

EFECTOS OLVIDADOS DEL USO DE LA INTELIGENCIA ARTIFICIAL EN LA EDUCACIÓN SUPERIOR

Alfaro-Calderón, Gerardo G.¹ - Carrillo Gómez, Daniel² – Ramos Díaz, Ramón G.³
^{1,2,3} Facultad de Contaduría y Ciencias Administrativas, Universidad Michoacana de San Nicolás de Hidalgo

^{1,2,3} Ave. Francisco J. Múgica S/N, 58030, Morelia Michoacán. México.

¹ gerardo.alfaro@umich.mx ² daniel.carrillo@umich.mx ³ ramon.ramos@umich.mx

¹ <https://orcid.org/0000-0002-8719-9934> - ² <https://orcid.org/0000-0001-6930-2195> - ³<https://orcid.org/0009-0008-3621-9588>

Recibido 23 de abril de 2025; aceptado 28 de mayo de 2025

RESUMEN

Este estudio analiza los impactos indirectos del uso de inteligencia artificial (IA) en la educación universitaria, integrando la lógica difusa y la teoría de los efectos olvidados como herramientas para cuantificar trayectorias acumulativas no visibles en evaluaciones tradicionales. A partir de valoraciones expertas se construyeron matrices de incidencia directa, auto-incidencia y acumulación, aplicando un modelo convolutivo max-min. El análisis permitió identificar y cuantificar efectos olvidados, es decir, relaciones indirectas que no fueron reconocidas en la valoración inicial pero que emergen al considerar la estructura relacional del sistema. Los resultados revelan tres trayectorias destacadas donde variables como estrategias pedagógicas (a_3) y preparación docente (a_4) inciden significativamente en resultados como retención de conocimientos (b_7), satisfacción estudiantil (b_3) y desempeño académico (b_1). La presencia reiterada de políticas institucionales (a_6) como nodo articulador evidencia su rol estructural en la generación de efectos acumulativos. Este trabajo aplica el modelo de efectos olvidados al contexto universitario mediante una adaptación empírica basada en valoraciones difusas y representación gráfica. La propuesta ofrece elementos útiles para la interpretación de relaciones sistémicas en entornos educativos mediados por IA, y abre la posibilidad de desarrollar líneas de investigación que amplíen su validación empírica, comparen contextos institucionales diversos y articulen este enfoque con otros modelos analíticos en ciencias de la educación.

Palabras Clave: Inteligencia artificial, Educación superior, Lógica difusa, Efectos olvidados, Evaluación educativa.

Códigos JEL: I23, C65, O33

FORGOTTEN EFFECTS OF ARTIFICIAL INTELLIGENCE USE IN HIGHER EDUCATION

Alfaro Calderón, Gerardo G.¹ – Carrillo Gómez, Daniel² - Ramos Díaz, Ramón G.³
^{1,2,3} Facultad de Contaduría y Ciencias Administrativas, Universidad Michoacana de San Nicolás de Hidalgo

^{1,2,3} Ave. Francisco J. Múgica S/N, 58030, Morelia Michoacán. México.

¹gerardo.alfaro@umich.mx - ²daniel.carrillo@umich.mx - ³ramon.ramos@umich.mx

¹ <https://orcid.org/0000-0002-8719-9934> - ² <https://orcid.org/0000-0001-6930-2195> - ³<https://orcid.org/0009-0008-3621-9588>

Received April 23rd 2025; accepted Mai 28th 2025

ABSTRACT

This study analyzes the indirect impacts of artificial intelligence (AI) in higher education by integrating fuzzy logic and the theory of forgotten effects as tools to quantify cumulative trajectories that are not visible through traditional evaluations. Based on expert assessments, matrices of direct incidence, self-incidence, and accumulation were constructed using a max–min convolution model. The analysis enabled the identification and quantification of forgotten effects—indirect relationships not initially recognized by experts but emerging from the system’s relational structure. The results highlight three key trajectories in which variables such as pedagogical strategies (a_3) and faculty preparedness (a_4) significantly influence learning outcomes such as knowledge retention (b_7), student satisfaction (b_3), and academic performance (b_1). The repeated presence of institutional policies (a_6) as an articulating node reveals their structural role in generating cumulative effects. This study applies the forgotten effects model to a university context through an empirical adaptation grounded in fuzzy expert assessments and graphical representation. The proposed approach provides meaningful insights for interpreting systemic relationships in AI-mediated educational environments and opens new research directions for expanding empirical validation, comparing institutional settings, and articulating this model with other analytical approaches in educational science.

Keywords: Artificial Intelligence, Higher Education, Fuzzy Logic, Forgotten Effects, Educational Evaluation.

JEL Codes: I23, C65, O33

1. INTRODUCCIÓN

Este estudio examina el impacto acumulativo de la inteligencia artificial (IA) en la educación superior a través de un enfoque basado en lógica difusa, empleando la teoría de los efectos olvidados como herramienta para explorar interacciones complejas entre variables educativas. El objetivo central es identificar y cuantificar cómo ciertas dimensiones pedagógicas, tecnológicas y organizativas inciden de manera indirecta en los resultados académicos, revelando trayectorias de influencia que no siempre son evidentes en los enfoques tradicionales.

Para ello, se llevó a cabo una consulta experta con docentes universitarios con más de cinco años de experiencia, quienes evaluaron las relaciones entre factores institucionales y pedagógicos clasificados como incidentales e incididos. Estas valoraciones permitieron construir un modelo relacional sensible a estructuras de influencia no lineales, reflejando la complejidad de los entornos universitarios contemporáneos mediados por tecnología.

Los resultados muestran que variables como la formación docente, las estrategias pedagógicas innovadoras y las políticas institucionales presentan los niveles más altos de incidencia sobre dimensiones clave del aprendizaje, como el desempeño académico, la satisfacción estudiantil y la retención de conocimientos. Asimismo, se identificaron rutas de impacto indirecto que contribuyen a una comprensión más integral del efecto acumulativo de la IA en el aula.

La principal contribución del estudio radica en el diseño de un procedimiento participativo de evaluación por expertos, aplicado en dos momentos clave del semestre académico. Esta estrategia permitió no solo capturar percepciones iniciales sobre las incidencias entre factores educativos, sino también ofrecer a los participantes la oportunidad de revisar y ajustar sus valoraciones al final del proceso. Al utilizar criterios de agregación robustos, se construyó un modelo replicable que permite anticipar impactos latentes en contextos complejos de enseñanza universitaria mediados por tecnologías inteligentes.

