

Estado de la publicación: El preprint no ha sido enviado para publicación

Psicohistoria como Lente Inspirador: Modelos Computacionales y Dinámicas Humanas en el Abandono Estudiantil

Hugo Roger Paz

<https://doi.org/10.1590/SciELOPreprints.14052>

Enviado en: 2025-11-10

Postado en: 2025-12-11 (versión 1)

(AAAA-MM-DD)

Psicohistoria como Lente Inspirador: Modelos Computacionales y Dinámicas Humanas en el Abandono Estudiantil

Psychohistory as an Inspiring Lens: Computational Models and Human Dynamics in Student Dropout

Hugo Roger Paz

Professor and researcher at the Faculty of Exact Sciences and Technology of the National University of Tucumán.

Doctoral student in Exact Sciences and Engineering from the Faculty of Exact Sciences and Technology of the National University of Tucumán.

Email: hpaz@herrera.unt.edu.ar

ORCID: <https://orcid.org/0000-0003-1237-7983>

Resumen

Introducción-problema. El abandono estudiantil es un problema persistente, donde la agenda de investigación dominante se centra en la predicción de riesgo (saber quién abandonará). Este enfoque es insuficiente para guiar intervenciones efectivas. Este artículo es el primero de una serie de dos trabajos dedicados a abordar esta brecha. Aquí, en la Parte I, se desarrolla un ensayo de integración conceptual para establecer las bases teóricas de un nuevo marco.

Metodología. La metodología consiste en proponer la psicohistoria como un lente conceptual integrador. Este lente articula hallazgos de la neurobiología del estrés y las funciones ejecutivas con enfoques de ciencia de datos y sistemas complejos. El objetivo es reorientar la agenda predictiva hacia el diseño de sistemas socio-técnicos empáticos y explicables.

Resultados-hallazgo. El resultado principal es el establecimiento de los fundamentos conceptuales que formarán el marco CAPIRE (detallado en la Parte II). Los hallazgos de esta síntesis incluyen: (i) la conceptualización de la vulnerabilidad neurobiológica como una biografía incorporada; (ii) la introducción de "psicoclases" como perfiles psicosociales latentes; y (iii) la postulación de principios de gobernanza ética (privacidad, XAI) como elementos centrales del diseño.

Discusión, Conclusiones y Recomendaciones. Se concluye que el objetivo debe ser desplazar la pregunta de "¿quién abandona?" hacia "¿qué hacer, para quién y cómo?". Este artículo (Parte I) sienta las bases teóricas. La Parte II de la serie operacionaliza estos fundamentos en el marco CAPIRE de cinco niveles (neurobiología, psicoclases, dinámicas, evaluación causal y gobernanza ética), formulando proposiciones testables y lineamientos metodológicos concretos para su validación empírica.

Palabras clave: Psicohistoria; Deserción Escolar; Modelado computacional; Neurobiología del estrés; Modelos Causales

Abstract

Introduction-Problem. Student dropout is a persistent problem, where the dominant research agenda focuses on risk prediction (knowing who will drop out). This approach is insufficient to guide effective interventions. This article is the first in a two-part series dedicated to addressing this gap. Here, in Part I, a conceptual integration essay is developed to establish the theoretical foundations for a new framework.

Methodology. The methodology consists of proposing psychohistory as an integrative conceptual lens. This lens articulates findings from the neurobiology of stress and executive functions

with approaches from data science and complex systems. The objective is to reorient the predictive agenda toward the design of empathetic and explainable socio-technical systems.

Results-Findings. The primary result is the establishment of the conceptual foundations that will form the CAPIRE framework (detailed in Part II). The findings from this synthesis include: (i) the conceptualization of neurobiological vulnerability as an embodied biography; (ii) the introduction of "psychoclasses" as latent psychosocial profiles; and (iii) the postulation of ethical governance principles (privacy, XAI) as central design elements.

Discussion, Conclusions and Recommendations. We conclude that the objective must be to shift the question from "who drops out?" towards "what to do, for whom, and how?" . This article (Part I) lays the theoretical groundwork. Part II of the series operationalizes these foundations within the five-level CAPIRE framework (neurobiology, psychoclasses, dynamics, causal assessment, and ethical governance), formulating testable propositions and concrete methodological guidelines for its empirical validation.

Keywords: Psychohistory; Dropouts; Computational modeling; Neurobiology of stress; Causal Models

INTRODUCCIÓN

El abandono estudiantil es uno de los problemas más persistentes y costosos que enfrentan los sistemas de educación superior a nivel mundial (López-Zambrano et al., 2024; Tejedor et al., 2023). Con tasas globales que indican que aproximadamente uno de cada tres estudiantes no completa sus estudios, y cifras que alcanzan el 40-45% en regiones como América Latina (García-González et al., 2022), el fenómeno representa una pérdida masiva de capital humano con graves consecuencias económicas y sociales. El período de mayor riesgo es, consistentemente, el primer año de estudios (Salmeron-Majadas et al., 2023).

Si bien la investigación educativa ha identificado un conjunto de factores de riesgo multifactoriales (García-González et al., 2022; Torres-Díaz et al., 2022), los modelos predictivos actuales a menudo se centran en el qué (quién abandonará) en lugar del porqué (las motivaciones profundas) o el cómo (los mecanismos sistémicos y biológicos). Este artículo propone un marco multidisciplinario novedoso para abordar esta brecha.

Argumentamos que la psicohistoria, una disciplina centrada en las motivaciones inconscientes y las experiencias formativas de la infancia como motores de la historia (deMause, 1982; Lawton, 2003), ofrece un lente conceptual invaluable para profundizar nuestra comprensión del abandono. Al transitar desde la búsqueda de motivaciones profundas —el "porqué" de la psicohistoria (Szajnberg, 2004)— hasta el modelado de ecosistemas educativos complejos —el "cómo" de la ciencia computacional—, y anclando ambos en la neurobiología del comportamiento (particularmente los trabajos de Robert Sapolsky sobre el estrés y el desarrollo), podemos construir modelos más humanos y efectivos (Revista Qualitas, 2021).

Este trabajo sintetiza el valor heurístico de la psicohistoria con métodos computacionales como la Cliodinámica (Turchin, 2003), la Inferencia Causal (Donoso-García et al., 2022), la Simulación Basada en Agentes (ABM) (Gisbert-Navarro et al., 2018) y el Análisis Topológico de Datos (TDA) (García-Trevizo et al., 2018). El objetivo final es transformar el análisis de datos educativos de una herramienta de diagnóstico a una de diseño de sistemas empáticos y de apoyo (Revista Qualitas, 2021).

PSICOHISTORIA ACADÉMICA: ORÍGENES, METODOLOGÍA Y CONTROVERSIAS

Para utilizar la psicohistoria como un "modelo inspirador", es imperativo primero establecer una comprensión académica rigurosa de la disciplina (Strozier, 2024), diferenciándola de sus representaciones en la cultura popular (Punset, 2011) y anclando sus

conceptos en la literatura académica. Esta sección sienta las bases para su aplicación conceptual al aclarar sus objetivos, metodología y las controversias que han definido su trayectoria.

