

EDUCACIÓN, CREATIVIDAD E INTELIGENCIA ARTIFICIAL: NUEVOS HORIZONTES PARA EL APRENDIZAJE. ACTAS DEL VIII CONGRESO INTERNACIONAL SOBRE APRENDIZAJE, INNOVACIÓN Y COOPERACIÓN, CINAIC 2025

María Luisa Sein-Echaluce Lacleta, Ángel Fidalgo Blanco y Francisco José García Peñalvo (coords.)

1ª Edición. Zaragoza, 2025

Edita: Servicio de Publicaciones. Universidad de Zaragoza.



Servicio de
Publicaciones
Universidad Zaragoza

EBOOK ISBN 978-84-10169-60-9

DOI 10.26754/uz.978-84-10169-60-9



Esta obra se encuentra bajo una licencia Creative Commons Reconocimiento – NoComercial (ccBY-NC). Ver descripción de esta licencia en <https://creativecommons.org/licenses/by-nc-nd/4.0/>

Referencia a esta obra:

Sein-Echaluce Lacleta, M.L., Fidalgo Blanco, A. & García-Peñalvo, F.J. (coords.) (2025). *Educación, Creatividad e Inteligencia Artificial: nuevos horizontes para el Aprendizaje. Actas del VIII Congreso Internacional sobre Aprendizaje, Innovación y Cooperación. CINAIC 2025 (11-13 de Junio de 2025, Madrid, España)*. Zaragoza. Servicio de Publicaciones Universidad de Zaragoza. DOI 10.26754/uz.978-84-10169-60-9

Uso de modelos de lenguaje a gran escala para identificar patrones de comportamiento en minería de procesos de aprendizaje

Using LLM to identify behavioral patterns in educational process mining

Juan Antonio Caballero-Hernández, Manuel Palomo-Duarte, Juan Manuel Dodero, Andrés Muñoz, Iván Ruiz-Rube, Antonio Balderas

juanantonio.caballero@uca.es, manuel.palomo@uca.es, juanma.dodero@uca.es, andres.munoz@uca.es, ivan.ruiz@uca.es, antonio.balderas@uca.es

Departamento de Ingeniería Informática
Universidad de Cádiz
Puerto Real, España

Resumen- La minería de procesos permite descubrir modelos de proceso a partir de registros de eventos y ha sido aplicada con éxito a diversos campos, incluyendo la educación. Sin embargo, en procesos con alta variedad de eventos y grandes volúmenes de datos, los modelos resultantes pueden ser demasiado complejos para un análisis manual eficiente. Este estudio evalúa el uso de Modelos Grandes de Lenguaje (LLM) para analizar modelos de proceso en una asignatura de Bases de Datos. Se examinan las interacciones en el campus virtual de 22 estudiantes (30.711 eventos). Mediante ChatGPT-4Turbo, se identifican patrones de navegación, dificultades en recursos clave y oportunidades de mejora en el curso. Los resultados muestran que los LLMs pueden extraer información relevante de modelos de procesos descubiertos, facilitando la optimización del diseño del curso para mejorar el aprendizaje.

Palabras clave: *Analíticas de Aprendizaje, Minería de Procesos, Inteligencia Artificial Generativa, Modelo Grande de Lenguaje, Bases de Datos*

Abstract- Process mining enables discovering process models from event logs and has been successfully applied in various fields, including education. However, the resulting models can be too complex for efficient manual analysis in processes with high event variety and large data volumes. This study evaluates the use of Large Language Models (LLMs) to analyze process models in a database course. The interactions of 22 students (30,711 events) in the virtual campus are examined. Using ChatGPT-4Turbo, navigation patterns, difficulties with key resources, and opportunities for course improvement are identified. The results show that LLMs can extract relevant information from discovered process models, facilitating the optimization of course design to enhance the learning process.

Keywords: *Learning Analytics, Process Mining, Generative Artificial Intelligence, Large Language Model, Databases*

1. INTRODUCCIÓN

La minería de procesos (*Process Mining*) analiza registros de eventos para descubrir, monitorear y mejorar procesos reales, combinando enfoques basados en modelos y en datos para extraer conocimiento y comparar la evidencia con los modelos de proceso (van der Aalst, 2022). Esta disciplina ha demostrado ser una herramienta valiosa para analizar el comportamiento de los usuarios en diferentes contextos, incluyendo el ámbito educativo (Bogarín et al., 2018). A partir de los eventos

registrados en plataformas de aprendizaje, es posible modelar los flujos de interacción de los estudiantes, identificar patrones de comportamiento y detectar posibles dificultades en el uso de los recursos (Cantabella et al, 2019).

