

Meta-Framework de calidad: MLOps, NLP y analítica del aprendizaje

Quality Meta-Framework: MLOps, NLP and learning analytics

Jacqueline Solís-Céspedes¹

Solís-Céspedes, J. Meta-framework de calidad: MLOps, NLP y analítica del aprendizaje. *Tecnología en Marcha*. Vol. 39 N° especial sobre Inteligencia Artificial. Febrero, 2026. Pág. 325-337.

 <https://doi.org/10.18845/tm.v39i5.8279>



¹ Instituto Tecnológico de Costa Rica. Costa Rica.
 jacsolis@itcr.ac.cr
 <https://orcid.org/0000-0001-6545-129X>

Palabras clave

Inteligencia artificial; gestión de la calidad; tecnologías de información; ética en la tecnología.

Resumen

Se presenta una propuesta teórica de meta-framework integrado de gestión de calidad educativa basado en Procesamiento de Lenguaje Natural (NLP) y Analítica del Aprendizaje (LA), orientado a posibilitar la evaluación escalable, trazable y auditable de las interacciones docente–estudiante en entornos digitales. La arquitectura conceptual articula NLP y LA para transformar el discurso académico y los metadatos conductuales en indicadores clave de desempeño (KPIs), alineados con las dimensiones pedagógica, técnica, social y psicológica de la calidad educativa. El modelo se estructura bajo una arquitectura cíclica de tres fases — Dirección, Operación y Optimización— que integra diseño estratégico, despliegue técnico y calibración continua. Asimismo, incorpora una estrategia híbrida de anotación que combina la escalabilidad de los Grandes Modelos de Lenguaje (LLMs) con validación humana periódica, garantizando control de sesgo, consistencia semántica y supervisión institucional. Su principal contribución reside en la incorporación explícita de un marco de Gobernanza Algorítmica (GA), sustentado en prácticas de MLOps, que operacionaliza la calidad mediante métricas auditables, protocolos de validación y mecanismos de monitoreo de deriva de datos y modelos. De esta forma, la propuesta trasciende enfoques basados en KPIs aislados y establece una arquitectura de segundo orden que integra evaluación pedagógica, control técnico y responsabilidad institucional, promoviendo transparencia, rendición de cuentas y mejora continua en sistemas educativos basados en IA.

Keywords

Artificial intelligence; quality management; information technology; ethics in technology.

Abstract

A theoretical proposal is presented for an integrated meta-framework for educational quality management based on Natural Language Processing (NLP) and Learning Analytics (LA), designed to enable the scalable, traceable, and auditable evaluation of teacher-student interactions in digital environments. The conceptual architecture articulates NLP and LA to transform academic discourse and behavioral metadata into key performance indicators (KPIs), aligned with the pedagogical, technical, social, and psychological dimensions of educational quality. The model is structured under a cyclical architecture of three phases: Direction, Operation, and Optimization that integrates strategic design, technical deployment, and continuous calibration. It also incorporates a hybrid annotation strategy that combines the scalability of Large Language Models (LLMs) with periodic human validation, ensuring bias control, semantic consistency, and institutional oversight. Its main contribution lies in the explicit incorporation of an Algorithmic Governance (AG) framework, based on MLOps practices, which operationalizes quality through auditable metrics, validation protocols, and mechanisms for monitoring data and model drift. In this way, the proposal transcends approaches based on isolated KPIs and establishes a second-order architecture that integrates pedagogical evaluation, technical control, and institutional responsibility, promoting transparency, accountability, and continuous improvement in AI-based educational systems.

Introducción

En el contexto de la tecnología educativa, la inteligencia artificial (IA) ha evolucionado de herramienta a activo estratégico [21,30,31] que requiere una gestión eficiente por parte de la Gerencia de Tecnologías de Información (TI) [30-32]. La evaluación de la calidad de las interacciones pedagógicas y discursivas que tienen lugar en los entornos de aprendizaje virtual (LMS) sigue siendo un desafío debido a la falta de mecanismos escalables y las limitaciones de la evaluación manual [18,20,21,27,33-36].

Aunque se han desarrollado estrategias automatizadas para analizar interacciones [37,38], explorar la percepción docente sobre sistemas adaptativos [38] y mejorar el desempeño estudiantil mediante ensayos controlados [5], el marco normativo, operativo y ético para su aplicación a gran escala aún está en desarrollo [27]. Este desafío se ve agravado por una fragmentación estructural entre la analítica pedagógica, la Gobernanza Algorítmica (GA) y la operacionalización técnica. Ante este escenario, es necesario que los mecanismos de control evolucionen hacia modelos que no sacrifiquen la calidad ni la responsabilidad institucional. Por ello, este artículo propone un meta-framework teórico integrador sustentado en Procesamiento de Lenguaje Natural (NLP) y Analítica del Aprendizaje (LA). Esta arquitectura articula dimensiones pedagógicas, psicológicas, sociales y técnicas dentro de un esquema de gobernanza inspirado en MLOps, orientado al aseguramiento multidimensional y sistemático de la calidad educativa en entornos digitales.

