



Percepción de los conocimientos de la analítica del aprendizaje en la educación superior. (Perception of learning analytics knowledge in higher education)

Maria de Jesús Araiza-Vázquez¹; Federico Guadalupe Figueroa Garza² y José Felipe Ramirez Ramirez³

¹ Universidad Autónoma de Nuevo León – Facultad de Contaduría Pública y Administración (México), maria.araiavz@uanl.edu.mx, <https://orcid.org/0000-0002-2622-805X>

² Universidad Autónoma de Nuevo León – Facultad de Contaduría Pública y Administración (México), federico.figueroagrz@uanl.edu.mx, <https://orcid.org/0000-0001-9161-8057>

³ Universidad Autónoma de Nuevo León – Facultad de Contaduría Pública y Administración (México), jose.ramirezrr@uanl.edu.mx, <https://orcid.org/0000-0002-7394-1659>

Información revisada por pares

Fecha de recepción: Abril 2023

Fecha de aceptación: Mayo 2023

Fecha de publicación en línea: Septiembre 2023

DOI: <https://doi.org/10.29105/vtga9.5-506>

Resumen

Se pueden obtener múltiples beneficios del análisis de aprendizaje (AA) en las Instituciones de Educación Superior (IES) y las partes interesadas, mediante el uso de una variedad de estrategias de análisis de datos para generar recomendaciones y conocimientos sumativos, predictivos y en tiempo real. Sin embargo, es necesario analizar si los entornos educativos y el personal académico y administrativo están capacitados para llevar a cabo estos procesos. En este trabajo se utilizó una matriz de beneficios de la AA para investigar las capacidades actuales de la AA en las IES, se exploró la fuente de datos para generar un marco válido de AA y comprender como se perciben los conocimientos relacionados con la AA. Concluimos que se necesita más investigación empírica sobre la solidez y los beneficios esperados de los marcos de análisis de aprendizaje para la enseñanza y el aprendizaje para confirmar la promesa de esta nueva tecnología prometedora.

Palabras clave: Analítica del Aprendizaje, Educación Superior, Conocimiento de analítica de datos, Gestión del Cambio

Códigos JEL: I21, I23, M15, O31, O33

Abstract

Multiple benefits of learning analytics (LA) can be realized by Higher Education Institutions (HEIs) and stakeholders through the use of a variety of data analytics strategies to generate summative, predictive and real-time recommendations and insights. However, it is necessary to analyze whether the educational environments and the academic and administrative staff are trained to carry out these processes. In this paper we used an LA benefits matrix to investigate current LA capabilities in HEIs, explored the data source to generate a valid LA framework and understand how OA-related knowledge is perceived. We conclude that more empirical research on the robustness and expected benefits of learning analytics frameworks for teaching and learning is needed to confirm the promise of this promising new technology.

Key words: Learning Analytics, Higher Education, Knowledge of data analytics, Change Management

JEL Codes: I21, I23, M15, O31, O33

Introducción

Farrell et al., (2022) identificó la analítica del aprendizaje como una tendencia de rango medio que impulsará permutaciones en la educación superior en los cercanos tiempos. La analítica del aprendizaje (AA) utiliza información permanente y dinámica sobre los alumnos y los ambientes de aprendizaje -evaluando, adquiriendo y analizando- para constituir, presagiar y perfeccionar en tiempo real los métodos de aprendizaje, los ambientes de aprendizaje y la toma de decisiones educativas (Ifenthaler y Drachsler 2020).

Se están desplegando promisorias aplicaciones de AA que utilizan los datos creados por el educando y otra información notable para individualizar y adecuar perennemente el entorno de aprendizaje (Mangaroska y Giannakos 2018). Se espera que las AA proporcione una base pedagógica y tecnológica para originar intervenciones en tiempo real en todo instante durante el proceso de aprendizaje. Los estudiantes se favorecen de la AA mediante vías de aprendizaje optimizadas, intervenciones personalizadas y andamiajes en tiempo real (Gašević et al. 2015). La AA proporciona a los instructores un análisis y un seguimiento detallados a nivel individual de los estudiantes, lo que les permite identificar factores especialmente inestables, como la motivación o las pérdidas de atención, antes de que se produzcan (Gašević et al. 2016).