En entornos educativos, los registros de procesos pueden contener trazas de comportamiento flexible, lo que da lugar a resultados difíciles de predecir (Imran et al., 2022). Por ejemplo, en un curso en línea, los estudiantes pueden acceder a los materiales en distinto orden, repetir ciertas actividades o incluso omitir algunas, generando secuencias de eventos altamente variables. Como resultado, los modelos de proceso obtenidos pueden resultar complejos y difíciles de interpretar, presentando estructuras enredadas similares a los denominados “modelos espagueti” (Gomes et al., 2021). Esta complejidad dificulta el análisis manual, haciendo necesario el uso de técnicas avanzadas para extraer información útil.

En este contexto, los Modelos Grandes de Lenguaje (*Language Large Models*, LLM) destacan por su capacidad para procesar y comprender grandes volúmenes de información no estructurada (Brown et al., 2020). Su entrenamiento en conjuntos de datos variados les permite identificar patrones complejos y relaciones sutiles en secuencias de eventos, facilitando la interpretación automatizada de los flujos de comportamiento de los estudiantes. Además, pueden sintetizar y resumir información, detectando anomalías o tendencias que serían difíciles de apreciar mediante análisis manual. Esto los convierte en una herramienta prometedora para extraer evidencias significativas de modelos de procesos educativos, proporcionando información clave para la toma de decisiones en entornos de aprendizaje.

Este estudio explora la aplicación de un LLM (*ChatGPT-4Turbo*) para el análisis de un modelo de proceso obtenido a partir de los registros de actividad en el Campus Virtual de una asignatura de Bases de Datos. En particular, se centra en los estudiantes con resultados académicos más bajos, analizando su navegación y uso de los recursos educativos para detectar patrones que puedan estar asociados a un desempeño bajo. Los resultados obtenidos muestran cómo la combinación de minería de procesos y modelos LLM puede ofrecer nuevas perspectivas para la mejora del aprendizaje en entornos virtuales.

El resto del trabajo tiene la siguiente estructura: la sección 2 incluye el contexto y metodología seguidos. En la sección 3 se muestran y discuten los resultados. La sección 4 resume las conclusiones y comenta los trabajos futuros.

2. CONTEXTO Y DESCRIPCIÓN

El público objetivo de este estudio incluye investigadores en minería de procesos educativos y docentes interesados en optimizar entornos virtuales de aprendizaje. A continuación, se presenta el contexto del estudio, seguido de la descripción del caso de estudio realizado.

A. La minería de procesos en educación

El análisis manual de grandes conjuntos de datos presenta limitaciones de escalabilidad y puede pasar por alto información crucial (Caballero-Hernández et al., 2017). Los métodos de analíticas del aprendizaje (*Learning Analytics*) abordan estos desafíos mediante la recopilación, análisis y reporte de datos de los estudiantes (Gašević & Pechenizkiy, 2016). Dentro de este campo, la minería de procesos permite descubrir patrones de aprendizaje y detectar oportunidades de mejora en entornos educativos a partir de registros de eventos (van der Aalst, 2022). La minería de procesos en educación se ha aplicado en educación superior para analizar el aprendizaje, incluyendo la colaboración, la regulación social y la predicción del rendimiento en MOOCs. Además, se ha usado en el aprendizaje autorregulado para estudiar cómo los estudiantes gestionan su progreso según sus objetivos y recursos (Saint et al., 2022).

Los modelos resultantes del descubrimiento de procesos pueden representarse en notaciones como redes de Petri o diagramas de seguimiento directo (*Directly-Follows Graph*, DFG). Cuando los registros de eventos contienen una alta variedad de interacciones y un gran volumen de datos, los modelos descubiertos pueden volverse excesivamente complejos (Imran et al., 2022). Para abordar esta complejidad, este estudio propone el uso de LLM como herramienta de apoyo en el análisis de modelos de proceso.

B. Caso de estudio

El caso de estudio se llevó a cabo en el curso 2023-2024, en la asignatura de Bases de Datos del grado en Ingeniería Informática en la Universidad de Cádiz. La selección de 22 estudiantes se basó en la calificación final de la asignatura, incluyendo a aquellos cuyo resultado fue igual o inferior al percentil 25 de todas las calificaciones del curso ($\leq 3,75$), a partir de cuyos registros de eventos se realizó el análisis. De este modo, el estudio se centra en los estudiantes con menor rendimiento académico, con el objetivo de detectar patrones asociados a un desempeño bajo.