Definiendo la Psicohistoria: Una Amalgama Transdisciplinaria

La psicohistoria se define formalmente como un campo de conocimiento transdisciplinario que representa una amalgama de psicología, historia, psicoanálisis, psicología política, antropología y ciencias sociales afines (deMause, 1982). Su propósito central es examinar los "porqués" de la historia, centrándose en la motivación histórica, un dominio que la disciplina reclama como su especialidad primordial (Szajnborg, 2004). Este enfoque se contrapone a la historia convencional, que, según los psicohistoriadores, se concentra predominantemente en la narrativa y la descripción de eventos, dejando la motivación psicológica en gran medida inexplorada (Lawton, 2003).

Lejos de ser una simple aplicación de teorías psicológicas a eventos pasados, la psicohistoria ha evolucionado hasta convertirse en un campo formal con su propia infraestructura académica. La fundación de revistas especializadas, como el *History of Childhood Quarterly: The Journal of Psychohistory* en 1973 (posteriormente *The Journal of Psychohistory*), marcó un hito en su institucionalización (deMause, 1982). El campo es nutrido por académicos de diversas procedencias (historia, educación, ciencias políticas, salud mental) que contribuyen a su desarrollo teórico y práctico a través de cursos y programas de formación específicos (Lawton, 2003). Esta integración formal subraya su estatus como una disciplina académica distinta.

Pilares Metodológicos Fundamentales

La metodología psicohistórica se distingue por un conjunto de principios que la diferencian de los enfoques tradicionales (Lawton, 2003).

El Enfoque "Bottom-Up" (de Abajo hacia Arriba): A diferencia del "psicoanálisis aplicado" temprano, la psicohistoria moderna aboga por un enfoque "de abajo hacia arriba" (Szajnborg, 2004). Los investigadores comienzan con un análisis exhaustivo de fuentes primarias (diarios, memorias, autobiografías) y "escuchan" en busca de signos del inconsciente, como patrones de comportamiento o lapsus linguae (Lawton, 2003). Este método representa un empirismo radical que se mueve desde la evidencia de las experiencias de la infancia hacia los patrones motivacionales adultos (Szajnborg, 2004). Las teorías psicológicas se utilizan como herramientas interpretativas solo después de que los datos han sido procesados (Lawton, 2003).

La Primacía de la Infancia: Un postulado central de la psicohistoria es que las prácticas de crianza y el abuso infantil son factores formativos cruciales en la historia humana (deMause, 1982). La teoría psicohistórica sugiere que comportamientos sociales a gran escala, como la guerra, pueden ser representaciones autodestructivas de traumas tempranos (Szajnborg, 2004). El campo postula la existencia de "psicoclasas", que son mentalidades de grupo resultantes de estilos de crianza particulares en una época histórica (deMause, 1982).

Herramientas Psicoanalíticas: La metodología se apoya fuertemente en conceptos derivados del psicoanálisis para explorar la "realidad psíquica" de los actores históricos (Lawton, 2003). Se analizan los mecanismos de defensa, la compulsión a la repetición y los sueños para desentrañar motivaciones inconscientes (Lawton, 2003). Un elemento distintivo es el uso de la contratransferencia del investigador como una herramienta vital para profundizar en la comprensión del sujeto (Lawton, 2003).

Tres Niveles de Análisis: La investigación psicohistórica opera en tres niveles: la historia de la infancia (prácticas de crianza), la psicobiografía (figuras individuales) y la psicohistoria de grupo (motivaciones de grandes grupos, como naciones) (deMause, 1982).

Controversias Académicas y el "Problema de Asimov"

A pesar de su base metodológica, la psicohistoria ha mantenido una posición controvertida (Strozier, 2024), agravada por la confusión con su homónimo de la ciencia ficción (Punset, 2011).

Distinción de la Psicohistoria Ficticia: Es fundamental distinguir la psicohistoria académica de la concepción popularizada por Isaac Asimov (Punset, 2011). La psicohistoria de Asimov es una ciencia ficticia, algorítmica y predictiva, basada en la mecánica estadística para pronosticar el comportamiento de poblaciones masivas (Krtolica, 2016). La psicohistoria académica es interpretativa, cualitativa y retrospectiva; su objetivo no es predecir el futuro, sino comprender las motivaciones emocionales del pasado (Szajnberg, 2004).

Críticas y Adopción Limitada: La psicohistoria ha enfrentado hostilidad por parte de los departamentos de historia y psicología convencionales (Strozier, 2024). Las críticas se centran en su naturaleza especulativa; las afirmaciones sobre motivaciones inconscientes son difíciles de verificar con evidencia objetiva (Plakun, 2023). Las primeras aplicaciones, influenciadas por el freudismo clásico, fueron criticadas por su determinismo biológico y reduccionismo (deMause, 1982).

Paralelismo con la IA Explicable (XAI): Esta tensión histórica refleja el desafío actual de la inteligencia artificial explicable (XAI) (Bokolo, 2023). Un modelo de "caja negra" puede predecir con alta precisión (p. ej., que un estudiante abandonará), pero si las razones permanecen ocultas, la predicción no es procesable, transparente ni éticamente defendible (Williamson & Kizilcec, 2023). La psicohistoria, en su intento de abrir la "caja negra" de la motivación, se enfrentó a un escepticismo similar (Plakun, 2023). Su historia sirve como recordatorio de que predecir no equivale a comprender.

Como resultado de estas controversias, el "apogeo" de la psicohistoria en las décadas de 1970 y 1980 decayó (Strozier, 2024).

EL FENÓMENO DEL ABANDONO ESTUDIANTIL: UN DESAFÍO MULTICAUSAL

El abandono estudiantil es uno de los problemas más persistentes y costosos que enfrentan los sistemas de educación superior a nivel mundial (López-Zambrano et al., 2024). Esta sección enmarca el problema, revisando los factores causales establecidos y aplicando los conceptos psichistóricos para explorar dinámicas subyacentes.

El Alcance y el Impacto del Abandono Universitario

El abandono de los estudios universitarios es un fenómeno global con tasas alarmantemente altas. Se estima que uno de cada tres estudiantes que ingresan a la educación superior no completa sus estudios. En regiones como América Latina, las tasas de deserción pueden alcanzar o superar el 40-45% (García-González et al., 2022; Universidad de la Iglesia, 2022). Esta problemática representa una pérdida masiva de capital humano con graves consecuencias económicas y sociales (López-Zambrano et al., 2024).

El período de mayor riesgo es, consistentemente, el primer año de estudios, donde las tasas de abandono pueden llegar hasta el 35% (Salmeron-Majadas et al., 2023). Para los estudiantes, no completar la educación se correlaciona con menores ingresos y movilidad social limitada (Tejedor et al., 2023). Para las instituciones, la retención es un indicador clave de éxito educativo y sostenibilidad financiera (López-Zambrano et al., 2024).

Una Revisión de los Factores Causales Establecidos

La investigación académica ha demostrado que el abandono estudiantil es un fenómeno multifactorial (García-González et al., 2022; Torres-Díaz et al., 2022). Las revisiones sistemáticas agrupan los factores de riesgo en categorías interrelacionadas:

- **Factores Académicos:** El rendimiento académico previo y las calificaciones obtenidas durante el primer semestre son predictores potentes del abandono (Salmeron-Majadas

et al., 2023). Otros factores incluyen hábitos de estudio deficientes y un desajuste entre las expectativas y la realidad académica (García-González et al., 2022).

