

ACADEMIC INTEGRITY IN THE AGE OF ARTIFICIAL INTELLIGENCE: CHALLENGES, RISKS AND OPPORTUNITIES FOR LATIN AMERICAN UNIVERSITIESOscar José Alejo-Machado¹**E-mail:** rektorado@istici.edu.ec**ORCID:** <https://orcid.org/0000-0002-0434-5183>Mario Enrique Vásquez-Jiménez¹**E-mail:** mario.enrique@istici.edu.ec**ORCID:** <https://orcid.org/0009-0002-0312-3957>Stephanie Marcela Delgado-Estrada²**E-mail:** stephanie.delgadoe@ug.edu.ec**ORCID:** <https://orcid.org/0000-0003-2629-1814>Juan Carlos López-Gutiérrez¹**E-mail:** vicerektorado@istici.edu.ec**ORCID:** <https://orcid.org/0000-0001-5294-7093>¹ Instituto Superior Tecnológico de Investigación Científica e Innovación. Ecuador.² Universidad de Guayaquil. Ecuador.**Cita sugerida (APA, séptima edición)**

Alejo-Machado, O. J., Vásquez-Jiménez, M. E., Delgado-Estrada, S. M., & López-Gutiérrez, J. C. (2026). Integridad académica en tiempos de inteligencia artificial: desafíos, riesgos y oportunidades para las universidades latinoamericanas. *Revista UGC*, 4(4), 66-77.

Fecha de presentación: 02/07/2026**Fecha de aceptación:** 27/08/2026**Fecha de publicación:** 01/10/2026**RESUMEN**

La expansión de la inteligencia artificial generativa ha trasladado la integridad académica desde una discusión centrada en el plagio y la autoría hacia un problema institucional relacionado con el aprendizaje, la evaluación, la transparencia y la gobernanza. El objetivo de este artículo fue analizar los desafíos, riesgos y oportunidades que la inteligencia artificial generativa plantea a las universidades latinoamericanas y proponer un marco operativo para políticas de uso responsable. Se realizó una revisión documental de un archivo de Scopus exportado el 3 de agosto de 2026, integrado inicialmente por 51 registros. Mediante criterios de actualidad, pertinencia temática, educación superior y disponibilidad de identificador digital de objeto se seleccionaron exactamente 20 artículos publicados entre 2025 y 2026. El análisis se organizó en seis dimensiones: apropiación y dependencia, autoría y declaración de uso, evaluación auténtica, confiabilidad de detectores, alfabetización en inteligencia artificial y gobernanza institucional. La evidencia muestra que la respuesta universitaria no puede reducirse a prohibiciones ni a sistemas automáticos de detección. Los estudios recientes describen una normalización acelerada de la inteligencia artificial generativa, diferencias entre docentes y estudiantes, ambigüedad normativa, problemas de equidad

y riesgos de delegación cognitiva. Al mismo tiempo, se identifican oportunidades para la retroalimentación, el aprendizaje autorregulado, el rediseño de evaluaciones y la coautoría entre seres humanos e inteligencia artificial con trazabilidad. Se propone un modelo de integridad académica basado en la declaración proporcional, la evidencia del proceso, la verificación de contenidos, el rediseño evaluativo y la alfabetización institucional.

Palabras clave:

Integridad académica, inteligencia artificial generativa, educación superior, evaluación, gobernanza universitaria.

ABSTRACT

The expansion of generative artificial intelligence has shifted academic integrity from a discussion centered on plagiarism and authorship toward an institutional challenge involving learning, assessment, transparency, and governance. The objective of this article was to analyze the challenges, risks, and opportunities that generative artificial intelligence poses to Latin American universities and to propose an operational framework for responsible use policies. A documentary review was conducted using a Scopus file exported on August 3, 2026, initially comprising 51 records. Based on criteria of

recency, thematic relevance, higher education focus, and availability of a digital object identifier, exactly 20 articles published between 2025 and 2026 were selected. The analysis was organized into six dimensions: adoption and dependence, authorship and disclosure of use, authentic assessment, reliability of detection tools, artificial intelligence literacy, and institutional governance. The evidence shows that university responses cannot be limited to prohibitions or automated detection systems. Recent studies describe the rapid normalization of generative artificial intelligence, differences between faculty and students, regulatory ambiguity, equity concerns, and risks of cognitive delegation. At the same time, opportunities were identified for feedback, self-regulated learning, assessment redesign, and traceable human and artificial intelligence coauthorship. An academic integrity model is proposed based on proportional disclosure, evidence of the work process, content verification, assessment redesign, and institutional literacy.

