

REVISIÓN

Educational Leadership Enhanced by Machine Learning: Proposal for a Conceptual Model for Executive Decision-Making in Public Educational Institutions in Peru

Liderazgo educativo aumentado por Machine Learning: propuesta de un modelo conceptual para la toma de decisiones directivas en instituciones educativas públicas del Perú

Rafael Romero-Carazas^{a*}  

^aSabal University, Florida, United States of America.

How to Cite:

Romero-Carazas, R. (2026). Educational Leadership Enhanced by Machine Learning: Proposal for a Conceptual Model for Executive Decision-Making in Public Educational Institutions in Peru. *Edu - Tech Enterprise*, 4, 139. <https://doi.org/10.71459/edutech2026139>

Submitted: 02-03-2026

Revised: 19-05-2026

Accepted: 22-07-2026

Published: 23-07-2026

ABSTRACT

School leadership is, after teachers' classroom practice, the second within-school factor with the greatest influence on student learning outcomes. In Arequipa's public educational institutions, however, principals' decision-making still relies mainly on experience and fragmented information, since the systematic use of evidence for school management remains an exceptional practice within the Peruvian educational system. At the same time, machine learning has become a consolidated tool capable of anticipating dropout risk, characterising school performance and sustaining dashboards for educational management. Nevertheless, the literature reviewed shows a disconnection between the technical advances of ML applied to education and the pedagogical leadership frameworks currently in force in developing countries' educational systems, which are marked by digital divides, low data literacy and technology-adoption barriers. This theoretical-conceptual article proposes an integrative model termed Machine-Learning-Augmented Educational Leadership (LEA-ML, for its Spanish acronym) articulating six dimensions: baseline pedagogical leadership, data infrastructure, the ML analytical layer, augmented decision interpretation, ethical governance and organisational adoption. The model was built through an integrative documentary analysis of 54 sources indexed in Scopus, Web of Science, Redalyc, SciELO, Dialnet and ERIC, published mostly between 2015 and 2026. Its relevance for the Arequipa context is discussed considering the existing infrastructure of the Educational Institution Management Support Information System (SIAGIE) and the region's persistent connectivity gaps. It is concluded that the model offers a pertinent theoretical basis for future empirical validation aimed at strengthening evidence-based school management among public-school principals.

Keywords: machine learning; educational leadership; evidence-based school management; school principals; public educational institutions; Arequipa.

RESUMEN

El liderazgo directivo constituye, después de la actuación docente en el aula, el segundo factor intraescolar con mayor incidencia sobre los logros de aprendizaje. Sin embargo, en las instituciones educativas públicas de la región Arequipa, la toma de decisiones directivas continúa apoyándose predominantemente en la experiencia y en información fragmentada, mientras que el uso sistemático de evidencia para la gestión escolar sigue siendo una práctica excepcional dentro del sistema educativo peruano. En paralelo, el *machine learning* se ha consolidado como una herramienta capaz de anticipar el riesgo de deserción, caracterizar el desempeño escolar y sostener paneles de control para la gestión educativa. No obstante, la literatura revisada evidencia una desconexión entre los avances técnicos del ML aplicado a la educación y los marcos de liderazgo pedagógico vigentes en sistemas educativos

de países en desarrollo, atravesados por brechas digitales, baja alfabetización de datos y barreras de adopción tecnológica. Este artículo, de naturaleza teórico-conceptual, tiene como propósito proponer un modelo integrador denominado Liderazgo Educativo Aumentado por Machine Learning (LEA-ML) que articula seis dimensiones: liderazgo pedagógico de base, infraestructura de datos, capa analítica de ML, interpretación aumentada de decisiones, gobernanza ética y aceptación organizacional. El modelo se construyó mediante un análisis documental integrador de 54 fuentes indexadas en Scopus, Web of Science, Redalyc, Scielo, Dialnet y ERIC, publicadas mayoritariamente entre 2015 y 2026. Se discute su pertinencia para el contexto de Arequipa considerando la infraestructura del Sistema de Información de Apoyo a la Gestión de la Institución Educativa (SIAGIE) y las persistentes brechas de conectividad regional. Se concluye que el modelo ofrece una base teórica pertinente para futuras validaciones empíricas orientadas a fortalecer la gestión escolar basada en evidencia entre los directivos de escuelas públicas.

Palabras clave: machine learning; liderazgo educativo; gestión escolar basada en evidencia; directivos educativos; instituciones educativas públicas; Arequipa.

INTRODUCCIÓN

Durante las últimas tres décadas, la investigación en administración y gestión educativa ha consolidado una conclusión robusta: el liderazgo directivo influye de manera significativa, aunque en su mayor parte indirecta, sobre el aprendizaje de los estudiantes (Hallinger & Heck, 1996; Leithwood & Sun, 2012). El metaanálisis de Robinson et al. (2008) mostró que ciertas dimensiones del liderazgo particularmente aquellas centradas en la promoción y participación en el aprendizaje y desarrollo docente presentan efectos considerablemente mayores sobre los resultados escolares que otras orientadas exclusivamente a la administración. Investigaciones posteriores, como la de Leithwood et al. (2020) sobre el modelo de las cuatro rutas, han refinado esta evidencia al identificar los caminos racional, emocional, organizacional y familiar mediante los cuales la dirección escolar llega a impactar en el estudiante. En conjunto, esta línea de investigación ha desplazado el interés académico desde el «qué hace» un director eficaz hacia el «cómo» articula procesos, información y personas para sostener la mejora escolar (Gümüş et al., 2018).

En el Perú, esta evidencia internacional fue incorporada a la política pública mediante el Marco de Buen Desempeño del Directivo (MBDDIR), instrumento normativo que definió el liderazgo pedagógico como el eje articulador de la gestión escolar y que reconoce explícitamente que la dirección escolar constituye el segundo factor intraescolar de mayor incidencia en los aprendizajes, después de la actuación del docente en el aula (Ministerio de Educación del Perú [MINEDU], 2014). El MBDDIR recoge, de forma sintética, elementos del liderazgo instruccional propuesto originalmente por Hallinger y Murphy (1985) y desarrollado posteriormente por Hallinger (2003) una perspectiva cuya vigencia ha sido reafirmada en revisiones muy recientes de la literatura especializada (Bush, 2025; Hallinger et al., 2025), así como principios del liderazgo transformacional formulado por Burns (1978) y sistematizado por Bass (1985) y Bass y Avolio (1994). Estudios recientes realizados en la propia región Arequipa, sin embargo, revelan que la traducción de este marco normativo a la práctica cotidiana de los directivos dista de ser óptima: Vela-Quico et al. (2020), al evaluar a 60 directivos de instituciones estatales de la región mediante una escala de autovaloración y una rúbrica de gestión, encontraron que estos tienden a ser generosos en su autopercepción, reconocen dificultades para diagnosticar las características del entorno institucional y muestran una gestión poco exitosa de la información que produce la propia institución educativa para la toma de decisiones.

