

Alumnado subrepresentado e inteligencia artificial

Underrepresented students and artificial intelligence

Rosa María Ricoy-Casas¹: Universidad de Vigo y UNED-Lugo, España.

rricoy@uvigo.gal

Raquel Fernández-González: Universidad de Vigo, España.

raquelf@uvigo.gal

Miguel Santos-Garrido: Universidad de Vigo, España.

miguelsantosgarrido@gmail.com

Fecha de Recepción: 07/06/2024

Fecha de Aceptación: 05/08/2024

Fecha de Publicación: 12/12/2024

Cómo citar el artículo

Ricoy-Casas, R. M., Fernández-González, R. y Santos-Garrido, M. (2025). Alumnado subrepresentado e inteligencia artificial [Underrepresented students and artificial intelligence]. *European Public & Social Innovation Review*, 10, 01-22. <https://doi.org/10.31637/epsir-2025-843>

Resumen

Introducción: Los educadores, la administración pública y los gobiernos, deben ser conscientes de las fortalezas y debilidades de la IA en el aprendizaje, a fin de ser empoderados, no dominados por la tecnología en las prácticas de educación para la ciudadanía digital, especialmente con minorías y/o estudiantes subrepresentados, porque podría aumentar la brecha social y digital. **Metodología:** Este estudio, utiliza la metodología PRISMA y analiza datos obtenidos de la Web of Science y Google Scholar. **Resultados:** Se analiza si se producen errores, sesgos, subrepresentación y discriminación, o estos sistemas contribuyen a la inclusión; su interés en la comunidad científica y principales desafíos normativos y éticos a través de numerosos ejemplos. **Discusión:** Los hallazgos subrayan la importancia de su implementación, de la escasez de la investigación en este ámbito, las oportunidades, las prácticas nocivas y sus efectos, y los retos por alcanzar. **Conclusiones:** Este análisis subraya su efecto en otros ámbitos como el laboral, su importancia en relación a los derechos fundamentales, y la afectación a nuestros propios modelos de Estado social y democrático de derecho.

¹ Autor Correspondiente: Rosa María Ricoy-Casas. Universidad de Vigo y UNED-Lugo (España).

Palabras clave: inteligencia artificial; machine learning; educación; subrepresentación; discriminación; inclusión; derechos fundamentales; políticas públicas.

Abstract: Introduction: Educators, public administration, and governments need to be aware of the strengths and weaknesses of AI in learning, in order to be empowered, not dominated by technology, in digital citizenship education practices, especially with minorities and/or underrepresented students, because it could increase the social and digital divide. **Methodology:** This study uses the PRISMA methodology and analyzes data obtained from the Web of Science and Google Scholar. **Results:** It is analyzed whether errors, biases, underrepresentation and discrimination occur, or these systems contribute to inclusion; their interest in the scientific community and main normative and ethical challenges through numerous examples. **Discussion:** The findings underscore the importance of its implementation, the paucity of research in this area, the opportunities, harmful practices and their effects, and the challenges to be met. **Conclusions:** This analysis underlines its effect in other areas such as labor, its importance in relation to fundamental rights, and the impact on our own models of social and democratic rule of law

Keywords: artificial intelligence; machine learning; education; subrepresentation; discrimination; inclusion; fundamental rights; public policies.

1. Introducción

La “electricidad” que mueve la mayoría de las tecnologías es la inteligencia artificial (IA). El crecimiento de la capacidad informática, la disponibilidad de datos, y los avances en los algoritmos, la han convertido en una de las tecnologías más estratégicas del siglo XXI. Su desarrollo ha acaparado atención e inversiones en las principales economías del mundo, y desde hace años la UE intenta liderar su uso (Ricoy-Casas, 2019). Además de las actividades cotidianas, tienen múltiples utilidades para rastrear documentación histórica, para descifrar lenguas antiguas, e incluso en ciertas tareas ya supera las capacidades humanas: con solo un mes de desarrollo del sistema, los investigadores de Stanford pudieron usar IA para diagnosticar 14 tipos de afecciones médicas utilizando imágenes de rayos X (Rajpurkar *et al.*, 2017); y el sistema AlphaZero, logró en 24 horas un nivel sobrehumano de juego (Silver *et al.*, 2017). No obstante, las preocupaciones que aparecen en la ciencia ficción se centran en “la singularidad tecnológica” (Kurzweil 2006) o en máquinas que adquieren autonomía propia y exponen a graves riesgos a los humanos, basadas en las leyes de la robótica de Asimov (1942). Por ello es necesario abordar las cuestiones problemáticas que rodean a su funcionamiento de manera interdisciplinar, en ámbitos como la educación y en el contexto de poblaciones vulnerables como el alumnado subrepresentado, no sólo desde un punto de vista tecnológico. Sus implicaciones pueden tener graves consecuencias sobre los derechos fundamentales (DDFF), y nuestras propias democracias.

1.1. IA y Aprendizaje en diversos ámbitos. Cuestiones problemáticas

Los modelos algorítmicos que sirven de base a la IA se nutren de datos masivos (big data) que recopilan durante su uso. Un sistema biométrico puede tener dificultades en identificar a una persona de otra raza, o contemplar como una anomalía a una persona que se desplace en silla de ruedas. El sistema funciona bien para la mayoría “normalizada”, pero tendrá dificultades con las excepciones. Es aquí donde el factor humano no puede, por el momento, ser sustituido. Ya existen evidencias sobre algunos sistemas de IA que pueden ser frágiles: un pequeño cambio en una señal de tráfico puede evitar que un sistema de reconocimiento de imágenes de IA lo reconozca (Heaven 2019); pueden estar sesgados como los datos con los que se han capacitado (Access Now 2018; Ledford 2019); modelos como GPT-3 (Romero

2021) a menudo escriben tonterías (Hutson 2021; Marcus y Davis 2020), y ciertos enfoques de IA tuvieron poco impacto en abordar la Covid-19 cuando la pandemia estaba en su apogeo (Benaich 2020); Heaven 2021; Roberts *et al.* 2021). En determinados ámbitos, como la administración de justicia, la utilización de IA y algoritmos en las decisiones judiciales ya han revelado discriminaciones por razón de sexo y raza (Ricoy-Casas, 2021a; 2021b).

El chatbot Tay de Microsoft y Galactica de Meta exhibieron un comportamiento negativo y abusivo al difundir contenido racista, sexista y otras formas de contenido dañino (Borji 2023). GPT-3 también era con frecuencia parcial, poco fiable y, en ocasiones, creaba textos ofensivos (Kocoń *et al.* 2023). Ha habido informes de que ChatGPT escribió un código Python discriminatorio que juzgaba injustamente las habilidades de una persona en función de su género, raza y características físicas (Borji 2023). Las opciones dentro de ChatGPT, permiten a los usuarios especificar el género y la raza del asistente virtual, de modo que los sesgos políticos pueden estar inspirados en los posibles sesgos de ChatGPT (Wolf, 2023). Existe una creciente preocupación de que los sistemas de IA puedan reflejar y amplificar el sesgo humano y reducir la calidad del rendimiento cuando se trata de mujeres y personas negras (Seyyed-Kalantari *et al.*, 2021; Retzlaff, 2024). Se han documentado los sesgos políticos de ChatGPT en el tratamiento desigual de los grupos demográficos por parte de su sistema de moderación de contenido, al clasificar una variedad de comentarios negativos sobre algunos grupos demográficos como no odiosos/odiosos, y en su mayor parte, los grupos que es más probable que "proteja" son aquellos que generalmente se cree que están en desventaja según la ideología de izquierda (Rozado, 2023a, 2023b). Ghosh *et al.* (2021) revelaron prejuicios en torno a la religión (musulmanes, hindúes, judíos), el país/etnicidad (indios, paquistaníes, árabes) y la ideología (feministas, liberales, comunistas). Zack *et al.*, (2023) han afirmado que GPT-4 no modela adecuadamente la diversidad demográfica de las condiciones médicas, produciendo situaciones clínicas que estereotipan ciertas razas, etnias e identidades de género.

Según Ghosh *et al.* (2021) el texto de las redes sociales en el globo puede contener lenguaje conmutado por código generado por hablantes multilingües, neologismos y otras variaciones ortográficas que rara vez se ven en el entrenamiento de los datos, y ello plantea desafíos adicionales para detectar y mitigar las fallas de equidad en estos modelos. Dixon *et al.* (2018) lo identificó con una lista de términos de identidad LGBTQ, y Hutchinson *et al.* (2020) utilizaron una lista de términos que se refieren a personas con una discapacidad. Se ignoran los sesgos en contextos no occidentales (Sambasivan *et al.*, 2021) y la interpretación del odio varía entre países y contextos culturales (Salminen *et al.*, 2018, 2019). Ello resulta consistente con el hecho de que la tecnología se crea en determinados países por muy pocas empresas (algunas de las mejor cotizadas del mundo y con un poder exorbitante para imponerse en relación a las regulaciones que les afectan).

1.2. IA y aprendizaje automático en educación. Avances y desafíos

El interés por el aprendizaje con IA en el campo de investigación académica de la IA en la educación (AIED) se remonta al menos a la década de 1980 (revistas como el "International Journal of Artificial Intelligence in Education" en 1989 o el "International AI in Education Society" en 1993). Algunos autores incluso lo sitúan en 1930 (Watters, 2023; Holmes *et al.*, 2022). Sus usos son diversos, principalmente para apoyar a los sistemas administrativos; al profesorado, y al alumnado.