Keywords:

Academic integrity, generative artificial intelligence, higher education, assessment, university governance.

INTRODUCCIÓN

La aparición de herramientas generativas de acceso masivo alteró con rapidez una de las premisas sobre las que descansaba la evaluación universitaria: que el texto, el código, la síntesis o la respuesta presentada por un estudiante representaban de manera razonable su propio proceso cognitivo. Ebrahimzadeh et al. (2026) muestran que este supuesto debe revisarse cuando la producción académica puede ser resultado de una coautoría humano-IA difícil de observar. El problema ya no consiste únicamente en decidir si una herramienta está permitida. La pregunta central es qué evidencia necesita una institución para atribuir aprendizaje, autoría y responsabilidad cuando una parte del proceso puede ser asistida por modelos generativos. Esta transformación obliga a conectar integridad académica, validez de la evaluación y alfabetización tecnológica, porque una política que se limite a prohibir puede quedar rápidamente desfasada frente a prácticas que se normalizan fuera y dentro del aula.

La literatura reciente sugiere que el uso de IAG en educación superior se está desplazando desde la experimentación hacia una incorporación cotidiana. Verma & Kumar (2026) identifican factores de aprendizaje, accesibilidad y participación asociados con la intención de continuar utilizando ChatGPT en contextos académicos. En estudiantes de grado y posgrado, Mady et al. (2026) describen perfiles de integración que no encajan en una dicotomía simple entre uso correcto y uso fraudulento. Muchos estudiantes combinan automatización y apoyo al aprendizaje, lo que dificulta clasificar una práctica exclusivamente por la herramienta empleada. Esta normalización también alcanza al profesorado. Alshamy et al. (2025) encontraron

diferencias de percepción entre estudiantes y académicos, aunque ambos grupos reconocieron utilidades para tareas educativas. Por ello, las universidades necesitan reglas capaces de distinguir asistencia legítima, delegación indebida y colaboración transparente.

La integridad académica adquiere además una dimensión cultural. Harrington et al. (2025) evidencian que estudiantes de distintos contextos pueden juzgar de manera diferente una misma conducta apoyada por IAG. Esa variabilidad es relevante para América Latina, donde sistemas universitarios heterogéneos combinan instituciones públicas y privadas, distintos niveles de conectividad, regulaciones nacionales diversas y culturas disciplinares que no necesariamente interpretan del mismo modo la autoría o la ayuda tecnológica. Jin et al. (2025), en su revisión global de políticas institucionales, muestran que las universidades han seguido trayectorias de adopción diferentes. Para la región, el desafío consiste en evitar la importación mecánica de prohibiciones o protocolos y construir orientaciones compatibles con sus marcos de evaluación, condiciones de acceso y prácticas académicas.

El problema de investigación se organiza en tres tensiones. La primera enfrenta uso extendido y alfabetización insuficiente: disponer de una herramienta no implica comprender sus límites, sesgos o exigencias de verificación. La segunda enfrenta aprovechamiento pedagógico y atribución de autoría: la IAG puede apoyar la ideación, la revisión o la retroalimentación, pero también puede sustituir actividades necesarias para demostrar aprendizaje. La tercera enfrenta control e incertidumbre: las instituciones buscan detectar textos generados, aunque la evidencia reciente cuestiona la confiabilidad de tales sistemas para decisiones de alto impacto. Sun et al. (2026) evaluaron múltiples detectores sobre trabajos, tesis y código, y documentaron fallos sistemáticos y vulnerabilidad frente a modificaciones. En consecuencia, basar sanciones únicamente en una puntuación algorítmica puede crear nuevos problemas de justicia académica.