Calidad educativa en entornos digitales basados en IA

La calidad educativa, tradicionalmente conceptualizada como un constructo multidimensional de resultados, coherencia y equidad, se transforma en los entornos digitales contemporáneos debido a la incorporación de sistemas basados en IA que median y modelan las interacciones formativas [26, 45, 47–49]. Bajo esta premisa, la calidad trasciende los indicadores agregados de desempeño académico para entenderse como una propiedad socio-técnica que articula el diseño pedagógico, la experiencia cognitiva y emocional del estudiante, la equidad algorítmica y la robustez de las infraestructuras analíticas. En consecuencia, la medición de estas dimensiones —que involucran factores pedagógicos, psicológicos, sociales y técnicos— exige mecanismos capaces de capturar tanto variables observables como procesos latentes. Para ello, el aprovechamiento de datos masivos en plataformas educativas ha impulsado enfoques basados en LA y técnicas de NLP, permitiendo transformar los registros de actividad en métricas cuantificables y modelables temporalmente [26,45,47–49].

Sin embargo, la incorporación de modelos avanzados —incluyendo sistemas basados en aprendizaje automático (ML) y grandes modelos de lenguaje (LLMs)— introduce nuevos desafíos relacionados con interpretabilidad, sesgo algorítmico y responsabilidad en la toma de decisiones automatizadas [10,13,16,17,28,41–44,46]. En consecuencia, el aseguramiento de la calidad educativa requiere de marcos de gobernanza que permitan controlar el ciclo de vida de los modelos y mitigar riesgos éticos y técnicos asociados a su implementación [4,8,9,21,28,29,47].

LA se ha consolidado como un campo orientado a la medición, recopilación, análisis y reporte de datos sobre estudiantes y sus contextos con el propósito de comprender y optimizar los procesos educativos [26,45,47–49]. En entornos digitales, permite integrar información proveniente de múltiples fuentes, facilitando el modelado temporal de comportamientos de aprendizaje y la identificación de patrones asociados al desempeño académico mediante enfoques que han evolucionado desde análisis descriptivos hacia modelos predictivos y prescriptivos que buscan anticipar riesgos académicos y apoyar procesos de toma de decisiones institucionales [26,47–49]. Asimismo, la integración multimodal de datos ha ampliado

la capacidad analítica del campo, incorporando dimensiones conductuales, temporales y contextuales del aprendizaje digital. También, la literatura señala que, aunque LA ha fortalecido las capacidades de modelado y visualización de datos, persisten desafíos relacionados con la interpretación pedagógica de los resultados y con la articulación de los análisis dentro de marcos de gobernanza y control algorítmico.

Por otro lado, el NLP en la educación constituye un componente central en el análisis de interacciones textuales generadas en entornos educativos digitales. A través de técnicas de extracción semántica y pragmática, permite transformar materiales discursivos en datos estructurados susceptibles de análisis cuantitativo [39–41,45]. La literatura distingue al menos tres enfoques principales para la conversión de texto en datos anotados: (a) métodos basados en palabras clave, orientados a métricas simples de frecuencia y detección temática; (b) modelos de ML supervisado, que requieren corpus previamente anotados para entrenar clasificadores específicos; y (c) LLMs, que posibilitan procesos de anotación más flexibles mediante *prompts* y transferencia de aprendizaje, reduciendo la dependencia de grandes conjuntos de datos manualmente etiquetados [16,41–44,46]. Estas técnicas permiten identificar dimensiones discursivas relevantes en contextos educativos, tales como complejidad léxica, coherencia argumentativa, tono emocional y señales metacognitivas [14,15,23,41]. La combinación de NLP con marcos de analítica de aprendizaje amplía las posibilidades de caracterizar dinámicamente la evolución del comportamiento académico y explorar relaciones entre comunicación pedagógica y logro educativo [26,45,47–49].

Sin embargo, el uso de modelos avanzados —especialmente arquitecturas basadas en *transformers* y LLMs— plantea interrogantes en torno a la interpretabilidad, la reproducibilidad y el sesgo algorítmico, dado su carácter parcialmente opaco y su dependencia de datos de entrenamiento a gran escala [10,13,16,17,28,42–44,46]. Estos aspectos han motivado una creciente atención hacia la necesidad de marcos de gobernanza capaces de supervisar el ciclo de vida de los modelos y mitigar riesgos éticos y técnicos asociados a su aplicación en contextos educativos [21,28,29].

La incorporación de sistemas analíticos avanzados en entornos educativos ha ampliado el alcance de los debates sobre gobernanza tecnológica. Tradicionalmente, la gobernanza de TI se ha estructurado mediante marcos normativos orientados a la alineación estratégica, la gestión de riesgos y el control de procesos organizacionales. Estándares como ISO/IEC 38500, COBIT, ITIL y CMMI han proporcionado principios y prácticas para asegurar trazabilidad, responsabilidad y eficiencia en la gestión de sistemas [4,8,9].