- Factores Socioeconómicos: Las dificultades económicas son citadas con frecuencia como la causa predominante (García-González et al., 2022). La necesidad de trabajar y la falta de recursos son barreras significativas. La disponibilidad de becas ha demostrado tener un impacto causal en la reducción del abandono (Tejedor et al., 2023).
- Factores Institucionales: La calidad de la docencia, la infraestructura, los servicios de apoyo y el clima institucional juegan un papel crucial (García-González et al., 2022). Un fuerte sentido de pertenencia e integración social y académica es un factor protector clave (Schreiner, 2025).
- Factores Personales y Psicológicos: La falta de motivación, la ansiedad, la depresión y otros problemas de salud mental son contribuyentes significativos (García-González et al., 2022). Eventos vitales estresantes o una vocación poco clara también pueden precipitar la decisión (Revista Qualitas, 2021).

Una Lente Psicohistórica sobre el Abandono: Más Allá de los Factores Superficiales

Si bien el análisis de los factores mencionados es esencial, un enfoque psicohistórico invita a especular sobre las dinámicas latentes y las motivaciones inconscientes (Lawton, 2003). Los factores cuantitativos (bajas calificaciones, poca asistencia) pueden ser conceptualizados, a través de una lente psicoanalítica, como el "residuo diurno" (Lawton, 2003). En el análisis de los sueños, el residuo diurno se refiere a los eventos manifiestos que enmascaran un significado latente (Lawton, 2003). De manera análoga, los puntos de datos educativos son los síntomas observables de un problema subyacente.

Una perspectiva psicohistórica argumentaría que un bajo promedio no es la causa final, sino la manifestación de dinámicas inconscientes (miedo al éxito, síndrome del impostor) (Szajnberg, 2004). Este reencuadre cambia el objetivo del análisis: de la mera predicción a partir de los síntomas, a utilizar los síntomas como pistas para diagnosticar una cuestión humana más profunda (Revista Qualitas, 2021).

- Compulsión a la Repetición: El psicoanálisis describe la compulsión a la repetición como la tendencia inconsciente a repetir situaciones traumáticas o no resueltas (Lawton, 2003). Desde esta perspectiva, el abandono universitario podría ser la re-escenificación de un patrón de evasión aprendido.
- Fantasía Grupal e Identidad Institucional: La psicohistoria de grupo analiza cómo las "fantasías grupales" inconscientes moldean el comportamiento colectivo (deMause, 1982). El abandono podría ser el resultado de un conflicto entre la fantasía personal del estudiante y la fantasía grupal que la institución proyecta.
- Transmisión Transgeneracional del Trauma: El concepto postula que los traumas pueden transmitirse inconscientemente a través de las generaciones (deMause, 1982). Aplicado a la educación, esto sugiere que la historia familiar con la educación puede crear barreras invisibles.
- El Choque de "Psicoclasas" en la Universidad: El concepto psicohistórico de "psicoclasas" (deMause, 1982) puede adaptarse al contexto universitario. Los estudiantes llegan desde "psicoclasas" contemporáneas diversas. El abandono estudiantil puede enmarcarse como un "conflicto de psicoclasas" dentro del ecosistema institucional.

La Perspectiva Neurobiológica de Robert Sapolsky: La Biología del Comportamiento en Contexto

El trabajo del neurobiólogo Robert Sapolsky ofrece un puente científico entre las intuiciones de la psicohistoria y los mecanismos biológicos observables (O'Connor, 2017;

Raghavan, 2018). Su enfoque multidisciplinario, detallado en *Behave: The Biology of Humans at Our Best and Worst* (O'Connor, 2017; Saini, 2018), insiste en que, para entender cualquier comportamiento, es necesario analizarlo en múltiples escalas temporales (Devi Partners, 2018).

- La Incorporación Biológica de la Experiencia Temprana: Sapolsky proporciona una base biológica sólida para la primacía de la infancia (Hertzman, 2012). El concepto de "incorporación biológica" describe cómo las experiencias tempranas, especialmente las adversas, "se meten bajo la piel" para alterar permanentemente los procesos biológicos (Hertzman, 2012). La adversidad en la infancia (pobreza, abuso) aumenta la probabilidad de que un adulto sufra de depresión, ansiedad y capacidad cognitiva deteriorada (Sapolsky, 2012). A los cinco años, el estatus socioeconómico de la familia ya es un predictor de los niveles de hormonas del estrés y de la maduración de la corteza frontal (Sapolsky, 2012). Esto significa que un estudiante que llega a la universidad no es una "pizarra en blanco", sino el producto de una historia que ha esculpido la arquitectura de su cerebro.
- El Cerebro bajo Estrés Crónico: La investigación de Sapolsky sobre el estrés es fundamental (Sapolsky, 2012). Mientras que el estrés agudo es adaptativo, los humanos son únicos en su capacidad para activar esta respuesta por razones puramente psicológicas y mantenerla (Sapolsky, 2012). El estrés crónico (dificultades económicas, presiones académicas) tiene efectos perjudiciales en el cerebro:
- Hipocampo: El estrés crónico y la exposición prolongada a glucocorticoides pueden dañar y atrofiar el hipocampo, una región crucial para el aprendizaje y la memoria (Sapolsky, 2000a). Esto se conoce como la "hipótesis de la cascada de glucocorticoides". Un hipocampo dañado puede explicar las dificultades académicas (Sapolsky, 2000a).
- Amígdala: El estrés crónico provoca el crecimiento y la hiperreactividad de la amígdala, el centro del miedo y la ansiedad (Sapolsky, 2012). Esto crea un estado de mayor ansiedad.
- Corteza Prefrontal (CPF): El estrés crónico causa atrofia y desconexión de circuitos en la CPF, la región responsable de la toma de decisiones, la planificación a largo plazo y el control de impulsos (Sapolsky, 2012). Un estudiante bajo estrés crónico es, biológicamente, menos capaz de tomar decisiones racionales y a largo plazo.
- El Cerebro Adolescente en la Universidad: Sapolsky enfatiza que la corteza prefrontal es la última parte del cerebro en madurar por completo, un proceso que no finaliza hasta mediados de los veinte años (O'Connor, 2017). Esto hace que el cerebro del joven adulto sea "la parte del cerebro menos limitada por los genes y más esculpida por la experiencia" (Saini, 2018). Este período se caracteriza por una mayor toma de riesgos y afiliación con los compañeros, debido a una CPF inmadura (Devi Partners, 2018). Para muchos estudiantes, el primer año de universidad coincide con esta volatilidad neurobiológica, haciéndolos particularmente vulnerables.

NUEVAS FRONTERAS CUANTITATIVAS: DE LA CLIODINÁMICA AL MODELADO CAUSAL

Esta sección marca la transición del marco conceptual de la psichistoria a los métodos cuantitativos rigurosos que pueden analizar las tendencias educativas a escala macro (social) y micro (individual).

Cliodinámica: La Historia Matemática y la Longue Durée de la Educación

La cliodinámica es un campo transdisciplinario emergente que aborda la historia como una ciencia (Turchin, 2003). Utiliza el modelado matemático, el análisis de sistemas dinámicos

y bases de datos históricas a gran escala para identificar y explicar patrones macrohistóricos (Turchin, 2008). Fenómenos como el auge y la caída de los imperios o los ciclos de inabilidad política se traducen en modelos matemáticos (Turchin, 2003).

La disciplina integra la evolución cultural y la macrosociología (Turchin, 2008), con la revista *Cliodynamics: The Journal of Quantitative History and Cultural Evolution* como su principal vehículo (Turchin, 2011; Turchin et al., 2015). Aunque la investigación cliodinámica no se ha centrado directamente en el "abandono estudiantil", sus principios son relevantes para comprender las fuerzas a largo plazo que configuran la educación.