1) En relación a los procedimientos y a la gestión: para contratación, horario y procesos de admisión (Newton, 2021) aunque en algunos se han demostrado sesgos (Waters y Miikkulainen 2014; Universidad de Austin, 2020; Dennis 2018) (Marcinkowski *et al.* 2020;

Zeide 2019); para predecir y reducir la deserción escolar, especialmente en los MOOC (Dalipi *et al.* 2018; Feng *et al.* 2019; Goel y Goyal 2020), aunque sigue habiendo poca evidencia de la efectividad de tales sistemas o si las conexiones son predictivas o causales (Holmes *et al.*, 2022) y en algunos con resultados controvertidos por sus riesgos en relación a la privacidad o la ética (Arnold y Pistilli 2012; Sclater, 2016).

2) para apoyar al profesorado: para la generación y evaluación automática de pruebas; para aprender sobre cómo aprenden los alumnos; para monitorear el rendimiento del alumnado mientras se lleva a cabo el módulo y luego adaptar su enseñanza (si por ejemplo identifican que los estudiantes presentan especial dificultad en un tema en particular o qué diseños de aprendizaje son efectivos). Otros análisis se llevan a cabo retrospectivamente, lo que permite que el alumnado futuro se beneficie de las mejoras en el contenido y los procesos educativos (Nazaretsky *et al.*, 2021; Cyndecka, 2020; BBC, 2020; Ashrafi y Javadi, 2024; Bogen y Rieke, 2018). Asimismo para predecir cuáles no progresarán al próximo año académico, y una vez que se ha identificado a un estudiante en riesgo, se pueden tomar intervenciones personalizadas como el asesoramiento o el apoyo de un tutor. En el Instituto de Tecnología de Nueva York (NYIT), aproximadamente tres de cada cuatro estudiantes que no regresan a sus estudios al año siguiente habían sido pronosticados en riesgo (Sclater, 2016).

3) para apoyar al alumnado con herramientas que evalúan la comprensión de los estudiantes, adaptan el contenido que se les proporciona y modulan el tiempo en el que se ofrece dicho servicio; sistemas de tutoría basados en el diálogo, entornos de aprendizaje exploratorio, evaluación automática de la escritura, orquestadores de redes de aprendizaje, o chatbots para apoyarlos con ciertas dificultades e incluso diversidad funcional (Drigas y Ioannidou, 2012; Kohli y Prasad, 2010; Jacobsson, 2017; Anuradha *et al.*, 2010; Scassellati, 2012; Boccanfuso *et al.*, 2016; Lundy *et al.* 2019; Segovia-García, 2024). Se utilizan plataformas que registran las interacciones de los alumnos con los materiales, monitorean la frecuencia de uso, las páginas a las que acceden, y las anotaciones que hacen. Los cuestionarios de fin de módulo y las encuestas también puede ser información valiosa para el análisis del aprendizaje. Ello permite establecer objetivos para sus actividades de estudio, registrarlos, y comparar su progreso y resultados con otros. En Purdue, el algoritmo predictivo se basa en el rendimiento, esfuerzo, historial académico previo, y las características de los estudiantes; y en NYIT, los factores de riesgo incluyen calificaciones y datos financieros como la contribución de los padres a las tarifas (Sclater, 2016).

Por ello, y teniendo en cuenta su amplia y diversa aplicación en educación, los docentes, la administración pública y los gobiernos deben ser conscientes de las fortalezas y debilidades de la IA en el aprendizaje, a fin de ser empoderados, no dominados por la tecnología en las prácticas de educación para la ciudadanía digital, especialmente con minorías y/o alumnado subrepresentado, porque podría aumentar la brecha social y digital. Este trabajo se centra en muchos desafíos complejos planteados por las conexiones entre la IA y la educación, para proporcionar una visión holística a fin de garantizar que los desarrollos y prácticas futuras se utilicen de manera genuina para el bien común, avanzar en el conocimiento de su utilización en educación, en relación a minorías y personas subrepresentadas, analizando si se producen errores, sesgos sobrerrepresentación o subrepresentación con su uso. Hay poca investigación sobre por qué las minorías subrepresentadas tienen menos probabilidades de estudiar específicamente el aprendizaje automático y la inteligencia artificial (ML/AI). Si bien el uso de la IA para perfilar a los alumnos puede tener algunos beneficios que exponдемos, también puede ser demasiado intrusivo, socavando la expectativa legítima de privacidad del alumnado. Asimismo puede tener efectos punitivos en la familia cuando la asistencia está vinculada a los pagos de asistencia social del Estado (como en el programa Bolsa Familia en Brasil). Teniendo en cuenta lo anterior, empleando una revisión sistemática de la literatura,

se propone investigar el impacto y las posibilidades de implementación de estos sistemas de IA en el ámbito de la asistencia y orientación educativa en relación al alumnado subrepresentado; identificar prácticas que pueden mitigarlo o evitarlo; los desafíos y las consideraciones éticas asociadas; y estrategias o recomendaciones prácticas para superarlos. Con este fin, se formulan las siguientes preguntas de investigación:

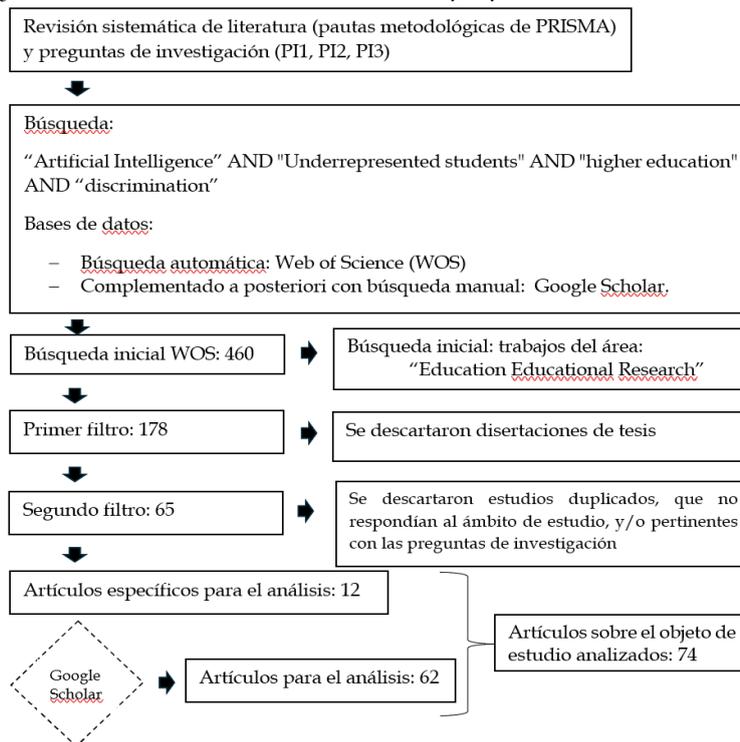
- PI1- Herramientas de Inteligencia Artificial (IA) y alumnado subrepresentado: ¿En qué medida la comunidad científica ha mostrado interés en estudiar el impacto de la IA en relación al alumnado subrepresentado, especialmente en el ámbito de la educación superior? ¿En qué aspectos se centra principalmente la revisión de literatura analizada?
- PI2- IA e impacto en el alumnado subrepresentado: ¿Existen herramientas de IA que discriminan al alumnado subrepresentado? ¿En qué áreas se están implementando soluciones de IA que podrían impactar de una manera excluyente? Demostrar y analizar si se producen errores, sesgos o subrepresentación a través del análisis de evidencias científicas. Si la respuesta es afirmativa, analizar algunos casos y los factores que lo determinan.
- PI3- Principales desafíos normativos y éticos. ¿Puede afirmarse que el uso de sistemas de IA para tomar decisiones implica claramente no sólo aspectos económicos, sino también sociales y éticos (por la forma en que los sistemas están diseñados y programados, su propio funcionamiento, o las fuentes de información de las que se nutren)? ¿Cuáles son los principales desafíos asociados con el uso de la IA en la educación superior en relación al alumnado subrepresentado? ¿Cómo pueden las instituciones educativas abordarlos?

2. Metodología

Para llevar a cabo la revisión sistemática de la literatura, se han seguido las pautas metodológicas de PRISMA, abarcando sus tres fases fundamentales: planificación, ejecución y presentación de resultados, permitiendo identificar el contexto previamente estudiado y determinar hallazgos, limitaciones, implicaciones, brechas y áreas de trabajo futuras para responder a las preguntas de investigación planteadas (PI1, PI2 y PI3) (Page *et al.*, 2021; PRISMA, s.f.). Durante la etapa de planificación de la revisión, se diseñó una estrategia de búsqueda exhaustiva que abarcó los términos clave pertinentes para el estudio. El operador AND se utilizó para incluir los términos "artificial intelligence" y "underrepresented students". También se empleó este operador para integrar en el estudio el nivel educativo "higher education" y la palabra "discrimination", asegurando una cobertura completa de los aspectos relacionados con la implementación y la experiencia del usuario en lo relativo a si estas herramientas pueden crear nuevas brechas, profundizando y reflexionando sobre su actualidad, el futuro y su importancia en relación con la alfabetización digital, las nuevas políticas educativas, y la inclusión social. Además, se estableció una limitación temporal, incluyendo estudios publicados después de 2018 (hasta julio 2024), garantizando así la relevancia de los hallazgos más recientes en el ámbito de la educación superior.

Figura 1.

Flujo de Selección y Evaluación de Fuentes. Elaboración propia



Fuente: Elaboración propia (2024).