Con la expansión de la IA, estos enfoques han evolucionado hacia marcos de gobernanza específicos para sistemas basados en IA. Organismos internacionales y agencias regulatorias han enfatizado principios como transparencia, rendición de cuentas, equidad, explicabilidad y supervisión humana significativa [56–58]. Estos marcos buscan mitigar riesgos asociados a la automatización de decisiones y establecer criterios éticos para el desarrollo y despliegue de modelos algorítmicos.

No obstante, la aplicación de estos principios generales en contextos educativos presenta particularidades relevantes. Los sistemas analíticos educativos procesan datos sensibles, influyen en trayectorias académicas y pueden amplificar desigualdades preexistentes si no se gestionan adecuadamente [28,41]. En este escenario emerge el concepto de GA, entendido como el conjunto de mecanismos orientados al control del ciclo de vida de los modelos analíticos, la supervisión de datos de entrenamiento y la evaluación continua de desempeño y sesgo [28,29].

La GA se distingue de la gestión de TI tradicional al incorporar el comportamiento dinámico de los modelos, la deriva de datos y la auditoría de decisiones [21,28, 29]; desafíos que, en el ámbito educativo, adquieren una complejidad mayor por su impacto directo en los procesos pedagógicos y la experiencia estudiantil. Para abordar esta operatividad técnica, el sector industrial ha consolidado prácticas de MLOps orientadas a la integración continua y el monitoreo de desempeño [56–62]. No obstante, aunque estos enfoques fortalecen la estabilidad de los sistemas, su naturaleza es esencialmente técnica, lo que genera un vacío en la medición de indicadores de calidad educativa y en la integración de marcos pedagógicos explícitos.

Desafíos de la Evaluación de la Calidad en la Era de la IA: La Fragmentación Estructural

El análisis de la literatura evidencia un desarrollo significativo pero segmentado de los componentes que intervienen en la gestión de la calidad educativa basada en datos. Por un lado, LA y NLP han fortalecido la capacidad de transformar interacciones y registros de actividad en métricas temporales y semánticas del aprendizaje, enriqueciendo el análisis de dimensiones semánticas, emocionales y metacognitivas del involucradas en el proceso [14,15,23,26, 39–41,45, 47–49]. Por otro lado, los marcos de gobernanza de IA y las prácticas industriales de MLOps han sistematizado la gestión ética del ciclo de vida del ML, priorizando estabilidad y la transparencia [56–62].

Sin embargo, estos avances han evolucionado de manera independiente, generando una fragmentación conceptual donde las dimensiones pedagógica, psicológica, social y técnica no se articulan bajo un marco común. Esta separación provoca que la calidad educativa en entornos mediados por IA tienda a evaluarse de forma parcial, ya sea mediante métricas analíticas aisladas o principios normativos abstractos. La ausencia de un enfoque integrador dificulta la alineación entre el análisis educativo y el control algorítmico, creando brechas críticas entre la producción de datos y la toma de decisiones institucionales.

Para sistematizar esta comparación, se seleccionaron cuatro tipos de enfoques consolidados en la literatura: (i) marcos tradicionales de LA, como los promovidos por la *Society for Learning Analytics Research (SoLAR)* [53–55]; (ii) enfoques clásicos de *Educational Data Mining (EDM)*; (iii) marcos normativos de Gobernanza en IA desarrollados por organismos internacionales como OECD, NIST y la Unión Europea [56–58]; y (iv) modelos industriales de MLOps orientados a la gestión del ciclo de vida del ML [59–62]. Este análisis comparativo se realizó bajo una perspectiva socio-técnica, asumiendo que la calidad es una propiedad emergente de la interacción entre el diseño algorítmico y el contexto institucional [53–62].

Mediante un análisis cualitativo de la literatura, el Cuadro 1 sintetiza esta fragmentación estructural. En dicha comparativa, se identificaron dimensiones como “Parciales” cuando, a pesar de estar implícitas en los marcos analizados, carecen de una formalización como componentes estructurales explícitos. Este contraste de énfasis entre las dimensiones pedagógicas, técnicas y de gobernanza evidencia los vacíos que justifican la necesidad del modelo integrador.

Cuadro 1. Comparación estructural entre frameworks existentes

Dimensión / Framework	LA tradicional (SoLAR)	EDM clásico	AI Governance (OECD/NIST/EU)	MLOps industrial
Enfoque pedagógico explícito	Sí	Parcial	x	x
Análisis NLP educativo	Parcial	Parcial	x	x
Integración multimodal (texto+procesos+logs)	Parcial	Sí	x	Sí (técnico)
Ciclo estratégico-operativo	x	x	Parcial	Sí (DevOps loop)
KPIs pedagógicos formalizados	Parcial	Sí	x	x
Gobernanza educativa específica	x	x	General IA	General ML
Control de sesgo en contexto educativo	Parcial	Parcial	Sí (abstracto)	Parcial
Auditoría humana integrada	Parcial	x	Sí	Parcial
Arquitectura multicapa formal	x	x	x	Sí
Enfoque sistémico integral	Parcial	Parcial	Parcial	Técnico