Los diseñadores pedagógicos utilizan la información de la AA para evaluar los materiales de aprendizaje, ajustar los niveles de dificultad y medir el impacto de las intervenciones (Blumenstein, 2020). Además, la AA facilita la toma de decisiones a nivel institucional y ayuda a analizar la deserción estudiantil y a identificar las brechas en la planificación curricular. Sin embargo, ¿están las instituciones y los académicos, así como el personal administrativo, preparados para la AA? Por ejemplo, la gran cantidad de datos educativos disponibles requiere herramientas flexibles de extracción y nuevos métodos estadísticos, incluidos algoritmos de aprendizaje automático (Cervantes et al. 2020).

Además, las instituciones necesitan desarrollar e implementar visualizaciones de datos interactivos que proporcionen a los estudiantes, instructores, diseñadores de instrucción y administradores como una visión general de información relevante (Tsai et al 2018). Este estudio utiliza una matriz de beneficios de la AA para investigar las capacidades actuales de AA en las instituciones de educación superior, explora la calidad de las fuentes de datos para un marco válido de la AA, y conseguir una comprensión de cómo se perciben las ideas importantes de la AA.

Desde un punto de vista holístico, la AA puede aportar múltiples beneficios para las IES. La producción de información sumativa, en tiempo real y predictiva implica necesariamente la aplicación de datos. En la Tabla 1 se presenta una matriz en la que se esbozan los beneficios de la AA para las

partes interesadas utilizando tres perspectivas analíticas (Ifenthaler y Drachsler 2020).

Tabla 1. *Matriz de ventajas de la analítica del aprendizaje*

Stakeholder Perspective	Sumativa	En tiempo Real	Predictiva
Gobernabilidad	<ul style="list-style-type: none"> • Aplicar a través de comparaciones institucionales • Desarrollar puntos de referencia • Informar la elaboración de políticas • Informar los procesos de garantía de calidad 	<ul style="list-style-type: none"> • Aumentar la productividad • Aplique una respuesta rápida a incidentes críticos • Analizar el rendimiento 	<ul style="list-style-type: none"> • Modelar el impacto de la toma de decisiones organizativas • Planificar la gestión del cambio
Institución	<ul style="list-style-type: none"> • Analizar los procesos • Optimizar la asignación de recursos • Cumplir las normas institucionales • Comparar unidades entre programas y facultades 	<ul style="list-style-type: none"> • Supervisar los procesos • Evaluar los recursos • Seguimiento de las inscripciones • Analizar el abandono 	<ul style="list-style-type: none"> • Procesos de previsión • Proyectar el desgaste • Modelizar las tasas de retención • Identificar carencias
Diseño de Aprendizaje	<ul style="list-style-type: none"> • Analizar los modelos pedagógicos • Medir el impacto de las intervenciones • Aumentar la calidad de los planes de estudios 	<ul style="list-style-type: none"> • Comparar diseños de aprendizaje • Evaluar los materiales didácticos • Ajustar los niveles de dificultad • Proporcionar los recursos que necesitan los alumnos 	<ul style="list-style-type: none"> • Identificar las preferencias de aprendizaje • Planificar futuras intervenciones • Modelar niveles de dificultad • Modelar itinerarios
Facilitador	<ul style="list-style-type: none"> • Comparar alumnos, cohortes y cursos • Analizar las prácticas docentes • Aumentar la calidad de la enseñanza 	<ul style="list-style-type: none"> • Supervisar el progreso • Crear intervenciones significativas • Aumentar interacción • Modificar el contenido para satisfacer las necesidades de las cohortes 	<ul style="list-style-type: none"> • Identificar a los alumnos en situación de riesgo • Prever el progreso del aprendizaje • Planificar intervenciones • Modelizar las tasas de éxito
Estudiante	<ul style="list-style-type: none"> • Comprender los hábitos de aprendizaje • Comparar itinerarios de aprendizaje • Analizar los resultados del aprendizaje • Seguimiento del progreso hacia los objetivos 	<ul style="list-style-type: none"> • Recibir intervenciones y andamiajes automatizados • Realice evaluaciones con comentarios en tiempo real 	<ul style="list-style-type: none"> • Optimizar las vías de aprendizaje • Adaptarse a las recomendaciones • Aumentar el compromiso • Aumentar las tasas de éxito