En esta revisión sistemática de la literatura (figura 1), se han seleccionado artículos de revistas indexadas en la Web of Science. Esta selección se basó en los índices de impacto, JCR y SJR (WOS y Scopus), así como en las palabras clave del tesoro Europeo de la Educación (ERIC). Una vez obtenidos los resultados (460 publicaciones), se analizaron los trabajos del área: “Education Educational Research” (178 resultados). Se incluyeron los artículos, descartándose otro tipo de documentos como las disertaciones de tesis (65 resultados). Mediante un análisis específico, se procedió a descartar aquellos estudios duplicados, que no respondían al ámbito de estudio y aquellos que no eran pertinentes con las preguntas de investigación planteadas (12 publicaciones). Después se complementaron los resultados con otras investigaciones y publicaciones de organismos públicos que no se encuentran en estas delimitaciones ni formatos, y trabajos con búsqueda manual en Google Scholar (en relación a IA, sesgos y discriminación que pueden relacionarse con alumnado subrepresentado) (62 publicaciones) claramente discernibles en el trabajo. Estos estudios fueron empleados en una fase posterior, como complemento para el análisis y las reflexiones.

3. Resultados

3.1. Herramientas de Inteligencia Artificial (IA) y alumnado subrepresentado

Hemos mencionado algunos trabajos previos que ya han analizado la utilización de alguna herramienta concreta, como el uso de chatbots de IA en la educación superior para la optimización de la atención estudiantil (Segovia-García, 2024), en donde se resalta un interés en constante crecimiento, con un punto de inflexión significativo en 2021 (de aumento sin retroceso), coincidiendo con la fase de recuperación de la pandemia de COVID-19. Lo que ahora analizamos es el impacto de la utilización de la IA (con diversas herramientas, no sólo chatbots) en relación al alumnado subrepresentado.

Tabla 1.
Análisis de las principales fuentes bibliográficas utilizadas y las temáticas abordadas

Área de estudio	12 Referencias WOS (IA y alumnado subrepresentado)	62 Referencias bibliográficas Google Scholar (en relación a IA, sesgos y discriminación que pueden relacionarse con alumnado subrepresentado)
Herramientas de IA y discriminación	Nixon <i>et al.</i> (2024); Gin <i>et al.</i> (2024); Yang <i>et al.</i> (2020); Gu y Ming (2023)	Borji (2023); Wolf (2023); Seyyed-Kalantari <i>et al.</i> (2021); Retzlaff (2024); Ghosh <i>et al.</i> (2021); Zack <i>et al.</i> , (2023); Dixon <i>et al.</i> (2018); Hutchinson <i>et al.</i> (2020); Sambasivan <i>et al.</i> , (2021); Salminen <i>et al.</i> (2018, 2019); Universidad de Austin (2020); Sclater (2016); Centre for Data Ethics and Innovation (2020); Ilkka (2018); Brown (2020); Conijn <i>et al.</i> (2022); Holmes <i>et al.</i> (2022); Chrysafiadi y Virvou, (2013); Sapiezynski <i>et al.</i> (2017); Leaton Gray y Kucirkova (2018), Crawford (2021); Lundy <i>et al.</i> (2019); Popenici y Kerr (2017); Olney <i>et al.</i> (2017); Baker y Hawn (2021); García-Bullé (2021); Teninbaum (2021); Holstein y Doroudi, (2021); Naismith y Juffs (2021); Finkelstein <i>et al.</i> (2013).
Herramientas IA para mitigar la discriminación y el abandono	Cano y Leonard (2019); Oskotsky <i>et al.</i> (2022); Duncan, <i>et al.</i> (2022); Guilbaud y Hirsch (2022); Tsai <i>et al.</i> (2018); Okolo (2024); Ojha <i>et al.</i> (2023).	Dalipi <i>et al.</i> (2018); Feng <i>et al.</i> (2019) Goel y Goyal (2020); Holmes <i>et al.</i> , (2022); Arnold y Pistilli (2012); Drigas y Ioannidou (2012); Kohli y Prasad, (2010); Jacobsson (2017); Anuradha <i>et al.</i> (2010); Stevens <i>et al.</i> (2019); Porayska-Pomsta <i>et al.</i> (2018); Scassellati (2012); Boccanfuso <i>et al.</i> (2016); Nkambou <i>et al.</i> (2018); Rosé <i>et al.</i> (2018).
IA y docentes para mejorar la inclusión	Duncan <i>et al.</i> (2022); Gin <i>et al.</i> (2024);	Nazaretsky <i>et al.</i> (2021); Cyndecka (2020); BBC (2020); Ashrafi y Javadi, (2024); Bogen y Rieke, (2018)
Políticas y procesos públicos: IA con impacto en el aprendizaje de alumnado subrepresentado	Gu y Ming (2023); Kröplin <i>et al.</i> (2024); Nixon <i>et al.</i> (2024); Tsai <i>et al.</i> (2018); Ojha <i>et al.</i> (2023).	Dennis (2018); Marcinkowski <i>et al.</i> (2020); Zeide (2019); Drigas y Ioannidou, (2012); Kohli y Prasad (2010); Jacobsson (2017); Anuradha <i>et al.</i> (2010); Stevens <i>et al.</i> (2019); Porayska-Pomsta <i>et al.</i> (2018); Scassellati (2012); Boccanfuso <i>et al.</i> (2016); Nkambou <i>et al.</i> (2018); Rosé <i>et al.</i> (2018); Hwang <i>et al.</i> (2020); Gray (2017); Smirnov (2018); Hickey y Hossain (2019); Hendry (2018); Nkambou <i>et al.</i> (2018); Rosé <i>et al.</i> (2018); Ojha <i>et al.</i> (2023).

Fuente: Elaboración propia (2024).

La revisión de la literatura resalta la aplicación cada vez mayor de la IA en el aula en diversos ámbitos; el incremento del interés sobre la temática en todas las áreas, especialmente en la educación universitaria; y la diversidad de estudios que se centran principalmente en cuatro aspectos: a) la descripción y el análisis de herramientas de IA que pueden generar discriminación en alumnado subrepresentado; b) herramientas que pueden mitigar estos resultados constatados los errores, sesgos y otros; c) ejemplos de aplicaciones y su utilidad por los propios docentes para mejorar la inclusión; y d) políticas y procesos públicos en relación a implementación de la IA con impacto en el aprendizaje del alumnado subrepresentado (véase Tabla 1).

3.2. IA e impacto en el alumnado subrepresentado

La Universidad de Texas (Austin) lanzó un sistema de IA llamado GRADE para recomendar si un solicitante debe ser admitido, en función de sus puntajes de exámenes, antecedentes académicos previos y aportes textuales (como cartas de recomendación) (Waters y Miiikkulainen 2014). Sin embargo, para 2020, GRADE se había eliminado debido a sus diversos sesgos (Universidad de Austin, 2020). Gu y Ming (2023) han examinado la relación entre la discriminación social experimentada en la escuela secundaria y la matriculación en la

universidad. El sistema de un curso en la Universidad de Purdue, que inicialmente pareció tener un impacto positivo en la retención del alumno (Arnold y Pistilli 2012) se enfrentó a discusiones académicas controvertidas sobre los hallazgos. Sclater (2016) ha señalado debilidades como la falta de coherencia en la gran variedad de fuentes de datos; la falta de resultados significativos de la investigación cualitativa; la mala interpretación de los datos; la complejidad de los sistemas que en ocasiones impiden la generalización de los resultados; o la realización de clasificaciones erróneas de patrones; o hallazgos contradictorios y amenazas en relación a la privacidad o la ética. A ello puede añadirse la tipología de los datos, a veces especialmente sensibles: por ejemplo, la Universidad de Derby utilizó análisis para garantizar que su toma de decisiones sobre el apoyo a los estudiantes negros y de minorías étnicas (BME) se basara en la evidencia.

El uso de software de supervisión durante la pandemia de COVID-19 ha planteado varias preocupaciones de equidad, incluidas las dificultades para identificar los rostros de los estudiantes de color, presumiblemente debido a los sesgos en los conjuntos de datos en los que se capacitaban las tecnologías de reconocimiento facial (García-Bullé, 2021; Teninbaum, 2021; Holstein y Doroudi, 2021). El estudio del Consejo de Europa "Dos clics hacia adelante y un clic hacia atrás" (Lundy *et al.* 2019) señala que los niños con discapacidad, independientemente de la naturaleza de su diversidad, están desproporcionadamente desfavorecidos cuando usan tecnologías digitales, y no fueron diseñadas originalmente para la educación, sino que han sido reutilizadas desde otros lugares. Estos incluyen algunas tecnologías de asistencia, como texto a voz, voz a texto, texto predictivo, correctores ortográficos y motores de búsqueda (Popenici y Kerr 2017). Esta reutilización no siempre es exitosa. El ruido ambiental en las aulas a menudo significa que el reconocimiento de voz no funciona bien (Olney *et al.* 2017), no son tan abundantes comercialmente, y hasta la fecha ha habido poco trabajo sobre sesgos algorítmicos o de datos específicos para la educación y la discapacidad del alumno (Baker y Hawn 2021). El colonialismo de algunas tecnológicas (recopilación y tratamiento de datos para el perfilado, capitalismo de vigilancia, plataformización) en su mayor parte en inglés americano estándar (Cotterell *et al.* 2020), plantea múltiples preguntas centradas en el impacto en contextos no ingleses, y en los niños que los usan (Naismith y Juffs 2021). Finkelstein *et al.* (2013) han afirmado que los estudiantes afroamericanos mostraban un razonamiento más científico cuando se les enseñaba un avatar virtual que hablaba completamente en inglés vernáculo afroamericano (AAVE), en comparación al inglés americano convencional (MAE).