Un ejemplo es la investigación de cliodinamicistas como Andrey Korotayev (HSE University, n.d.) sobre la relación entre la alfabetización y el desarrollo económico. Sus análisis han confirmado una correlación fuerte entre la introducción temprana de la alfabetización masiva (a menudo impulsada por factores religiosos) y las tasas posteriores de desarrollo económico (Korotayev et al., 2012).

Desde una perspectiva cliodinámica, la evolución social puede modelarse como un aumento en la capacidad computacional colectiva. La educación formal y las cualificaciones son mecanismos centrales para la acumulación de esta información. Sin embargo, análisis más recientes también exploran las dinámicas del credencialismo y la creciente desconfianza pública en el valor real de los títulos (McGuinness & Hyland, 2025; Nguyen, 2024).

La cliodinámica opera a nivel macrohistórico, identificando fuerzas causales lentas (p. ej., "¿Por qué la educación se ha convertido en una institución central?") (Turchin, 2008). La inferencia causal opera a nivel microindividual, identificando el impacto inmediato de intervenciones específicas (p. ej., "¿Este programa de becas evita que este estudiante abandone sus estudios ahora?") (Donoso-García et al., 2022). Juntos, proporcionan una visión anidada de la causalidad.

Inferencia Causal: Más Allá de la Predicción para Entender "Qué Funciona"

Los modelos predictivos son excelentes para identificar a los estudiantes en riesgo de abandono (Salmeron-Majadas et al., 2023), pero no pueden, por sí mismos, demostrar que una intervención específica causa una reducción en ese riesgo. La inferencia causal es un conjunto de métodos estadísticos diseñados para estimar el verdadero efecto causal de un "tratamiento" (p. ej., una intervención) sobre un resultado, controlando las variables de confusión (Donoso-García et al., 2022).

Metodologías clave incluyen el Emparejamiento por Puntuación de Propensión (Propensity Score Matching - PSM), que intenta emular un ensayo controlado aleatorizado (RCT) en estudios observacionales (Tejedor et al., 2023). Calcula la probabilidad (puntuación de propensión) de que un individuo reciba un tratamiento y luego empareja a individuos tratados y no tratados con puntuaciones similares (Tejedor et al., 2023).

Técnicas más avanzadas como la Ponderación por el Inverso de la Puntuación de Propensión (IPW), la Ponderación Aumentada por el Inverso de la Propensión (AIPW) y los Bosques Aleatorios Ortogonales Doblemente Robustos (DROrthoForest) ofrecen formas más sofisticadas de estimar el Efecto Promedio del Tratamiento (ATE) (Donoso-García et al., 2022). Estos métodos son "doblemente robustos" porque proporcionan una estimación insesgada si al menos uno de los dos modelos que utilizan (el de resultado o el de propensión) está correctamente especificado (Donoso-García et al., 2022).

El paso de los modelos predictivos a los de inferencia causal representa una evolución crítica. Es un movimiento desde una postura pasiva y diagnóstica ("¿quién abandonará?") hacia una activa e intervencionista ("¿qué debemos hacer?"). Intervenir con una beca solo es eficaz si la falta de fondos es una causa del abandono, no simplemente una correlación. Los modelos de inferencia causal están explícitamente diseñados para responder a esta pregunta de "qué hacer" (Donoso-García et al., 2022; Tejedor et al., 2023).

Casos de Estudio en Inferencia Causal para la Retención Estudiantil

La aplicación de estos métodos ha arrojado luz sobre la eficacia de intervenciones específicas.

- Caso de Estudio 1: El Efecto de la Carga Académica en el Primer Año. Una investigación que utilizó un conjunto de métodos (PSM, IPW, AIPW y DROrthoForest) evaluó el impacto de la carga académica en el primer año (Donoso-García et al., 2022). El estudio demostró que una reducción en la carga de trabajo (tomar menos créditos) reduce el riesgo de abandono (Donoso-García et al., 2022). El modelo DROrthoForest, el más robusto, estimó una clara reducción en la probabilidad de abandono de aproximadamente 5 puntos porcentuales (Donoso-García et al., 2022).
- Caso de Estudio 2: El Impacto de las Becas. Otro estudio utilizó PSM para aislar el efecto causal de recibir una beca (Tejedor et al., 2023). Los resultados fueron contundentes: recibir una beca reduce significativamente la probabilidad de abandono (Tejedor et al., 2023). Un Modelo Aditivo Generalizado (GAM) estimó que una beca reduce las probabilidades (odds) de abandonar en casi un 40%, lo que equivale a una reducción del 22.2% en la probabilidad de abandono (Tejedor et al., 2023). Es interesante notar que un modelo predictivo XGBoost asociado identificó las calificaciones del segundo semestre y los créditos aprobados como los predictores más importantes (Pérez-Sánchez et al., 2024; Tejedor et al., 2023).

Tabla 1

Comparación de Métodos de Inferencia Causal en la Investigación sobre Abandono Estudiantil

Método de Inferencia Causal	Supuesto Principal	Caso de Uso en Investigación sobre Abandono	Fortalezas	Limitaciones
Emparejamiento por Puntuación de Propensión (PSM)	Ignorabilidad fuerte (todas las variables de confusión relevantes son observadas).	Evaluar el efecto causal de recibir una beca en el abandono estudiantil.	"Intuitivo; crea grupos de comparación equilibrados en variables observadas, emulando un RCT."	Solo puede controlar las variables de confusión observadas; sensible a la especificación del modelo.
Ponderación por el Inverso de la Puntuación de Propensión (IPW)	Ignorabilidad fuerte; positividad.	Estimar el efecto de una carga académica reducida en el riesgo de abandono.	"Utiliza toda la muestra, lo que puede aumentar la eficiencia estadística."	Puede ser inestable si algunas puntuaciones de propensión son muy cercanas a 0 o 1.
Ponderación Aumentada por el Inverso de la Propensión (AIPW)	Ignorabilidad fuerte; positividad.	Estimar el efecto de una carga académica reducida en el riesgo de abandono.	Doblemente robusto: la estimación es insesgada si el modelo de resultado O el de propensión es correcto.	Más complejo de implementar.
Bosques Aleatorios Ortogonales Doblemente Robustos (DROrthoForest)	Ignorabilidad fuerte; positividad.	Estimar el efecto de una carga académica reducida en el riesgo de abandono.	Combina la robustez doble con la flexibilidad del aprendizaje automático (bosques causales).	Computacionalmente intensivo; menor interpretabilidad.

Nota. Basado en Donoso-García et al. (2022) y Tejedor et al. (2023).

MODELANDO LA COMPLEJIDAD: SIMULACIÓN BASADA EN AGENTES Y ANÁLISIS TOPOLÓGICO DE DATOS

Esta sección explora dos métodos computacionales de vanguardia que son excepcionalmente adecuados para capturar la complejidad inherente a las poblaciones estudiantiles y sus interacciones dinámicas.

Modelos Basados en Agentes (ABM): Simulando Resultados Educativos Emergentes

Un Modelo Basado en Agentes (ABM) es un método de simulación computacional "de abajo hacia arriba" (Gisbert-Navarro et al., 2018; Segedy et al., 2025). En lugar de programar directamente los resultados a nivel de sistema (macro), estos resultados emergen de las interacciones de "agentes" autónomos (micro) que operan bajo un conjunto de reglas simples (Segedy et al., 2025). Este enfoque es ideal para estudiar sistemas adaptativos complejos.