Este hallazgo local no constituye un caso aislado. A escala regional, la Organización de Estados Iberoamericanos advierte que los sistemas educativos de América Latina y el Caribe enfrentan desafíos persistentes en el logro de aprendizajes de calidad, en un escenario donde más de la mitad del estudiantado de 15 años no alcanza el nivel mínimo de competencia en lectura y ciencia, y hasta tres de cada cuatro no lo alcanza en matemática (Weinstein et al., 2025). A ello se suma que, en la mayoría de los sistemas educativos de la región, los directores enfrentan una multiplicidad de funciones generalmente más de veinte sin contar frecuentemente con formación previa específica para asumir el cargo (Banco Interamericano de Desarrollo, s.f.). Frente a este panorama, el Banco Interamericano de Desarrollo ha subrayado la relevancia de los Sistemas de Información y Gestión Educativa (SIGED) como herramienta clave para la toma de decisiones de autoridades, directivos, docentes y familias, al tiempo que ha documentado que el aprovechamiento tecnológico de dichos sistemas continúa siendo heterogéneo entre los países de la región (Banco Interamericano de Desarrollo, 2022). En el caso peruano, el Ministerio de Educación administra desde hace más de una década el Sistema de Información de Apoyo a la Gestión de la Institución Educativa (SIAGIE), plataforma que centraliza los procesos de matrícula, asistencia y evaluación de todas las instituciones educativas públicas y privadas del país (MINEDU, s.f.); se trata, en los hechos, de una infraestructura de datos ya instalada que, sin embargo, rara vez es aprovechada más allá de sus funciones administrativas y de registro.

La noción de que la información sistemática puede y debe orientar las decisiones directivas no es nueva en la literatura internacional. Desde hace más de una década, el concepto de toma de decisiones basada en datos (*data-driven decision-making*) ha ganado terreno en la investigación sobre liderazgo escolar, entendido como el proceso mediante el cual los directivos recopilan, analizan e interpretan información institucional para orientar

sus decisiones de gestión (Halverson et al., 2007). Estudios posteriores han documentado que el rol del director resulta decisivo para que esta práctica se consolide o se diluya en la cultura escolar (Levin & Datnow, 2012), y que su adopción efectiva requiere del desarrollo de capacidades específicas entre el personal directivo, más allá de la sola disponibilidad de información (Fernandes, 2019, 2023). El *machine learning*, en este sentido, no introduce un paradigma completamente nuevo en la gestión escolar, sino que intensifica y automatiza parcialmente un proceso la toma de decisiones basada en evidencia cuya relevancia ya había sido reconocida por la literatura especializada. En paralelo a este debate sobre el liderazgo, el campo de la inteligencia artificial (IA) y, en particular, del *machine learning* (ML) definido clásicamente como la capacidad de un programa de mejorar su desempeño en una tarea determinada a partir de la experiencia (Mitchell, 1997) ha experimentado una expansión notable dentro de la investigación educativa. La minería de datos educativos (*educational data mining*, EDM) y la analítica de aprendizaje (*learning analytics*) han evolucionado, en poco más de una década, de un campo emergente a un cuerpo consolidado de conocimiento, con metodologías propias para la predicción, la agrupación y la detección de patrones en datos escolares (Bienkowski et al., 2012; Romero & Ventura, 2010, 2020; Siemens & Baker, 2012). Revisiones sistemáticas recientes documentan que el ML se aplica hoy a tareas tan diversas como la personalización del aprendizaje, la tutoría inteligente, la evaluación automatizada y el apoyo a la toma de decisiones institucionales (Reina-Parrado et al., 2025), mientras que estudios bibliométricos sitúan a la intersección entre inteligencia artificial y liderazgo educativo como un campo de interés creciente, aunque todavía escasamente sistematizado (Arar et al., 2026).

Entre las aplicaciones más consolidadas del ML en educación se encuentra la predicción temprana de la deserción estudiantil. Modelos supervisados árboles de decisión, bosques aleatorios, máquinas de soporte vectorial y algoritmos de *boosting*, entre otros han demostrado niveles de precisión superiores al 90% al identificar estudiantes en riesgo a partir de variables como la asistencia, el desempeño académico y el nivel socioeconómico (Bhutto et al., 2026), mientras que estudios comparativos en educación superior han evidenciado que distintas técnicas de ML ofrecen ventajas diferenciadas según el tipo de dato disponible y el nivel de desbalance de las clases a predecir (Kabathova & Drlik, 2021). Estos hallazgos consolidan al ML como una herramienta con potencial de anticipación que, en teoría, podría integrarse a los procesos de diagnóstico institucional que el propio MBDDIR exige a los directivos peruanos (MINEDU, 2014) y que, de acuerdo con Vela-Quico et al. (2020), constituyen precisamente uno de los puntos más débiles de la práctica directiva en Arequipa.

Pese a este potencial, la literatura revisada evidencia una desconexión relevante. La mayor parte de la investigación sobre ML en educación se ha concentrado en la predicción del desempeño o la deserción de estudiantes individuales, o en el desarrollo de paneles de control para la enseñanza universitaria (Romero & Ventura, 2020), pero rara vez examina de qué manera esta información analítica puede integrarse a los marcos de liderazgo pedagógico que efectivamente utilizan los directivos de educación básica. Adicionalmente, la evidencia disponible sobre inteligencia artificial en educación proviene mayoritariamente de países desarrollados, mientras que los estudios centrados en el Sur Global incluida América Latina continúan siendo escasos y documentan barreras estructurales específicas: infraestructura digital limitada, baja alfabetización en datos entre el personal docente y directivo, y ausencia de estrategias de adopción tecnológica adaptadas al contexto local (Henadirage & Gunarathne, 2025).

Esta brecha es particularmente visible en el contexto peruano. El censo educativo 2023 del Ministerio de Educación reveló que, en promedio nacional, existen siete estudiantes por computadora en secundaria y doce en primaria dentro de las escuelas públicas, con disparidades regionales aún más marcadas en zonas rurales y amazónicas, donde la cifra puede llegar a superar los noventa estudiantes por equipo (Gestión, 2024). A ello se suma que aproximadamente seis de cada diez escuelas públicas de primaria y tres de cada diez de secundaria carecen de acceso a internet, y que cerca del 55% de los docentes peruanos declara no poseer las habilidades necesarias para el uso de las tecnologías de la información y la comunicación (TIC) en el aula (CARE Perú, 2023). Estudios previos realizados en la propia ciudad de Arequipa ya documentaban, antes de la pandemia, que el acceso a las TIC era menor en los colegios de gestión pública que en los de gestión privada (Arias Gallegos, 2015), un patrón que informes recientes sobre brechas de conectividad confirman que persiste hasta la actualidad, especialmente en las provincias alejadas de la capital regional (ComexPerú, 2026), pese a la existencia de un Plan de Cierre de Brecha Digital promovido por el propio Ministerio de Educación (MINEDU, 2021). Estos desafíos no son exclusivos del Perú: ya desde inicios de la pasada década, la UNESCO advertía sobre las limitaciones estructurales para integrar las TIC de manera efectiva en los sistemas educativos de América Latina y el Caribe (UNESCO, 2013).