Ya hemos mencionado los resultados positivos de algunas aplicaciones por varios autores (Drigas y Ioannidou, 2012; Kohli y Prasad, 2010; Jacobsson, 2017; Anuradha *et al.*, 2010; Stevens *et al.* 2019; Porayska-Pomsta *et al.* 2018; Scassellati, 2012; Boccanfuso *et al.*, 2016). La IA también está comenzando a utilizarse para diagnosticar la atención, la emoción y la dinámica de conversación de los estudiantes en entornos de aprendizaje asistidos por computadora, por ejemplo, para el desarrollo y la gestión de cursos, en un intento de generar grupos óptimos para tareas de aprendizaje colaborativo y reconocer patrones que predicen el abandono de los estudiantes (Nkambou *et al.*, 2018; Rosé *et al.*, 2018). Y ello desde diferentes técnicas como el enfoque de aprendizaje multivista (Cano y Leonard, 2019), sistemas de capacitación en línea (Oskotsky *et al.*, 2022) u otras aplicaciones (Duncan *et al.*, 2022; Guilbaud y Hirsch, 2022; Tsai *et al.*, 2018), la retroalimentación (Gin *et al.*, 2024), para identificar a los estudiantes con mayor riesgo en las clases de física (Yang *et al.*, 2020), e incluso para promover la diversidad y la inclusión en los equipos STEM (Nixon *et al.*, 2024).

Sin embargo, como hemos visto, y en algunos trabajos recientes (Centre for Data Ethics and Innovation, 2020; Ilkka, 2018) se destacan los límites técnicos, sociales, científicos y conceptuales de la IA en los sistemas educativos, y se señala la falta de evidencia

independiente sólida de su eficacia o éxito en la entrega de los resultados previstos. El uso de la supervisión electrónica es controvertido y ha sido acusado de intrusión, discriminación racial, de no funcionar correctamente, de impedir que los estudiantes realicen sus exámenes, y exacerbar los problemas de salud mental, mientras que tiene poco impacto en el engaño o el logro (Brown 2020; Conijn *et al.* 2022). Esto constituye un ejemplo de automatización y ampliación de las prácticas pedagógicas deficientes, en lugar de utilizar la IA para desarrollar enfoques innovadores. El cuello de botella técnico más importante de la IA es la disponibilidad de datos (Ilkka, 2018; Morozov 2014). Los usos convencionales de AIED para la enseñanza y el aprendizaje implican perfilar patrones de comportamiento o puntuación de logros para hacer predicciones (que pueden estar estereotipados), que pueden tener un efecto significativo en el estado mental o emocional del niño en desarrollo, y pueden hacerlo a escala (Chrysafiadi y Virvou, 2013). Este enfoque puede conducir a la discriminación en poblaciones subrepresentadas (Sapiezynski *et al.*, 2017). Inferir los estados de los alumnos a partir de indicadores o características como el género, el origen étnico o cultural e, incluso, el estatus socioeconómico, también introduce sesgos y amplía aún más las brechas existentes.

3.3. Principales desafíos normativos y éticos

Su utilización para apoyar las admisiones es incremental, y aunque algunos señalan ciertos esfuerzos relacionados con la equidad y la reputación de las instituciones (Dennis 2018; Zeide 2019; Marcinkowski *et al.* 2020; Gu y Ming, 2023; Kröplin *et al.*, 2024; Nixon *et al.*, 2024), como estos algoritmos de aprendizaje supervisado de IA se basan en datos históricos, solo pueden ver el mundo como una repetición del pasado. Esto tiene profundas implicaciones éticas. Cuando, por ejemplo, los estudiantes y sus logros se evalúan utilizando dichos sistemas de IA, la evaluación se basa necesariamente en criterios que reflejan sesgos culturales y medidas de éxito históricamente destacadas. A menudo se asume que los sistemas de IA permiten nuevos niveles de personalización y diversidad para los sistemas de información. Gran parte de esto, sin embargo, es el resultado de una categorización detallada que coloca a los usuarios en clases predefinidas (Holmes *et al.*, 2022). El argumento a favor de utilizar la IA para apoyar a los alumnos en contextos donde hay pocos docentes experimentados o cualificados, como en las zonas rurales de los países en desarrollo, podría ser más sólido. Sin embargo, el uso de la tecnología para sustituir a los maestros aborda el síntoma de este problema clave (los niños que no reciben la educación a la que tienen un derecho humano) en lugar de la causa (la escasez mundial de maestros).

Los desarrolladores de AIED tienden a estar basados en países WEIRD de altos ingresos, occidentales, educados, industrializados, ricos y democráticos (Pinkwart 2016) y, por lo tanto, están menos familiarizados con las necesidades de los jóvenes en los países en desarrollo (Schiff 2021). Al mismo tiempo, aunque no hay evidencia específica disponible, es probable que AIED sufra de la misma falta de diversidad por la cual la IA en general es bien conocida (West *et al.* 2019). Todo esto potencialmente tendría como resultado datos y algoritmos sesgados. Si bien el tema del sesgo en los datos y algoritmos ha sido objeto de mucha investigación (Baker y Hawn 2021; Suresh y Guttag 2019), el sesgo es en realidad un problema social que podría quedar para siempre sin poder conseguir una solución técnica (Powles 2018). Asimismo, como la mayoría de este tipo de aplicaciones están amparadas por derechos de propiedad intelectual e industrial, actúan como "black boxes", y ello genera dudas sobre la veracidad de la información. Se han documentado los sesgos políticos de ChatGPT en el tratamiento desigual de los grupos demográficos por parte de su sistema de moderación de contenido, al clasificar una variedad de comentarios negativos sobre algunos grupos demográficos como no odiosos, y en su mayor parte, los grupos que es más probable que "proteja" son aquellos que generalmente se cree que están en desventaja según la ideología de izquierda (Rozado, 2023a, 2023b; Johnson, 2023; Hartman *et al.*, 2023). Los

sistemas de IA con este tipo de sesgos pueden aumentar la polarización social existente, y no sólo en el contexto político, sino en todos los ámbitos sociales a los que los queramos extender como el de la educación. Se podría poner en riesgo la diversidad y pluralidad de voces imprescindibles en todo debate, contrastada con múltiples puntos de vista. Por eso es tan importante que su funcionamiento interno sea transparente, trazable y verificable.

La mayoría de las herramientas de IA para su uso en educación requieren un cierto nivel de competencia técnica y habilidades lingüísticas. En consecuencia, la IA puede exacerbar en lugar de mitigar inequidades en la educación para las comunidades marginadas, entre ricos y pobres, entre los capaces y los estudiantes con discapacidad, y entre aquellos que tienen acceso a una infraestructura de banda ancha confiable y aquellos que no lo tienen. Asimismo, cuando se someten a un monitoreo continuo, que por definición es invasivo, los escolares tienden a alterar su comportamiento para eludir las políticas y proteger su privacidad, libertad de expresión y libertad de asociación (Leaton Gray y Kucirkova 2018), y cualquier daño de dicha IA basada en predicciones, puede afectar a comunidades enteras, así como a individuos (Crawford 2021). Habrá un fuerte interés económico en el uso de sistemas de IA conectados a video en las aulas y para complementar los datos recopilados con datos de redes sociales y plataformas de Internet de las cosas (IoT). La privacidad y la seguridad de la IA se convierten en temas importantes también en la educación. Una sola sesión, con un niño interactuando con una IA u otro sistema de educación electrónica (como un MOOC o un serious game), puede generar "alrededor de 5-10 millones de puntos de datos procesables por estudiante cada día" (Hwang *et al.*, 2020) y existen prácticas en algunos centros como en la Universidad de Buckingham del Reino Unido (Gray 2017). Permiten recopilar múltiples evidencias (Olha *et al.*, 2023) como habilidades, experiencia y competencia de fuentes de datos abiertos, incluidas las redes sociales, las carteras de alumnos, y las insignias abiertas. Esto crea desafíos éticos y regulatorios inexplorados sobre todo en la utilización del Metaverso que proporcionará una gran exhaustividad en la elaboración de perfiles (una especie de panóptico 360°) (Ricoy-Casas, 2022). Un artículo reciente propuso ocho factores que influyen en la confianza de los docentes en la adopción de herramientas educativas basadas en IA, todos los cuales se centran en los profesores, y ninguno de los cuales requiere que los desarrolladores de IA hagan que sus herramientas sean confiables (Nazaretsky *et al.* 2021). Las directrices éticas de la Comisión Europea para AI25 confiables también deberían aplicarse a los sistemas AIED. Lo alarmante es su práctica incluso en la UE, utilizándose los seguimientos digitales para predicciones de las puntuaciones PISA (Smirnov, 2018).

¿Cómo podemos crear conjuntos de datos y modelos que sean equilibrados y representativos para todas las poblaciones educativas y que no refuercen el sesgo? Alternativamente, ¿cómo podemos diseñar enfoques metodológicos que nos permitan corregir el sesgo, si eso es posible, y desarrollar sistemas que salvaguarden la equidad? ¿Podrían favorecer los resultados de exámenes finales en el histórico de un centro educativo, no en relación a las calificaciones anteriores de un estudiante individual, a escuelas previamente exitosas (generalmente aquellas en distritos socioeconómicos más altos) y penalizar a los estudiantes en escuelas de bajo rendimiento (generalmente en zonas con menores medios)? Ello puede ser una realidad como ha relatado algún autor (Cyndecka, 2020; BBC, 2020), y lejos de la retórica dominante de la "personalización algorítmica", tuvo graves consecuencias para los estudiantes individuales, impactando negativamente en su acceso a la educación superior o en su entrada al mundo del trabajo. Estados Unidos ha visto una proliferación de empresas de consultoría que ofrecen análisis predictivos a instituciones educativas para el reclutamiento y retención de personal y estudiantes, y la IA se está utilizando a nivel estatal en la India para abordar el problema perenne de las tasas de retención más allá de la escuela primaria, especialmente para las niñas. Sin embargo, tales usos de la tecnología pueden ser engañosos, ya que las medidas de participación no son medidas de calidad o equidad. En la

UE se ha identificado como "de alto riesgo" y "sujetos al cumplimiento de ciertos requisitos obligatorios" a los "sistemas de IA destinados a ser utilizados con el fin de evaluar a los estudiantes" (Exposición de Motivos (5.2.3) del Reglamento Europeo COM(2021) 206 final).