El análisis comparativo evidencia que, aunque cada enfoque contribuye en su respectivo dominio, ninguno integra de manera simultánea y explícita las dimensiones pedagógica, psicológica, social y técnica dentro de una arquitectura sistémica de aseguramiento continuo de calidad educativa. Además, puede observarse que ningún enfoque articula simultáneamente un modelo pedagógico explícito, mecanismos formales de control de sesgo en contexto educativo, indicadores estructurados de calidad multidimensional y un ciclo operativo continuo de supervisión algorítmica. Esta brecha conceptual y operativa constituye el punto de partida para la formulación de un marco integrador que permita abordar la calidad educativa basada en IA como un sistema coherente y gobernable.

Propuesta integradora para la gobernanza y calidad educativa basada en IA

Ante la fragmentación conceptual identificada, este trabajo propone un meta-framework integrador para la gobernanza y el aseguramiento multidimensional de la calidad educativa en entornos mediados por IA. El modelo se constituye como una arquitectura conceptual de GA adaptada al dominio pedagógico, articulando capacidades de LA y NLP bajo un control sistémico del ciclo de vida de los modelos mediante prácticas de MLOps.

Más que una implementación tecnológica, esta propuesta establece una base estructural orientada a tres ejes fundamentales: (i) Sincronización de dimensiones: Alinear los factores pedagógicos, psicológicos, sociales y técnicos en un esquema coherente de supervisión. (ii) Visión sistémica: Superar la evaluación parcial basada en métricas aisladas o principios abstractos para avanzar hacia una gestión estratégica gobernable y (iii) Mejora continua: Facilitar la convergencia entre la evaluación pedagógica, el control algorítmico y el aseguramiento de la calidad.

Ontología multidimensional de la calidad educativa basada en IA

El meta-framework parte de la premisa de que la calidad educativa en entornos mediados por IA es una propiedad emergente de un sistema compuesto por actores humanos, modelos algorítmicos, infraestructuras tecnológicas y procesos pedagógicos. Bajo esta visión se proponen cuatro dimensiones estructurales interrelacionadas:

- Pedagógica: Se refiere a la coherencia entre diseño instruccional, objetivos formativos y evidencias de aprendizaje observables a través de datos educativos. Se sustenta en la capacidad de LA para modelar $\approx$ trayectorias de aprendizaje y resultados académicos.
- Psicológica: Integra variables de la experiencia cognitiva y emocional del estudiante. Se centra en identificar señales metacognitivas, de compromiso y tono emocional extraídos mediante técnicas de NLP.
- Social: Aborda los principios de equidad, mitigación de sesgos y justicia algorítmica. Garantiza que el impacto del sistema sea equitativo, alineándose con los marcos de gobernanza y ética de la IA contemporáneos.
- Técnica: Asegura la robustez, trazabilidad y estabilidad de los modelos analíticos. Su gestión se sustenta en prácticas de MLOps, permitiendo un monitoreo continuo del ciclo de vida algorítmico y de la infraestructura que soporta el proceso educativo.

Estas dimensiones no operan de manera independiente, sino que interactúan dinámicamente, configurando el nivel global de calidad del sistema educativo basado en IA.

Formalización conceptual del modelo

Con fines analíticos, la calidad educativa mediada por IA puede representarse como una función multidimensional:

$$Q_{IA} = f(D_{Pedagógica}, D_{Psicológica}, D_{Social}, D_{Técnica})$$

donde cada dimensión D_x puede desagregarse en un conjunto de indicadores específicos derivados de LA y NLP, sujetos a mecanismos de control algorítmico y gobernanza. De manera general:

$$D_i = \sum_{j=1}^n w_{ij} KPI_{ij}$$

donde KPI_{ij} representa indicadores asociados a cada dimensión y w_{ij} ponderaciones relativas, definidas según contexto institucional o marco normativo adoptado. Esta formalización no presupone una parametrización empírica específica, sino que establece una estructura conceptual que permite integrar métricas pedagógicas, psicológicas, sociales y técnicas bajo un esquema común de evaluación.

Con el propósito de traducir la ontología multidimensional en componentes analíticos observables, se propone un conjunto estructurado de indicadores conceptuales asociados a cada dimensión. Estos indicadores derivan de capacidades descritas en la literatura de LA, NLP, GA y MLOps.

Los indicadores se clasifican según su naturaleza analítica en cuatro categorías: los diagnósticos (D), que describen el estado actual del proceso educativo; los predictivos (P), orientados a estimar riesgos o desempeños futuros; los evaluativos (E), encargados de validar la coherencia entre los objetivos planteados y los resultados obtenidos; y los de control (C), diseñados para monitorear el desempeño algorítmico y garantizar la equidad en el sistema. El Cuadro 2 sintetiza esta operacionalización conceptual.