Un segundo conjunto de barreras remite a la aceptación tecnológica y a la gobernanza ética del ML. Desde la perspectiva de la aceptación individual, el Modelo de Aceptación de la Tecnología (*Technology Acceptance Model*, TAM) formulado por Davis (1989) sostiene que la utilidad percibida y la facilidad de uso percibida determinan, en gran medida, la disposición de una persona a adoptar una nueva herramienta tecnológica; revisiones posteriores han confirmado la robustez de este modelo en contextos organizacionales diversos, aunque también han señalado sus límites para explicar la adopción sostenida en el tiempo (Legris et al., 2003). Desde una perspectiva más sistémica, la propia UNESCO ha advertido sobre los riesgos de sesgo algorítmico, opacidad y vulneración de derechos que puede introducir la IA en contextos educativos si su implementación no se acompaña de principios de transparencia, supervisión humana y rendición de cuentas (UNESCO, 2019, 2021), preocupación que estudios recientes sobre sesgo algorítmico en sistemas educativos han documentado empíricamente al mostrar cómo estos modelos pueden

reproducir o incluso amplificar desigualdades preexistentes si no se auditan adecuadamente (Boateng, 2025; YIP Institute, 2025). Estos principios se han traducido, en años recientes, en instrumentos más específicos, como las orientaciones sobre inteligencia artificial generativa en educación superior (Sabzalieva & Valentini, 2023) y el marco de competencias en IA dirigido a estudiantes (Miao & Shiohira, 2024), que evidencian la magnitud del esfuerzo normativo internacional por acompañar, desde una perspectiva ética, la incorporación de estas tecnologías en los sistemas educativos.

En síntesis, la literatura revisada permite identificar tres vacíos convergentes: (a) un vacío teórico, en la medida en que los modelos de liderazgo pedagógico vigentes en el Perú no incorporan explícitamente el uso de analítica avanzada de datos como una competencia directiva; (b) un vacío contextual, dado que la evidencia sobre ML en educación proviene mayoritariamente de sistemas educativos con condiciones de infraestructura y financiamiento distintas a las de una región peruana con brechas digitales documentadas; y (c) un vacío ético-organizacional, en la medida en que la adopción de estas herramientas exige salvaguardas de equidad y aceptación institucional que rara vez se abordan de manera integrada. Frente a estos vacíos, el presente artículo, de naturaleza teórico-conceptual, tiene como objetivo general proponer un modelo integrador el Liderazgo Educativo Aumentado por Machine Learning (LEA-ML) que articule el liderazgo pedagógico-directivo con la infraestructura de datos, la capa analítica de ML, la interpretación aumentada de decisiones, la gobernanza ética y la aceptación organizacional, tomando como caso de referencia a los directivos de instituciones educativas públicas de la región Arequipa.

De manera específica, el artículo busca: (a) sistematizar los principales aportes teóricos sobre liderazgo educativo y *machine learning* aplicado a la gestión escolar; (b) identificar las condiciones contextuales normativas, tecnológicas y culturales que enmarcan la posible integración de estas dos líneas de conocimiento en instituciones educativas públicas de Arequipa; y (c) proponer y fundamentar un modelo conceptual susceptible de orientar futuras investigaciones empíricas de validación. Cabe precisar, como se detalla en el apartado metodológico, que este trabajo no reporta resultados obtenidos mediante la aplicación de instrumentos a directivos reales, sino una propuesta teórica derivada del análisis sistemático de la literatura, la cual constituye una etapa previa y necesaria para el diseño de estudios empíricos posteriores.

MÉTODO

El presente trabajo se enmarca dentro de la tradición de los artículos teórico-conceptuales, un tipo de producción científica reconocida en las ciencias sociales y de la gestión como un aporte legítimo y necesario cuando el objetivo no es probar una hipótesis a través de datos primarios, sino sistematizar, integrar y reinterpretar el conocimiento existente para proponer marcos explicativos novedosos (Snyder, 2019). A diferencia de una revisión sistemática exhaustiva orientada a cuantificar efectos, o de un estudio empírico orientado a contrastar relaciones causales, este artículo adopta un enfoque de revisión integradora (*integrative review*), cuyo propósito es sintetizar cuerpos de literatura heterogéneos en este caso, la investigación sobre liderazgo educativo, por un lado, y sobre *machine learning* aplicado a la educación, por otro para construir una propuesta teórica coherente (Snyder, 2019). Se declara explícitamente que este estudio no recolectó datos primarios de directivos, docentes o estudiantes de instituciones educativas de Arequipa; en consecuencia, el apartado de resultados no reporta hallazgos estadísticos, sino el producto de la síntesis teórica: el modelo conceptual propuesto.

La búsqueda y selección de literatura se realizó entre los meses de junio y julio de 2026, en las bases de datos Scopus, Web of Science, Scielo, Redalyc, Dialnet y ERIC, complementada con documentos institucionales de acceso abierto publicados por el Ministerio de Educación del Perú, la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO), el Banco Interamericano de Desarrollo y la Organización de Estados Iberoamericanos. Se emplearon combinaciones de descriptores en español e inglés, entre ellos: «machine learning» AND «liderazgo educativo»; «artificial intelligence» AND «educational leadership»; «data-driven decision making» AND «school leadership»; «educational data mining»; «brecha digital» AND «educación» AND «Perú»; «liderazgo pedagógico» AND «directivo» AND «Arequipa»; y «technology acceptance model» AND «education». Los operadores booleanos AND y OR se combinaron con comillas y truncamientos para precisar cada búsqueda.

Se establecieron los siguientes criterios de inclusión: (a) artículos publicados en revistas indexadas o capítulos de libro con revisión por pares; (b) documentos institucionales oficiales de organismos multilaterales o del sector educativo peruano; (c) estudios publicados preferentemente entre 2015 y 2026, salvo en el caso de obras teóricas fundacionales sobre liderazgo (p. ej., Burns, 1978; Bass, 1985) o sobre aceptación tecnológica (Davis, 1989) y *machine learning* (Mitchell, 1997), cuya vigencia conceptual justifica su inclusión independientemente de su fecha de publicación; y (d) pertinencia temática directa con al menos una de las tres líneas conceptuales del estudio: liderazgo educativo, *machine learning*/analítica educativa, o contexto educativo peruano y latinoamericano. Se excluyeron publicaciones sin proceso de revisión editorial identificable, entradas de blogs sin respaldo institucional, y estudios de ML no vinculados de manera directa o indirecta al ámbito educativo.