2. FUNDAMENTACIÓN TEÓRICA Y ENFOQUE ANALÍTICO DEL ESTUDIO

Desde comienzos del siglo XXI, múltiples investigaciones han documentado cómo el despliegue de tecnologías digitales ha transformado las dinámicas de enseñanza universitaria, afectando tanto los métodos pedagógicos como la interacción entre docentes y estudiantes. En este contexto, la inteligencia artificial (IA) ha adquirido una presencia creciente, no solo como herramienta de apoyo, sino como componente estructurante de nuevas formas de enseñanza, evaluación y gestión del aprendizaje (Chu et al., 2022; Ifenthaler & Yau, 2020; Zawacki-Richter et al., 2019). Esta evolución ha suscitado tanto entusiasmo como cautela: por un lado, las herramientas basadas en

IA prometen personalizar los procesos formativos, optimizar recursos y ampliar el acceso al conocimiento (Ma et al., 2024; Zawacki-Richter et al., 2019); por otro, numerosos estudios advierten que su impacto no es homogéneo y que puede reproducir desigualdades, desdibujar el rol docente o invisibilizar dimensiones no cuantificables del aprendizaje (Holmes et al., 2019; Luckin & Holmes, 2016; Memarian & Doleck, 2023).

Ante esta complejidad, ha cobrado fuerza un enfoque ecosistémico que analiza las interacciones entre múltiples dimensiones (tecnológicas, pedagógicas, organizacionales) desde perspectivas sistémicas y no lineales. En este contexto, la lógica difusa se ha consolidado como una herramienta metodológica potente para representar la incertidumbre inherente a los entornos educativos y captar matices en la percepción de fenómenos complejos (Guruprasad et al., 2016; Hegazi et al., 2023). Esta aproximación ha permitido, por ejemplo, modelar escenarios de decisión, evaluar el desempeño académico en entornos inciertos y analizar sistemas educativos caracterizados por relaciones vagas y multicausales (Jan et al., 2023; Li et al., 2024).

En los últimos años, diversos autores han propuesto combinar la lógica difusa con modelos que capturen influencias acumulativas e indirectas. Entre ellos, destaca la teoría de los efectos olvidados, formulada por Kaufmann y Gil Aluja (1988), que permite cuantificar trayectorias latentes de incidencia entre variables que no son perceptibles en una evaluación directa. Esta metodología ha sido aplicada recientemente en estudios sobre política pública, evaluación institucional y procesos de desarrollo económico territorial, mostrando su capacidad para detectar patrones ocultos de influencia que los enfoques tradicionales no registran (Alfaro-Calderón et al., 2019; Pérez-Romero et al., 2024).

Este estudio se inscribe en esta línea de investigación al aplicar una perspectiva sistémica que permite identificar no solo relaciones directas, sino también trayectorias de incidencia acumulativas y no evidentes entre dimensiones pedagógicas, organizativas y estructurales. Se parte del supuesto de que los efectos de la inteligencia artificial en educación no siempre se manifiestan de forma inmediata ni observable, sino que operan a través de vínculos latentes que condicionan los resultados de aprendizaje. Para abordar esta complejidad, se recurre a la teoría de los efectos olvidados, una propuesta metodológica basada en la lógica difusa que permite cuantificar influencias indirectas mediante un análisis relacional del sistema. Esta aproximación ha demostrado ser útil en investigaciones recientes sobre educación superior y políticas públicas, al ofrecer una visión más integrada y dinámica de los procesos que configuran el impacto real de la IA en entornos universitarios.

La estructura del artículo es la siguiente: la sección 2 describe el diseño metodológico, incluyendo la recolección de datos, la construcción de la matriz R y la aplicación del

modelo de efectos olvidados. La sección 3 presenta los principales hallazgos empíricos, distinguiendo entre efectos directos, olvidados e intermedios. La sección 4 discute las implicaciones teóricas y prácticas de los resultados, mientras que la sección 5 ofrece las conclusiones finales y líneas de investigación futura.

3. METODOLOGÍA

Este estudio adopta un enfoque exploratorio-cuantitativo basado en la lógica difusa y la teoría de los efectos olvidados para analizar las trayectorias indirectas de incidencia entre factores pedagógicos, organizativos y estructurales vinculados al uso de inteligencia artificial (IA) en la educación superior. La investigación se llevó a cabo durante un semestre académico en una universidad en México, con la participación de un grupo deliberado de 10 profesores universitarios. Estos expertos fueron seleccionados con base en su experiencia docente (mínimo cinco años de antigüedad) y su familiaridad con herramientas digitales aplicadas a la enseñanza-aprendizaje.

La recolección de datos se desarrolló en dos momentos clave. En la primera fase, al inicio del semestre, se realizaron entrevistas individuales en las que se solicitó a los participantes valorar, mediante una escala endecadaria difusa de tipo [0,1], el grado de incidencia entre un conjunto de variables causales (incidentales) y otro de variables evaluativas (incidadas). Estas valoraciones también incluyeron la autoevaluación interna de cada conjunto (auto-incidencia causal y evaluativa). La escala utilizada responde a la propuesta metodológica de Kaufmann y Gil Aluja (1988), ampliamente reconocida por su capacidad para capturar percepciones expertas en contextos de alta complejidad e incertidumbre.

En la segunda fase, al término del semestre, se retornó a los participantes los resultados obtenidos a partir de sus respuestas iniciales, específicamente las matrices construidas de incidencia directa y autoevaluación. En este punto, se les brindó la oportunidad de validar, mantener o ajustar sus valoraciones, asegurando así la consistencia interna del modelo. El procedimiento completo permitió no solo captar relaciones entre variables, sino también observar cómo estas relaciones eran confirmadas o modificadas tras un ciclo de reflexión informada.

A partir de esta fase empírica, se procedió a estructurar el modelo teórico de análisis conforme a los principios de la teoría de los efectos olvidados. Este modelo permite identificar relaciones indirectas, encadenadas o acumulativas que no son evidentes en un análisis exclusivamente directo. La construcción del modelo se organizó en diversas fases metodológicas, siguiendo la propuesta original de Kaufmann y Gil Aluja (1988), y su aplicación en sistemas complejos contemporáneos documentada por Alfaro-Calderón et al. (2019).

3.1 Construcción del modelo de efectos olvidados

1. Formación del conjunto de elementos incidentales (A):

En esta fase se seleccionan los elementos que ejercen influencia sobre otros. Estos se denotan como A y se definen como:

$$A = \{a_1, a_2, \dots, a_i\}. \quad (1)$$

2. Formación del conjunto de elementos afectados (B):

Se identifican los elementos que recibirán la influencia de los elementos en A. Se definen como:

$$B = \{b_1, b_2, \dots, b_j\}. \quad (2)$$

3. Construcción de la matriz de incidencias directas \tilde{M} :

A partir de las valoraciones expertas $\vartheta(a_i, b_j)$, se forma la matriz de relaciones causales directas entre A y B.

$$\tilde{M} = [\vartheta(a_i, b_j)]. \quad (3)$$

4. Construcción de la matriz de auto-incidencia del conjunto A (\tilde{A}):

Se recopilan las valoraciones $\vartheta(a_i, a_h)$, que representan la influencia interna entre los elementos del conjunto A. Esto da lugar a una matriz cuadrada:

$$\tilde{A} = [\vartheta(a_i, a_h)] \text{ para } i, h = 1, \dots, n. \quad (4)$$