El espíritu metodológico de los ABM presenta un paralelismo con el enfoque "de abajo hacia arriba" de la psicohistoria (Szajnborg, 2004). La psicohistoria insiste en comenzar con las motivaciones de los individuos (Szajnborg, 2004). De manera idéntica, un ABM simula fenómenos de nivel macro (tasas de retención) definiendo las reglas y atributos de "agentes" individuales (estudiantes, profesores) y observando su comportamiento colectivo emergente (Gisbert-Navarro et al., 2018).

Los investigadores han comenzado a desarrollar ABMs para explorar cómo la interacción social y el apoyo institucional influyen en la retención (Segedy et al., 2025). Un ABM típico incluye agentes-estudiante (con atributos como "determinación" y estatus socioeconómico), agentes "centros de apoyo" (recursos institucionales) y un entorno (p. ej., ubicación del campus) (Gisbert-Navarro et al., 2018; Segedy et al., 2025). Las reglas de interacción gobiernan cómo los agentes buscan conexiones sociales o experimentan "eventos exógenos" (Gisbert-Navarro et al., 2018). Los resultados sugieren que tanto las interacciones sociales como los componentes ambientales tienen un impacto significativo en la retención (Segedy et al., 2025).

Es crucial señalar una contradicción aparente en la literatura. Una revisión sistemática de 2024 concluyó explícitamente que "no se identificaron modelos de simulación relacionados con el abandono universitario" (López-Zambrano et al., 2024). Sin embargo, existen otros artículos revisados por pares que describen precisamente ABMs para este fin (Gisbert-Navarro et al., 2018; Segedy et al., 2025). Esta discrepancia sugiere que el campo es incipiente, está fragmentado y revela una brecha entre la comunidad de modelado predictivo y la de simulación de sistemas complejos.

Análisis Topológico de Datos (TDA): Mapeando la "Forma" de la Diversidad Estudiantil

El Análisis Topológico de Datos (TDA) es un método emergente de la matemática aplicada para analizar la "forma" y la estructura de conjuntos de datos complejos y de alta dimensión (Carlsson, 2014; García-Trevizo et al., 2018). A diferencia de los métodos de agrupamiento tradicionales, el TDA crea una representación geométrica simplificada (un grafo o un complejo simplicial) que revela conexiones, progresiones y vacíos (García-Trevizo et al., 2018; Gismera Lobera, 2024). Las técnicas clave incluyen la homología persistente y el algoritmo Mapper (CORDIS, 2015; Mukhopadhyay, 2016).

El TDA es particularmente útil para comprender la "diversidad latente" de los estudiantes (Allmendinger et al., 2021). Puede analizar datos de encuestas sobre actitudes y mentalidades para identificar subgrupos matizados que los métodos tradicionales pasarían por

alto (Allmendinger et al., 2021; Purdue University, 2021). Su fortaleza radica en visualizar progresiones continuas en lugar de categorías rígidas (Allmendinger et al., 2021).

La aplicación del TDA requiere decisiones metodológicas cuidadosas por parte del investigador, como la elección de un método de filtrado y el grado de superposición (Allmendinger et al., 2021). Un estudio aplicó el TDA a una encuesta a gran escala de estudiantes de ingeniería (Allmendinger et al., 2021; Purdue University, 2021). El análisis reveló una estructura subyacente compleja, identificando seis progresiones de datos distintas y un grupo de estudiantes atípicos (Allmendinger et al., 2021). Este "mapa" de la diversidad estudiantil proporciona una visión mucho más rica que una simple categorización.

Sintetizando ABM y TDA: De los Perfiles Latentes a los Sistemas Dinámicos

La combinación de TDA y ABM ofrece un marco computacional concreto para explorar las preguntas de la psicohistoria. La psicohistoria busca entender cómo las motivaciones individuales (agentes) conducen a comportamientos de grupo (resultados emergentes), lo cual es conceptualmente idéntico a un ABM (Segedy et al., 2025). Al mismo tiempo, la psicohistoria enfatiza la existencia de agrupaciones complejas ("psicoclases") (deMause, 1982), algo que el TDA está diseñado para descubrir (Carlsson, 2014).

Por lo tanto, se puede proponer una síntesis novedosa:

- Usar el TDA para definir tipos de agentes: Emplear el TDA para identificar perfiles latentes de estudiantes (Allmendinger et al., 2021). Esto permite identificar empíricamente las "psicoclases" dentro de una población.
- Usar el ABM para simular interacciones: Poblar el ABM con estos tipos de agentes derivados empíricamente para simular cómo sus interacciones únicas conducen a resultados sistémicos (Segedy et al., 2025).
- Integración con el Aprendizaje Automático: El proceso puede ser mejorado mediante el aprendizaje automático para derivar las reglas de decisión de los agentes (Troisi, 2022), creando un ABM asistido por máquinas.

Este enfoque integrado traduce los conceptos abstractos de la psicohistoria en un programa de investigación computable.

DISCUSIÓN: IMPLICACIONES ÉTICAS Y EL FUTURO DEL ANÁLISIS EDUCATIVO

La creciente sofisticación de las herramientas computacionales en la educación conlleva profundas responsabilidades. Esta sección examina críticamente los desafíos éticos y ofrece una perspectiva sobre su futuro papel.

El Campo Minado Ético del Análisis Predictivo en la Educación

El uso del análisis predictivo crea una tensión entre el objetivo institucional de mejorar la retención y los principios éticos de privacidad, autonomía y equidad (Slade & Prinsloo, 2013).

- Privacidad y Consentimiento Informado: Los estudiantes a menudo no son conscientes del alcance de la recopilación de sus datos ni de cómo se utilizan (Willis et al., 2016).
- Sesgo Algorítmico: Los modelos entrenados con datos históricos pueden perpetuar e incluso amplificar los sesgos existentes contra grupos marginados (Ifenthaler, 2024).
- Estigmatización y Determinismo: Etiquetar a un estudiante como de "alto riesgo" puede convertirse en una profecía autocumplida (Slade & Prinsloo, 2013). Existe el riesgo de un "determinismo algorítmico" (Ifenthaler, 2024), que irónicamente refleja las críticas de determinismo dirigidas a la psicohistoria temprana (deMause, 1982). El desafío es usar estas herramientas para el empoderamiento, rompiendo ciclos en lugar de reforzarlos (Ifenthaler, 2024).

- Falta de Transparencia (El Problema de la "Caja Negra"): Cuando las instituciones utilizan modelos cuyas decisiones internas no pueden explicar, se socava la rendición de cuentas (Williamson & Kizilcec, 2023).
- De la "Sugerencia" al "Empujón" (Nudge): Las intervenciones basadas en análisis predictivos ("nudges") están diseñadas para guiar a los estudiantes (Willis et al., 2016), pero existe una delgada línea entre una sugerencia útil y una manipulación que socava la autonomía (Slade & Prinsloo, 2013).