El proceso de búsqueda exploratoria identificó un conjunto amplio de documentos potencialmente relevantes, de los cuales, tras la lectura de títulos, resúmenes y cuando fue necesario el texto completo, se seleccionaron 54 fuentes que cumplieron los criterios señalados y que constituyen la base documental de este artículo. Esta selección no pretende ser exhaustiva en el sentido de una revisión sistemática de tipo PRISMA, sino representativa de las

principales corrientes teóricas y de la evidencia empírica más pertinente para fundamentar el modelo propuesto. Para la construcción del modelo, las fuentes seleccionadas se organizaron en tres corpus temáticos: (a) teorías y evidencia sobre liderazgo educativo (liderazgo instruccional, transformacional y distribuido, y su traducción normativa en el Marco de Buen Desempeño del Directivo peruano); (b) teoría y evidencia sobre *machine learning*, minería de datos educativos y analítica de aprendizaje, incluyendo sus aplicaciones, limitaciones técnicas y desafíos éticos; y (c) evidencia contextual sobre la región Arequipa y el sistema educativo peruano, referida a infraestructura tecnológica, brecha digital y gestión basada en evidencia. Sobre esta base, se aplicó un procedimiento de codificación temática axial: se identificaron categorías recurrentes dentro de cada corpus, se examinaron sus intersecciones conceptuales y se organizaron en dimensiones jerárquicas e interdependientes, procedimiento coherente con la lógica de construcción de modelos conceptuales en ciencias sociales (Snyder, 2019). El resultado de este proceso presentado en el siguiente apartado es un modelo de seis dimensiones que integra, de manera secuencial y con retroalimentación, el liderazgo pedagógico de base, la infraestructura de datos, la capa analítica de ML, la interpretación aumentada de decisiones, la gobernanza ética y la aceptación organizacional.

Como toda revisión de tipo integrador, este procedimiento posee limitaciones que conviene explicitar. En primer lugar, la selección de fuentes, aunque sistemática, conserva un componente de juicio interpretativo, lo que puede introducir sesgos de selección. En segundo lugar, al no tratarse de una revisión sistemática con protocolo PRISMA, no es posible garantizar la exhaustividad de la búsqueda ni calcular indicadores de concordancia entre revisores. En tercer lugar, y de manera más sustantiva, el modelo propuesto constituye una síntesis teórica que requiere validación empírica posterior mediante, por ejemplo, juicio de expertos, técnica Delphi o estudios piloto con directivos reales antes de que pueda considerarse una herramienta de gestión validada para las instituciones educativas públicas de Arequipa. Esta limitación no debilita el aporte del artículo, sino que delimita con precisión su alcance: se trata de una etapa de fundamentación teórica, no de una etapa de comprobación empírica.

RESULTADOS

Fundamentación general del modelo

El análisis integrador de las fuentes seleccionadas permitió identificar seis dimensiones interdependientes que, articuladas de manera secuencial y con mecanismos de retroalimentación, constituyen el modelo que en este artículo se denomina Liderazgo Educativo Aumentado por *Machine Learning* (LEA-ML). El término «aumentado» se emplea deliberadamente en lugar de «automatizado» o «sustituido», para subrayar que el modelo concibe al ML como un recurso que amplía la capacidad analítica del directivo sin reemplazar su juicio profesional, en línea con la advertencia de la UNESCO (2019, 2021) respecto a preservar la supervisión humana significativa sobre cualquier sistema de inteligencia artificial aplicado a la educación. La Figura 1 sintetiza la arquitectura del modelo, cuyas seis dimensiones se desarrollan a continuación.

Figura 1.

Modelo conceptual de Liderazgo Educativo Aumentado por Machine Learning (LEA-ML)



Fuente: Elaboración propia.

Dimensión 1: Liderazgo pedagógico-directivo de base

La primera dimensión del modelo recoge el consenso de la literatura internacional respecto a que ninguna herramienta analítica sustituye la función directiva de liderazgo pedagógico (Hallinger, 2003; Leithwood & Sun, 2012). El LEA-ML asume como punto de partida el Marco de Buen Desempeño del Directivo peruano (MINEDU, 2014), que integra elementos del liderazgo instruccional centrado en la gestión curricular y el acompañamiento docente (Hallinger & Murphy, 1985) y del liderazgo transformacional orientado a movilizar visión y compromiso colectivo (Bass, 1985; Bass & Avolio, 1994; Burns, 1978). Esta dimensión constituye la condición de posibilidad de todo el modelo: sin un ejercicio de liderazgo pedagógico consolidado capaz, entre otras cosas, de formular preguntas de gestión relevantes, ninguna capa analítica adicional puede generar valor institucional, un principio consistente con la evidencia de Vela-Quico et al. (2020) sobre las limitaciones de autodiagnóstico institucional que presentan actualmente los directivos de Arequipa.

Dimensión 2: Infraestructura y gobernanza de datos

La segunda dimensión reconoce que ningún modelo analítico puede operar sin datos de calidad, oportunos y accesibles. En el contexto peruano, el SIAGIE constituye la infraestructura de datos más relevante y ya instalada a nivel nacional, al centralizar los registros de matrícula, asistencia y evaluación de todas las instituciones educativas públicas y privadas del país (MINEDU, s.f.). El LEA-ML propone que esta dimensión incluya no solo la disponibilidad técnica de los datos, sino también su gobernanza: protocolos claros de acceso, actualización y calidad de la información, así como el reconocimiento explícito de las limitaciones estructurales del contexto, entre ellas la persistencia de brechas de conectividad que afectan de manera desigual a las instituciones educativas urbanas y rurales de la región (ComexPerú, 2026; Gestión, 2024). Sin una base de datos confiable, cualquier modelo de ML construido sobre esta infraestructura reproducirá, en el mejor de los casos, información parcial y, en el peor, sesgos sistemáticos que afectarán la validez de las predicciones (Boateng, 2025).