Por ejemplo, los estudiantes utilizan la AA sumativa implementada como un tablero interactivo

para analizar los resultados del aprendizaje de los cursos individuales después de haber completado un semestre de estudio o para seguir su progreso hacia las metas autodefinidas (por ejemplo, créditos). Los estudiantes pueden comparar sus propias trayectorias y resultados de aprendizaje entre unidades o cursos individuales. Esto les permite entender sus hábitos de estudio y ajustar sus estrategias de aprendizaje, así como sus hábitos privados para tener éxito en sus estudios Azevedo et al. 2018).

Los estudiantes reciben información en tiempo real basada en los datos de los que disponen actualmente en el mismo tablero o en un sistema de gestión de aprendizaje. Los avisos automatizados y personalizados les indican materiales de aprendizaje y consejos para seguir avanzando en una unidad de estudio concreta (Fan, et al. 2022). Los estudiantes realizan pruebas de autoevaluación sobre un tema específico y reciben o recomendaciones para participar en debates en línea o conectarse con sus compañeros a través de sus medios sociales preferidos. Las AA predictivas ayudan a los estudiantes a optimizar su itinerario de aprendizaje en una unidad de estudio específica, mostrándoles sus probabilidades de éxito cuando eligen un itinerario concreto. Se espera que estas predicciones aumenten el compromiso general de los estudiantes y las tasas de éxito, así como que se promueven en el aprendizaje autorregulado (Cogliano, et al., 2022).

Los facilitadores utilizan el AA sumativa para comparar a los estudiantes en unidades de estudio individuales, en la planificación de intervenciones y en actividades individuales. Así como a comprender las características de los grupos y los efectos específicos de los cursos, en el aumento de la interacción con los estudiantes y la comprensión inter e intraindividuales de los estudiantes.

La AA predictiva ponen de relieve los posibles estudiantes en riesgo y permite facilitar las intervenciones tempranas. Los diseñadores pedagógicos utilizan la AA sumativo, en tiempo real y predictivo para mejorar la calidad del plan de estudios, los materiales, los andamiajes y las evaluaciones. Por ejemplo, se puede identificar el uso redundante de materiales de lectura o ajustar los niveles de dificultad de los materiales para satisfacer las necesidades de los alumnos. materiales para cumplir los requisitos del plan de estudios. Las evaluaciones formativas (por ejemplo, las valoraciones de los materiales) dentro del entorno de aprendizaje proporcionan los conocimientos necesarios en consecuencia.

Los líderes institucionales utilizan la AA sumativa para optimizar la asignación de recursos y apoyar mejor las necesidades de aprendizaje de los estudiantes, analiza el abandono de los estudiantes y realiza un seguimiento de la matriculación en programas de estudio y cohortes. Las AA predictivas ayudan a las instituciones a identificar lagunas en la planificación institucional y a prever procesos y desarrollos organizativos.

Los beneficios para la gobernanza incluyen el desarrollo de puntos de referencia de calidad, la recopilación de pruebas para la acreditación y el suministro de información detallada a los

responsables políticos. Es importante señalar que no es necesario aplicar todas las características de la matriz de beneficios de la AA presentada (véase Tabla 1). Más bien, las instituciones de enseñanza superior deben elaborar cuidadosamente una estrategia sobre cómo implantar la AA y proporcionar la infraestructura necesaria para implantarla con éxito.

Objetivo del estudio

La aplicación de un marco de AA que siga la matriz de beneficios de AA descrita anteriormente requiere personal especializado y capacidades tecnológicas (Viberg et al. 2020). Dado que la AA es un campo relativamente nuevo, hay una falta de personal, así como de soluciones tecnológicas. Por lo tanto, el propósito de este estudio era triple:

- a) Investigar las capacidades actuales de la AA en las instituciones de educación superior, b)
- b) Explorar la importancia de varias fuentes de datos para un marco válido de la AA, y
- c) Comprender cómo se perciben las percepciones significativas de la AA desde una perspectiva sumativa, en tiempo real y predictiva.