4. Discusión

El Comité de Ministros del Consejo de Europa (2019) adoptó una recomendación por la que instaba a educadores y gestores a ser conscientes de los desafíos éticos que plantea el uso de herramientas de IA. Las implicaciones éticas del uso de los modelos algorítmicos obligan a adoptar un principio de precaución, la necesidad de analizar en el caso concreto cuáles son los potenciales beneficios, qué riesgos pueden derivarse, y cómo es posible mitigarlos. Los resultados permiten una nítida comprensión del desarrollo e implementación de la IA en educación y su relación con el alumnado subrepresentado, las dificultades a las que en la actualidad se enfrentan los operadores gubernamentales, y el grado de aceptación por la ciudadanía. Se visibiliza también que hay poca investigación sobre por qué las minorías subrepresentadas tienen menos probabilidades de estudiar específicamente el aprendizaje automático y la inteligencia artificial, y pueden ser discriminadas por este tipo de aplicaciones disruptivas. Existen oportunidades, pero también enormes implicaciones y desafíos que justifican una mayor discusión crítica e investigación sobre su impacto mientras no exista una regulación sólida y garantista en casos concretos, por ejemplo desde la óptica de la ética por diseño, a favor de los DDFF.

Debe establecerse un control humano de los contenidos generados mediante IA para garantía de los derechos en riesgo. La IA es solo una herramienta, pero es deber ineludible de los gobiernos y los parlamentos construir un andamiaje legislativo robusto que garantice un uso responsable y conforme a los valores democráticos. La educación es propensa a ser altamente politizada. Para algunos autores, crear un plan de estudios o determinar cómo debe ocurrir el aprendizaje son actos políticos (Hickey y Hossain, 2019). Pero si además, el uso de la IA y los algoritmos.

- 1) no son infalibles;
- 2) sin intencionalidad o sin ser detectados, pueden heredar sesgos de programadores, usuarios, bancos de datos o fuentes de información de las cuales se alimentan;
- 3) su verificabilidad 100% es imposible en el estado actual de su desarrollo, debido a su sistema autónomo de aprendizaje; y
- 4) no son completamente transparentes ("black boxes") que en ocasiones justifica la desregulación, la autorregulación o la gobernanza impulsada por el mercado, en una instrumentalización del lenguaje ético por parte de las empresas tecnológicas, de "lavado ético" (Bietti 2020).

Asimismo, cuando los sistemas de IA predicen nuestros actos utilizando datos históricos promediados sobre un gran número de otras personas, no pueden entender ciertas decisiones. Aun cuando las decisiones algorítmicas pueden basarse en datos objetivos, no siempre son las mejores. Un estudio en Australia donde se realizó un experimento con repartidores, mostró que los aplicativos marcaban un lugar, pero ellos iban por donde había sombra, para evitar "morir" de sed o tener una insolación en determinadas épocas del año. El algoritmo detectó que estaban utilizando una ruta más lenta, no tuvo en cuenta la temperatura ni la fatiga. Esta necesidad de protección es una explicación que le valdría a cualquier ser humano, pero no para un algoritmo que no hubiera sido programado con esa

variable (Montero, 2021). La IA no es capaz de la profundidad de interpretación o precisión del análisis que un maestro humano puede dar (Byrne *et al.* 2010; Holmes *et al.* 2019), una preocupación que llevó a Australia a abandonar los planes de usar la calificación automatizada para exámenes estatales (Hendry 2018). Incluso si la IA fuera capaz de marcar de manera justa y precisa el texto libre, la implementación de un sistema de este tipo también ignoraría cuánto aprende un maestro sobre sus alumnos cuando leen lo que el alumno ha escrito, ideas que ningún panel de control proporcionará. En resumen, si bien la IA podría ahorrar tiempo al profesorado, aunque hay poca evidencia de ello, todavía no está claro cuál podría ser el impacto en la calidad de la enseñanza y el aprendizaje.

Existen además numerosas lagunas que alimentan numerosos interrogantes tales como: ¿quién puede recopilar esas huellas digitales?; ¿cómo se transforman en conocimiento útil?; ¿quién tiene acceso a él y quién se beneficia?; ¿se utilizan estos datos con fines de inteligencia empresarial?; ¿qué y cómo se filtran estos datos al alumnado, al profesorado, o son gestionados por los sistemas académicos, administrativos o gubernamentales?; ¿son evaluados los sesgos?; ¿se garantiza la diversidad y la equidad?; ¿qué impacto ocasionan estos sistemas en el derecho a la educación, a la dignidad, a la autonomía, a ser escuchado, a no sufrir discriminación, a la privacidad y la protección de datos? Se ha sugerido que un enfoque de aprendizaje basado en competencias, tal como lo adopta gran parte de la IA diseñada para la educación, es inevitablemente utilitario y está orientado a satisfacer las necesidades sociales y económicas en lugar de las necesidades del alumno (Ashrafi y Javadi, 2024). Si la IA se generaliza en la educación mientras no se corrigen estos errores y sesgos que pueden tener efectos negativos en alumnado subrepresentado, se degradarán los propios valores humanistas y redundará en un mayor desequilibrio de algunos grupos sociales.

Todos esos datos, podrían incluso utilizarse en estadios posteriores, en la contratación. Los diferentes tipos de plataformas publicitarias en línea permiten a los empleadores dirigirse a los posibles solicitantes de formas muy diferentes, por ejemplo: promocionar sus ofertas de trabajo a tipos particulares de solicitantes de empleo; colocar sus anuncios junto a las consultas de búsqueda (en los motores de búsqueda y eligiendo determinados factores como las ubicaciones geográficas, estudios cursados en determinados centros educativos); los sitios de redes sociales permiten a los empleadores mostrar anuncios que se combinan con otro contenido social, segmentados en función de una amplia gama de características personales. Muchas redes publicitarias utilizan datos proporcionados por los usuarios e inferidos de su actividad en línea. Los datos se utilizan para generar automáticamente grupos de usuarios con ciertos atributos compartidos que los reclutadores pueden usar para orientar anuncios (o excluir que las personas vean) anuncios. (Bogen y Rieke, 2018). Ello expone numerosos riesgos, pues las tecnologías predictivas pueden desempeñar roles muy diferentes a lo largo del embudo de contratación: 1) determinar quién y qué ve (en relación a los anuncios de trabajo); 2) estimar el desempeño de un solicitante; 3) pronosticar los requisitos salariales de un candidato. Es por ello importante la información que se recabe, incluso en el ámbito educativo, porque puede ser errónea, sesgada, discriminatoria y condenar a un círculo vicioso el futuro laboral de un estudiante.

5. Conclusiones

Existen ya múltiples temores en relación a la utilización de la IA: en relación a la accesibilidad e integridad de los datos personales; la intromisión en la intimidad de las personas; fallos técnicos y de seguridad que pueden producir graves daños y/o perjuicios (a las personas, a las infraestructuras críticas); su inclusión podría ocasionar la destrucción de trabajo, eliminación de ciertos sectores o menor empleabilidad por la introducción de máquinas o trabajo invisibilizado y mal pagado generalmente realizados por trabajadores de

economías en desarrollo (APC, 2019); toma de decisiones discriminatorias sin cumplir criterios éticos, por ejemplo en la selección de empleados y en ciertas contrataciones por empresas y administraciones (sesos algorítmicos); la modificación de la propia cultura y los valores actuales; y ciertas repercusiones en el medio ambiente, pues la tecnología, especialmente algunas de intensiva utilización de minerales y fuentes de electricidad, no son neutras, además de todos los aspectos sobre los que hemos tenido de reflexionar a colación de la relación entre IA y alumnado subrepresentado. Es por ello, que la identificación, reflexión y regulación de casos como los señalados, resultan decisivos.

Existen oportunidades, pero también enormes implicaciones y desafíos que justifican una mayor discusión crítica e investigación sobre su impacto en la educación, y adoptar el principio de precaución mientras no exista una regulación sólida y garantista, ya desde la óptica de la ética por diseño, a favor de los DDF. Es necesario desarrollar planes de estudio acordes con la revolución que suponen algunas tecnologías disruptivas que incorporen la alfabetización en IA y el conocimiento de ciertos riesgos en su implementación. Sólo el conocimiento en todas sus dimensiones puede hacer crecer una sociedad, y considerarse verdaderamente democrática en sus elecciones. Muchas de estas cuestiones deben seguir debatiéndose en foros como la Declaración de Montreal para el Desarrollo Responsable de la Inteligencia Artificial (2018) o el Marco Europeo de Competencias Digitales para los Ciudadanos. En consecuencia, es esencial que los gobiernos, las empresas y las organizaciones, que actúan en entornos educativos, reconozcan que los algoritmos no pueden perfilar a los humanos de manera justa y equitativa, y debemos desafiar la creencia de que los algoritmos son objetivos y pueden predecir con seguridad el comportamiento humano, especialmente el comportamiento de los niños. El uso indiscriminado de la IA para el reconocimiento automatizado de características humanas en espacios de acceso público (rostros, huellas dactilares, ADN, voz, pulsaciones de teclas y otras señales biométricas o de comportamiento) en cualquier contexto (especialmente en entornos educativos), es peligroso, porque también lo es la personalización y el perfilado encubierto, opaco con el cual intervenir, sin que los directamente interesados accedan a dicha información y puedan tomar decisiones informadas.