Cuadro 2. Operacionalización conceptual de las dimensiones del meta-framework.

Dimensión	Indicador conceptual (KPI) (Tipo)	Fuente analítica
Pedagógica	Coherencia entre objetivos formativos y desempeño académico(E)	LA [26,47–49]
	Trayectoria temporal de aprendizaje (D/P)	LA [26,45,47–49]
	Relación entre interacción discursiva y logro académico (E)	LA + NLP [39–41,45]
	Detección temprana de riesgo académico (P)	LA predictiva [26,47–49]
Psicológica	Complejidad léxica y estructura argumentativa (D)	NLP [14,15,41]
	Señales metacognitivas en producción textual (D)	NLP [23,41]
	Análisis de tono emocional en interacciones (D/P)	NLP [14,15,23]
	Indicadores de compromiso cognitivo (D)	LA + NLP [39–41,45]
Social	Distribución diferencial de desempeño por subgrupos (C)	LA + Justicia [28,41]
	Medidas de equidad algorítmica (C)	Gobernanza IA [56–58]
	Detección de sesgo en predicciones (C)	GA [28,29]
	Transparencia y explicabilidad del modelo (E/C)	Gobernanza IA [56–58]
Técnica	Precisión y estabilidad del modelo (E)	MLOps [59–62]
	Detección de deriva de datos (data drift) (C)	MLOps [59–62]
	Trazabilidad del ciclo de vida del modelo (C)	Gobernanza+MLOps[28,59–62]
	Auditoría humana integrada (C)	Gobernanza IA [56–58]

Además, la propuesta integra principios de GA orientados al control del ciclo de vida de los modelos analíticos utilizados en entornos educativos en tres niveles: (i) Estratégico: definición de objetivos educativos, criterios de calidad y políticas de equidad alineadas con marcos de gobernanza de IA. (ii) Operativo-analítico: implementa de procesos LA y NLP para generar métricas, entrenamiento de modelos y análisis multimodal y (iii) Supervisión y control continuo: monitoreo de desempeño, detección de deriva, auditoría humana y control de sesgo, inspiradas en MLOps y la mitigación de riesgos éticos.

La interacción entre estos niveles configura un ciclo de evaluación y mejora, donde los resultados retroalimentan decisiones pedagógicas y ajustes técnicos con transparencia y responsabilidad.




Figura 1. Arquitectura conceptual de GA para aseguramiento de la calidad educativa basada en IA.

La Figura 1 presenta la arquitectura conceptual de la propuesta, integrando las dimensiones ontológicas con los niveles de gobernanza descritos en las secciones anteriores.

El núcleo del modelo está constituido por la generación de KPIs multidimensionales, derivados de procesos de LA y NLP. Estos indicadores se estructuran en cuatro dimensiones interrelacionadas —pedagógica, psicológica, social y técnica— cuya agregación ponderada permite representar la calidad educativa como una función sistémica.

Rodeando este núcleo se sitúa la capa de GA, concebida como mecanismo transversal de control del ciclo de vida del modelo. Esta capa articula principios de responsabilidad, trazabilidad, control de sesgo y monitoreo continuo, inspirados en marcos de IA responsable y prácticas de MLOps.

La arquitectura se organiza en tres fases cíclicas:

- Dirección (nivel estratégico), donde se definen formalmente los KPIs, umbrales de equidad, criterios de desempeño y políticas institucionales.
- Operación (nivel analítico-operativo), donde se ejecutan procesos de entrenamiento, despliegue y monitoreo del modelo, incluyendo evaluación de deriva y métricas de equidad y,

- iii. Optimización (nivel de mejora continua), donde los resultados operativos y los reportes de validación independiente retroalimentan ajustes técnicos y estratégicos.

El modelo incorpora explícitamente mecanismos de validación independiente y auditoría externa, así como la posibilidad de retiro del modelo cuando los criterios de desempeño, equidad o estabilidad no sean satisfechos. De esta manera, la calidad educativa mediada por IA se conceptualiza no como una métrica estática, sino como un proceso gobernado de evaluación y mejora continua y la infraestructura de ciclo de vida —incluyendo versionado, registro de decisiones, monitoreo de deriva y trazabilidad reproducible— opera como capa transversal que garantiza la auditabilidad del sistema.

Un componente distintivo de la propuesta es la integración explícita entre generación de métricas educativas y mecanismos de control de equidad algorítmica. La dimensión social no se concibe como adición externa, sino como criterio transversal que condiciona la interpretación y utilización de indicadores derivados de LA y NLP. En este sentido, la medición de desempeño académico o de variables psicológicas debe acompañarse de evaluaciones de distribución diferencial de resultados entre subgrupos poblacionales, siguiendo lineamientos de justicia establecidos en la literatura de gobernanza de IA. La articulación entre métricas educativas y métricas de equidad permite evitar que procesos automatizados amplifiquen desigualdades estructurales.