Método

Diseño

Para llegar a un gran número de instituciones de educación superior, utilizamos una encuesta en línea como principal medio de recogida de datos para nuestro estudio. La encuesta se implementó en la plataforma QuestionPro. Se utilizaron listas de correo electrónico, foros y canales de medios sociales centrados en la tecnología educativa y el análisis del aprendizaje para difundir el enlace a la encuesta en línea.

Participantes

El conjunto de datos inicial constaba de 171 respuestas. Una vez eliminadas las respuestas incompletas, el conjunto de datos final incluía 153 respuestas válidas (21% mujeres, 78% hombres, 1% no especificado). La edad media de los participantes era 44,68 años (SD = 9.10). El 30% trabajaba en un puesto de investigación, el 28% era personal de investigación y docencia, el 7% informó de que ocupaba un puesto de docencia, el 4% desempeñaba una función de alta dirección, el 1% informó de que trabajaba en servicios de TI y el 1% trabajaba como personal de biblioteca. El 29% trabajaban en otras funciones, como analista de datos, estadístico o diseñador de instrucción. El 31% de los participantes declaró estar involucrado en un proyecto centrado en AA.

Instrumento

El instrumento de la encuesta constaba de las siguientes secciones: (a) capacidades del personal para la analítica del aprendizaje, (b) tecnología disponible para la analítica del aprendizaje, (c) barreras para la implementación de la analítica del aprendizaje, (d) importancia de los datos de los estudiantes, (e) importancia de los datos del entorno de aprendizaje, (f) beneficios de la analítica del aprendizaje para la institución, (g) importancia de la analítica del aprendizaje sumativa, (h) importancia de la analítica del aprendizaje en tiempo real, (i) importancia de la analítica del aprendizaje predictiva, (j) antecedentes personales.

La mayoría de los ítems se respondieron en una escala Likert de cinco puntos (por ejemplo, 5 = muy importante; 4 = importante; 3 = indeciso; 2 = poco importante; 1 = nada importante). La tabla 2 muestra los elementos incluidos en cada una de las secciones, así como las medidas de fiabilidad del alfa de Cronbach. El promedio de tiempo dedicados para completar la encuesta tardó aproximadamente 15 minutos.

Tabla 2. *Resumen del estudio de fiabilidad de la encuesta*

Sección	No. Preguntas	Alfa de Cronbach
1. Capacidades del personal para el análisis del aprendizaje	7	$\alpha = .89$
2. Tecnología disponible para el análisis del aprendizaje	12	$\alpha = .94$
3. Barreras para la implantación de la analítica del aprendizaje	13	$\alpha = .93$
4. Importancia de los datos de los alumnos	9	$\alpha = .81$
5. Datos sobre la importancia del entorno de aprendizaje	13	$\alpha = .85$
6. Beneficios de la analítica del aprendizaje para la institución	12	$\alpha = .88$
7. Importancia de la analítica sumativa del aprendizaje	20	$\alpha = .93$
8. Importancia de la analítica del aprendizaje en tiempo real	17	$\alpha = .94$
9. Importancia del análisis predictivo del aprendizaje	18	$\alpha = .94$
10. Datos personales	5	

Análisis de datos

Todos los datos fueron exportados y analizados con SPSS V.27. Las comprobaciones iniciales de los datos mostraron que las distribuciones de las valoraciones y las puntuaciones cumplían los supuestos en los que se basaban los procedimientos de análisis. Todos los efectos se evaluaron al nivel de 0.05.

Resultados

Los resultados se presentan en el orden de los tres propósitos de la investigación expuestos anteriormente en este documento.

Capacidades de la analítica del aprendizaje

Cuando se les preguntó por las capacidades del personal disponible para proyectos de AA, más de la mitad de los participantes informaron de que su institución contaba con al menos un diseñador de aprendizaje (68.6%) y al menos un especialista en gestión del aprendizaje (62.7%). Otras capacidades del personal disponible para proyectos de AA incluían analista de bases de datos (41.2%), estadístico (38.5%) y arquitecto de gestión de la información (22.9%). Sólo el 25% de los participantes declaró tener personal con funciones de especialista en análisis del aprendizaje (véase la Tabla 3).