Dimensión 3: Capa analítica de machine learning

La tercera dimensión corresponde al núcleo técnico del modelo: la aplicación de algoritmos de ML sobre los datos institucionales para generar información analítica útil a la gestión directiva. Siguiendo la definición clásica de Mitchell (1997), se entiende por ML la capacidad de un sistema de mejorar su desempeño en una tarea determinada (T) a partir de la experiencia (E), medida a través de un indicador de desempeño (P). Para efectos del LEA-ML se distinguen tres familias de algoritmos con aplicaciones potenciales diferenciadas en la gestión escolar:

- Modelos supervisados de clasificación y predicción (árboles de decisión, bosques aleatorios, máquinas de soporte vectorial, regresión logística y algoritmos de *boosting*), orientados a anticipar el riesgo de deserción o de bajo rendimiento a partir de variables de asistencia, desempeño académico previo y características socioeconómicas (Bhutto et al., 2026; Kabathova & Drlik, 2021).
- Modelos no supervisados de agrupamiento (*clustering*), útiles para segmentar a estudiantes, secciones o instituciones según patrones de necesidades similares sin necesidad de una variable objetivo predefinida, apoyando así la focalización de recursos pedagógicos.
- Herramientas de analítica descriptiva y paneles de control (*dashboards*), que sistematizan la información institucional en visualizaciones interpretables para la toma de decisiones cotidiana del directivo (Romero & Ventura, 2020).

Es importante subrayar que la selección del tipo de algoritmo debe subordinarse a la pregunta de gestión que el directivo busca responder y no a la inversa, un principio que retoma la advertencia de Romero y Ventura (2010, 2020) sobre el riesgo de que la sofisticación técnica de un modelo se convierta en un fin en sí mismo, desconectado de su utilidad práctica para la institución educativa.

Dimensión 4: Interpretación aumentada y apoyo a la decisión

La cuarta dimensión atiende a un problema documentado de manera consistente en la literatura sobre IA aplicada a dominios de alto impacto: la opacidad de los modelos de ML más complejos, conocidos como modelos de «caja negra», dificulta que sus usuarios comprendan la lógica detrás de una predicción o recomendación (Rogha, 2023). Este problema es particularmente sensible en el ámbito educativo, donde las decisiones basadas en estas herramientas pueden afectar trayectorias escolares individuales. El LEA-ML incorpora, por ello, el principio de la inteligencia artificial explicable (*explainable AI*, XAI), que promueve el uso de modelos intrínsecamente interpretables como los árboles de decisión cuando sea posible, y el uso de técnicas de explicación complementarias cuando se emplean modelos más complejos, de modo que el directivo pueda comprender qué variables sustentan una alerta o recomendación antes de actuar sobre ella (Rogha, 2023).

Esta dimensión reafirma el papel central del juicio profesional del directivo: el modelo no propone que las salidas del sistema de ML determinen automáticamente una decisión de gestión, sino que las incorpore como un insumo adicional explicado y contextualizado dentro de los procesos de análisis institucional que el propio Marco de Buen Desempeño del Directivo ya exige (MINEDU, 2014). En este sentido, el LEA-ML dialoga con la literatura sobre liderazgo

distribuido (Spillane, 2006; Spillane et al., 2001), en la medida en que la interpretación de la información analítica puede y debe ser un ejercicio colegiado entre el equipo directivo, antes que una decisión unipersonal, particularmente en contextos, como el peruano, donde la formación técnica de los directivos en análisis de datos suele ser limitada.

Dimensión 5: Gobernanza ética y equidad algorítmica

La quinta dimensión incorpora explícitamente las salvaguardas éticas que la literatura especializada considera indispensables para cualquier implementación de IA en contextos educativos. La Recomendación sobre la Ética de la Inteligencia Artificial de la UNESCO (2021), adoptada por 193 Estados miembros, establece principios de transparencia, supervisión humana, sostenibilidad y equidad que deben orientar el diseño de políticas de IA en educación, principios desarrollados con mayor detalle en la guía para responsables de política educativa publicada por la propia organización (Miao et al., 2021).

Esta dimensión resulta especialmente relevante en el contexto de Arequipa, donde coexisten instituciones educativas urbanas con mejor infraestructura tecnológica e instituciones rurales considerablemente más rezagadas (Arias Gallegos, 2015; ComexPerú, 2026). Si los modelos de ML se entrenan predominantemente con datos de las instituciones mejor dotadas de infraestructura, existe el riesgo de que sus predicciones sean menos precisas o incluso sistemáticamente sesgadas cuando se apliquen a instituciones rurales, reproduciendo así las desigualdades educativas que, en principio, se busca reducir (Boateng, 2025; YIP Institute, 2025). El LEA-ML propone, en consecuencia, que toda implementación incluya auditorías periódicas de equidad algorítmica, desagregadas por ámbito geográfico y nivel socioeconómico, como condición necesaria para su uso institucional.

Dimensión 6: Aceptación organizacional y cultura de cambio

La sexta y última dimensión reconoce que ningún modelo técnico, por sofisticado que sea, genera valor institucional si no es adoptado efectivamente por sus usuarios. El Modelo de Aceptación de la Tecnología (Davis, 1989; Davis et al., 1989) postula que la utilidad percibida y la facilidad de uso percibida son los principales determinantes de la intención de uso de una tecnología, hallazgo confirmado de manera consistente en revisiones posteriores en diversos contextos organizacionales (Legris et al., 2003). Aplicado al LEA-ML, este principio implica que la introducción de herramientas de ML en la gestión directiva debe ir acompañada de procesos deliberados de fortalecimiento de capacidades y de comunicación clara sobre los beneficios prácticos de estas herramientas para el trabajo cotidiano del directivo.

Esta dimensión cobra particular relevancia en países del Sur Global, donde la evidencia disponible documenta barreras de adopción específicas tecnológicas, organizacionales y culturales que trascienden la mera disponibilidad de la tecnología (Henadirage & Gunarathne, 2025). En el caso peruano, el dato de que aproximadamente el 55% de los docentes carece de las habilidades necesarias para el uso de TIC en el aula (CARE Perú, 2023) sugiere que un desafío equivalente, o mayor, puede existir entre el personal directivo respecto al uso de herramientas analíticas más sofisticadas que el simple registro administrativo. El LEA-ML propone, en este sentido, que la aceptación organizacional se apoye en estructuras de liderazgo distribuido (Spillane, 2006) que permitan compartir la carga cognitiva y técnica de interpretar la información analítica entre distintos miembros del equipo directivo, en lugar de concentrarla exclusivamente en la figura del director o directora.

Síntesis del modelo

La tabla 1 sintetiza las seis dimensiones del LEA-ML, la pregunta de gestión que cada una atiende, su principal anclaje teórico y un ejemplo ilustrativo de aplicación en el contexto de una institución educativa pública de Arequipa.