5. Construcción de la matriz de auto-incidencias del conjunto B (\tilde{B}):

De modo análogo, se construyen las valoraciones $\vartheta(b_j, b_k)$, que reflejan las relaciones internas entre los efectos evaluativos. Estas forman una matriz cuadrada difusa:

$$\tilde{B} = [\vartheta(b_j, b_k)] \text{ para } j, k = 1, \dots, m. \quad (5)$$

6. Obtención de la matriz semi-convolucionada $\tilde{R}' = \tilde{A} \circ \tilde{M}$:

Se aplica el operador max-min para detectar relaciones indirectas entre A y B a través de un eslabón causal intermedio a_h . La operación se expresa como:

$$\vartheta'(a_i, b_j) = \max_h \min(\vartheta(a_i, a_h), \vartheta(a_h, b_j)). \quad (6)$$

7. Construcción de la matriz total de incidencias $\tilde{R}^2 = \tilde{A} \circ \tilde{M} \circ \tilde{B}$:

Esta segunda convolución permite captar trayectorias acumulativas o en cadena, extendiendo la relación indirecta al espacio evaluativo. Se representa como:

$$\vartheta''(a_i, b_j) = \max_k \min(\vartheta'(a_i, b_k), \vartheta(b_k, b_j)). \quad (7)$$

8. Cálculo de los efectos olvidados:

La matriz de efectos olvidados surge de la diferencia entre las incidencias acumuladas y las directas:

$$\tilde{D} = \tilde{R}^2 - \tilde{M}. \quad (8)$$

Este resultado permite identificar impactos latentes que no fueron percibidos por los expertos en la evaluación directa, pero que se hacen visibles al considerar la dinámica estructural del sistema.

9. Visualización gráfica:

Los resultados son representados gráficamente mediante grafos de incidencia, que permiten detectar relaciones de segundo orden y determinar los efectos olvidados que deben fortalecerse para optimizar el uso de la IA en educación superior.

Una vez definido y estructurado el modelo lógico de análisis, el siguiente paso consistió en su aplicación al estudio de caso concreto. Para ello, fue necesario traducir los conjuntos abstractos A y B en variables empíricas observables, definidas mediante consenso experto. Esta operacionalización permitió capturar de forma contextualizada las trayectorias de incidencia entre condiciones institucionales vinculadas al uso de IA y sus impactos educativos percibidos. A continuación, se describen los elementos que integran cada conjunto, los cuales estructuran las matrices de valoración utilizadas en este trabajo.

3.2 Definición operativa de las variables causales (A) y evaluativas (B).

El conjunto A comprende variables asociadas a condiciones estructurales, tecnológicas y pedagógicas que facilitan o condicionan el uso de IA en entornos universitarios; el conjunto B agrupa variables relacionadas con los efectos percibidos en el proceso educativo. La siguiente tabla presenta ambos conjuntos:

Tabla 1. Variables causales (A) y evaluativas (B) utilizadas en el modelo.

| Código | Variable causal (A) | Código | Variable evaluativa (B) |
|----------------|--|----------------|--|
| a ₁ | Acceso a tecnología y recursos digitales | b ₁ | Desempeño académico |
| a ₂ | Competencias digitales del estudiantado | b ₂ | Autonomía en el aprendizaje |
| a ₃ | Estrategias pedagógicas innovadoras | b ₃ | Satisfacción estudiantil |
| a ₄ | Preparación docente | b ₄ | Desigualdad en el acceso y calidad del aprendizaje |
| a ₅ | Infraestructura tecnológica | b ₅ | Mejora en habilidades para resolución de problemas |
| a ₆ | Políticas educativas institucionales | b ₆ | Colaboración e interacción |
| | | b ₇ | Retención de conocimientos a largo plazo |
| | | b ₈ | Desarrollo de competencias transversales |

Fuente: Elaboración propia.

Con base en estos conjuntos de variables, se construyeron las matrices \tilde{M} , \tilde{A} y \tilde{B} , conforme al procedimiento descrito. A partir de ellas, se aplicaron las operaciones de composición max–min necesarias para obtener las matrices \tilde{R}' (semi-convolucionada), \tilde{R}^2 (incidencias acumuladas) y \tilde{D} (efectos olvidados). Estas matrices constituyen la base del análisis presentado en el siguiente apartado, revelando trayectorias no evidentes en el análisis convencional del impacto de la IA en educación superior.

4. RESULTADOS

En este apartado se presentan los resultados obtenidos mediante la aplicación del modelo de efectos olvidados al sistema educativo universitario analizado. La exposición se estructura en tres momentos complementarios: primero, se describen las incidencias directas percibidas entre los factores causales y los efectos evaluativos; en segundo lugar, se identifican los efectos olvidados resultantes de las trayectorias indirectas del sistema; finalmente, se exponen las trayectorias acumulativas que integran los vínculos estructurales más significativos. Cada uno de estos niveles se ilustra mediante las matrices correspondientes y se analizan los patrones de incidencia a partir de umbrales previamente establecidos.

4.1 Incidencias directas: \tilde{M} .

La matriz \tilde{M} representa la intensidad de las incidencias directas entre cada variable causal del conjunto A y cada variable evaluativa del conjunto B, expresadas en una escala difusa [0,1], donde 0 indica ausencia total de incidencia y 1 corresponde a incidencia máxima. Esta matriz refleja las relaciones percibidas como más evidentes dentro del sistema educativo analizado, y constituye el punto de partida para la identificación de efectos indirectos y acumulativos. Este tipo de representación ha sido desarrollado en el marco de los sistemas de lógica difusa propuestos por Kaufmann y Gil Aluja (1988), particularmente útil para modelar relaciones complejas con alto grado de incertidumbre.

La Tabla 2 muestra los valores de \tilde{M} , organizados con las variables causales como filas y las evaluativas como columnas. Esta matriz ofrece un panorama inicial de las incidencias percibidas como directas dentro del sistema, y permite identificar patrones relevantes de asociación entre condiciones estructurales y resultados educativos observados por los expertos participantes.

Tabla 2. Matriz de incidencias directas \tilde{M} .

| $[\tilde{M}]$ | b_1 | b_2 | b_3 | b_4 | b_5 | b_6 | b_7 | b_8 |
|---------------|-------|-------|-------|-------|-------|-------|-------|-------|
| a_1 | 0.5 | 0.6 | 0.3 | 0.7 | 0.5 | 0.9 | 0.9 | 0.8 |
| a_2 | 0.5 | 0.9 | 0.6 | 0.8 | 0.5 | 1 | 0.8 | 0.9 |
| a_3 | 0.4 | 0.7 | 0.1 | 0.5 | 0.6 | 0.7 | 0.1 | 0.7 |
| a_4 | 0.2 | 0.4 | 0.5 | 0.5 | 0.5 | 0.7 | 0.8 | 0.8 |
| a_5 | 0.5 | 0.4 | 0.3 | 0.4 | 0.8 | 0.9 | 0.7 | 0.6 |
| a_6 | 0.3 | 0.5 | 0.3 | 0.5 | 0.6 | 0.5 | 0.9 | 0.8 |

Fuente: Elaboración propia.