Cuando se les preguntó por la tecnología disponible para el AA, sólo un pequeño número de participantes informó de que su institución disponía de capacidades de análisis predictivo (28.1%), practicaba la elaboración automatizada de informes de datos (21.6%), disponía de un almacén de datos (19.0%) y utilizaba capacidades de visualización de datos (19.0%). Uno de cada cuatro participantes indicó que su institución disponía de cuadros de mando interactivos para estudiantes y profesores (25.5%). Curiosamente, varias instituciones estaban preparadas para utilizar la puntuación automatizada de ensayos (27.5%), el procesamiento de lenguaje natural (26.8%), el análisis automatizado de foros de discusión (26.1%) y el análisis de redes sociales (24.2%).

Tabla 3. Frecuencias (porcentaje) de las capacidades del personal

Papel	N/A	No hay personal	De 1 a 5 personas	6-10 empleados	Más de 10 empleados
Especialista en análisis de aprendizaje	53 (34.6%)	60 (39.2%)	38 (24.8%)	1 (0.7%)	1 (0.7%)
Arquitecto de gestión de la información	55 (35.9%)	63 (41.2%)	30 (19.6%)	—	5 (3.3%)
Estadístico	50 (32.7%)	44 (28.8%)	34 (22.2%)	17 (11.1%)	8 (5.2%)
Analista de bases de datos	48 (31.4%)	42 (27.5%)	40 (26.1%)	16 (10.5%)	7 (4.6%)
Especialista en sistemas de gestión del aprendizaje	42 (27.5%)	15 (9.8%)	67 (43.8%)	21 (13.7%)	8 (5.2%)
Científico de datos	60 (39.2%)	50 (32.7%)	38 (24.8%)	1 (0.7%)	4 (2.6%)
Diseñador de aprendizaje	20 (13.1%)	28 (18.3%)	80 (52.3%)	13 (8.5%)	12 (7.8%)

** $p < .01$, *** $p < .01$

Importancia de las fuentes de datos

Los participantes señalaron que es importante disponer de las siguientes fuentes de datos de los alumnos para aplicar un marco de AA válido: formación académica (97.4%), conocimientos previos (95.5%), datos sociodemográficos (94.1%), interés personal (92.8%), conocimientos informáticos (90.2%), historial de aprendizaje (85.0%) y estrategias de aprendizaje preferidas (79.7%). Las fuentes de datos menos importantes fueron los vínculos sociales (18.9%) y las (18.9%)

y las preferencias por los medios sociales (18.3%).

Un marco de AA válido también requiere fuentes de datos del entorno de aprendizaje (por ejemplo, el sistema de gestión del aprendizaje). Los participantes calificaron la importancia de las fuentes de datos de la siguiente manera: uso de materiales de aprendizaje (98.3%), resultados de la evaluación (97.7%), resultados esperados del aprendizaje (97.1%), interacción de los facilitadores (96.2%), tiempo de aprendizaje (94.7%), nivel de dificultad del curso (94.7%), rutas de aprendizaje esperadas (93.5%), navegación por el contenido (92.2%), actividad de debate (92.1%), resultados de la evaluación (90.9%) y uso de materiales externos (89.6%). La ubicación del aprendizaje no se consideró muy importante (18.3%).

Conocimiento de la analítica de los aprendizajes

Las tres percepciones sumativas más importantes de la AA comunicadas por los participantes en el estudio fueron el seguimiento del progreso de los estudiantes hacia los objetivos (98.3%), el análisis de los resultados del aprendizaje de los estudiantes (97.7%) y la comprensión de los hábitos de aprendizaje de los estudiantes (97.0%). Los puntos de vista en tiempo real más importantes de la AA incluyen proporcionar a los estudiantes una evaluación que incluya comentarios en tiempo real (97.0%), crear intervenciones significativas para los estudiantes (96.0%) y modificar el contenido para satisfacer las necesidades de los estudiantes (96.7%).

Los participantes calificaron las siguientes ideas del AA predictivo como las más importantes: aumentar el compromiso de los estudiantes (98.0%), modelar las tasas de éxito de los estudiantes (98.0%) y aumentar las tasas de éxito de los estudiantes (98.7%) y éxito de los estudiantes (98.7%). En general, los participantes indicaron que los facilitadores (96.0%) serían los que más se beneficiarían de la AA en su institución, seguidos de los estudiantes (95.4%) y los diseñadores de aprendizaje (95.1%). Los que menos beneficios esperaban eran los financieros (15.0%) y los servicios de instalaciones (9.2%).