El Determinismo de Sapolsky y la Responsabilidad del Estudiante

La perspectiva radicalmente determinista de Robert Sapolsky, articulada en su libro *Determined: A Science of Life Without Free Will*, añade una capa fundamental al debate ético (Horwitz, 2024). Sapolsky argumenta que el libre albedrío es una ilusión; cada decisión es el producto inevitable de una cadena de causas antecedentes sobre las cuales un individuo no tiene control (Horwitz, 2024). Esta postura de "determinismo duro" tiene profundas implicaciones para la educación:

- Cuestionamiento de la Meritocracia: Si el éxito o el fracaso es el resultado de una "suerte" biológica y ambiental acumulada, la noción misma de mérito se desmorona (Horwitz, 2024).
- De la Culpa a la Comprensión: Aceptar esta perspectiva, argumenta Sapolsky, debería conducir a una sociedad más humana (Horwitz, 2024). En lugar de culpar a los estudiantes por su "falta de voluntad", las instituciones deberían reconocer las desventajas que enfrentan. El abandono se transforma de un fracaso moral individual a un problema sistémico.
- Paralelismo con el Determinismo Algorítmico: La visión de Sapolsky refuerza los peligros del determinismo algorítmico. Si un modelo etiqueta a un estudiante como de "alto riesgo" basándose en proxies de la adversidad temprana (que tienen consecuencias biológicas deterministas, según Sapolsky), el algoritmo está, en efecto, castigando al estudiante por su "mala suerte" biológica (Síntesis de Horwitz, 2024, e Ifenthaler, 2024).

Aunque la postura de Sapolsky es controvertida (Horwitz, 2024), obliga a las instituciones a confrontar que las condiciones de partida de los estudiantes no son iguales y están arraigadas en su biología e historia.

El Auge de la IA Explicable (XAI) como Imperativo Ético

Para abordar el problema de la "caja negra", los métodos de Inteligencia Artificial Explicable (XAI) son esenciales (Bokolo, 2023). Herramientas como SHAP (SHapley Additive exPlanations) y LIME (Local Interpretable Model-agnostic Explanations) están diseñadas para proporcionar información sobre qué factores específicos están impulsando la predicción de un modelo para un estudiante en particular (Bokolo, 2023). Por ejemplo, un modelo XAI podría revelar que el "alto riesgo" se debe a una caída en las calificaciones de una asignatura específica (López-Zambrano et al., 2024). Esta transparencia permite intervenciones específicas y fomenta la confianza. El uso de XAI es un paso necesario para la implementación ética de la IA en la educación (Ifenthaler, 2024).

El Futuro de los Modelos Computacionales en la Política Educativa

El futuro de la analítica educativa reside en ir más allá de la simple predicción hacia un enfoque sistémico.

- Integración y Personalización: La IA se utilizará cada vez más para crear rutas de aprendizaje personalizadas y retroalimentación adaptativa (Farnós, 2025; University of Utah, 2024; Zhang et al., 2025).

- Política y Gobernanza: Esta integración requiere marcos de gobernanza robustos que gestionen los desafíos éticos, aseguren la equidad y mantengan una supervisión humana significativa (Williamson & Kizilcec, 2023).
- El Pensamiento Computacional como Competencia Fundamental: A medida que estos modelos se integran en la sociedad, se vuelve imperativo que el pensamiento computacional se enseñe como una competencia fundamental en todo el currículo educativo (Digital Promise, 2017; Royal Society, 2017), para equipar a todos los ciudadanos para comprender y criticar un mundo mediado por algoritmos (Källberg, 2024; Olsson et al., 2022).

CONCLUSIÓN: LA RELEVANCIA DURADERA DE LA PSICOHISTORIA EN LA ERA ALGORÍTMICA

Este informe concluye volviendo a su premisa central. Si bien la psichistoria predictiva de Asimov sigue siendo ciencia ficción (Krtolica, 2016), las preguntas planteadas por la psichistoria académica son más pertinentes que nunca (Plakun, 2023). En una era en la que podemos recopilar cantidades masivas de datos sobre el comportamiento estudiantil, la psichistoria sirve como un recordatorio crítico para mirar más allá de los puntos de datos y ver al ser humano en su totalidad: su historia personal, sus motivaciones inconscientes y su realidad emocional (Lawton, 2003).

El trabajo de Robert Sapolsky proporciona el andamiaje científico para este recordatorio, demostrando cómo la historia personal se inscribe en nuestra biología, moldeando el cerebro y predisponiendo comportamientos (Sapolsky, 2012).

El futuro más prometedor para la analítica educativa reside en una síntesis que combine la investigación cualitativa profunda inspirada en la psichistoria (el "porqué") (Szajnberg, 2004), la comprensión neurobiológica de los mecanismos subyacentes (el "cómo biológico") (Hertzman, 2012) y la exploración dinámica y sistémica de la simulación computacional (el "qué pasaría si") (Gisbert-Navarro et al., 2018).

- La psichistoria proporciona el marco para hacer preguntas profundas sobre la motivación (deMause, 1982).
- La neurobiología de Sapolsky explica cómo esas historias se convierten en propensiones biológicas (Hertzman, 2012; Sapolsky, 2012).
- La ciencia de datos (TDA, Inferencia Causal) proporciona las herramientas para investigar empíricamente estas preguntas a escala (Allmendinger et al., 2021; Donoso-García et al., 2022).
- Los Modelos Basados en Agentes proporcionan el entorno de simulación para pasar del análisis estático a la exploración dinámica (Segedy et al., 2025).

Este enfoque integrado representa un cambio de paradigma: de la predicción (¿qué sucederá?) al diseño (¿qué tipo de sistema queremos crear?). El objetivo final de estos modelos no debe ser la predicción y el control, sino la construcción de ecosistemas educativos más empáticos y solidarios que reconozcan la compleja vida interior y la historia biológica de cada estudiante (Revista Qualitas, 2021).

En la era algorítmica, el mayor valor de la psichistoria, reforzado por la neurociencia, es su insistencia en la humanidad.

DECLARACIÓN SOBRE EL USO DE INTELIGENCIA ARTIFICIAL

De conformidad con las directrices de RIED, se informa que se utilizaron herramientas de inteligencia artificial generativa (modelos de lenguaje grandes) como asistentes a lo largo del ciclo de vida de este artículo.

El uso de la IA se aplicó con los siguientes propósitos:

1. Conceptualización y Síntesis: Como herramienta de "sparring" intelectual para la exploración de conexiones interdisciplinarias entre la psicohistoria, la neurobiología y la ciencia de datos.
2. Análisis y Cumplimiento: Para realizar una revisión comparativa del manuscrito contra las normas de autores y la lista de comprobación de RIED.
3. Optimización y Formato: Para la reestructuración de los resúmenes (español e inglés) con el fin de alinearlos estrictamente con el formato IMRD exigido por la revista.
4. Traducción y Estilo: Como apoyo en la traducción del resumen al inglés y en la revisión general del estilo.

El autor ha dirigido, validado y editado activamente todas las contribuciones de la IA, asumiendo la plena responsabilidad por la autenticidad, precisión e integridad científica del contenido final del trabajo.

DECLARACIÓN DE CONFLICTO DE INTERESES

El autor declara no tener ningún conflicto de intereses financiero, profesional o personal que pudiera haber influido de forma inapropiada en la investigación o la redacción de este artículo.

CONTRIBUCIÓN DEL AUTOR

Hugo Roger Paz es el único autor de este trabajo y es responsable de todas las etapas del mismo, incluyendo: Conceptualización, Metodología, Investigación, Análisis, Redacción del borrador original, y Revisión y edición final.

DECLARACIÓN DE DISPONIBILIDAD DE LOS DATOS DE INVESTIGACIÓN

Este artículo es un ensayo de integración conceptual y no se basa en la generación o análisis de nuevos conjuntos de datos. Todos los materiales de origen utilizados para esta investigación consisten en literatura académica y científica públicamente disponible, la cual está completamente citada en la sección de Referencias.