6. Referencias

- Access Now (2018). *Human rights in the age of artificial intelligence*. AccessNow. bit.ly/4bITs0r
- Anuradha, J., Tisha, Ramachandran, V., Arulalan, K. V. y Tripathy, B. K. (2010). Diagnosis of ADHD using SVM algorithm. *Proceedings of the Third Annual ACM Bangalore Conference*. 1-4. <https://doi.org/10.1145/1754288.1754317>
- APC (Association for Progressive Communications) (2019). *Artificial intelligence: human rights, social justice and development*. Global Informat. Society Watch. <https://goo.su/697XaJa>
- Arnold K. E. y Pistilli M. D. (2012). Course signals at Purdue: using learning analytics to increase student success. *LAK12: Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*, 267-70. <https://doi.org/10.1145/2330601.2330666>
- Ashrafi F. y Javadi A. (2024). Correct characteristics of the newly involved artificial intelligence methods in science and technology using statistical data sets, *International Journal of Modern Engineering Technologies* 1(1), 1,13. <https://icdst.ir/OAJ/index.php/IJMET/article/view/30>
- Asimov, I. (1942). *Runaround, Astounding Science Fiction*. Street y Smith

- Baker, R. S. y Hawn, A. (2021). Algorithmic bias in education. *International Journal of Artificial Intelligence in Education*, 1-41. <https://doi.org/10.35542/osf.io/pbmvz>
- BBC (2020). A-levels: Algorithm at centre of grading crisis 'unlawful' says Labour. *BBC News* <https://www.bbc.com/news/uk-politics-53837722>
- Benaich, N. (2020). AI has disappointed on Covid, *Financ. Times*. <https://acortar.link/KcpeTZ>
- Bietti, E. (2020). From ethics washing to ethics bashing: a view on tech ethics from within moral philosophy. *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency*, 210-19. <https://dl.acm.org/doi/abs/10.1145/3351095.3372860>
- Biggs P. et al. (2018). *The state of broadband 2018: broadband catalyzing sustainable*. <http://handle.itu.int/11.1002/pub/810d0472-en>
- Borji, A. (2023). A categorical archive of chatgpt failures. <https://doi.org/10.48550/arXiv.2302.03494>
- Brown, L. X. (2020). *How automated test proctoring software discriminates against disabled students*. Center for Democracy and Technology. bit.ly/4f7dm8z
- Byrne, R., Tang, M., Truduc, J. y Tang, M. (2010). eGrader, a software application that automatically scores student essays: with a postscript on the ethical complexities. *Journal of Systemics, Cybernetics & Informatics*, 8(6), 30-35. <https://www.iiisci.org/journal/pdv/sci/pdfs/MJ910TT.pdf>
- Boccanfuso, L., Barney, E., Foster, C., Ahn, Y. A., Chawarska, K., Scassellati, B. y Shic, F. (2016). Emotional robot to examine different play patterns and affective responses of children with and without ASD. *11th ACM/IEEE Intern. Conf. on Human-Robot Inter. (HRI)*, 19-26. IEEE. <https://doi.org/10.1109/HRI.2016.7451729>
- Bogen, M. y Rieke, A. (2018). Help Wanted: An Examination of Hiring Algorithms, Equity, and Bias, *Upturn*, 26-39. <https://www.upturn.org/reports/2018/hiring-algorithms/>
- Cano, A. y Leonard, J. D. (2019). Interpretable multiview early warning system adapted to underrepresented student populations. *IEEE Transactions on Learning Technologies*, 12(2), <https://doi.org/198-211.10.1109/TLT.2019.2911079>
- Centre for Data Ethics and Innovation (2020). *Review into bias in algorithmic decision-making*. bit.ly/4d1JuZb
- Chrysafiadi K. y Virvou M. (2013). Student modeling approaches: a literature review for the last decade. *Expert Systems with Applications* 40(11), 4715-4729. <https://doi.org/10.1016/j.eswa.2013.02.007>
- Conijn, R., Kleingeld, A., Matzat, U. y Snijders, C. (2022). The fear of big brother: The potential negative side-effects of proctored exams. *Journ. of Comp. Assisted Learn.*, 38(6), 1521-1534. <https://doi.org/10.1111/jcal.12651>
- Cotterell, R., Mielke, S. J., Eisner, J. y Roark, B. (2018). *Are all languages equally hard to language-model?* <http://arxiv.org/abs/1806.03743>

- Crawford K. (2021). *Atlas of AI: power, politics, and the planetary costs of artificial intelligence*. Yale University Press.
- Cyndecka M. A. (2020). *A dystopian story about Covid-19, artificial intelligence setting grades and the GDPR*. EFTA-Studies. bit.ly/467EMqB
- Dalipi F., Imran A. S. y Kastrati Z. (2018). MOOC dropout prediction using machine learning techniques. *EDUCON*, 1007-1014. <https://doi.org/10.1109/EDUCON.2018.8363340>
- Dennis M. J. (2018). Artificial intelligence and recruitment, admission, progression, and retention. *Enrollment Management Report*, 22(9), 1-3, <https://doi.org/10.1002/emt.30479>
- Dixon, L., Li, J., Sorensen, J., Thain, N. y Vasserman, L. (2018). Measuring and mitigating unintended bias in text classification. *AAAI/ACM Confer. on AI, Ethics, and Society*, 67-73. <https://doi.org/10.1145/3278721.3278729>
- Drigas, A. y Ioannidou, R. E. (2012). Artificial Intelligence in Special Education: A Decade Review. *International Journal of Engineering Education* 28(6), 1366-1372. bit.ly/3LqyQ2m
- Duncan, D., Garner, R., Bennett, A., Sinclair, M., Ramirez-de la Cruz, G. y Pasik-Duncan, B. (2022). Interdisciplinary K-12 Control Education in Biomedical and Public Health Applications. *IFAC-PapersOnLine*, 55(17), 242-248. <https://doi.org/10.1016/j.ifacol.2022.09.286>
- Feng W., Tang J. y Liu T. X. (2019). Understanding dropouts in MOOCs. *Proc. of the AAAI Conf. on AI*, 33(1), 517-24. <https://doi.org/10.1609/aaai.v33i01.3301517>
- Finkelstein, S., Yarzebinski, E., Vaughn, C., Ogan, A., y Cassell, J. (2013). The effects of culturally congruent educational technologies on student achievement. *Intern. Conf. on Artificial Intelligence in Education*. (pp.493-502). Springer.
- García-Bullé, S. (2021). The dark side of online exam proctoring. *Observatorio de Innov. Educativa*. <https://observatory.tec.mx/edu-news/dark-side-proctored-exams>
- Gin, B. C., Ten Cate, O., O'Sullivan, P. S. y Boscardin, C. (2024). Assessing supervisor versus trainee viewpoints of entrustment through cognitive and affective lenses. *Advances in Health Sciences Education*, 1-22. <https://doi.org/10.1007/s10459-024-10311-9>
- Goel Y. y Goyal R. (2020). On the effectiveness of self-training in MOOC dropout Prediction. *Open Computer Sci*, 10(1), 246-58. <https://doi.org/10.1515/comp-2020-0153>
- Ghosh, S., Baker, D., Jurgens, D. y Prabhakaran, V. (2021). *Detecting cross-geographic biases in toxicity modeling on social media*. <https://arxiv.org/pdf/2104.06999>
- Gray J. (2017). University of Buckingham to monitor students' social media accounts to tackle depression and suicide. *HuffPost UK*. bit.ly/468zAD6
- Gu, J. y Ming, X. (2023). Social discrimination and college enrollment. *Asia Pacific Educ. Review*, 24(1), 57-69. <https://doi.org/10.1007/s12564-021-09725-6>

- Guilbaud, P. y Hirsch, M. J. (2022, June). Promoting Equity and Achievement in Real-Time Learning (PEARL). *International Conference on Human-Computer Interaction* (pp. 159-173). Springer. https://doi.org/10.1007/978-3-031-05887-5_12
- Hartmann, J., Schwenzow, J. y Witte, M. (2023). *The political ideology of conversational AI: Converging evidence on ChatGPT's pro-environmental, left-libertarian orientation*. <https://doi.org/10.48550/arXiv.2301.01768>
- Heaven, D. (2019). Why deep-learning AIs are so easy to fool. *Nature*, 574 (7777), 163-166. <https://doi.org/10.1038/d41586-019-03013-5>
- Heaven W. D. (2021). Hundreds of AI tools have been built to catch covid. None of them helped, *MIT Technology Review*. bit.ly/4cEaIoV
- Hendry J. (2018, Junio, 30). Govts dump NAPLAN robo marking plans. *ITnews*. www.itnews.com.au/news/govts-dump-naplan-robo-marking-plans-482044
- Hickey, S. y Hossain, N. (Eds) (2019). *The Politics of Education in Developing Countries: From Schooling to Learning*. Oxford. <https://doi.org/10.1093/oso/9780198835684.001.0001>
- Holmes W. (2020, Febrero, 21). The right kind of AI in education. *Nesta*. bit.ly/3xVK3Fa
- Holmes, W., Persson, J., Chounta, I.A., Wasson, B., y Dimitrova, V. (2019) *Artificial intelligence and education - A critical view through the lens of human rights, democracy and the rule of law*. Council of Europe Publishing. bit.ly/3W3v6Jg
- Holstein, K. y Doroudi, S. (2021). *Equity and Artificial Intelligence in Education: Will "AIEd" Amplify or Alleviate Inequities in Education?* <https://doi.org/10.48550/arXiv.2104.12920>
- Hutchinson, B., Prabhakaran, V., Denton, E., Webster, K., Zhong, Y. y Denuyl, S. (2020). *Social biases in NLP models as barriers for pers. with disabilities*. <https://arxiv.org/pdf/2005.00813>
- Hutson, M. (2021). Robo-writers: the rise and risks of language-generating AI. *Nature*, 591(7848). 22-25. <https://doi.org/10.1038/d41586-021-00530-0>
- Hwang, G. J., Xie, H., Wah, B. W. y Gašević, D. (2020). Vision, challenges, roles and research issues of Artificial Intelligence in Education. *Computers and Education: AI*, 1(100001). <https://doi.org/10.1016/j.caeai.2020.100001>
- Ilkka, T. (2018). *The impact of artificial intelligence on learning, teaching, and education*. European Union. <https://hdl.handle.net/20.500.12799/6021>
- Jakobsson, J. (2017, Marzo, 29). Nya miljoner ska ta deras dyslexi-startup till USA. *Di Digital*. bit.ly/3xXHRwM
- Johnson, A. (2023, Febrero, 03). Is ChatGPT Partisan? Poems About Trump And Biden Raise Questions About The AI Bot's Bias—Here's What Experts Think. *Forbes*. bit.ly/3xXFFFA