Discusión

La AA se basa en un conjunto seleccionado de técnicas y datos para facilitar información sumativa, en tiempo real y predictiva para perfeccionar el aprendizaje, la enseñanza, la eficiencia organizativa y la toma de decisiones (Blumenstein, 2020; Mangaroska y Giannakos 2018). Si bien el campo de la AA está recogiendo cuantiosa atención por su capacidad de suministrar indicadores primordiales del fracaso de los estudiantes, hasta la fecha se ha centrado en cursos individuales de forma aislada, en lugar de las capacidades de las IES en general (Gašević et al. 2015).

Este trabajo de indagación se centró en tres cuestiones: (a) las capacidades actuales del AA en

las instituciones de educación superior, (b) la importancia de varias fuentes de datos para un marco válido de AA, (c) la importancia de las percepciones de la AA desde una perspectiva sumativa, en tiempo real y predictiva. Los resultados de este estudio dejan ver que hay una falta de personal especializada para los proyectos de AA, personal experto con una sólida formación en enseñanza aprendizaje, así como en ciencia de datos, es escaso. Por ejemplo, sólo el 25% de las instituciones participantes en nuestro estudio informan de que emplean a especialistas en análisis del aprendizaje. Del mismo modo, nuestros resultados indican claramente que las IES no disponen de la tecnología necesaria para implementar marcos válidos de AA. Por ejemplo, sólo el 19% de las instituciones informan de que han implementado un almacén de datos que funciona. En consecuencia, solo un pequeño número de IES cumple con los elevados requisitos de personal y tecnología para los marcos de AA (Kevan y Ryan 2016).

Los hallazgos sobre la calidad de las fuentes de datos relevantes para un marco legítimo de AA indican que la mayor parte de la información de los estudiantes y de los entornos de aprendizaje se percibe como importante. Un reto actual en el establecimiento de marcos de AA es la interpretación de los resultados de los análisis con respecto al entorno educativo y su naturaleza contextual (Tai, et al. 2018). En otras palabras, las variables y los indicadores pueden tener diferentes significados y, por tanto, diferentes implicaciones.

Por lo tanto, es imperativo que la investigación sobre el análisis del aprendizaje tenga en cuenta las condiciones de enseñanza a la hora de desarrollar modelos predictivos. Es necesario determinar las diferencias en las condiciones de instrucción, especialmente las relacionadas con si se utilizan o no las características del sistema gestor de la enseñanza (SGA) y cómo se utilizan, antes de fusionar los datos para crear un modelo generalizado de predicción del éxito académico. Si no se tienen en cuenta las condiciones de enseñanza, es probable que se sobrestimen o subestimen los efectos de las características específicas del SGA en el éxito académico de los estudiantes. Sin embargo, el uso de la tecnología, incluso dentro de un mismo curso, también puede cambiar como resultado de la evaluación de la eficacia del curso (Swan, et al., 2012). Por lo tanto, las condiciones de enseñanza definen el nivel de orientación pedagógica con respecto a cómo y cuándo un individuo utiliza las diversas características del SGA.

Los hallazgos encontrados sobre la importancia de las percepciones del AA indican que los estudiantes, los facilitadores y los diseñadores de aprendizaje obtendrían muchos beneficios, en tiempo real y predictivo. Los que menos beneficios esperan son las entidades organizativas y la gobernanza. Dado que son responsables del éxito de los estudiantes, las IES están llamadas a analizar y crear nuevas intervenciones y acciones basadas en la AA en sus contextos que pueden mejorar su eficacia institucional.

Si se desarrolla como una capacidad organizativa, el análisis continuo de los macrodatos puede proporcionar información sobre el diseño de los entornos de aprendizaje y fundamentar las decisiones sobre cómo gestionar los recursos educativos a todos los niveles (Fan et al. 2022; Huda, et al. 2017). Además, las organizaciones deben seguir desarrollándose para cumplir con los requisitos de la toma de decisiones rica en datos (Nieto et al. 2019; Whitelock-Wainwright et al. 2021).