REFERENCIAS / REFERENCES

- Allmendinger, K., Bux, K., & Zupanc, K. (2021). Using topological data analysis in social science research: Unpacking decisions and opportunities for a new method. *ASEE PEER*. <https://peer.asee.org/using-topological-data-analysis-in-social-science-research-unpacking-decisions-and-opportunities-for-a-new-method.pdf>
- Bokolo, A. J. (2023). A review of explainable artificial intelligence in supply chain management using neurosymbolic approaches. *International Journal of Production Research*, 62(12), 4347–4371. <https://doi.org/10.1080/00207543.2023.2281663>
- Carlsson, G. (2014). *Topological data analysis with applications*. Cambridge University Press.
- CORDIS. (2015, 28 de septiembre). Métodos topológicos para los análisis de dinámicas y datos. <https://cordis.europa.eu/article/id/190920-topological-methods-in-dynamics-and-data-analysis/es>
- deMause, L. (1982). *Foundations of psychohistory*. Creative Roots.
- Devi Partners. (2018, 6 de agosto). Behavior is complicated: Review of Behave by Robert M. Sapolsky. <https://devipartners.com/behavior-complicated-review-behave-robert-m-sapolsky/>
- Digital Promise. (2017). Computational thinking for a computational world. <https://digitalpromise.org/wp-content/uploads/2017/12/dp-comp-thinking-v1r5.pdf>
- Donoso-García, G., Sepúlveda-Sarrat, C., & Casanova-Durán, J. (2022). A causal inference study on the effects of first year workload on the dropout rate of undergraduates. *e-Repositori UPF*. <https://repositori.upf.edu/bitstreams/3bbaa8dc-2563-4480-a47c-325726409db3/download>

- Farnós, J. D. (2025, 24 de abril). MASTER: LA IA EN LA EDUCACIÓN SUPERIOR. Juandon. Innovación y conocimiento. <https://juandomingofarnos.wordpress.com/2025/04/24/master-la-ia-en-la-educacion-superior/>
- García-González, J., Nieto-Márquez, N., Reyes-Sosa, H., & Universidad-de-la-Iglesia, M. J. (2022). Causas asociadas a la deserción escolar en educación superior. Una revisión sistemática del 2010 al 2020. *Revista Ra Ximhai*, 18(1), 165–185. <https://doi.org/10.35191/ra.v18i1.138>
- García-Trevizo, E., Tlelo-Cuautle, E., & Tlahuice-Flores, A. (2018, octubre). Una introducción al análisis topológico de datos. Repositorio INFOTEC. <https://infotec.repositorioinstitucional.mx/jspui/bitstream/1027/199/1/Una%20introducci%C2%B4on%20al%20an%C2%B4alisis%20topol%C2%B4ogico%20de%20datos.pdf>
- Gisbert-Navarro, P., Miranda-Pérez, F., & Riera-Guasp, M. (2018). University student desertion analysis using agent based modelling and learning analytics. En *Proceedings of the 10th International Conference on Computer Supported Education (CSEDU 2018)* (pp. 194-201). SCITEPRESS. <https://www.scitepress.org/papers/2018/67776/67776.pdf>
- Gismera Lobera, J. (2024). Análisis topológico de datos [Trabajo de fin de grado, Universidad de Zaragoza]. Repositorio Institucional de Documentos. <https://zguan.unizar.es/record/149342>
- Hertzman, C. (2012). Putting the concept of biological embedding in historical perspective. *Proceedings of the National Academy of Sciences*, 109(Supplement 2), 17160–17167. <https://doi.org/10.1073/pnas.1121235109>
- Horwitz, A. (2024, 23 de mayo). A summary of 'Determined' by Robert Sapolsky — Does free will exist? The Psychiatry & Psychotherapy Podcast. <https://www.psychiatrypodcast.com/psychiatry-psychotherapy-podcast/a-summary-of-determined-by-robert-sapolsky-does-free-will-existalexander-horwitz-md>
- HSE University. (n.d.). Staff - Andrey Korotayev. <https://www.hse.ru/en/org/persons/72242054>
- Ifenthaler, D. (2024). Ethical imperatives and challenges: Review of the use of machine learning for predictive analytics in higher education. *Journal of Applied Research in Higher Education*, 16(3), 629–644. <https://doi.org/10.1108/JARHE-07-2023-0268>
- Källberg, L. (2024). Toward an ideal computational thinking education [Tesis doctoral, Umeå University]. DiVA portal. <https://diva-portal.org/smash/get/diva2:2005166/FULLTEXT01.pdf>
- Korotayev, A., Zinkina, J., & Bogevolnov, J. (2012). Literacy and development. *Cliodynamics*, 2(1), 74–106. <https://doi.org/10.21237/C72112344>
- Krtolica, P. (2016). Asimov's psychohistory: Vision of the future or present reality. *Sociološki pregled*, 50(2), 273–300. <https://doi.org/10.5937/socpreg50-8422>
- Lawton, H. W. (2003). The psychohistorian's handbook. *The Journal of Psychohistory*, 31(2), 119-133.
- López-Zambrano, J., Vélez-Jaramillo, J., & Lara-Paz, L. (2024). Factors, prediction, explainability, and simulating university dropout through machine learning: A systematic review, 2012–2024. *Applied Sciences*, 14(8), Artículo 3198. <https://doi.org/10.3390/app14083198>
- McGuinness, C., & Hyland, P. (2025). Revisiting credentialism – why qualifications matter: A theoretical exploration. *Journal of Education and Work*, 38(3), 239–253. <https://doi.org/10.1080/01425692.2025.2529814>
- Mukhopadhyay, S. (2016). Homotopy theory and topological data analysis. *Journal of Applied & Computational Mathematics*, 5(6). <https://doi.org/10.4172/2168-9679.1000343>
- Nguyen, T. (2024). Artificial intelligence and the sustainability of the signaling and human capital roles of higher education. *Sustainability*, 16(20), Artículo 8802. <https://doi.org/10.3390/su16208802>
- O'Connor, M. R. (2017). Behave: The Biology of Humans at our Best and Worst. Robert Sapolsky [Revisión del libro Behave: The Biology of Humans at our Best and Worst, por R. Sapolsky]. *Irish Journal of Psychological Medicine*, 34(2), 141–142. <https://doi.org/10.1017/ipm.2017.30>
- Olsson, O., Mozelius, P., & Häll, L. (2022). On the future of computational thinking education: Moving beyond the digital agenda, a discourse analysis perspective. *Education and Information Technologies*, 27, 7943–7962. <https://doi.org/10.1007/s10639-021-10825-y>
- Pérez-Sánchez, M. A., Torres-Barzallo, R., & Astudillo-Abarca, N. (2024). Predictive modeling of student dropout using academic data and machine learning techniques. *Recent Advances in Engineering Research and Development*, 7(1). https://www.researchgate.net/publication/396228538_Predictive_Modeling_of_Student_Dropout_Using_Academic_Data_and_Machine_Learning_Techniques