- Kocoń, J., Cichecki, I., Kaszyca, O., Kochanek, M., Szydło, D., Baran, J., Bielaniec, J., Gruza, M., Janz, A., Kanclerz, K., Kocoń, A., Koptyra, B., Mieszczewicz, W., Miłkowski, P., Oleksy, M., Piasecki, M., Radliński, L., Wojtasik, K., Woźniak, S. y Kazienko, P. (2023). ChatGPT: Jack of all trades, master of none. *Information Fusion*, 99, 101861. <https://doi.org/10.1016/j.inffus.2023.101861>
- Kohli, M. y Prasad, T. V. (2010, June). Identifying dyslexic students by using artificial neural networks. *Proceedings of the world congress on engineering*, 1(1). 1-4. https://www.iaeng.org/publication/WCE2010/WCE2010_pp118-121.pdf
- Kröplin, J., Maier, L., Lenz, J. H. y Romeike, B. (2024). Knowledge Transfer and Networking Upon Implementation of a Transdisciplinary Digital Health Curriculum in a Unique Digital Health Training Culture. *JMIR Medical Education*, 10, e51389. <https://doi.org/10.2196/51389>
- Kurzweil, R. (2005). *The singularity is near. In Ethics and emerging technologies*, 393-406. Palgrave Macmillan UK. https://doi.org/10.1057/9781137349088_26
- Leaton S. H. y Kucirkova N. (2018). A united and thriving Europe? A sociology of the European Schools' and 'If personalised education and artificial intelligence are a democratic problem, could pluralisation be the democratic solution? *Proceedings of British Educational Research Association (BERA) Annual Conference*, 11-13. <https://acortar.link/1b5e4T>
- Ledford, H. (2019). Millions affected by racial bias in health-care algorithm. *Nature*, 574(31), 608-609. <https://doi.org/10.1038/d41586-019-03228-6>
- Lundy, L., Byrne, B., Templeton, M. y Lansdown, G. (2019). *Two clicks forward and one click back*. Council of Europe. bit.ly/4d1RCsy
- Marcinkowski, F., Kieslich, K., Starke, C. y Lünich, M. (2020). Implications of AI (un-)fairness in higher education admissions. *Conference on Fairness, Accountability, and Transparency*, 122-130. <https://doi.org/10.1145/3351095.3372867>
- Marcus, G. y Davis, E. (2020). GPT-3, Bloviator: OpenAI's language generator has no idea what it's talking about. *MIT Technology Review*. bit.ly/3y0x84I
- Montero, S. (2021, Marzo, 27). Los algoritmos y sus sesgos de género, raza o clase: así te perjudican en la búsqueda de trabajo o de ayudas sociales. *Público*. bit.ly/4d0PYaR
- Morozov E. (2014). *To save everything, click here: technology, solutionism, and the urge to fix problems that don't exist*. Penguin.
- Naismith, B. y Juffs, A. (2021). Finding the sweet spot: Learners' productive knowledge of mid-frequency lexical items. *Language Teaching Research*, 28(3), 1106-1142. <https://doi.org/10.1177/13621688211020412>
- Newton, D. (2021). Artificial Intelligence grading your 'neuroticism'? Welcome to colleges' new frontier. *USA Today*. bit.ly/4bPl18u

- Nixon, N., Lin, Y. y Snow, L. (2024). Catalyzing Equity in STEM Teams: Harnessing Generative AI for Inclusion and Diversity. *Policy Insights from the Behavioral and Brain Sciences*, 11(1), 85-92. <https://doi.org/10.1177/23727322231220356>
- Nkambou, R., Azevedo, R. y Vassileva, J. (Eds.). (2018). Intelligent Tutoring Systems: 14th International Conference. *ITS 2018, Montreal, QC, Canada, Proc.* Springer.
- Nazaretsky, T., Cukurova, M. y Alexandron, G. (2022, March). An instrument for measuring teachers' trust in AI-based educational technology. *LAK22: 12th intern. learning analytics and knowledge conference*. <https://doi.org/10.1145/3506860.3506866>
- Ojha, V., Perdriau, C., Lagesse, B. y Lewis, C. M. (2023). Computing Specializations. *54th ACM Technical Symposium on Computer Science Education*, 1, 966-972. <https://doi.org/10.1145/3545945.3569782>
- Okolo, C. T. (2024). Beyond AI Hype: A Hands-on Workshop Series for Enhancing AI Literacy in Middle and High School Students. *RESPECT 2024: Proceedings of the 2024 on RESPECT Annual Conference* (pp. 86-93). <https://doi.org/10.1145/3653666.3656075>
- Olney, A. M., Donnelly, P. J., Samei, B. y D'Mello, S.K. (2017). Assessing the Dialogic Properties of Classroom Discourse. *Data Min Soc.* 162-67. <https://files.eric.ed.gov/fulltext/ED596578.pdf>
- Oskotsky, T., Bajaj, R., Burchard, J., Cavazos, T., Chen, I., Connell, W. T., Eaneff, S. y Sirota, M. (2022). Nurturing diversity and inclusion in AI in Biomedic. through a virtual summer program for high school students. *PLoS comput. biology*, 18(1), e1009719. <https://doi.org/10.1371/journal.pcbi.1009719>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., [...] y Mulrow, C.D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372(71), 1-9. <https://doi.org/10.1136/bmj.n71>
- Pinkwart, N. (2016). Another 25 years of AIED? Challenges and opportunities for intelligent educational technologies of the future. *International journal of artificial intelligence in education*, 26, 771-783. <https://doi.org/10.1007/s40593-016-0099-7>
- Popenici S.A.D. y Kerr S. (2017). Exploring the impact of artificial intelligence on teaching and learning in higher education. *Research and Practice in Technology, Enhanced Learning* 12 (22). <https://doi.org/10.1186/s41039-017-0062-8>
- Porayska-Pomsta, K., Alcorn, A. M., Avramides, K., Beale, S., Bernardini, S., Foster, M. E., [...] y Smith, T. J. (2018). Blending human and AI to support autistic children's social commun. skills. *TOCHI*, 25(6), 1-35. <https://doi.org/10.1145/3271484>
- Powles J. (2018). The seductive diversion of 'solving' bias in artificial intelligence, *OneZero*. bit.ly/3Sb6i0O
- PRISMA. (s. f.). *PRISMA 2020 Checklist*. <https://prisma.shinyapps.io/checklist/>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., [...] y Ng, A. Y. (2017). *Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning*. <http://arxiv.org/abs/1711.05225>

- Retzlaff, N. (2024). Political Biases of ChatGPT in Different Languages. *Preprints 2024*, 2024061224 <https://doi.org/10.20944/preprints202406.1224.v1>
- Ricoy-Casas, R. M. (2019). Inteligencia artificial y políticas públicas en la UE. *Derecho, desarrollo y nuevas tecnologías* (pp. 187-234). Thomson Reuters Aranzadi.
- Ricoy-Casas, R. M. (2021a). Sesgos y algoritmos: inteligencia de género y Algunos dilemas éticos en la utilización de la inteligencia artificial y los algoritmos. En P.R. Bonorino-Ramírez, R. Fernández, y P. Valcárcel (Dirs.). *Nuevas normatividades: inteligencia artificial, derecho y género*. Thomson Reuters Aranzadi.
- Ricoy-Casas, R. M. (2021b). Inteligencia artificial y administración de justicia: una política pública sub iudice. .R. Bonorino-Ramírez, R. Fernández, y P. Valcárcel e I.S. García (Dirs.). *Justicia, administración y derecho*. Thomson Reuters Aranzadi.
- Ricoy-Casas, R. M. (2022). The Metaverse as a New Space for Political Communication. En P.C. López-López, D. Barredo, Á. Torres-Toukoumidis, A. De-Santis y Ó. Avilés (eds) *Communication and Applied Technologies. Smart Innovation, Systems and Technologies*, 318. Springer. https://doi.org/10.1007/978-981-19-6347-6_29
- Roberts, M., Driggs, D., Thorpe, M., Gilbey, J., Yeung, M., Ursprung, S., [...] y Schönlieb, C. B. (2021). Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans. *Nature Machine Intelligence*, 3(3), 199-217. <https://doi.org/10.1038/s42256-021-00307-0>
- Romero A. (2021). Understanding GPT-3 in 5 minutes, *Medium*. bit.ly/4d0XceT
- Rosé, C. P., Martínez-Maldonado, R., Hoppe, H. U., Luckin, R., Mavrikis, M., Porayska-Pomsta, K., [...] y Du Boulay, B. (Eds.). (2018). *AIED. Part I*. Springer.
- Rozado, D. (2023). The Political Biases of ChatGP, *Soc. Sci.* 12, 148. <https://doi.org/10.3390/socsci12030148>
- Rozado, D. (2023b). Danger in the Machine: The Perils of Political and Demographic Biases Embedded in AI Systems. *Manhattan Institute*, 14/03/2023. bit.ly/3Wj2w82
- Salminen, J., Almerexhi, H., Kamel, A.M., Jung, S.G., y Jansen, B.J. (2019). Online hate ratings vary by extremes: A statistical analysis. *Confer. on human information interaction and retrieval*, 213-217. <https://doi.org/10.1145/3295750.3298954>
- Sambasivan, N., Arnesen, E., Hutchinson, B., Doshi, T. y Prabhakaran, V. (2021). Re-imagining algorithmic fairness in india and beyond. *Proceed. of the 2021 ACM confer. on fairness, accountab., and transp.*, 315-328. <https://doi.org/10.1145/3442188.3445896>
- Sapiezynski P., Kassarnig V. y Wilson C. (2017). *Academic performance prediction in a gender-imbalanced environment (Data set)*. Boise State Univ. <https://doi.org/10.18122/B20Q5R>
- Sclater N. (2016). *Learning analytics in higher education: a review of UK and international*. bit.ly/3xU3RZz