Conclusiones y líneas de investigación futuras

Este artículo ha presentado una propuesta integradora diseñado para abordar la calidad educativa en entornos mediados por IA mediante un esquema de analítica avanzada y responsabilidad institucional. Al constituirse como una propuesta teórica y arquitectónica, su valor no reside en una implementación técnica inmediata, sino en establecer las bases conceptuales para guiar futuras investigaciones y desarrollos aplicados. La contribución del modelo se centra en dos ejes fundamentales:

- i. Gobernanza como pilar arquitectónico: La propuesta supera los enfoques basados en indicadores aislados al integrar sistemáticamente LA, NLP y MLOps dentro de un marco de GA. Esta estructura permite que la evaluación automatizada deje de ser un conjunto de métricas técnicas para convertirse en un sistema gobernable, trazable y sometido a criterios explícitos de transparencia y equidad.
- ii. Rigor metodológico y viabilidad operacional: El modelo formaliza una ontología multidimensional que transforma el discurso docente-estudiante y los datos conductuales en indicadores con impacto real en las dimensiones pedagógica, psicológica, social y técnica. Al incorporar el control de sesgo como un componente estructural y definir una organización cíclica de mejora continua, la propuesta se posiciona como un prototipo metodológico para la validación empírica en contextos educativos.

Como propuesta de investigación futura, el desafío principal es su validación en entornos reales. Las futuras líneas de investigación se dividen en dos ejes:

- i. Validación mediante un estudio piloto tipo Living Lab: Se propone desarrollar un plan piloto que permita: (a) Cuantificar la precisión, estabilidad y capacidad de generalización de los clasificadores de NLP y de los modelos predictivos de LA en distintos contextos disciplinarios. (b) Documentar sistemáticamente los resultados de pruebas periódicas de sesgo, incluyendo métricas de equidad intergrupales y procedimientos de mitigación implementados. (c) Evaluar el impacto de las alertas tempranas y KPIs multidimensionales en la mejora efectiva de las prácticas docentes, la experiencia de aprendizaje y los

indicadores de retención estudiantil. Este proceso permitiría contrastar la consistencia interna del modelo, analizar su comportamiento ante deriva de datos y validar su contribución real al aseguramiento de la calidad educativa.

- ii. Formalización y extensión del marco de gobernanza: Se plantea extender los modelos tradicionales de gobernanza incorporando procedimientos de MLOps para la gestión auditable del ciclo de vida algorítmico. Esto incluiría el desarrollo de protocolos estandarizados para trazabilidad, linaje de datos, versionamiento de modelos, definición de umbrales de desempeño y mecanismos de rendición de cuentas institucional.

Ambas líneas permitirán transitar desde la formulación conceptual hacia una arquitectura validada empíricamente para la gestión responsable de la calidad educativa mediada por IA.

Referencias

- [1] K. Alalawi, R. Athauda, y R. Chiong, "An extended learning analytics framework integrating machine learning and pedagogical approaches for student performance prediction and intervention," *International Journal of Artificial Intelligence in Education*, vol. 35, no. 3, pp. 1239–1287, 2025.
- [2] A. Anwar et al., "Emotions matter: A systematic review and meta analysis of the detection and classification of students' emotions in STEM during online learning," *Education Sciences*, vol. 13, no. 9, p. 914, 2023.
- [3] Axelos, ITIL Foundation: ITIL 4 Edition. TSO (The Stationery Office), 2019.
- [4] CMMI Institute, CMMI for Development, Version 2.0. CMMI Institute, 2018.
- [5] D. Demszky, J. Liu, H. C. Hill, D. Jurafsky, y C. Piech, "Can automated feedback improve teachers' uptake of student ideas? Evidence from a randomized controlled trial in a large-scale online course," *Educational Evaluation and Policy Analysis*, vol. 46, no. 3, pp. 483–505, 2024.
- [6] D. Herrero Pascual, *Ciclo de Vida de los Datos y MLOps: Herramientas, metodologías, puesta en producción y mantenimiento de proyectos de Data Science*, 2022.
- [7] ISACA, COBIT 2019 Framework: Introduction and Methodology. ISACA, 2019.
- [8] ISO/IEC, Information technology—Governance of IT for the organization, ISO/IEC 38500:2015, 2015.
- [9] ISO, Quality management systems — Fundamentals and vocabulary, ISO 9000:2015, 2015.
- [10] S. Issar y A. Aneesh, "What is algorithmic governance?," *Sociology Compass*, vol. 16, no. 1, e12955, 2022.
- [11] K. F. Hew, C. Qiao, y Y. Tang, "Understanding student engagement in large-scale open online courses: A machine learning facilitated analysis of student's reflections in 18 highly rated MOOCs," *Int. Rev. Res. Open Distrib. Learn.*, vol. 19, no. 3, 2018.
- [12] R. Kaliisa, B. Rienties, A. I. Mørch, y A. Kluge, "Social learning analytics in computer-supported collaborative learning environments: A systematic review of empirical studies," *Computers and Education Open*, vol. 3, p. 100073, 2022.
- [13] C. Katzenbach y L. Ulbricht, "Algorithmic governance," *Internet Policy Review*, vol. 8, no. 4, pp. 1–18, 2019.
- [14] S. Knight y S. Buckingham Shum, "Theory and learning analytics," *Handbook of Learning Analytics*, vol. 1, pp. 17–22, 2017.
- [15] S. Knight y K. Littleton, "Dialogue as data in learning analytics for productive educational dialogue," *Journal of Learning Analytics*, vol. 2, no. 3, pp. 111–143, 2015.
- [16] J. O. Krugmann y J. Hartmann, "Sentiment analysis in the age of generative AI," *Customer Needs and Solutions*, vol. 11, no. 3, 2024.
- [17] A. Kucharavy, O. Plancherel, V. Mulder, A. Mermoud, y V. Lenders, Eds., *Large Language Models in Cybersecurity: Threats, Exposure and Mitigation*. Springer, 2024.
- [18] V. Lukarov, "Scaling up Learning Analytics in Blended Learning Scenarios," Ph.D. dissertation, RWTH Aachen Univ., 2019.
- [19] Q. Lu et al., "Sentiment analysis: Comprehensive reviews, recent advances, and open challenges," *IEEE Trans. Neural Netw. Learn. Syst.*, 2023.
- [20] R. Martinez-Maldonado et al., "Interactive surfaces and learning analytics: Data, orchestration aspects, pedagogical uses and challenges," in *Proc. 6th Int. Conf. on Learning Analytics & Knowledge*, 2016, pp. 124–133.