El objetivo general fue analizar desafíos, riesgos y oportunidades de la IAG para la integridad académica en universidades latinoamericanas mediante una revisión reciente de literatura internacional y proponer un marco de acción institucional adaptable a la región. De este objetivo se derivaron tres propósitos específicos: sistematizar los hallazgos sobre prácticas de estudiantes y docentes; identificar riesgos relacionados con autoría, evaluación, declaración de uso, dependencia y detección; y formular lineamientos para políticas, formación y evaluación auténtica. La pregunta orientadora fue: ¿qué componentes debería integrar una política universitaria de integridad académica para reconocer el uso extendido de IAG sin normalizar la delegación de aprendizaje ni recurrir a mecanismos de control técnicamente débiles?

La primera transformación observable es el cambio de estatus de la IAG: de herramienta extraordinaria a recurso ordinario. Bailey et al. (2026), al estudiar estudiantes de posgrado, encontraron que la utilidad percibida y determinadas prácticas de apoyo durante el proceso de escritura predicen el uso autoinformado de IAG. Esta evidencia es importante porque desplaza el foco desde la existencia de la herramienta hacia el momento y la función con que se utiliza. Generar ideas, reorganizar un esquema, recibir retroalimentación lingüística o comparar alternativas no representan el mismo nivel de sustitución cognitiva que entregar un texto producido por IA sin comprensión. Una política universitaria que trate todas estas acciones como equivalentes crea incentivos para ocultar el uso en lugar de promover una conducta verificable.

Isvaeva et al. (2026) muestran que los estudiantes describen la IAG como apoyo para eficiencia y comprensión conceptual, pero mantienen tensiones asociadas con creatividad, confianza e integridad. La idea de un repertorio de “confiar y verificar” resulta especialmente útil para la educación superior: la alfabetización no consiste en aceptar ni rechazar automáticamente una respuesta, sino en contrastar, revisar y conservar control epistémico. En universidades latinoamericanas, donde la masificación de herramientas gratuitas o de bajo costo puede preceder a la capacitación formal, esta competencia debería convertirse en un resultado de aprendizaje transversal. La pregunta institucional no es solamente quién utiliza IA, sino si el usuario puede explicar qué hizo, qué verificó, qué modificó y qué parte del producto final representa su propio juicio.

Jurcec et al. (2026) confirman que la intención de utilizar ChatGPT en tareas académicas está relacionada con utilidad, facilidad, percepción de riesgo y preocupaciones éticas. Los perfiles de usuarios más activos tienden a evaluar favorablemente la herramienta y a percibir menos riesgos. Esto introduce un desafío para las campañas basadas únicamente en advertencias: quienes más usan IAG pueden ser precisamente quienes menos se identifiquen con mensajes generales sobre peligro. Una estrategia de integridad debe trabajar con prácticas concretas y escenarios disciplinarios. En ingeniería, derecho, salud, educación o ciencias sociales cambian las consecuencias de un error, el valor de la escritura original y las obligaciones de evidencia. La regulación universitaria necesita un núcleo común, pero también reglas locales para asignaturas, programas y tipos de evaluación.

La declaración de uso se ha convertido en uno de los puntos más sensibles. Qu et al. (2025) describen formas estratégicas y conceptuales de no declaración: en algunos casos el estudiante entiende que debería informar el uso y decide no hacerlo; en otros, no considera que determinadas asistencias deban declararse. Esa diferencia es clave para el diseño de políticas. Una regla genérica del tipo “declare cualquier uso de IA” puede resultar tan

amplia que pierda significado, mientras una regla excesivamente permisiva puede ocultar intervenciones sustantivas. La solución más defendible es una declaración proporcional: informar cuando la herramienta haya contribuido a generación de contenido, análisis, traducción sustantiva, estructura argumental, código, imágenes, datos o decisiones metodológicas, y diferenciarlo de correcciones menores equivalentes a herramientas convencionales de edición.

La noción de integridad de coautoría propuesta por Ebrahimzadeh et al. (2026) permite superar la discusión centrada en si la IA debe figurar como autora. El punto relevante es si quien presenta un trabajo comprende, puede defender y asume responsabilidad por aquello que entrega. En trabajos de grado, tesis y proyectos de maestría, esta responsabilidad es especialmente importante porque el producto acredita competencias profesionales y de investigación. Narimani (2026); y Yıldız & Merzifonluoğlu (2026) destacan que el uso ético en investigación de posgrado requiere transparencia, responsabilidad y rendición de cuentas compartida entre estudiantes, tutores e instituciones. Por ello, la supervisión académica debería incluir conversaciones explícitas sobre qué usos son aceptables en búsqueda, análisis, redacción y revisión, en lugar de dejar la interpretación para el momento de una sospecha.