Limitaciones

Este estudio tiene limitaciones obvias que deben ser abordadas. Hay que tener en cuenta la naturaleza de los datos de auto informe y el pequeño tamaño de la muestra de un grupo con conciencia de AA a la hora de interpretar los resultados. Además, a pesar del enfoque del estudio, registramos respuesta de estados del norte y noroeste de México. En consecuencia, las investigaciones futuras deberían aportar más pruebas empíricas sobre la capacidad de las instituciones de educación superior para aplicar los marcos de AA.

Las encuestas nacionales pueden ayudar a identificar las lagunas de los sistemas de educación superior específicos. Y lo que es más importante, la eficacia de los marcos de AA para mejorar el aprendizaje y la enseñanza debe abordarse en una investigación empírica rigurosa. Sin embargo, esto requiere la existencia de sistemas de AA implementados (Cervantes et al., 2020).

Por último, las cuestiones relativas a la propiedad y la seguridad de los datos deben examinarse críticamente a escala nacional e internacional (Tsai et al, 2020). Cuestiones como quién debe tener acceso a qué datos, dónde y cuánto tiempo se almacenarán los datos, qué análisis y deducciones deben realizarse, y si los estudiantes deben ser conscientes de los datos que se recogen sobre ellos, deben debatirse en la investigación prospectiva. Los estudiantes son algo más que fragmentos de información producidos al interactuar con los sistemas de AA implantados por las instituciones de enseñanza superior (Waldman 2018).

La AA puede revelar información personal y conocimientos sobre el historial de aprendizaje de un individuo. Sin embargo, esta información no está verificada y dista mucho de ser imparcial, exhaustiva y válida. Por lo tanto, en un momento de creciente interés por los sistemas de AA en las IES, es importante comprender las implicaciones de los principios de privacidad como medio para garantizar que los sistemas implementados sean capaces de facilitar el aprendizaje, la instrucción y la toma de decisiones académicas, pero que no invadan la privacidad de los estudiantes (Schumacher, y Ifenthaler, 2018).

Para concluir, más datos educativos no siempre significa mejores datos educativos (Tsai et al. 2018). La AA tiene limitaciones obvias, y los datos recogidos de fuentes personales y educativas pueden tener múltiples significados. Lo más importante es que necesitamos investigaciones empíricas

sobre la validez de los marcos de trabajo de las AA y sobre los beneficios esperados para el aprendizaje y la educación para confirmar las grandes esperanzas que suscita esta prometedora tecnología emergente.

En general, los resultados de los artículos utilizados como soporte muestran que la investigación sobre AA se ha llevado a cabo principalmente para medir y no para apoyar el aprendizaje autorregulado. Por lo tanto, existe una necesidad crítica de explotar aún más los mecanismos de apoyo de la AA con el fin de utilizarlos en última instancia para fomentar el aprendizaje autorregulado de los estudiantes en entornos de aprendizaje en línea.