- [21] X. Ochoa et al., "Multimodal learning analytics—Rationale, process, examples, and direction," en *The Handbook of Learning Analytics*, vol. 2, pp. 54–65, 2022.
- [22] D. Owusu-Mensah, P. A. Sarfo, y G. A. Kusi, "Exploring the Impact of Artificial Intelligence on Customer Experience Personalization and Marketing Strategy Optimization in Digital Marketing: An Empirical Analysis," *Journal of Management and Informatics*, vol. 4, no. 2, pp. 822-843, 2025.
- [23] S. Rüdian, J. Podelo, J. Kužilek, y N. Pinkwart, "Feedback on feedback: Student's perceptions for feedback from teachers and few-shot LLMs," in *Proc. 15th Int. Learning Analytics and Knowledge Conf.*, Dublin, Ireland: ACM, Mar. 2025, pp. 82–92.
- [24] M. Sokovic, D. Pavletic, y K. K. Pipan, "Quality improvement methodologies—PDCA cycle, RADAR matrix, DMAIC and DFSS," *Journal of achievements in materials and manufacturing engineering*, vol. 43, no. 1, pp. 476-483, 2010.
- [25] B. T. Wong y K. C. Li, "Learning analytics intervention: A review of case studies," en *2018 International Symposium on Educational Technology (ISET)*, IEEE, 2018, pp. 178-182.
- [26] B. Yang, "Learning analytics through machine learning and natural language processing," 2023.
- [27] L. Yan, L. Zhao, D. Gašević, y R. Martinez-Maldonado, "Scalability, sustainability, and ethicality of multimodal learning analytics," in *Proc. LAK'22: 12th Int. Learning Analytics and Knowledge Conf.*, 2022, pp. 13–23.
- [28] L. Yan et al., "Practical and ethical challenges of large language models in education: A systematic scoping review," *British Journal of Educational Technology*, vol. 55, no. 1, pp. 90–112, 2024.
- [29] U. Hanson, C. A. Okonkwo, y C. U. Orakwe, "Implementing AI-enhanced learning analytics to improve educational outcomes using psychological insights," *Journal of Educational Technology Innovations*, 2024.
- [30] A. Alam y A. Mohanty, "Business models, business strategies, and innovations in EdTech companies: Integration of learning analytics and artificial intelligence in higher education," in *Proc. IEEE 6th Conf. on Information and Communication Technology (CICT)*, 2022, pp. 1–6.
- [31] Dutta, D. (2022). *Edtech with Perspective of Business Analysis*. perception, 6(03).
- [32] B. Williamson, "Meta-edtech," *Learning, Media and Technology*, vol. 46, no. 1, pp. 1–5, 2021, doi: 10.1080/17439884.2021.1876089.
- [33] M.A.Chatti et al., "Learning analytics: Challenges and future research directions," *E-Learning and Education*, no.10, 2014.
- [34] R. Pelánek, "Learning analytics challenges: Trade-offs, methodology, scalability," in *Proc. 10th Int. Conf. on Learning Analytics & Knowledge*, 2020, pp. 554–558.
- [35] C. Herodotou et al., "The scalable implementation of predictive learning analytics at a distance learning university: Insights from a longitudinal case study," *The Internet and Higher Education*, vol. 45, p. 100725, 2020.
- [36] A. Wilson, C. Watson, T. L. Thompson, V. Drew, y S. Doyle, "Learning analytics: Challenges and limitations," *Teaching in Higher Education*, vol. 22, no. 8, pp. 991–1007, 2017.
- [37] S. Dyer, *Feedback by Design: Exploring Interactions Between Novice Programmers and Automated Teaching Assistants*, Ph.D. dissertation, Univ. of Auckland, 2025.
- [38] J. C. Debuse, M. Lawley, y R. Shibl, "Educators' perceptions of automated feedback systems," *Australasian Journal of Educational Technology*, vol. 24, no. 4, 2008.
- [39] UNESCO, *A Global Conversation on the Ethics of AI for Children*, UNESCO, 2024. [Online]. Available: <https://media.unesco.org/sites/default/files/webform/ed3002/390204eng.pdf>
- [40] K. Vayadande, P. A. Bailke, L. S. Khedekar, R. Kumar, y V. R. Dange, "A review on text analysis using NLP," in *How Machine Learning is Innovating Today's World: A Concise Technical Guide*, pp. 13–23, 2024.
- [41] R. Ranganath, A. K. Fetterman, A. N. Gesselman, y E. J. Johnson, "Using natural language processing to analyse text data in behavioural science," *Nature Human Behaviour*, 2024.
- [42] S. Rathje et al., "GPT is an effective tool for multilingual psychological text analysis," *Proc. Natl. Acad. Sci. USA*, vol. 121, e2308950121, 2024.
- [43] F. Gilardi, M. Alizadeh, y M. Kubli, "ChatGPT outperforms crowd workers for text-annotation tasks," *Proc. Natl. Acad. Sci. USA*, vol. 120, e2305016120, 2023.
- [44] A. S. Ziabari et al., "Reinforced multiple instance selection for speaker attribute prediction," in *Proc. Conf. North American Chapter of the Assoc. Computational Linguistics: Human Language Technologies*, 2024, pp. 3307–3321.

