursos, ejercicios y evaluación formativa en progresión coherente.

En segundo lugar, los cuatro modos cognitivos latentes no son solo categorías: describen una progresión. Un estudiante típico comienza en Z0 (Lector / explorador de recursos), consumiendo materiales y videos en las primeras semanas. Luego puede derivar hacia Z1 (Navegador superficial), donde la actividad se dispersa sin foco en la práctica. El modo Z3 (Pasivo / difuso) es especialmente problemático: la matriz de transición muestra que Z3 tiene probabilidad 0.569 de recaer en Z1 y probabilidad nula de transitar directamente a Z2. Es, en términos dinámicos, una trampa. En contraste, quienes logran ingresar a Z2 (Aprendiz activo regulado) en la fase media-tardía tienden fuertemente a permanecer en él ($A[Z2 \rightarrow Z2] = 0.796$) y son los únicos que predicen buen rendimiento académico. Para los docentes, la implicación es concreta: las intervenciones más valiosas son las que facilitan ese tránsito hacia Z2 antes de que el estudiante quede atrapado en dinámicas pasivas. La Fig. 5 cierra la cadena: los clusters de mayor rendimiento son exactamente los de mayor ocupación de Z2.

En tercer lugar, que la navegación y el consumo de recursos no predigan el rendimiento implica que el acceso a materiales de alta calidad no garantiza aprendizaje efectivo sin práctica activa regulada (Verykios et al., 2024). Los indicadores de

progreso basados exclusivamente en accesos son insuficientes y pueden ser engañosos en cursos de IA.

Estos hallazgos tienen implicaciones pedagógicas concretas. Un docente que monitoree la proporción de PRACT en las trayectorias de sus estudiantes dispone de una señal temprana de riesgo: un alumno con Z2 bajo y Z1 o Z3 dominantes consume recursos o acumula evaluaciones sin práctica regulada, patrón que predice bajo rendimiento antes de que se produzca. De ahí que las intervenciones más efectivas sean específicas: redirigir al alumno hacia las consolas CPIAE, proponer secuencias REC→PRACT→EVAL estructuradas, o activar alertas pedagógicas automáticas integradas al LMS. La especificidad de este resultado en computación neuronal radica en que el contenido del curso —desde el Perceptrón hasta arquitecturas Transformer— exige manipulación computacional iterativa para construir comprensión genuina: no es posible aprender a ajustar una red neuronal leyendo su descripción. La brecha entre Z0/Z1 y Z2 es, por tanto, pedagógicamente más crítica en este dominio que en cursos de contenido principalmente declarativo.

El marco FSM + clustering + HMM ofrece una herramienta replicable para el análisis de cursos de IA en entornos virtuales, con potencial directo para integración en sistemas de alerta temprana orientados a la práctica regulada. En esos entornos, donde la falta de presencialidad limita el diagnóstico directo, monitorear la proporción de Z2 permite identificar estudiantes en riesgo antes de que el bajo rendimiento se materialice. El marco está diseñado precisamente para contextos de alta densidad longitudinal y cohorte reducida, los más comunes en la enseñanza especializada de IA universitaria.

6 Alcance, condiciones de transferibilidad y agenda futura

Este trabajo opera en condiciones específicas que vale la pena delimitar: no para debilitar los hallazgos sino para situar correctamente qué generalizan y qué preguntas quedan abiertas.

El estudio se centra en un único curso por diseño, no por limitación. El objetivo del trabajo es demostrar que el marco de analíticas de aprendizaje FSM + clustering + HMM puede revelar estructura cognitiva significativa a partir de logs de interacción en un contexto disciplinar específico. La contribución generalizable es el método y su lógica de análisis; los valores numéricos son instancias de aplicación en un contexto específico. La replicación en otros cursos, plataformas y disciplinas constituye la agenda natural de validación externa: el paso siguiente lógico, no el que este trabajo debería haber dado.

El tamaño de la muestra analizada ($N = 13$, sobre 15 inscriptos) es característico de cursos altamente especializados y no constituye una restricción analítica: como se argumentó en la Sección 3.4, en analítica secuencial la masa de evidencia reside en los eventos — $T = 2.546$, con una media de 196 por estudiante— y no en el número de individuos. La estructura no emerge del número de personas sino de la riqueza temporal de sus trayectorias (Saqr et al., 2024).

Tres propiedades del análisis refuerzan esta lectura. Los clusters $K=4$ son genuinamente separables (Silhouette 0.315, estables con $n_{init}=50$) y sus perfiles coinciden con los modos pedagógicos del diseño del curso, lo que descarta que sean artefactos de muestra pequeña. El HMM exhibe discriminación correcta: un único

estado significativo (Z_2 , $\rho = 0.599$, $p = 0.030$) frente a tres no significativos, la huella de un modelo que diferencia señal de ruido. Y los tres métodos convergen en el mismo hallazgo, lo que aumenta la confianza en su estabilidad, aunque estudios con muestras más amplias serán necesarios para evaluar su generalización. Cabe señalar que el poder estadístico para las correlaciones de Spearman es limitado y los p-valores deben leerse con esa cautela. Los estudios metodológicamente comparables han sido publicados con N similares (Osmanli, 2025; Verykios et al., 2024).

Por último, el mapeo de eventos a estados FSM involucra decisiones de diseño que son, en sí mismas, parte de la contribución: la FSM fue construida con criterios semánticos anclados en el diseño pedagógico del curso, no aplicada mecánicamente. Granularidades alternativas producirían representaciones diferentes, lo que anticipa una línea de investigación productiva sobre sensibilidad del análisis a las decisiones de mapeo, pero no invalidan los hallazgos obtenidos con la FSM, cuya validez interna fue verificada mediante las correlaciones de la Sección 4.2.