Tabla 1
Dimensiones del modelo LEA-ML, anclaje teórico y aplicación contextual

Dimensión	Pregunta de gestión que atiende	Anclaje teórico principal	Ejemplo de aplicación en Arequipa
D1. Liderazgo pedagógico-directivo de base	¿Qué buscamos lograr pedagógicamente?	MBDDIR (MINEDU, 2014); Hallinger y Murphy (1985); Bass (1985)	Diagnóstico institucional y definición de metas de aprendizaje del PEI
D2. Infraestructura y gobernanza de datos	¿Con qué información contamos y es confiable?	Romero y Ventura (2010, 2020)	Consolidación y depuración de los registros del SIAGIE de la IE
D3. Capa analítica de machine learning	¿Qué patrones o riesgos revelan los datos?	Mitchell (1997); Bhutto et al. (2026)	Modelo de alerta temprana de riesgo de deserción por sección
D4. Interpretación aumentada y apoyo a la decisión	¿Cómo comprendemos esa información?	Rogha (2023)	Panel de control explicado en reunión de equipo directivo
D5. Gobernanza ética y equidad algorítmica	¿La herramienta trata con equidad a todas las IEs?	UNESCO (2021); Boateng (2025)	Auditoría de sesgo urbano-rural en las predicciones del modelo
D6. Aceptación organizacional y cultura de cambio	¿El equipo directivo confía en la herramienta y la usa?	Davis (1989); Spillane (2006)	Capacitación directiva y liderazgo distribuido para el uso del panel

DISCUSIÓN

El modelo LEA-ML dialoga con marcos previos de liderazgo digital escolar sin superponerse completamente con ellos. Por ejemplo, la revisión de Rahmatullah (2025) identifica cinco dimensiones del liderazgo digital directivo: liderazgo visionario, cultura de aprendizaje, desarrollo profesional, mejora sistémica y ciudadanía digital que resultan compatibles con varias de las dimensiones del LEA-ML, particularmente con la de aceptación organizacional y cultura de cambio. Sin embargo, mientras que la literatura sobre liderazgo digital tiende a enfatizar la integración general de tecnología en la enseñanza, el LEA-ML se concentra de manera más específica en el uso de *machine learning* para la analítica de gestión, un énfasis que responde directamente a la necesidad, documentada en Arequipa, de fortalecer el diagnóstico institucional y el uso de información para la toma de decisiones directivas (Vela-Quico et al., 2020).

La pertinencia práctica del modelo debe evaluarse, sin embargo, a la luz de las condiciones reales de infraestructura de la región. Los datos sobre brecha digital revisados en la introducción entre siete y doce estudiantes por computadora en escuelas públicas, y hasta noventa y cuatro estudiantes por computadora en las provincias más alejadas del país (Gestión, 2024) sugieren que la implementación del LEA-ML no puede plantearse como una intervención homogénea para toda la región Arequipa. Es previsible que las instituciones educativas urbanas, con mejor conectividad y mayor densidad de personal con competencias digitales, se encuentren en mejores condiciones para iniciar procesos piloto que las instituciones rurales o de zonas alejadas, lo que exige que cualquier estrategia de implementación contemple fases diferenciadas y evite convertir al propio modelo en un factor adicional de inequidad educativa.

En cuanto a la infraestructura de datos, si bien el SIAGIE representa un punto de partida valioso al centralizar información de matrícula, asistencia y evaluación a nivel nacional (MINEDU, s.f.), conviene no sobrestimar su preparación actual para sostener análisis de ML complejos. Un sistema diseñado originalmente con fines administrativos y de registro no necesariamente cuenta con la estructura, la granularidad o los mecanismos de exportación necesarios para alimentar modelos predictivos de manera directa, lo que sugiere que la segunda dimensión del LEA-ML: gobernanza de datos requerirá, en la práctica, un trabajo previo de adecuación técnica que excede las capacidades de una institución educativa individual y que probablemente demande una decisión de política pública a nivel de la Dirección Regional de Educación o del propio Ministerio de Educación.

Un riesgo que merece atención específica es el de la sobrevaloración tecnocrática de las herramientas analíticas, es decir, la tentación de sustituir el juicio profesional del directivo por las salidas de un modelo estadístico. La literatura sobre sesgo algorítmico en educación advierte que estos modelos pueden reproducir desigualdades preexistentes cuando se entrenan con datos poco representativos o cuando se emplean sin auditorías adecuadas (Boateng, 2025), un riesgo que se agrava en un contexto, como el de Arequipa, donde la calidad y disponibilidad de datos varía sustancialmente entre instituciones urbanas y rurales. Por ello, el modelo propuesto asigna a la dimensión de gobernanza ética un carácter no negociable: ninguna implementación del LEA-ML debería considerarse legítima si prescinde de mecanismos explícitos de auditoría de equidad y de supervisión humana significativa, en línea con los principios establecidos por la UNESCO (2021).

La dimensión de aceptación organizacional plantea, quizás, el desafío más inmediato para una futura implementación. La evidencia sobre adopción tecnológica en el Sur Global (Henadirage & Gunarathne, 2025) y los datos peruanos sobre alfabetización digital docente (CARE Perú, 2023) sugieren que cualquier estrategia de introducción del LEA-ML deberá invertir de manera prioritaria en el fortalecimiento de capacidades, más que asumir que la sola disponibilidad de herramientas analíticas modificará las prácticas de gestión directiva. En este sentido, la incorporación del liderazgo distribuido (Spillane, 2006; Spillane et al., 2001) como principio transversal del modelo no es solo una opción teórica, sino una respuesta pragmática a la constatación, documentada por organismos como la OEI, de que los sistemas educativos latinoamericanos enfrentan aún brechas considerables entre la retórica de las políticas de liderazgo compartido y su implementación efectiva en las escuelas (Organización de Estados Iberoamericanos, 2024; Weinstein et al., 2025).

Finalmente, corresponde reconocer las limitaciones del modelo propuesto y, con ellas, delinear una agenda de investigación futura. En su formulación actual, el LEA-ML constituye una síntesis teórica no validada empíricamente; su valor de uso dependerá de que futuros estudios sometan cada una de sus dimensiones a evaluación mediante, por ejemplo, un panel de juicio de expertos que valore su pertinencia y suficiencia, el diseño y validación psicométrica de un instrumento de autoevaluación directiva derivado del modelo, o la implementación de estudios piloto en un número reducido de instituciones educativas de la región que permitan documentar su viabilidad práctica antes de recomendar su escalamiento. Cada una de estas rutas constituye, en sí misma, una línea de investigación posdoctoral legítima que el presente artículo busca fundamentar teóricamente.