Avdiu-Kryeziu & Kryeziu (2026); y Rodríguez-Morales (2026) examinan el uso de IA en investigación académica y muestran que estudiantes de maestría recurren a estas herramientas en diferentes etapas del proceso. Su trabajo refuerza la necesidad de enseñar integridad dentro del propio flujo de investigación. La declaración no debería funcionar como una confesión de conducta dudosa, sino como un elemento normal de trazabilidad. Un anexo breve que indique herramienta, propósito, etapas de uso y tipo de verificación puede convertir una zona de ocultamiento en evidencia de proceso. Este mecanismo resulta compatible con la lógica de cuadernos de laboratorio, bitácoras metodológicas o registros de decisiones que ya existen en distintas disciplinas.

La disponibilidad de IAG obliga a revisar qué pretende medir una evaluación. Kofinas et al. (2025) analizaron el efecto de la IAG sobre la integridad de evaluaciones auténticas y muestran que no basta con asumir que una tarea contextualizada es inmune a la automatización. La autenticidad debe construirse mediante evidencias que vinculen el producto con decisiones del estudiante. Gao et al. (2025) proponen aumentar multimodalidad e interactividad para reducir la facilidad con que una tarea puede externalizarse completamente a la IA. En términos prácticos, una evaluación puede integrar entregas parciales, defensa oral, comparación de fuentes, decisiones justificadas, datos locales, reflexión sobre errores y revisión posterior. El objetivo no es hacer imposible el uso de IA, sino asegurar que el aprendizaje atribuido al estudiante permanezca observable.

Esta orientación modifica la lógica del control. Una tarea diseñada para un único producto final concentra la evidencia en un documento fácilmente asistido o generado. En cambio, un proceso con hitos distribuye la evidencia: planteamiento, búsqueda, decisiones, borradores, retroalimentación, producto y defensa. La IAG puede utilizarse en algunas etapas siempre que su participación sea explícita y que el estudiante conserve responsabilidad. Mady et al. (2026) sostienen que políticas restrictivas pueden quedar obsoletas frente a una tecnología que los estudiantes perciben como instrumento profesional. Esto no significa eliminar límites, sino formularlos en función del resultado de aprendizaje. Si el propósito es evaluar escritura autónoma, la asistencia generativa puede restringirse; si el propósito es evaluar criterio profesional, puede permitirse con trazabilidad y verificación.

La formación docente es decisiva para este rediseño. Martín-Gómez & González Ruiz (2025) integraron agentes de IA en una secuencia de formación inicial basada en cuestionamiento, comparación, diálogo crítico, verificación, reelaboración y reflexión. El estudio reporta avances en competencias para comparar sistemas, diseñar indicaciones y analizar respuestas, al tiempo que mantiene preocupaciones sobre plagio y dependencia cognitiva. El hallazgo es relevante para universidades latinoamericanas: formar al profesorado solamente en detección o en redacción de prohibiciones deja intacto el problema pedagógico. Se necesitan competencias para diseñar tareas resistentes a la delegación total, evaluar procesos, enseñar verificación y reconocer usos productivos sin reducir la exigencia académica.

El riesgo de dependencia no debe confundirse con frecuencia de uso. Una persona puede utilizar IAG con alta frecuencia y conservar control crítico, mientras otra puede delegar decisiones centrales en pocas ocasiones. Beckman et al. (2025) identifican perfiles diferenciados de estudiantes según conocimientos, experiencia e intención de uso, lo que permite hablar de una nueva brecha de IAG. La inequidad ya no se limita al acceso a internet o dispositivos; incluye capacidad para formular problemas, verificar salidas, reconocer errores y utilizar versiones avanzadas. En América Latina, estas diferencias pueden amplificarse por desigualdades entre instituciones, territorios y programas. Una prohibición uniforme no corrige esa brecha y una apertura sin formación puede convertirla en ventaja acumulativa para quienes poseen mayor alfabetización y recursos.