El análisis de la matriz revela que algunas variables causales muestran asociaciones frecuentes con múltiples dimensiones evaluativas. Por ejemplo, a_2 (competencias digitales del estudiantado) presenta varios valores en los rangos superiores de la escala, particularmente en relación con b_1 (desempeño académico), b_7 (retención de conocimientos) y b_6 (colaboración e interacción). Este patrón también se observa en a_1 (acceso a tecnología) y a_5 (infraestructura tecnológica), cuyas valoraciones se concentran en los mismos dominios. Estas asociaciones, identificadas por la recurrencia de valores cercanos a 1 en la matriz \tilde{M} , sugieren una percepción reiterada entre los expertos sobre la conexión directa entre las condiciones tecnológicas institucionales y los resultados observables del aprendizaje.

Esta matriz debe entenderse como un insumo exploratorio inicial que recoge las percepciones directas de incidencia entre variables, según lo valorado por los expertos. Si bien permite identificar relaciones que fueron reconocidas explícitamente, no contempla los efectos indirectos, encadenados o acumulativos que podrían emerger de la estructura sistémica en su conjunto. Para abordar esta dimensión latente del sistema, en los apartados siguientes se aplicará el modelo de efectos olvidados mediante la composición de matrices, lo cual permitirá mapear trayectorias no evidentes en la valoración directa, pero relevantes para comprender el impacto estructural de la inteligencia artificial en la educación superior.

4.2 Auto-incidencias internas: matrices \tilde{A} y \tilde{B} .

Como parte del modelo estructural empleado en este estudio, fue necesario incorporar las matrices de auto-incidencia difusa de los conjuntos causal y evaluativo, denominadas \tilde{A} y \tilde{B} , respectivamente. Estas matrices recogen las valoraciones otorgadas por los expertos sobre la influencia interna de cada variable dentro de su propio conjunto. Su finalidad no es representar relaciones observables entre condiciones y resultados, sino capturar la lógica estructural con la que se configuran los factores causales (A) y evaluativos (B) como sistemas interrelacionados. Como señalan Kaufmann y Gil Aluja (1988), la construcción de matrices de auto-incidencia permite

representar la configuración funcional de un conjunto, más allá de las relaciones cruzadas entre variables.

Estas matrices fueron construidas a partir de las valoraciones consolidadas mediante el criterio de moda por celda, lo que permitió asegurar una representación estable y coherente de las relaciones internas entre las variables de cada conjunto. A continuación, se presentan los resultados organizados por conjunto: primero, la matriz de auto-incidencia del conjunto causal \tilde{A} ; posteriormente, la correspondiente al conjunto evaluativo \tilde{B} .

Tabla 3. Matriz de auto-incidencia difusa del conjunto A (\tilde{A}).

| $[\tilde{A}]$ | a₁ | a₂ | a₃ | a₄ | a₅ | a₆ |
|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| a₁ | 1 | 0.9 | 0.8 | 0.5 | 0.5 | 0.5 |
| a₂ | 0.8 | 1 | 0.9 | 0.7 | 0.6 | 0.8 |
| a₃ | 0.5 | 0.7 | 1 | 0.7 | 0.6 | 0.8 |
| a₄ | 0.8 | 0.6 | 0.6 | 1 | 0.7 | 0.9 |
| a₅ | 0.5 | 0.6 | 0.6 | 0.7 | 1 | 0.6 |
| a₆ | 0.5 | 0.5 | 0.7 | 0.7 | 0.6 | 1 |

Fuente: Elaboración propia.

Tabla 4 complementa esta estructura, mostrando las relaciones internas percibidas entre las variables evaluativas del conjunto B.

Tabla 4. Matriz de auto-incidencia difusa del conjunto B (\tilde{B}).

| $[\tilde{B}]$ | b₁ | b₂ | b₃ | b₄ | b₅ | b₆ | b₇ | b₈ |
|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| b₁ | 1 | 0.8 | 0.7 | 0.6 | 0.8 | 0.8 | 0.9 | 0.8 |
| b₂ | 0.7 | 1 | 0.6 | 0.8 | 0.8 | 0.6 | 0.7 | 0.8 |
| b₃ | 0.6 | 0.7 | 1 | 0.8 | 0.7 | 0.7 | 0.8 | 0.8 |
| b₄ | 0.7 | 0.7 | 0.6 | 1 | 0.6 | 0.7 | 0.4 | 0.3 |
| b₅ | 0.6 | 0.6 | 0.8 | 0.8 | 1 | 0.9 | 0.5 | 0.9 |
| b₆ | 0.7 | 0.6 | 0.8 | 0.7 | 0.8 | 1 | 0.6 | 0.8 |
| b₇ | 0.9 | 0.8 | 0.7 | 0.8 | 0.8 | 0.9 | 1 | 0.8 |
| b₈ | 0.6 | 0.5 | 0.9 | 0.8 | 0.9 | 0.8 | 0.7 | 1 |

Fuente: Elaboración propia.

La presentación de estas matrices completa el conjunto de insumos derivados del proceso de valoración experta. En el siguiente apartado se integrarán estas matrices con la matriz de incidencias directas \tilde{M} , con el fin de generar la matriz de incidencias acumuladas del sistema mediante el modelo convolutivo.

4.3 Auto-incidencias internas: matrices \tilde{A} y \tilde{B} .

La matriz \tilde{R}^2 representa las incidencias acumuladas obtenidas a partir de la composición convolutiva entre las matrices \tilde{A} , \tilde{M} y \tilde{B} . Este resultado refleja trayectorias indirectas o encadenadas que no fueron percibidas de forma explícita en la valoración directa, pero que emergen al considerar las interacciones internas de cada conjunto.

La siguiente tabla presenta los valores de \tilde{R}^2 , los cuales servirán de base para identificar los efectos olvidados mediante su comparación con la matriz \tilde{M} en el siguiente apartado.

Tabla 5. Matriz de incidencias acumuladas $\tilde{R}^2 = \tilde{A} \circ \tilde{M} \circ \tilde{B}$.

| \tilde{R}^2 | b_1 | b_2 | b_3 | b_4 | b_5 | b_6 | b_7 | b_8 |
|---------------|-------|-------|-------|-------|-------|-------|-------|-------|
| a_1 | 0.9 | 0.9 | 0.9 | 0.8 | 0.9 | 0.9 | 0.9 | 0.9 |
| a_2 | 0.8 | 0.9 | 0.9 | 0.8 | 0.9 | 1 | 0.8 | 0.9 |
| a_3 | 0.8 | 0.8 | 0.8 | 0.8 | 0.8 | 0.8 | 0.8 | 0.8 |
| a_4 | 0.9 | 0.8 | 0.8 | 0.8 | 0.8 | 0.9 | 0.9 | 0.8 |
| a_5 | 0.7 | 0.7 | 0.8 | 0.8 | 0.8 | 0.9 | 0.7 | 0.8 |
| a_6 | 0.9 | 0.8 | 0.8 | 0.8 | 0.8 | 0.9 | 0.9 | 0.8 |

Fuente: Elaboración propia.