El conjunto de datos del estudio incluye todas las interacciones realizadas en el curso por estos estudiantes, extraídas de Moodle, el sistema de gestión del aprendizaje de la Universidad. En total, se recopilaron 30.711 interacciones.

Para procesar los datos, se utilizó la librería *pm4py* (PM4Py, 2025), una herramienta especializada en minería de procesos en Python. Se generó un modelo de proceso en forma de DFG, que representa las transiciones entre eventos junto con sus frecuencias. La Figura 1 muestra el DFG obtenido. Debido a la diversidad de interacciones registradas en Moodle, el modelo resultante es un caso claro de “modelo espagueti”, donde la

densidad de transiciones dificulta la identificación de patrones claros de navegación y comportamiento.




Figura 1. Modelo DFG del comportamiento de estudiantes con bajo desempeño (Caballero-Hernández, 2025)

Para facilitar su análisis, se transformó el DFG en una representación textual mediante *pm4py*, la cual incluye el evento origen, el evento destino y la frecuencia de ocurrencia para cada transición del modelo. Esta representación fue analizada mediante *ChatGPT-4Turbo*, elegido por su capacidad avanzada para procesar información estructurada y generar análisis contextuales detallados.

El LLM recibió un prompt específico para identificar patrones de navegación, dificultades en el acceso a recursos clave y oportunidades de mejora en el curso. Se le instruyó a justificar sus hallazgos con evidencia cuantitativa siempre que fuera posible, garantizando así la validez del análisis. A continuación, se presenta una versión sintetizada del prompt:

El análisis se basa en registros de eventos de Moodle correspondientes a estudiantes con calificaciones en el percentil 25 o inferior en un curso de Bases de Datos. Se emplea un modelo Directly-Follows Graph (DFG) en formato textual para identificar patrones de comportamiento, tendencias, anomalías y posibles indicadores de compromiso o dificultades en el aprendizaje. Se debe prestar especial atención a flujos de trabajo comunes y poco frecuentes, variabilidad en la interacción con el curso, cuellos de botella y desviaciones del comportamiento esperado. Los hallazgos deben presentarse de manera clara y estructurada, justificándose con la estructura del modelo DFG, la frecuencia de las transiciones y el perfil temporal. Además, se requiere evaluar el impacto de los patrones detectados en la experiencia de los estudiantes y el diseño del curso, proporcionando sugerencias de mejora basadas en el análisis. El razonamiento debe ser detallado y fundamentado en los datos proporcionados, evitando suposiciones externas al modelo.

3. RESULTADOS

En esta sección se presentan los hallazgos obtenidos por el LLM, así como sugerencias de mejora en base a ellos.

A. Hallazgos

Los resultados proporcionados por el LLM se organizaron en apartados según los hallazgos detectados. Para cada hallazgo, el LLM dividió el análisis en una justificación de la detección del patrón o comportamiento identificado, y en las implicaciones de su posible impacto en los estudiantes.

1) Dominancia del evento `\core\event\course_viewed`

El evento `course_viewed` indica que un usuario ha visualizado la página principal de un curso. Este evento aparece

como el nodo central, tanto en sus transiciones salientes (hacia `\mod_resource\event\course_module_viewed`, `\mod_workshop\event\course_module_viewed`, `\mod_quiz\event\course_module_viewed`, etc.) como en las entrantes (desde `\mod_resource\event\course_module_viewed` y `\mod_workshop\event\course_module_viewed`).

Esto sugiere que los estudiantes pasan gran parte de su actividad navegando en la vista principal del curso. La alta frecuencia (por ejemplo, 9027 en la autotransición de `course_viewed`) puede interpretarse de dos maneras:

- Compromiso: Los estudiantes revisan constantemente la página principal en busca de actualizaciones o información.
- La necesidad de volver repetidamente a la vista principal puede indicar que no encuentran de forma inmediata lo que buscan en el contenido específico, lo que podría dificultar la progresión en el curso.

2) Transiciones bidireccionales entre módulos y vista principal

Ejemplos relevantes:

- `\core\event\course_viewed` ↔ `\mod_resource\event\course_module_viewed`: (2154 de `course_viewed` a `course_module_viewed` y 1991 en la dirección inversa)
- `\core\event\course_viewed` ↔ `\mod_workshop\event\course_module_viewed`: Frecuencias similares (2127 y 1698, respectivamente)

La existencia de estas transiciones en ambas direcciones indica que los estudiantes frecuentemente pasan de la vista principal a contenidos específicos (como recursos o actividades de taller) y luego regresan. Este comportamiento podría reflejar:

- Una estrategia de búsqueda de información en la que se consulta la página de inicio antes y después de acceder a un recurso.
- Posibles problemas de navegación, donde la información o la orientación dentro del módulo no es lo suficientemente clara, obligando al estudiante a "reorientarse" en la vista principal.