La dependencia también afecta la agencia del estudiante. Madleňák et al. (2026) identifican riesgos transversales de integridad, privacidad, sesgo, equidad y pérdida de capacidades, y proponen principios de declaración, evidencia de proceso y proporcionalidad. Desde esta perspectiva, el problema no es solo que una respuesta sea correcta o incorrecta, sino qué habilidades dejan de ejercitarse cuando la IA sustituye de manera reiterada la

búsqueda, la argumentación o la escritura. Las universidades necesitan distinguir automatización beneficiosa de automatización que elimina oportunidades de aprendizaje. Esta distinción requiere acuerdos curriculares: algunas capacidades pueden apoyarse con IA después de ser dominadas, mientras otras necesitan momentos de práctica sin asistencia para verificar competencia individual.

Las tensiones emocionales también influyen en la integridad. Qu et al. (2025) muestran que la ambigüedad institucional y la percepción de injusticia en la detección pueden favorecer la no declaración. Esto significa que una política punitiva mal comunicada puede producir el efecto contrario al deseado. Cuando estudiantes y docentes no saben qué está permitido, aparecen estrategias defensivas, ocultamiento y decisiones inconsistentes. La claridad normativa debe acompañarse de ejemplos, criterios de proporcionalidad y mecanismos de consulta. Una institución que modifica sus reglas cada semestre sin un lenguaje común puede aumentar incertidumbre, mientras una política demasiado rígida puede convertirse rápidamente en una norma ignorada.

Los detectores de contenido generado por IA se han convertido en una respuesta rápida a la expansión de estas herramientas, pero su uso disciplinario exige cautela. Sun et al. (2026) evaluaron trece detectores sobre conjuntos de trabajos académicos, tesis y código y encontraron fallos sistemáticos según tipo de tarea y disciplina, además de vulnerabilidad frente a ediciones. La implicación institucional es directa: una puntuación de probabilidad no debería utilizarse como prueba única de fraude. En contextos multilingües, como buena parte de América Latina, esta precaución es todavía más importante porque estilos de escritura, traducción, dominio lingüístico y convenciones disciplinarias pueden afectar el comportamiento de sistemas entrenados con distribuciones distintas.

La detección puede conservar una función auxiliar cuando se integra en un procedimiento humano. Un resultado atípico puede motivar revisión de borradores, conversación con el estudiante, defensa del contenido o comparación con evidencia previa; no debería producir automáticamente una sanción. Tsao (2025) muestra que las políticas ambiguas y la aplicación desigual generan ansiedad, inequidad y estrategias para evadir controles. Por ello, la justicia procedimental debe formar parte de la integridad académica. Una universidad no protege la integridad si combate una posible conducta indebida mediante instrumentos que no puede explicar o cuya tasa de error desconoce. La carga probatoria debe descansar en evidencia académica acumulada y en procedimientos transparentes.

El cambio de enfoque implica pasar de detectar productos a documentar procesos. Portafolios, versiones, bitácoras de decisiones, fuentes consultadas, registros de cambios, defensas orales y actividades presenciales breves pueden ofrecer evidencia más sólida que una estimación

algorítmica. Gao et al. (2025) vinculan este principio con diseños interactivos y multimodales. La oportunidad para América Latina consiste en adoptar estrategias de bajo costo que no dependan exclusivamente de licencias comerciales. Muchas medidas de integridad pueden implementarse mediante diseño curricular, conversación pedagógica y evidencias secuenciales, reduciendo al mismo tiempo el riesgo de falsas acusaciones.

La misma tecnología que introduce riesgos puede utilizarse para fortalecer competencias académicas si su empleo se integra en actividades de verificación. Verma & Kumar (2026) muestran que el apoyo al aprendizaje y la accesibilidad son factores relevantes para el uso futuro de ChatGPT. En lugar de negar esa utilidad, una política responsable puede exigir que los estudiantes contrasten respuestas con literatura, identifiquen errores, reformulen preguntas y documenten decisiones. Este enfoque convierte la IAG en objeto de análisis y no en autoridad epistémica. La alfabetización en IA debería incluir funcionamiento básico de modelos, límites de actualidad, alucinaciones, sesgos, privacidad, propiedad intelectual, trazabilidad y responsabilidad. También debe enseñar cuándo no utilizar una herramienta, especialmente cuando la actividad busca evidenciar una competencia individual específica.