Referencias

- Azevedo, R., Taub, M., y Mudrick, N.V. (2018). Understanding and reasoning about real-time cognitive, affective, and metacognitive processes to foster self-regulation with advanced learning technologies. In D.H. Schunk y J.A. Greene (Eds.), *Handbook of self-regulation of learning and performance* (pp. 254-270). Routledge/Taylor & Francis Group. <https://doi.org/10.4324/9781315697048-17>
- Blumenstein, M. (2020). Synergies of Learning Analytics and Learning Design: A Systematic Review of Student Outcomes. *Journal of Learning Analytics*, 7(3), 13-32. <https://dx.doi.org/10.18608/jla.2020.73.3>
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189-215. <https://doi.org/10.1016/j.neucom.2019.10.118>
- Cogliano, M., Bernacki, M. L., Hilpert, J. C., & Strong, C. L. (2022). A self-regulated learning analytics prediction-and-intervention design: Detecting and supporting struggling biology students. *Journal of Educational Psychology*. <https://doi.org/10.1037/edu0000745>
- Fan, Y., van der Graaf, J., Lim L., Raković, M., Singh, S., Kilgour, J., ... & Gašević, D. (2022). Towards investigating the validity of measurement of self-regulated learning based on trace data. *Metacognition and Learning*, 17(3), 949-987. <https://doi.org/10.1007/s11409-022-09291-1>
- Farrell, T., Alani, H., & Mikroyannidis, A. (2022). Mediating learning with learning analytics technology: guidelines for practice. *Teaching in Higher Education*, 1-21. <https://doi.org/10.1080/13562517.2022.2067745>
- Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: learning analytics are about learning. *TechTrends*, 59(1), 64–71. <https://doi.org/10.1007/s11528-014-0822-x>
- Gašević, D., Dawson, S., Rogers, T., & Gašević, D. (2016). Learning analytics should not promote one size fits all: the effects of instructional conditions in predicting academic success. *Internet and Higher Education*, 28, 68–84. <https://doi.org/10.1016/j.iheduc.2015.10.002>
- Huda, M., Maseleno, A., Shahrill, M., Jasmi, K. A., Mustari, I., & Basiron, B. (2017). Exploring adaptive teaching competencies in big data era. *International Journal of Emerging Technologies in Learning*, 12(3) 68-83. <https://doi.org/10.3991/ijet.v12i03.6434>
- Ifenthaler, D., & Drachsler, H. (2020). *Learning analytics*. Handbuch Bildungstechnologie. Konzeption und Einsatz digitaler Lernumgebungen, 515-525. ISBN: 978-3-662-54368-9
- Kevan, J. M., & Ryan, P. R. (2016). Experience API: flexible, decentralized and activity-centric data collection. *Technology, Knowledge and Learning*, 21(1), 143–149. <https://doi.org/10.1007/s10758-015-9260-x>
- Mangaroska, K., & Giannakos, M. (2018). Learning analytics for learning design: A systematic

- literature review of analytics-driven design to enhance learning. *IEEE Transactions on Learning Technologies*, 12(4), 516-534. <https://dx.doi.org/10.1109/TLT.2018.2868673>
- Nieto, Y., Gacía-Díaz, V., Montenegro, C., González, C. C., & Crespo, R. G. (2019). Usage of machine learning for strategic decision making at higher educational institutions. *IEEE Access*, 7, 75007-75017. <https://doi.org/10.1109/ACCESS.2019.2919343>
- Schumacher, C., & Ifenthaler, D. (2018). Features students really expect from learning analytics. *Computers in human behavior*, 78, 397-407. <https://doi.org/10.1016/j.chb.2017.06.030>
- Swan, K., Matthews, D., Bogle, L., Boles, E., & Day, S. (2012). Linking online course design and implementation to learning outcomes: A design experiment. *The Internet and Higher Education*, 15(2), 81–88. <http://dx.doi.org/10.1016/j.iheduc.2011.07.002>
- Tai, J., Ajjawi, R., Boud, D., Dawson, P., & Panadero, E. (2018). Developing evaluative judgement: enabling students to make decisions about the quality of work. *Higher education*, 76, 467-481. <https://doi.org/10.1007/s10734-017-0220-3>
- Tsai, Y. S., Whitelock-Wainwright, A., & Gašević, D. (2020, March). The privacy paradox and its implications for learning analytics. In *Proceedings of the tenth international conference on learning analytics & knowledge* (pp. 230-239). <https://doi.org/10.1145/3375462.3375536>
- Tsai, Y.-S., Moreno-Marcos, P. M., Jivet, I., Scheffel, M., Tammets, K., Kollom, K., & Gašević, D. (2018). The SHEILA Framework: Informing Institutional Strategies and Policy Processes of Learning Analytics. *Journal of Learning Analytics*, 5(3), 5–20. <https://doi.org/10.18608/jla.2018.53.2>
- Viberg, O., Khalil, M., & Baars, M. (2020, March). Self-regulated learning and learning analytics in online learning environments: A review of empirical research. In *Proceedings of the tenth international conference on learning analytics & knowledge* (pp. 524-533). <https://doi.org/10.1145/3375462.3375483>
- Waldman, A. E. (2018). *Privacy as trust: Information privacy for an information age*. Cambridge University Press.
- Whitelock-Wainwright, A., Tsai, Y. S., Drachsler, H., Scheffel, M., & Gašević, D. (2021). An exploratory latent class analysis of student expectations towards learning analytics services. *The Internet and Higher Education*, 51, 100818. <https://doi.org/10.1016/j.iheduc.2021.100818>