La matriz \tilde{R}^2 permite observar cómo ciertas trayectorias de incidencia emergen al integrar las relaciones internas de cada conjunto con las valoraciones directas. Este resultado sirve como base para el cálculo de los efectos olvidados, que se obtienen al contrastar \tilde{R}^2 con la matriz \tilde{M} , como se detalla en el siguiente apartado.

4.4 Efectos olvidados: matriz \tilde{D} .

La matriz de efectos olvidados \tilde{D} se obtuvo a partir de la diferencia entre las incidencias acumuladas \tilde{R}^2 y las incidencias directas \tilde{M} . Este resultado permite identificar trayectorias que no fueron percibidas como relevantes por los expertos en la valoración inicial, pero que emergen al considerar la estructura relacional del sistema.

La siguiente tabla presenta los valores de \tilde{D} , donde se observan relaciones latentes entre variables causales y evaluativas. Para efectos analíticos, se consideran relevantes aquellas trayectorias con valores iguales o superiores a 0.7, siguiendo el criterio empleado tanto por Alfaro-Calderón et al. (2019) como por Pérez-Romero et al. (2024) en estudios previos basados en esta metodología.

Tabla 6. Matriz de efectos olvidados: matriz \tilde{D} .

| $\left[\tilde{R}^2 \right]$ | b₁ | b₂ | b₃ | b₄ | b₅ | b₆ | b₇ | b₈ |
|------------------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| a₁ | 0.4 | 0.3 | 0.6 | 0.1 | 0.4 | 0 | 0 | 0.1 |
| a₂ | 0.3 | 0 | 0.3 | 0 | 0.4 | 0 | 0 | 0 |
| a₃ | 0.4 | 0.1 | 0.7 | 0.3 | 0.2 | 0.1 | 0.7 | 0.1 |
| a₄ | 0.7 | 0.4 | 0.3 | 0.3 | 0.3 | 0.2 | 0.1 | 0 |
| a₅ | 0.2 | 0.3 | 0.5 | 0.4 | 0 | 0 | 0 | 0.2 |
| a₆ | 0.6 | 0.3 | 0.5 | 0.3 | 0.2 | 0.4 | 0 | 0 |

Fuente: Elaboración propia.

La matriz anterior muestra que tres trayectorias indirectas presentan efectos olvidados significativos en el sistema educativo analizado. Destacan especialmente las relaciones entre a_3 (estrategias pedagógicas innovadoras) y b_3 (satisfacción estudiantil), entre a_4 (preparación docente) y b_1 (desempeño académico), así como entre a_3 y b_7 (retención de conocimientos). En estos casos, la incidencia acumulada fue considerablemente mayor que la incidencia percibida de forma directa, revelando vínculos latentes que podrían estar incidiendo de forma relevante en los resultados educativos.

Para profundizar en su interpretación, la siguiente tabla resume las relaciones específicas en las que la diferencia entre la incidencia directa y la incidencia acumulada fue igual o superior a 0.7, destacando así vínculos que fueron subestimados en la valoración experta inicial, pero que emergen con fuerza al considerar las interacciones internas del sistema.

Tabla 7. Principales efectos olvidados identificados en el sistema educativo universitario.

| Causa | Efecto | Valor inicial | Valor acumulado | Efecto Olvidado |
|-------|--------|------------------------------------|------------------------------------|-----------------|
| a_3 | b_3 | $\mu_i(a_3 \rightarrow b_3) = 0.1$ | $\mu_a(a_3 \rightarrow b_3) = 0.8$ | 0.7 |
| a_4 | b_1 | $\mu_i(a_4 \rightarrow b_1) = 0.2$ | $\mu_a(a_4 \rightarrow b_1) = 0.9$ | 0.7 |
| a_3 | b_7 | $\mu_i(a_3 \rightarrow b_7) = 0.1$ | $\mu_a(a_3 \rightarrow b_7) = 0.8$ | 0.7 |

Fuente: Elaboración propia.

Estas relaciones sugieren la existencia de trayectorias influyentes que no fueron reconocidas en la valoración directa, pero que emergen claramente al incorporar la estructura interna del sistema. Su exploración visual y contextual se desarrollará en el apartado siguiente mediante grafos relacionales.

4.5 Visualización estructural de efectos olvidados

El análisis de la matriz \tilde{D} permitió identificar trayectorias con efectos olvidados relevantes, entendidas como relaciones indirectas que no fueron reconocidas por los expertos en su valoración inicial, pero que emergen con fuerza al considerar la estructura del sistema. A continuación, se presentan tres trayectorias destacadas que

ejemplifican la magnitud de estos efectos y su articulación mediante caminos acumulativos.

Figura 1 ilustra la trayectoria olvidada entre las estrategias pedagógicas innovadoras (a_3) y la satisfacción estudiantil (b_3). La relación directa entre estas variables fue valorada en 0.3, sin embargo, la trayectoria acumulada revela un efecto total de 0.8. Este incremento se explica por la incidencia indirecta que opera a través de las políticas institucionales (a_6) y el desarrollo de competencias transversales (b_8), lo que indica que la satisfacción estudiantil no se genera exclusivamente a partir de acciones pedagógicas directas, sino que emerge de su integración con estructuras organizativas y procesos de desarrollo competencial más amplios.