Alshamy et al. (2025) señalan que estudiantes y académicos reconocen beneficios de eficiencia e innovación, aunque difieren en sus preocupaciones. Esta asimetría puede aprovecharse mediante espacios de deliberación institucional. Las políticas más sostenibles no deberían redactarse únicamente desde oficinas jurídicas o tecnológicas; necesitan participación de docentes, estudiantes, bibliotecas, unidades de investigación, ética y apoyo pedagógico. Karkoulían et al. (2025), a partir de percepciones de estudiantes y profesores, subrayan precisamente la necesidad de políticas claras acompañadas de soporte y capacitación. Para universidades latinoamericanas, la construcción participativa puede además adaptar reglas a diferencias lingüísticas, disciplinares y culturales.

La alfabetización también debe alcanzar a investigadores y posgrados. Yıldız & Merzifonluoğlu (2026) proponen entender la integridad en investigación asistida por IAG como responsabilidad compartida. Esto supone que directores de tesis y comités conozcan usos aceptables y puedan orientar sin asumir que toda asistencia constituye fraude. En trabajos de maestría y doctorado, la trazabilidad puede incluir una declaración metodológica del uso de IA, conservación de prompts relevantes, verificación de referencias y prohibición explícita de fabricar datos, fuentes o resultados. La IAG puede apoyar redacción o exploración, pero no legitima presentar evidencia inexistente.

Jin et al. (2025) muestran que las instituciones de educación superior han respondido a la IAG mediante políticas y guías con distintos grados de apertura. La diversidad

de respuestas sugiere que no existe una única política óptima. Tsao (2025) añade que las políticas adquieren significado cuando estudiantes y docentes las interpretan y aplican en contextos reales; por ello, el texto formal es solo una parte de la gobernanza. Una política latinoamericana debería definir un mínimo institucional —principios, transparencia, privacidad, responsabilidad y debido proceso— y permitir que facultades y asignaturas especifiquen reglas según sus resultados de aprendizaje. Esta arquitectura evita tanto la fragmentación absoluta como una norma central incapaz de responder a diferencias disciplinares.

Madleňák et al. (2026) proponen un marco de cuatro pilares para gobernanza institucional y destacan principios de evidencia del proceso, privacidad y proporcionalidad. Estos elementos pueden convertirse en una matriz de implementación. Primero, toda política debe explicar qué usos requieren declaración. Segundo, la institución debe establecer qué datos no pueden introducirse en servicios externos. Tercero, las evaluaciones deben identificar qué competencias necesitan desempeño individual. Cuarto, el procedimiento disciplinario debe excluir decisiones automáticas basadas únicamente en detectores. Quinto, el acceso a formación y herramientas debe considerar equidad. Una política que cubra estos componentes transforma la integridad académica en una responsabilidad del sistema y no solo del estudiante.

La oportunidad más significativa consiste en redefinir integridad como capacidad para trabajar con herramientas avanzadas sin perder autoría, comprensión ni responsabilidad. El mercado profesional utilizará IA en múltiples sectores; prohibirla de manera general puede separar la universidad del entorno laboral. Sin embargo, normalizar cualquier forma de delegación también sería incompatible con la función formativa. La respuesta adecuada es una integración con límites: permitir asistencia donde aporte valor, exigir evidencia cuando el aprendizaje pueda quedar oculto y mantener espacios de desempeño autónomo. La integridad deja así de ser únicamente un régimen de sanción y se convierte en una competencia académica y profesional.

MATERIALES Y MÉTODOS

La investigación adoptó un diseño documental, cualitativo y descriptivo-interpretativo. El corpus se construyó a partir de un archivo RIS exportado desde Scopus el 3 de agosto de 2026. El archivo contenía 51 registros sobre inteligencia artificial generativa, educación superior, ética, evaluación e integridad académica. La unidad de análisis fue el artículo científico. Se aplicaron cuatro criterios de inclusión: publicación en 2025 o 2026; relación directa con educación superior o con evaluación académica aplicable a este nivel; presencia explícita de IAG, ChatGPT, integridad, ética, política, evaluación o alfabetización; y DOI registrado en el archivo. Se excluyeron

estudios sin DOI, trabajos centrados exclusivamente en educación secundaria cuando no ofrecían implicaciones transferibles y artículos cuyo foco principal se alejaba del problema de integridad. El proceso produjo exactamente veinte referencias, conforme al límite editorial establecido para el artículo.