CONCLUSIONES

Este artículo tuvo como propósito proponer un modelo conceptual: el Liderazgo Educativo Aumentado por *Machine Learning* (LEA-ML) que articule el liderazgo pedagógico-directivo con las posibilidades analíticas del *machine learning*, tomando como referencia contextual a las instituciones educativas públicas de la región Arequipa, Perú. A partir de un análisis documental integrador de 54 fuentes académicas e institucionales, se identificaron seis dimensiones interdependientes: liderazgo pedagógico de base, infraestructura y gobernanza de datos, capa analítica de ML, interpretación aumentada de decisiones, gobernanza ética y aceptación organizacional que, en conjunto,

ofrecen una arquitectura teórica capaz de orientar tanto la reflexión académica como el diseño de futuras políticas de gestión escolar basada en evidencia.

Desde el punto de vista teórico, el modelo contribuye a cerrar un vacío identificado en la literatura: la escasa integración explícita entre los marcos de liderazgo pedagógico consolidados en la investigación educativa (Hallinger & Heck, 1996; Leithwood & Sun, 2012; Leithwood et al., 2020) y el creciente cuerpo de conocimiento sobre *machine learning* aplicado a la gestión escolar (Romero & Ventura, 2020). Al posicionar al ML como un recurso que amplía y no sustituye la capacidad analítica y el juicio profesional del directivo, el LEA-ML se distancia de visiones tecnocéntricas de la transformación digital escolar y se alinea, en cambio, con una perspectiva centrada en el fortalecimiento del liderazgo pedagógico como condición de posibilidad de cualquier innovación tecnológica sostenible.

Desde el punto de vista práctico, el modelo ofrece a la Dirección Regional de Educación de Arequipa, a las Unidades de Gestión Educativa Local y al propio Ministerio de Educación una hoja de ruta conceptual para pensar la modernización de la gestión escolar de manera integral, evitando reducir la incorporación de tecnología a la sola provisión de equipos o plataformas. En particular, los hallazgos discutidos sugieren la necesidad de priorizar tres frentes de política: el fortalecimiento de la infraestructura de datos institucional más allá de sus funciones puramente administrativas, la inversión sostenida en alfabetización de datos del personal directivo, y el establecimiento de mecanismos explícitos de auditoría de equidad algorítmica antes de cualquier escalamiento de herramientas analíticas.

Como se ha reiterado a lo largo del artículo, el LEA-ML constituye una propuesta teórica que requiere validación empírica. Se recomienda que futuras investigaciones incluya la fase empírica del presente proyecto posdoctoral sometan el modelo a juicio de expertos, desarrollen y validen psicométricamente instrumentos derivados de sus dimensiones, y evalúen su viabilidad mediante estudios piloto con directivos de instituciones educativas públicas de la región. Solo a través de este proceso de contrastación empírica será posible determinar en qué medida el modelo propuesto contribuye efectivamente a fortalecer una gestión escolar basada en evidencia, respetuosa de la equidad educativa, en los términos que la propia normativa peruana exige a sus directivos (MINEDU, 2014).

REFERENCIAS

- Arar, K., Tlili, A., & Salha, S. (2026). Human-machine symbiosis in educational leadership in the era of artificial intelligence (AI): Where are we heading? *Educational Management Administration & Leadership*. Publicación anticipada en línea. <https://doi.org/10.1177/17411432241292295>
- Arias Gallegos, W. (2015). Tecnologías de la información y la comunicación en colegios públicos y privados de Arequipa. *Interacciones*, 1(1), 11–28. <https://doi.org/10.24016/2015.v1n1.1>
- Banco Interamericano de Desarrollo. (2022, 19 de abril). 6 cosas que no sabías sobre la gestión educativa en América Latina y el Caribe. *Enfoque Educación*. <https://blogs.iadb.org/educacion/es/6-cosas-que-no-sabias-sobre-la-gestion-educativa-en-america-latina-y-el-caribe/>
- Banco Interamericano de Desarrollo. (s.f.). *Directores de escuela en América Latina y el Caribe: ¿Líderes del cambio o sujetos a cambio?* BID.
- Bass, B. M. (1985). *Leadership and performance beyond expectations*. Free Press.
- Bass, B. M., & Avolio, B. J. (1994). *Improving organizational effectiveness through transformational leadership*. Sage Publications.
- Bhutto, R., Batool, K., Soomro, P., Ali, M. H., & Qureshi, M. N. M. (2026). A comprehensive review of machine learning algorithms for predicting student dropouts in educational data mining. *Advance Social Science Archive Journal*, 5(2), 1361–1370.
- Bienkowski, M., Feng, M., & Means, B. (2012). *Enhancing teaching and learning through educational data mining and learning analytics: An issue brief*. U.S. Department of Education, Office of Educational Technology.
- Boateng, O. (2025). Algorithmic bias in educational systems: Examining the impact of AI-driven decision making in modern education. *World Journal of Advanced Research and Reviews*, 25(1), 2012–2017. <https://doi.org/10.30574/wjarr.2025.25.1.0253>
- Burns, J. M. (1978). *Leadership*. Harper & Row.
- Bush, T. (2025). Instructional leadership in the 21st century: Building on the Hallinger and Murphy PIMRS model. *Educational Management Administration & Leadership*. Publicación anticipada en línea. <https://doi.org/10.1177/17411432251327800>