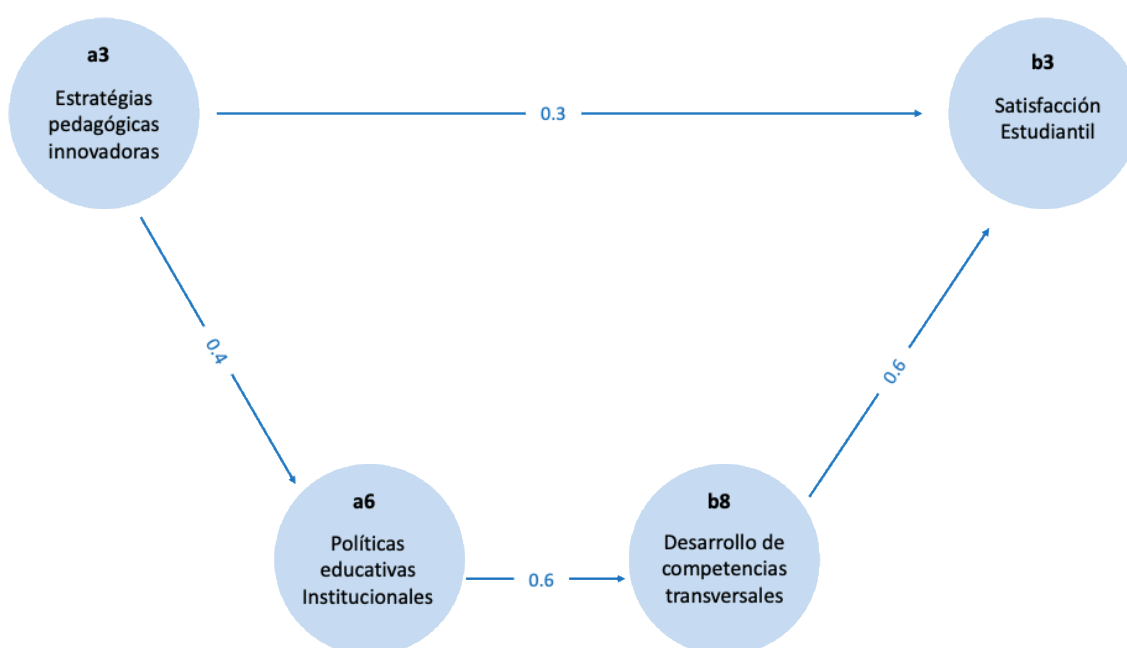


Figura 1. Trayectoria olvidada entre estrategias pedagógicas (a_3) y satisfacción estudiantil (b_3) mediada por a_6 y b_8 .

Fuente: elaboración propia con base en los resultados del modelo de efectos olvidados.

Figura 2 muestra una segunda trayectoria significativa que parte también desde a_3 , pero en este caso con destino en la retención de conocimientos (b_7). Aunque la incidencia directa fue de apenas 0.1, la trayectoria acumulada alcanzó un valor de 0.8. Este vínculo se fortalece mediante la interacción con políticas institucionales (a_6) y el refuerzo interno del propio conjunto evaluativo (b_7), cuya auto-incidencia potencia el impacto global. El resultado evidencia cómo la implementación pedagógica requiere estructuras institucionales sólidas para generar aprendizajes duraderos.

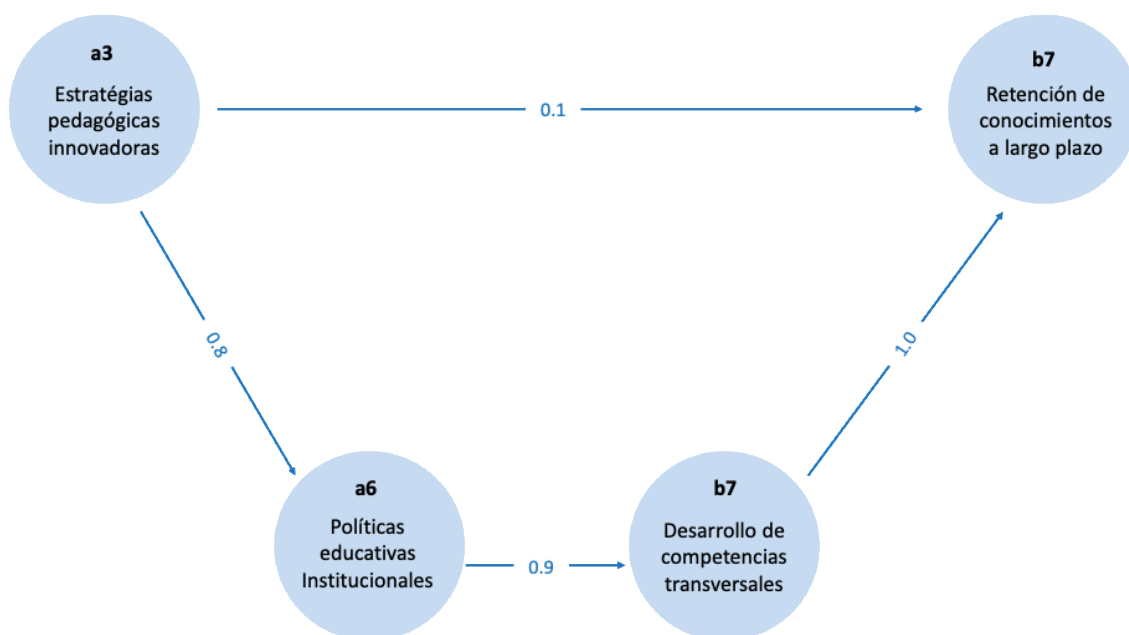


Figura 2. Trayectoria olvidada entre estrategias pedagógicas (a_3) y retención de conocimientos (b_7), mediada por a_6 y auto-incidencia en b_7 .

Fuente: elaboración propia con base en los resultados del modelo de efectos olvidados.

Finalmente, la Figura 3 representa una trayectoria acumulativa originada en la preparación docente (a_4) y culmina en el desempeño académico (b_1). La incidencia directa entre estas variables fue valorada en 0.2, pero el modelo reveló un efecto olvidado de magnitud 0.7. Esta trayectoria se estructura a través de distintos nodos intermedios del conjunto causal: acceso a tecnología (a_1), estrategias pedagógicas (a_3), políticas institucionales (a_6) y retención de conocimientos (b_7). Se identifican tres subrutas que articulan este camino, cada una con implicaciones diferenciadas, como se detalla en la figura. Esta constituye la trayectoria más ramificada del modelo, y pone de manifiesto la estructura multicapa a través de la cual los factores organizativos condicionan el desempeño académico.

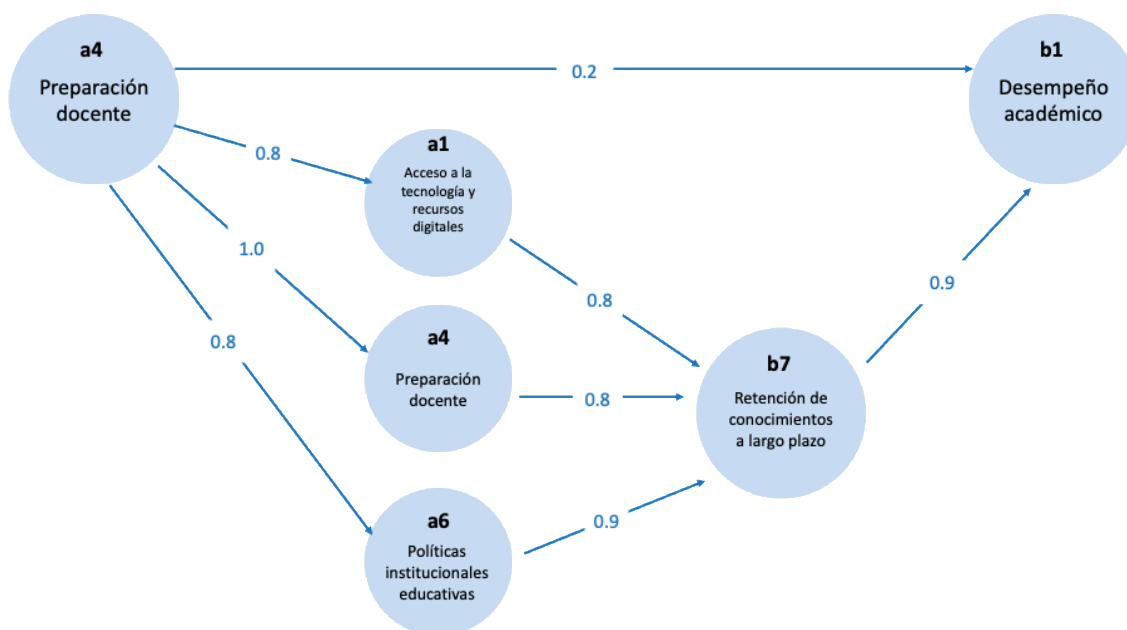


Figura 3. Trayectoria olvidada entre preparación docente (a_4) y desempeño académico (b_1), mediada por a_1 , a_3 , a_6 y b_7 .