3) Comportamiento en actividades de Quiz

Existe un intercambio casi simétrico entre los eventos `\mod_quiz\event\attempt_updated` y `\mod_quiz\event\attempt_viewed` (frecuencias de 1223 y 1216, respectivamente), además de otras transiciones relacionadas con los quiz.

Esto sugiere una dinámica en la que los estudiantes:

- Revisan continuamente sus intentos de quiz y actualizan sus respuestas.
- Pueden estar iterando en su intento de comprender o corregir respuestas, lo que podría reflejar inseguridad o dificultades para resolver las preguntas.

4) Flujo en actividades de Taller (Workshop)

Existen múltiples transiciones entre eventos del taller, como:

- `\mod_workshop\event\course_module_viewed` → `\mod_workshop\event\submission_created` (220)
- `\mod_workshop\event\submission_created` → `\mod_workshop\event\submission_updated` (297)

- `\mod_workshop\event\submission_viewed` → `\mod_workshop\event\course_module_viewed` (77)
- Otras transiciones entre eventos de evaluación (`submission_assessed` y `submission_reassessed`)

Aunque las frecuencias son más bajas en comparación con los eventos de navegación general, este flujo indica que:

- Los estudiantes siguen una serie de pasos para la realización y revisión de las actividades de taller.
- La existencia de ciclos y pasos reiterados en la cadena de envío y evaluación podría sugerir que el proceso no es completamente fluido, lo que podría afectar la eficiencia en la realización de estas actividades.

5) Otros eventos y transiciones menos frecuentes

Se observan transiciones con frecuencias menores de 100 en eventos relacionados con foros, mensajes de correo y vistas de perfil en comparación con las del flujo principal (existiendo una única excepción con la visualización de mensajes).

Estas bajas frecuencias indican que:

- La exploración de funcionalidades adicionales del curso es muy baja en comparación con el flujo principal.
- La posible falta de uso o el uso esporádico de estas herramientas podría señalar áreas donde la interacción y el compromiso son reducidos.

B. Sugerencias de mejora en el diseño del curso

En este apartado se presentan las mejoras propuestas por el LLM para optimizar la experiencia de los estudiantes en el curso.

1) *Optimizar la navegación.* Rediseñar la interfaz de la página principal para que ofrezca resúmenes claros y accesos directos a recursos y actividades importantes. Además, incorporar indicadores visuales que orienten a los estudiantes sobre en qué parte del proceso se encuentran.

2) *Refinar la gestión de quizzes.* Proporcionar retroalimentación inmediata y detallada en los quizzes para reducir múltiples intentos derivados de dudas o confusión. Asimismo, simplificar la transición entre la actualización y visualización de intentos, incluyendo guías o ejemplos que faciliten su comprensión.

3) *Simplificar el proceso en talleres.* Revisar y reducir la complejidad de los pasos en las actividades de taller (creación, actualización, evaluación) en la medida de lo posible. También se recomienda incluir tutoriales o ayudas contextuales para guiar a los estudiantes en cada etapa del proceso.

4) *Fomentar el uso de canales de comunicación.* Incentivar la participación en foros y actividades colaborativas para ofrecer un soporte adicional y compartir dudas y soluciones entre compañeros.

C. Evaluación y limitaciones de los resultados del LLM

Los hallazgos generados por el LLM han permitido identificar patrones relevantes en la navegación y el uso de recursos dentro del curso. La segmentación del análisis en observación e implicación ha proporcionado de manera separada la justificación de los hallazgos y cómo estos afectan a la experiencia de aprendizaje dentro del curso.

Los resultados destacan aspectos clave del comportamiento estudiantil que no podrían haberse llevado a cabo por métodos manuales debido a la alta cantidad de eventos (30.711). La detección de flujos recurrentes y transiciones bidireccionales entre módulos permite inferir posibles problemas de orientación y acceso a la información. Además, las sugerencias de mejora proporcionadas por el LLM son coherentes con las problemáticas detectadas y podrían servir como guía para la optimización del diseño del curso.

Sin embargo, también se identifican ciertas limitaciones en el análisis del LLM. Si bien la justificación cuantitativa fortalece la validez de los hallazgos, la interpretación de los datos sigue dependiendo del contexto específico del curso y de la experiencia de los autores. Algunos patrones detectados pueden deberse a particularidades del diseño actual y no necesariamente a problemas de navegación. La falta de datos cualitativos limita, además, la posibilidad de contrastar las inferencias con percepciones directas de los estudiantes. Finalmente, los resultados deben entenderse dentro del marco de la muestra analizada, centrada exclusivamente en el grupo con menor rendimiento académico.