- Scassellati, B., Admoni, H. y Matarić, M. (2012). Robots for use in autism research. *Ann. Rev. of biom. Eng.*, 14(1). 275-294. <https://doi.org/10.1146/annurev-bioeng-071811-150036>.
- Schiff, D. (2021). Out of the laboratory and into the classroom. *AI & society*, 36(1), 331-348. <https://doi.org/10.1007/s00146-020-01033-8>
- Segovia-García, N. (2024). Optimización de la atención estudiantil: una revisión del uso de chatbots de IA en la educación superior. *European Public y Social Innovation Review*, 9, 1-20. <https://doi.org/10.31637/epsir-2024-324>
- Seyyed-Kalantari, L., Zhang, H., McDermott, M. B., Chen, I. Y. y Ghassemi, M. (2021). Underdiagnosis bias of artificial intelligence algorithms applied to chest radiographs in under-served patient populations. *Nature medicine*, 27(12), 2176-2182. <https://doi.org/10.1038/s41591-021-01595-0>
- Silver, D., Hubert, T., Schrittwieser, J., Antonoglou, I., Lai, M., Guez, A., Lanctot, M., Sifre, L., Kumaran, D., Graepel, T., Lillicrap, T., Simonyan, K. y Hassabis, D. (2017). *Mastering chess and shogi by self-play with a general reinforcement learning algorithm*. <http://arxiv.org/abs/1712.01815>
- Smirnov, I. (2018). Predicting PISA scores from students' digital traces. *Proc. Intern. AAAI Confer. on Web and Social Media*, 12(1). <https://doi.org/10.1609/icwsm.v12i1.14996>
- Stevens, E., Dixon, D. R., Novack, M. N., Granpeesheh, D., Smith, T. y Linstead, E. (2019). Identification and analysis of behavioral phenotypes in autism spectrum disorder via unsupervised machine learning. *International journal of medical informatics*, 129, 29-36. <https://doi.org/10.1016/j.ijmedinf.2019.05.006>
- Suresh, H. y Guttag, J. (2021). A framework for understanding sources of harm throughout the machine learning life cycle. *Equity and access in algorithms, mechanisms, and optimization*. EAAMO. <https://doi.org/10.1145/3465416.3483305>
- Teninbaum, G. H. (2021). Report on ExamSoft's ExamID Feature (and a Method to Bypass It). *Journ. of Robotics, AI, and Law*, 4. <http://dx.doi.org/10.2139/ssrn.3759931>
- Tsai, Y. T., Wang, C. C., Peng, H. S., Huang, J. H. y Tsai, C. P. (2018). Construction of artificial intelligence mechanical laboratory with engineering education based on CDIO teaching strategies. *Innovative Techn. and Learn.* 81-87. https://doi.org/10.1007/978-3-319-99737-7_8
- Universidad de Austin (2020). *Tweet del Departamento de Ciencias de la Computación UT Austin*. <https://twitter.com/UTCompSci/estado/1333890167782957060>
- Watters A. (2023). *Teaching machines*. The MIT Press
- Waters A. y Miikkulainen R. (2014). GRADE: machine learning support for graduate admissions. *AI Magazine* 35(1), 64. <https://doi.org/10.1609/aimag.v35i1.2504>
- West, S.M., Whittaker, M., y Crawford, K. (2019). Discriminating systems. *AI Now*, 1-33. bit.ly/4cEun8t
- Wolf, Z. B. (2023). *AI can be racist, sexist and creepy. What should we do about it*. bit.ly/4cJbn8I

- Yang, J., DeVore, S., Hewagallage, D., Miller, P., Ryan, Q. X. y Stewart, J. (2020). Using machine learning to identify the most at-risk students in physics classes. *Physical Review Physics Educ. Research*, 16(2), 020130. <https://doi.org/10.1103/PhysRevPhysEducRes.16.020130>
- Zack, T., Lehman, E., Suzgun, M., Rodriguez, J. A., Celi, L. A., Gichoya, J., Jurafsky, D., Szolovits, P., W. Bates, D., E. Abdalnour, R. E., Butte, A. J. y Alsentzer, E. (2023). Coding Inequity. *medRxiv*, 2023-07. <https://doi.org/10.1101/2023.07.13.23292577>
- Zeide, E. (2019). Artificial intelligence in higher education: Applications, promise and perils, and ethical questions. *Educause Review*, 54(3). <https://ssrn.com/abstract=4320049>

CONTRIBUCIONES DE AUTORES, FINANCIACIÓN Y AGRADECIMIENTOS

Contribuciones de los autores: **Conceptualización:** Ricoy-Casas, R.M.; **Software:** Ricoy-Casas, R.M. y Fernández-González, R.; **Validación:** Ricoy-Casas, R.M. y Fernández-González, R.; **Análisis formal:** Todos los autores; **Curación de datos:** Todos los autores; **Redacción-Preparación del borrador original:** Ricoy-Casas, R.M. y Fernández-González, R.; **Redacción-Revisión y Edición:** Todos los autores; **Visualización:** Todos los autores; **Supervisión:** Ricoy-Casas, R.M.; **Administración de proyectos:** Todos los autores; **Todos los/as autores/as han leído y aceptado la versión publicada del manuscrito.**

Financiación: Esta investigación no recibió financiamiento externo.

Agradecimientos: Rosa Ricoy ha realizado este trabajo en el marco de las actividades del Proyecto PID2022-136352NB-I00 financiado por MCIN/ AEI/10.13039/501100011033/ y FEDER; “UNESCO Chair: Transformative Education: Science, Communication and Society” 39 C/5; HYP Project (Hypothesis You Preserve) “Creative Europe Programme”. Raquel Fernández-González ha realizado este trabajo en el marco de las actividades de la ayuda posdoctoral ED481D 2023/002 de la Xunta de Galicia. Ambas realizan este trabajo en el Grupo de innovación docente (InnovAcción) e Instituto de Justicia y Género (IXEX) UVIGO.

Conflicto de intereses: No existen conflictos de intereses.

AUTORES:

Rosa María Ricoy-Casas

Universidad de Vigo. UNED-Lugo, España.

rricoy@uvigo.gal

Lecturer C.Política Uvigo (España) y Prof. Tut. *Venia Docendi* (Derecho y C. Política) UNED-Lugo. Doctora Derecho e Historia (Uvigo) y Lic. C.Políticas (UNED). Coord.-Directora del Grado en Dir. y Gestión Pública y Vicedecana (2015-2018) y Secretaria del Tribunal de Garantías (Uvigo) (2011-2014). Vicepresidenta ICOMOS España, Secretaria Doctorado CREA (Uvigo), IP española del proyecto de Europa Creativa “HYP you preserve”. Ha impartido docencia y conferencias en diversas y destacadas Univ., Congresos y Entidades púb. (INAP, EGAP, FEGAMP, Sorbonne, King’s College, Corvinus Budapest, Kielce Polonia, Firenze, Sao Paulo, Mar del Plata, Rep. de Irlanda, IPSA, AECPA, APCP, CEISAL, GIGAPP, REPS, etc). Ha

recibido varios premios (Consejo Abogacía Gallega, Fundac. Alternativas, Congreso-USC, o la Asoc. Española de C. Política).

Orcid ID: <https://orcid.org/0000-0002-9130-1102>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=15726227600>

Google Scholar: <https://acortar.link/e7SkT4>

Raquel Fernández-González

Universidad de Vigo, España.

raquelf@uvigo.es

Doctora en Economía (Premio extraordinario 2016). Investigación principal sobre temas relacionados con la gestión sostenible de los recursos naturales, centrándose en ámbitos como la pesca, acuicultura y energía. Como resultado de sus investigaciones, sus trabajos que han sido publicados en revistas como *Aquaculture*, *Energy*, *Reviews in aquaculture*, *Papers in Regional Science*, o *Aquaculture Economics & Management*. Ha realizado estancias internacionales en Universidades de Europa y Asia, así como también cuenta con experiencia en proyectos internacionales.

Índice H: 12

Orcid ID: <https://orcid.org/0000-0001-5356-2793>

Scopus ID: <https://www.scopus.com/authid/detail.uri?authorId=56536432000>

Google Scholar: <https://scholar.google.es/citations?user=i1wS0UAAAAJ&hl=es>

Miguel Santos-Garrido

Universidad de Vigo, España.

Diplomado en Ciencias empresariales por la Universidad de Vigo (premio extraordinario-), y Licenciado por la Universidad de Santiago. Profesor de secundaria en administración de empresas desde 2002 en Madrid. Máster en Educación secundaria (2003). Máster en dirección estratégica y responsabilidad social corporativa. Estudios sobre sostenibilidad, RSC (2020-2021). Doctorando en el programa de doctorado CREA de la Universidad de Vigo. Autor de publicaciones y participante en diversos congresos y seminarios. Ha sido revisor de una publicación de McGraw-Hill Education.

miguelsantosgarrido@gmail.com