- CARE Perú. (2023). *Brecha digital en educación: ¿Cómo afecta a las y los estudiantes y qué estamos haciendo para cerrarla?* CARE Perú.
- ComexPerú. (2026, 10 de mayo). Brechas de conectividad en la educación peruana. *Semanario ComexPerú*. <https://www.comexperu.org.pe/articulo/brechas-de-conectividad-en-la-educacion-peruana>
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319–340. <https://doi.org/10.2307/249008>
- Davis, F. D., Bagozzi, R. P., & Warshaw, P. R. (1989). User acceptance of computer technology: A comparison of two theoretical models. *Management Science*, 35(8), 982–1003.
- Fernandes, J. (2023). The role of data-driven decision-making in effective educational leadership. *Academy of Educational Leadership Journal*, 27(Special Issue 2), 1–3.
- Fernandes, V. (2019). Investigating the role of data-driven decision-making within school improvement processes. En *Evidence-based initiatives for organizational change and development* (pp. 201–219). IGI Global.
- Gestión. (2024, 2 de marzo). Brecha digital en escuelas públicas: Solo 1 computadora por cada 12 estudiantes de primaria [Censo educativo 2023]. *Gestión*. <https://gestion.pe/peru/brecha-digital-en-escuelas-publicas-solo-1-computadora-por-cada-12-estudiantes-de-primaria-censo-educativo-2023-ministerio-de-educacion-noticia/>
- Gümüş, S., Bellibaş, M. Ş., Esen, M., & Gümüş, E. (2018). A systematic review of studies on leadership models in educational research from 1980 to 2014. *Educational Management Administration & Leadership*, 46(1), 25–48.
- Hallinger, P. (2003). Leading educational change: Reflections on the practice of instructional and transformational leadership. *Cambridge Journal of Education*, 33(3), 329–352.
- Hallinger, P., & Heck, R. H. (1996). Reassessing the principal's role in school effectiveness: A review of empirical research, 1980–1995. *Educational Administration Quarterly*, 32(1), 5–44.
- Hallinger, P., & Murphy, J. (1985). Assessing the instructional management behavior of principals. *The Elementary School Journal*, 86(2), 217–247.
- Hallinger, P., Liu, S., Aung, P. N., & Yan, M. (2025). A systematic review of instructional leadership research conducted with the Principal Instructional Management Rating Scale (PIMRS), 1983–2024. *Educational Management Administration & Leadership*. Publicación anticipada en línea. <https://doi.org/10.1177/17411432251358575>
- Halverson, R., Grigg, J., Prichett, R., & Thomas, C. (2007). The new instructional leadership: Creating data-driven instructional systems in schools. *Journal of School Leadership*, 17(2), 159–194.
- Henadirage, A., & Gunaratne, N. (2025). Barriers to and opportunities for the adoption of generative artificial intelligence in higher education in the Global South: Insights from Sri Lanka. *International Journal of Artificial Intelligence in Education*, 35, 245–281. <https://doi.org/10.1007/s40593-024-00439-5>
- Kabathova, J., & Drlik, M. (2021). Towards predicting student's dropout in university courses using different machine learning techniques. *Applied Sciences*, 11(7), 3130.
- Legris, P., Ingham, J., & Colletette, P. (2003). Why do people use information technology? A critical review of the technology acceptance model. *Information & Management*, 40(3), 191–204.
- Leithwood, K., & Sun, J. (2012). The nature and effects of transformational school leadership: A meta-analytic review of unpublished research. *Educational Administration Quarterly*, 48(3), 387–423. <https://doi.org/10.1177/0013161X11436268>
- Leithwood, K., Sun, J., & Schumacker, R. (2020). How school leadership influences student learning: A test of «the four paths model». *Educational Administration Quarterly*, 56(4), 570–599. <https://doi.org/10.1177/0013161X19878772>

- Levin, J. A., & Datnow, A. (2012). The principal role in data-driven decision making: Using case-study data to develop multi-mediator models of educational reform. *School Effectiveness and School Improvement*, 23(2), 179–201.
- Miao, F., Holmes, W., Huang, R., & Zhang, H. (2021). *AI and education: Guidance for policy-makers*. UNESCO.
- Miao, F., & Shiohira, K. (2024). *AI competency framework for students*. UNESCO.
- Ministerio de Educación del Perú. (2014). *Marco de Buen Desempeño del Directivo*. MINEDU.
- Ministerio de Educación del Perú. (2021). *Plan de cierre de brecha digital*. MINEDU.
- Ministerio de Educación del Perú. (s.f.). *SIAGIE: Sistema de Información de Apoyo a la Gestión de la Institución Educativa*. Recuperado el 11 de julio de 2026, de <https://siagie.minedu.gob.pe>
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- Organización de Estados Iberoamericanos. (2024). *Liderazgo y gobernanza en educación en Iberoamérica*. OEI.
- Rahmatullah, R. (2025). School principals' digital leadership role on integration of technology in education: A review. *SSRN Electronic Journal*. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5288658
- Reina-Parrado, M., Román-Graván, P., & Hervás-Gómez, C. (2025). Integration of artificial intelligence and machine learning in education: A systematic review. *International Journal of Educational Methodology*, 11(2), 203–216. <https://doi.org/10.12973/ijem.11.2.203>
- Robinson, V. M. J., Lloyd, C. A., & Rowe, K. J. (2008). The impact of leadership on student outcomes: An analysis of the differential effects of leadership types. *Educational Administration Quarterly*, 44(5), 635–674.
- Rogha, M. (2023). *Explain to decide: A human-centric review on the role of explainable artificial intelligence in AI-assisted decision making* (arXiv:2312.11507). arXiv. <https://doi.org/10.48550/arXiv.2312.11507>
- Romero, C., & Ventura, S. (2010). Educational data mining: A review of the state of the art. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 40(6), 601–618. <https://doi.org/10.1109/TSMCC.2010.2053532>
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *WIREs Data Mining and Knowledge Discovery*, 10(3), Artículo e1355. <https://doi.org/10.1002/widm.1355>
- Sabzalieva, E., & Valentini, A. (2023). *ChatGPT and artificial intelligence in higher education*. UNESCO.
- Siemens, G., & Baker, R. S. J. d. (2012). Learning analytics and educational data mining: Towards communication and collaboration. En *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (pp. 252–254). ACM.
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Spillane, J. P. (2006). *Distributed leadership*. Jossey-Bass.
- Spillane, J. P., Halverson, R., & Diamond, J. B. (2001). Investigating school leadership practice: A distributed perspective. *Educational Researcher*, 30(3), 23–28. <https://doi.org/10.3102/0013189X030003023>
- UNESCO. (2013). *Enfoques estratégicos sobre TIC en educación en América Latina y el Caribe*. Oficina Regional de Educación de la UNESCO para América Latina y el Caribe.
- UNESCO. (2019). *Consenso de Beijing sobre la inteligencia artificial y la educación*. UNESCO.
- UNESCO. (2021). *Recomendación sobre la ética de la inteligencia artificial*. UNESCO.

Vela-Quico, G. A., Cáceres-Coaquira, T. J., Vela-Quico, A. F., & Gamero-Torres, H. E. (2020). Liderazgo pedagógico en Arequipa-Perú: Competencias directivas. *Revista de Ciencias Sociales*, 26(Número Especial 2), 376–400. <https://doi.org/10.31876/rcs.v26i0.34134>

Weinstein, J., Peña, J., & Maldonado, F. (2025). *Liderazgo distribuido en la educación en América Latina: Resultados de la encuesta a los ministerios de educación*. Organización de Estados Iberoamericanos.

YIP Institute. (2025). *Ensuring fairness in AI: Addressing algorithmic bias in education and hiring*. Young Icons Professional Institute.

FINANCIACIÓN

Ninguna.

CONFLICTO DE INTERESES

Los autores declaran que no existe conflicto de intereses.

CONTRIBUCIÓN DE AUTORÍA

Conceptualización: Rafael Romero-Carazasa.

Curación de datos: Rafael Romero-Carazasa.

Análisis formal: Rafael Romero-Carazasa.

Investigación: Rafael Romero-Carazasa.

Metodología: Rafael Romero-Carazasa.

Administración del proyecto: Rafael Romero-Carazasa.

Recursos: Rafael Romero-Carazasa.

Validación: Rafael Romero-Carazasa.

Redacción – borrador original: Rafael Romero-Carazasa.

Redacción – revisión y edición: Rafael Romero-Carazasa.