4. CONCLUSIONES

El presente estudio demuestra que la integración de LLMs en el análisis de modelos de procesos educativos es una estrategia viable para identificar patrones de comportamiento, detectar ineficiencias y proponer mejoras en el diseño de cursos. A partir del DFG obtenido mediante técnicas de minería de procesos extrayendo información de eventos de Moodle, el LLM (ChatGPT-4Turbo) proporcionó un análisis del modelo con hallazgos donde se indican tanto las justificaciones según los datos de eventos analizados, como las implicaciones que pueden tener en el curso. Estos hallazgos incluyen visualizaciones constantes de la página principal del curso, transiciones bidireccionales entre la página principal y ciertos módulos, flujos relevantes dentro de los quizzes y de los talleres.

Aunque los resultados obtenidos están limitados al contexto del estudio, el enfoque presentado es sostenible y transferible a otros contextos educativos y de análisis de procesos, dado que la metodología basada en herramientas de minería de procesos y LLM se puede adaptar a diferentes plataformas y disciplinas. Como trabajo futuro proponemos tanto el uso de datos cualitativos para contrastar los resultados con las percepciones de los estudiantes, así como el uso de otros modelos LLM para comparar los análisis realizados. Además, se plantea la ampliación del estudio para incluir a estudiantes con mejor rendimiento académico, con el fin de comparar patrones de comportamiento y enriquecer el análisis.

AGRADECIMIENTOS

Esta publicación es parte del proyecto PID2023-149674OB-I00, financiado por MICIU/AEI/10.13039/501100011033 y por ERDF, EU.

REFERENCIAS

Bogarín, A., Cerezo, R., & Romero, C. (2018). A survey on educational process mining. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(1), e1230. <https://doi.org/10.1002/widm.1230>

- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). Language models are few-shot learners. *Proceedings of the 34th International Conference on Neural Information Processing Systems*. <https://dl.acm.org/doi/abs/10.5555/3495724.3495883>
- Caballero-Hernández, J. A., Palomo-Duarte, M., & Dodero, J. M. (2017). Skill assessment in learning experiences based on serious games: A Systematic Mapping Study. *Computers and Education*, 113, 42–60. <https://doi.org/10.1016/j.compedu.2017.05.008>
- Caballero-Hernández, J. A. (2025). Modelo DFG del comportamiento de estudiantes con bajo desempeño. *FigureShare*. <https://doi.org/10.6084/m9.figshare.28791854>
- Cantabella, M., Martínez-España, R., Ayuso, B., Yáñez, J. A., & Muñoz, A. (2019). Analysis of student behavior in learning management systems through a Big Data framework. *Future Generation Computer Systems*, 90, 262–272. <https://doi.org/https://doi.org/10.1016/j.future.2018.08.003>
- Gašević, D., & Pechenizkiy, M. (2016). Let's Grow Together: Tutorials on Learning Analytics Methods. *Journal of Learning Analytics*, 3(3), 5–8. <https://doi.org/10.18608/jla.2016.33.2>
- Gomes, A.F.D., de Lacerda, A.C.W.G., da Silva Fialho, J.R. (2021). Comparative Analysis of Process Mining Algorithms in Python. In: Pires, I.M., Spinsante, S., Zdravevski, E., Lameski, P. (eds) *Smart Objects and Technologies for Social Good. GOODTECHS 2021. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*, vol 401. Springer, Cham. https://doi.org/10.1007/978-3-030-91421-9_3
- Imran, M., Ismail, M. A., Hamid, S., & Nasir, M. H. N. M. (2022). Complex Process Modeling in Process Mining: A Systematic Review. *IEEE Access*, 10, 101515–101536. <https://doi.org/10.1109/ACCESS.2022.3208231>
- PM4Py. (2025). *Process Mining for Python* [Repositorio GitHub]. <https://github.com/process-intelligence-solutions/pm4py>
- Saint, J., Fan, Y., Gašević, D., & Pardo, A. (2022). Temporally-focused analytics of self-regulated learning: A systematic review of literature. *Computers and Education: Artificial Intelligence*, 3, 100060. <https://doi.org/https://doi.org/10.1016/j.caeai.2022.100060>
- van der Aalst, W. M. P. (2022). Process Mining: A 360 Degree Overview. In J. van der Aalst Wil M. P. and Carmona (Ed.), *Process Mining Handbook* (pp. 3–34). Springer International Publishing. https://doi.org/10.1007/978-3-031-08848-3_1