- [45] M. Kurday y G. Vladova, "Learning analytics and educational data mining applications: Bibliometric and ChatGPT-based analysis of research publications from 2014 to 2023," *Journal of Computers in Education*, pp. 1–36, 2025.
- [46] A. Vaswani et al., "Attention is all you need," in *Advances in Neural Information Processing Systems*, vol. 30, pp. 5998–6008, 2017.
- [47] C. Romero y S. Ventura, "Educational data mining: A review of the state of the art," *IEEE Trans. Syst., Man, Cybern., Part C (Applications and Reviews)*, vol. 40, no. 6, pp. 601–618, 2010.
- [48] V. Kagklis, A. Karatrantou, M. Tantoula, C. T. Panagiotakopoulos, y V. S. Verykios, «A learning analytics methodology for detecting sentiment in student fora: A Case Study in Distance Education.», *European Journal of Open, Distance and E-learning*, vol. 18, n.o 2, pp. 74-94, 2015.
- [49] C. Lang, G. Siemens, A. Wise, y D. Gasevic, «Handbook of learning analytics», 2017.
- [50] V. Kovanovic, S. Joksimovic, D. Gašević, y M. Hatala, "What is the source of social capital? The association between social network position and social presence in communities of inquiry," in *CEUR Workshop Proc.*, CEUR-WS, pp. 21–28, 2014.
- [51] J. P. Bernius, S. Krusche, y B. Bruegge, "Machine learning based feedback on textual student answers in large courses," *Computers and Education: Artificial Intelligence*, vol. 3, p. 100081, 2022.
- [52] M. Kumar, L. Khan, y H.-T. Chang, "Evolving techniques in sentiment analysis: A comprehensive review," *PeerJ Comput. Sci.*, vol. 11, p. e2592, 2025.
- [53] Siemens, G. (2013). Learning analytics: The emergence of a discipline. *American Behavioral Scientist*, 57(10), 1380–1400.
- [54] Long, P., & Siemens, G. (2011). Penetrating the fog: Analytics in learning and education. *EDUCAUSE Review*, 46(5), 31–40.
- [55] Baker, R. S., & Inventado, P. S. (2014). Educational data mining and learning analytics. In *Learning analytics* (pp. 61–75). Springer.
- [56] OECD (2019). *OECD Principles on Artificial Intelligence*.
- [57] European Commission (2019). *Ethics Guidelines for Trustworthy AI*.
- [58] NIST (2023). *AI Risk Management Framework (AI RMF 1.0)*.
- [59] Sculley, D. et al. (2015). Hidden technical debt in machine learning systems. *NeurIPS*.
- [60] Breck, E. et al. (2017). The ML Test Score: A rubric for ML production readiness. *Google Research*.
- [61] Amershi, S. et al. (2019). Software engineering for machine learning: A case study. *ICSE*.
- [62] IBM (2020). *AI Governance Framework*.

Declaración sobre uso de Inteligencia Artificial (IA)

Los autores declaramos que hemos utilizado la herramienta de inteligencia artificial *Gemini* para asistirnos en la redacción de este artículo para mejorar la estructura y la claridad del texto. Los contenidos generados por la IA fueron revisados para asegurar su precisión y coherencia con el objetivo del estudio.