7 Conclusiones y trabajo futuro

Este trabajo ofrece una respuesta concreta a la pregunta de cómo modelar trayectorias de aprendizaje en cursos universitarios de computación neuronal e IA. Para hacerlo, introduce un marco de analíticas de aprendizaje secuencial que combina FSM semántica, clustering exploratorio y HMM. Como resultado central se identifican cuatro modos cognitivos latentes, entre los cuales se destaca el Aprendiz activo regulado (Z_2).

Es el único significativamente asociado al rendimiento académico ($\rho = 0.53$ a nivel observable; $\rho = 0.599$, $p = 0.030$ a nivel latente) y se caracteriza por práctica computacional activa en la fase media-tardía. Este resultado emerge de tres métodos analíticamente independientes —correlaciones FSM, clustering y HMM— que convergen en el mismo hallazgo.

Esta investigación aporta a los docentes e investigadores de educación en Informática y Ciencias de la Computación tres contribuciones: un marco analítico replicable para estudiar el comportamiento estudiantil en cursos de IA en línea; evidencia empírica sobre qué tipos de actividad y modos cognitivos predicen el rendimiento; y una base metodológica para el desarrollo de sistemas de alerta temprana orientados a la práctica regulada.

En el futuro se buscará extender esta metodología a otros cursos del área, incorporar medidas de autorregulación, e integrar herramientas de monitoreo en tiempo real para intervenciones pedagógicas oportunas. Es esperable que la lógica del marco sea transferible a asignaturas universitarias con práctica interactiva basada en código o simulaciones: programación, ciencia de datos, física computacional, entre otras. La condición necesaria es disponer de logs de interacción con granularidad suficiente para distinguir actividades de consumo pasivo de actividades de transformación activa.

El repositorio público del proyecto (datos anonimizados, notebooks y pipeline reproducible) está disponible en la versión congelada v1.0 archivada en Zenodo:

DOI 10.5281/zenodo.20535177.

Referencias

- Baker, R. S., & Inventado, P. S. (2014). Educational data mining and learning analytics. In J. A. Larusson & B. White (Eds.), *Learning analytics: From research to practice* (pp. 61–75). Springer. https://doi.org/10.1007/978-1-4614-3305-7_4
- Gao, Z., Yan, H., Cui, C., Liu, J., Sun, X., & Feng, J. (2025). Untangling complexity of competency evolution: Multi-channel learning trajectories of score, engagement and problem-solving efficiency. *British Journal of Educational Technology*, 00, 1–26. <https://doi.org/10.1111/bjet.70017>
- Hadwin, A. F., Järvelä, S., & Miller, M. (2018). Self-regulation, co-regulation, and shared regulation in collaborative learning environments. In D. Schunk & J. Greene (Eds.), *Handbook of self-regulation of learning and performance* (2nd ed., pp. 83–106). Routledge. <https://doi.org/10.4324/9781315697048-6>
- Helske, J., Helske, S., Saqr, M., López-Pernas, S., & Murphy, K. (2024). A modern approach to transition analysis and process mining with Markov models in education. In M. Saqr & S. López-Pernas (Eds.), *Learning analytics methods and tutorials: A practical guide using R* (pp. 493–524). Springer. https://doi.org/10.1007/978-3-031-54464-4_12
- Koedinger, K. R., McLaughlin, E. A., Jia, J. Z., & Bier, N. L. (2016). Is the doer effect a causal relationship? How can we tell and why it's important. In *Proceedings of the Sixth International Conference on Learning Analytics & Knowledge* (pp. 388–397). ACM. <https://doi.org/10.1145/2883851.2883957>
- Osmanli, T. (2025). Predictive analysis of student engagement and academic performance in virtual learning environments using a hybrid Markov: machine learning model. *Asian Journal of Research in Computer Science*, 18(8), 102–112. <https://doi.org/10.9734/ajrcos/2025/v18i8743>
- Rabiner, L. R. (1989). A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2), 257–286. <https://doi.org/10.1109/5.18626>
- Romero, C., & Ventura, S. (2010). Educational data mining: A review of the state of the art. *IEEE Transactions on Systems, Man, and Cybernetics, Part C*, 40(6), 601–618. <https://doi.org/10.1109/TSMCC.2010.2053532>
- Saqr, M., López-Pernas, S., Helske, S., Durand, M., Murphy, K., Studer, M., & Ritschard, G. (2024). Sequence analysis in education: Principles, technique, and tutorial with R. In M. Saqr & S. López-Pernas (Eds.), *Learning analytics methods and tutorials*. Springer. https://doi.org/10.1007/978-3-031-54464-4_10
- Verykios, V. S., Alachiotis, N. S., Paxinou, E., & Feretzakis, G. (2024). Investigating student behavior in MOOCs using Hidden Markov Models: Resource access patterns and learning outcomes. *Applied Sciences*, 14(24), 12067. <https://doi.org/10.3390/app142412067>
- Villalobos, E., Pérez-Sanagustín, M., & Broisin, J. (2024). From learning actions to dynamics: Characterizing students' individual temporal behavior with sequence analysis. In *Artificial Intelligence in Education* (pp. 3–17). Springer. https://doi.org/10.1007/978-3-031-64302-6_1
- Winne, P. H., & Hadwin, A. F. (1998). Studying as self-regulated learning. In D. J. Hacker, J. Dunlosky, & A. C. Graesser (Eds.), *Metacognition in educational theory and practice* (pp. 277–304). Erlbaum.