Fuente: elaboración propia con base en los resultados del modelo de efectos olvidados.

Estas trayectorias ilustran la complejidad del sistema educativo universitario analizado, en el cual la interacción entre variables estructurales, organizativas y pedagógicas genera efectos no triviales que resultan invisibles en evaluaciones directas. El modelo de efectos olvidados permite así revelar vínculos latentes cuya comprensión es clave para la toma de decisiones estratégicas en el diseño y evaluación de políticas de integración de la inteligencia artificial en la educación superior.

La presencia recurrente de a_6 (políticas institucionales) en las trayectorias olvidadas no solo revela su centralidad en la arquitectura del sistema, sino que sugiere que puede operar como un punto de apalancamiento estratégico. Aunque no genera efectos evaluativos por sí solo, su capacidad de articular otras dimensiones, como estrategias pedagógicas (a_3), infraestructura (a_1) y competencias transversales (b_8), lo posiciona como un elemento clave para diseñar intervenciones más integradas. Desde esta perspectiva, fortalecer las políticas institucionales vinculadas al uso de inteligencia artificial podría amplificar los efectos positivos en dimensiones como la satisfacción estudiantil (b_3) y el desempeño académico (b_1), siempre que dichas políticas estén coordinadas con el resto de los componentes estructurales del sistema.

5. DISCUSIÓN

Los resultados obtenidos mediante el modelo difuso de efectos olvidados permiten una interpretación más profunda del impacto de la inteligencia artificial en contextos educativos universitarios. La identificación de trayectorias acumulativas, no

reconocidas por los expertos en su valoración directa pero reveladas a través de la matriz \tilde{D} , muestra que ciertas variables, como las estrategias pedagógicas innovadoras (a_3) y la preparación docente (a_4), influyen de forma significativa sobre resultados como la satisfacción estudiantil (b_3), la retención de conocimientos (b_7) y el desempeño académico (b_1). Estas influencias no lineales solo pueden ser detectadas mediante el proceso de convolución max-min aplicado a las matrices \tilde{A} , \tilde{M} y \tilde{B} , lo que confirma la pertinencia de emplear herramientas analíticas capaces de captar la complejidad estructural del sistema educativo (Kaufmann A. & Gil Aluja J., 1988; Papageorgiou & Salmeron, 2013).

Estos hallazgos son consistentes con investigaciones recientes que reconocen que los efectos de la IA en la educación superior no se manifiestan de forma inmediata ni aislada. Estudios como los de Chu et al. (2022), Zawacki-Richter et al. (2019) y Holmes et al. (2019) han señalado que el impacto real de estas tecnologías depende tanto del diseño pedagógico como del contexto organizativo en el que se insertan. El hallazgo de trayectorias en las que dimensiones como las políticas institucionales (a_6) operan como nodos de articulación entre componentes causales y evaluativos refuerza la idea de que la efectividad de la IA no radica solo en su adopción técnica, sino en su integración sistémica.

Por el contrario, una parte considerable de la literatura sobre inteligencia artificial en entornos educativos continúa apoyándose en modelos analíticos predominantemente lineales o de tipo correlacional, que privilegian asociaciones directas entre variables independientes y resultados de aprendizaje. Si bien estos enfoques han demostrado utilidad en tareas de predicción o clasificación, presentan limitaciones importantes para capturar estructuras causales complejas o trayectorias acumulativas. Por ejemplo, Lykourantzou et al. (2009) aplican técnicas de aprendizaje automático para predecir la deserción en cursos virtuales sin considerar interacciones sistémicas entre variables; de forma similar, Mason et al. (2018) utilizan regresión logística y redes neuronales para identificar factores de riesgo en ingeniería, y Wu y Nian (2021) modelan comunidades de aprendizaje desde una lógica relacional, pero sin incorporar procesos de incidencia indirecta. Esta limitación metodológica ha sido destacada por diversas revisiones recientes que subrayan la necesidad de enfoques más integrativos. En este sentido, el modelo de efectos olvidados representa una contribución sustantiva al análisis educativo, al permitir la detección de trayectorias acumulativas y relaciones latentes que suelen permanecer invisibles bajo esquemas de evaluación tradicionales.

Además, estos resultados ofrecen implicaciones teóricas relevantes. Como han argumentado Ifenthaler y Yau (2020), así como Papageorgiou y Salmeron (2013), los sistemas educativos deben entenderse como redes complejas donde la causalidad opera mediante nodos intermedios, retroalimentaciones internas y estructuras difusas. El

presente modelo se alinea con esta visión al evidenciar cómo ciertas dimensiones, aparentemente periféricas, adquieren centralidad estructural al funcionar como articuladores de efectos indirectos.

Desde una perspectiva práctica, los efectos olvidados identificados brindan información estratégica para las instituciones de educación superior. La constante aparición de la variable a_6 (políticas institucionales) en las trayectorias acumulativas sugiere que el fortalecimiento de estos marcos puede generar impactos significativos en dimensiones como el desempeño académico o la satisfacción estudiantil. Esta observación coincide con los planteamientos de Luckin y Holmes (2016), quienes destacan que los entornos educativos con gobernanza institucional sólida tienden a maximizar los beneficios de las tecnologías emergentes.

En última instancia, los efectos olvidados no deben entenderse como anomalías o ruido estadístico, sino como señales emergentes del comportamiento sistémico de la educación mediada por IA. Su identificación permite anticipar tensiones latentes, ajustar diseños curriculares y orientar la formación docente hacia un enfoque más reflexivo y estratégico. El modelo aquí propuesto no reemplaza a las evaluaciones tradicionales, sino que las complementa al ofrecer una visión más profunda de las trayectorias causales que estructuran el impacto educativo real de la inteligencia artificial.