- Plakun, E. (2023). Psychohistory in history education: Between urgency and problems. *Review of Education, Pedagogy, and Cultural Studies*, 45(4), 365-385. <https://doi.org/10.1080/10714413.2023.2215284>
- Punset, E. (2011, 12 de mayo). Asimov y la invención de la psicohistoria. Xataka. <https://www.xataka.com/ciencia-ficcion/asimov-invencion-psicohistoria-1>
- Purdue University. (2021, 14 de septiembre). Using topological data analysis in social science research: Unpacking decisions and opportunities for a new method. <https://engineering.purdue.edu/STORIES/2021/09/14/using-topological-data-analysis-in-social-science-research-unpacking-decisions-and-opportunities-for-a-new-method/>
- Raghavan, P. (2018, 21 de septiembre). Book review: Behave - The Biology of Humans at Our Best and Worst by Robert Sapolsky. Dhiti. <https://www.brhat.in/dhiti/behave-book-review/>
- Revista Qualitas. (2021). Abandono escolar: una cuestión de perspectiva humana. *Qualitas Revista Científica*, 21, 1-4. <https://revistas.unibe.edu.ec/index.php/qualitas/article/view/167/267>
- Royal Society. (2017). Computing education: An overview of research in the field. <https://royalsociety.org/~media/policy/projects/computing-education/literature-review-overview-research-field.pdf>
- Saini, A. (2018, 23 de marzo). Review: Robert M. Sapolsky's "Behave". Words and dirt. <https://www.words-and-dirt.com/words/review-robert-m-sapolskys-behave/>
- Salmeron-Majadas, J. L., Salmeron, S., & Rodriguez-Puyol, J. (2023). Predictive analytics study to determine undergraduate students at risk of dropout. *Frontiers in Education*, 8. <https://doi.org/10.3389/educ.2023.1244686>
- Sapolsky, R. M. (2000a). Glucocorticoids and hippocampal atrophy in neuropsychiatric disorders. *Archives of General Psychiatry*, 57(10), 925-935. <https://doi.org/10.1001/archpsyc.57.10.925>
- Sapolsky, R. M. (2012). Brain on stress: How the social environment gets under the skin. *Proceedings of the National Academy of Sciences*, 109(Supplement 2), 17180-17185. <https://doi.org/10.1073/pnas.1121254109>
- Schreiner, L. A. (2025). Keeping STEM in the game: Resilience, setbacks, and the development of commitment. *Teaching in Higher Education*, 30(5), 1145-1162. <https://doi.org/10.1080/03075079.2025.2566160>
- Segedy, J. R., Kinnebrew, J. S., & Biswas, G. (2025). Retention in higher education: An agent-based model of social interactions and motivated agent behavior. *International Journal of Artificial Intelligence in Education*, 35, 111-146. <https://doi.org/10.1007/s40593-024-00438-x>
- Slade, S., & Prinsloo, P. (2013). Learning analytics: Ethical issues and dilemmas. *American Behavioral Scientist*, 57(10), 1510-1529. <https://doi.org/10.1177/0002764213479366>
- Strozier, C. B. (2024, 22 de agosto). The disavowal of psychohistory and the teaching of history. *Psyche on Campus*. <https://web.sas.upenn.edu/psycheoncampus/2024/08/22/the-disavowal-of-psychohistory-and-the-teaching-of-history/>
- Szajnberg, N. (2004). Psychohistory: The new science. *Modern Psychoanalysis*, 29(1), 123-125.
- Tejedor, G., Casadiego, A. M., Musso, M. F., & Paoloni, P. V. (2023). Ciencia de datos educativos y aprendizaje automático: Un caso de estudio sobre la deserción estudiantil universitaria en México. *Education in the Knowledge Society (EKS)*, 24, e30080. <https://doi.org/10.14201/eks.30080>
- Torres-Díaz, L. A., Carrión-Ojeda, K. M., & Acurio-Pino, A. C. (2022, 20 de noviembre). Revisión sistemática para determinar las causas de reprobación en el nivel superior. *Revista Transdigital*, 3(5). <https://doi.org/10.56162/transdigital42>
- Troisi, R. (2022, 12 de septiembre). Machine-assisted agent-based modeling: Opening the black box of social systems [Presentación de conferencia]. ResearchGate. https://www.researchgate.net/publication/363530356_Machine-assisted_agent-based_modeling_opening_the_black_box
- Turchin, P. (2003). *Historical dynamics: Why states rise and fall*. Princeton University Press.
- Turchin, P. (2008). Arise 'cliodynamics'. *Nature*, 454(7200), 34-35. <https://doi.org/10.1038/454034a>
- Turchin, P. (2011). *Cliodynamics: The Journal of Quantitative History and Cultural Evolution*. <http://e-archaeology.org/wp-content/uploads/2017/04/eScholarship-UC-item-9qx38718.pdf>
- Turchin, P., Gavrillets, S., & Whitehouse, H. (2015). The evolution of economic history since 1950: From cliometrics to cliodynamics. *Cliodynamics*, 6(2). <https://doi.org/10.21237/C7cli6228312>
- University of Utah. (2024). AI has entered the classroom. *College of Education Magazine*. https://education.utah.edu/_resources/documents/edu-magazine-fall-2024.pdf

- Williamson, B., & Kizilcec, S. (2023). Barriers and beliefs: A comparative case study of how university educators understand the datafication of higher education systems. *Teaching and Teacher Education*, 131, Artículo 104230. <https://doi.org/10.1016/j.tate.2023.104230>
- Willis, J. E., Slade, S., & Prinsloo, P. (2016). Student attitudes toward learning analytics in higher education: “The Fitbit version of the learning world”. En *Proceedings of the 6th International Conference on Learning Analytics & Knowledge (LAK '16)* (pp. 36-40). Association for Computing Machinery. <https://doi.org/10.1145/2883851.2883883>
- Zhang, X., Gao, C., & Wang, Y. (2025). Shaping the future of education: A cluster analysis of generative AI's transformative impact. *Interactive Technology and Smart Education*, 22(3), 405–422. <https://doi.org/10.1108/ITSE-01-2025-0013>

Este preprint fue presentado bajo las siguientes condiciones:

- Los autores declaran que se obtuvieron los términos necesarios del consentimiento libre e informado de los participantes o pacientes en la investigación y se describen en el manuscrito, cuando corresponde.
- Los autores declaran que la preparación del manuscrito siguió las normas éticas de comunicación científica.
- Los autores declaran que son conscientes de que son los únicos responsables del contenido del preprint y que el depósito en SciELO Preprints no significa ningún compromiso por parte de SciELO, excepto su preservación y difusión.
- Los autores declaran que los datos, las aplicaciones y otros contenidos subyacentes al manuscrito están referenciados.
- El manuscrito depositado está en formato PDF.
- Los autores declaran que la investigación que dio origen al manuscrito siguió buenas prácticas éticas y que las aprobaciones necesarias de los comités de ética de investigación, cuando corresponda, se describen en el manuscrito.
- Los autores declaran que una vez que un manuscrito es postado en el servidor SciELO Preprints, sólo puede ser retirado mediante solicitud a la Secretaría Editorial deSciELO Preprints, que publicará un aviso de retracción en su lugar.
- Los autores aceptan que el manuscrito aprobado esté disponible bajo licencia [Creative Commons CC-BY](#).
- El autor que presenta el manuscrito declara que las contribuciones de todos los autores y la declaración de conflicto de intereses se incluyen explícitamente y en secciones específicas del manuscrito.
- Los autores declaran que el manuscrito no fue depositado y/o previamente puesto a disposición en otro servidor de preprints o publicado en una revista.
- Si el manuscrito está siendo evaluado o siendo preparando para su publicación pero aún no ha sido publicado por una revista, los autores declaran que han recibido autorización de la revista para hacer este depósito.
- El autor que envía el manuscrito declara que todos los autores del mismo están de acuerdo con el envío a SciELO Preprints.