6. CONCLUSIONES Y TRABAJOS FUTUROS

Este estudio partió del objetivo de analizar los impactos indirectos de la inteligencia artificial en la educación universitaria, integrando la teoría de los efectos olvidados y la lógica difusa como herramientas metodológicas para identificar trayectorias acumulativas no visibles en valoraciones lineales. A partir del modelado estructural entre variables pedagógicas, organizativas y evaluativas, se logró cuantificar relaciones de segundo orden que revelan la complejidad sistémica de los entornos educativos mediados por IA.

Los resultados muestran que variables como las estrategias pedagógicas innovadoras (a_3), la preparación docente (a_4) y las políticas institucionales (a_6) ejercen una influencia acumulativa sobre dimensiones clave como la satisfacción estudiantil (b_3), el desempeño académico (b_1) y la retención de conocimientos (b_7). Estas trayectorias no fueron plenamente reconocidas por los expertos en la evaluación directa, pero emergieron con fuerza al aplicar el modelo convolutivo. La presencia reiterada de ciertos nodos estructurales evidencia su centralidad funcional y sugiere que estos elementos deben ser considerados como puntos de apalancamiento estratégico para fortalecer el impacto positivo de la IA en educación superior.

A pesar de estos aportes, el estudio presenta limitaciones importantes. La muestra se circunscribió a una sola institución, lo que restringe la validez externa de los hallazgos. Asimismo, la valoración fue puntual, realizada en un único ciclo académico bajo condiciones controladas, y sin mediciones empíricas directas de los efectos educativos. Por ello, los resultados deben interpretarse como aproximaciones cualitativas a la estructura relacional del sistema, más que como afirmaciones causales concluyentes. A partir de estas limitaciones, se abren varias líneas de investigación futura. En primer lugar, se propone ampliar la muestra de expertos y extender la aplicación del modelo a universidades con distintos niveles de infraestructura digital. En segundo lugar, se recomienda incorporar evaluaciones longitudinales que permitan observar la evolución de las trayectorias acumulativas en el tiempo. Finalmente sería pertinente combinar este modelo difuso con técnicas empíricas cuantitativas o simulaciones basadas en agentes, con el fin de contrastar sus hallazgos y fortalecer su capacidad explicativa. Además, futuras investigaciones podrían explorar la replicabilidad del modelo en distintas universidades con grados diversos de madurez tecnológica, así como contrastar sus resultados con otras metodologías analíticas, tales como redes bayesianas o aprendizaje profundo, para evaluar su consistencia y utilidad comparada.

BIBLIOGRAFÍA

- Alfaro-Calderón, G. G., Godínez-Reyes, N. L., Gómez-Monge, R., Alfaro-García, V., & Gil-Lafuente, A. M. (2019). Forgotten effects in the valuation of the social well-being index in Mexico's sustainable development. *Fuzzy Economic Review*, 24(1). <https://doi.org/10.25102/fer.2019.01.04>
- Chu, H. C., Hwang, G. H., Tu, Y. F., & Yang, K. H. (2022). Roles and research trends of artificial intelligence in higher education: A systematic review of the top 50 most-cited articles. *Australasian Journal of Educational Technology*, 38(3). <https://doi.org/10.14742/ajet.7526>
- Guruprasad, M., Sridhar, R., & Balasubramanian, S. (2016). Fuzzy logic as a tool for evaluation of performance appraisal of faculty in higher education institutions. *SHS Web of Conferences*, 26. <https://doi.org/10.1051/shsconf/20162601121>
- Hegazi, M. O., Almaslukh, B., & Siddig, K. (2023). A Fuzzy Model for Reasoning and Predicting Student's Academic Performance. *Applied Sciences (Switzerland)*, 13(8). <https://doi.org/10.3390/app13085140>
- Holmes, W., Bialik, M., & Fadel, C. (2019). Artificial intelligence in education: Promises and implications for teaching and Learning. *Center for Curriculum Redesign*, 14(4).
- Ifenthaler, D., & Yau, J. Y. K. (2020). Utilising learning analytics to support study success in higher education: a systematic review. *Educational Technology Research and Development*, 68(4). <https://doi.org/10.1007/s11423-020-09788-z>

- Jan, N. U., Naqvi, S., & Ali, Q. (2023). Using Fuzzy Logic for Monitoring Students Academic Performance in Higher Education †. *Engineering Proceedings*, 46(1). <https://doi.org/10.3390/engproc2023046021>
- Kaufmann A., & Gil Aluja J. (1988). *Modelos para la investigación de los efectos olvidados* (Ed. Milladoiro).
- Li, S., Wang, C., & Wang, Y. (2024). Fuzzy evaluation model for physical education teaching methods in colleges and universities using artificial intelligence. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-53177-y>
- Luckin, R., & Holmes, W. (2016). *Intelligence Unleashed: An argument for AI in Education*.
- Lykourantzou, I., Giannoukos, I., Nikolopoulos, V., Mpardis, G., & Loumos, V. (2009). Dropout prediction in e-learning courses through the combination of machine learning techniques. *Computers and Education*, 53(3). <https://doi.org/10.1016/j.compedu.2009.05.010>
- Ma, L., Ali, Z., & Yin, S. (2024). Implementation of Learning Management Systems (LMS) in higher education systems through bipolar complex hesitant fuzzy Aczel-Alsina power aggregation operators: A case review for China. *PLOS ONE*, 19(4), e0300317. <https://doi.org/10.1371/JOURNAL.PONE.0300317>
- Mason, C., Twomey, J., Wright, D., & Whitman, L. (2018). Predicting Engineering Student Attrition Risk Using a Probabilistic Neural Network and Comparing Results with a Backpropagation Neural Network and Logistic Regression. *Research in Higher Education*, 59(3), 382–400. <https://doi.org/10.1007/S11162-017-9473-Z/FIGURES/3>
- Memarian, B., & Doleck, T. (2023). Fairness, Accountability, Transparency, and Ethics (FATE) in Artificial Intelligence (AI) and higher education: A systematic review. In *Computers and Education: Artificial Intelligence* (Vol. 5). <https://doi.org/10.1016/j.caeai.2023.100152>
- Papageorgiou, E. I., & Salmeron, J. L. (2013). A review of fuzzy cognitive maps research during the last decade. *IEEE Transactions on Fuzzy Systems*, 21(1). <https://doi.org/10.1109/TFUZZ.2012.2201727>
- Pérez-Romero, M. E., Flores-Romero, M. B., Álvarez-García, J., & Alfaro-García, V. G. (2024). Competitiveness and tourism GDP in Magic Towns: an analysis based on the theory of forgotten effects. *Quality and Quantity*, 1–18. <https://doi.org/10.1007/S11135-024-01900-2/FIGURES/13>
- Wu, J. Y., & Nian, M. W. (2021). The dynamics of an online learning community in a hybrid statistics classroom over time: Implications for the question-oriented problem-solving course design with the social network analysis approach. *Computers & Education*, 166, 104120. <https://doi.org/10.1016/J.COMPEDU.2020.104120>

Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? In *International Journal of Educational Technology in Higher Education* (Vol. 16, Issue 1). <https://doi.org/10.1186/s41239-019-0171-0>