La selección priorizó fuentes que permitieran representar diferentes actores y problemas. Se incluyeron estudios sobre estudiantes de grado, estudiantes de posgrado, docentes y académicos; análisis de políticas institucionales; investigaciones sobre declaración de uso, dependencia, intenciones, percepción ética y desigualdad; propuestas de evaluación auténtica; y evaluaciones de detectores. La presencia de estudios internacionales se utilizó como evidencia comparada y no como descripción directa de América Latina. Esta distinción es metodológicamente importante porque el archivo proporcionado contenía poca investigación empírica específicamente latinoamericana. En consecuencia, el artículo formula implicaciones para la región mediante transferencia analítica de problemas y soluciones, y reconoce la necesidad de validación local.

La técnica fue el análisis temático dirigido. Para cada referencia se registraron año, población o actor estudiado, diseño, problema de integridad, riesgo principal, oportunidad y recomendación institucional. A partir de una lectura iterativa se consolidaron seis categorías: apropiación y dependencia; autoría y declaración; evaluación auténtica; detección de IAG; alfabetización y equidad; y gobernanza. Una misma fuente podía contribuir a varias categorías cuando su resumen y resultados lo justificaban. La síntesis evitó convertir frecuencia de aparición en importancia causal; el objetivo fue identificar convergencias y tensiones entre estudios recientes.

Como complemento se diseñó un instrumento de encuesta para una futura validación latinoamericana con docentes, estudiantes de grado y estudiantes de maestría. El cuestionario propuesto mide frecuencia de uso, finalidades, conocimiento de políticas, prácticas de verificación, declaración de uso y percepción de integridad. Debido a que no se dispone de una base individual verificable de respuestas, el presente artículo no presenta inferencias estadísticas ni atribuye resultados de encuesta a una muestra real. Para planificación del trabajo de campo se consideran tres umbrales de contraste planteados por el equipo investigador: uso intensivo cercano al 70 %, uso técnicamente correcto por debajo del 50 % y declaración explícita de uso por debajo del 10 %. Estos valores deben validarse mediante una nueva aplicación antes de ser tratados como hallazgos empíricos.

La calidad bibliográfica se controló conservando únicamente registros con DOI y manteniendo la información

de autoría, año, título y revista proveniente del archivo Scopus. Los DOI se incorporaron en formato URL al listado final para facilitar verificación y gestión en Zotero. En el plano ético, la revisión no involucró datos personales. La principal limitación es la escasez de evidencia específica para universidades latinoamericanas dentro del corpus aportado; por ello, las recomendaciones se presentan como un marco adaptable y no como una descripción homogénea de todos los sistemas nacionales de la región (Tabla 1).

Tabla 1. Composición temática del corpus seleccionado.

Eje	N.º de referencias	Problema central	Aporte a la integridad académica
Uso, adopción y perfiles	5	Frecuencia, utilidad, dependencia y diversidad de usuarios.	Distinguir frecuencia de uso de sustitución cognitiva.
Autoría, ética y declaración	5	Transparencia, coautoría, responsabilidad y no declaración.	Establecer reglas proporcionales y trazabilidad.
Evaluación y detección	4	Validez de tareas, autenticidad y confiabilidad de detectores.	Priorizar evidencia del proceso y debido proceso.
Política y gobernanza	3	Guías institucionales, interpretación y aplicación.	Combinar principios centrales con adaptación disciplinar.
Alfabetización y equidad	3	Competencias, brechas de acceso y formación docente.	Desarrollar capacidades para verificar, declarar y decidir.

Nota. Las categorías son analíticas; algunas referencias aportan a más de un eje, aunque se asignaron a un eje principal para el conteo.

La Tabla 2 presenta un marco operativo orientado a garantizar el uso responsable de la inteligencia artificial generativa en el ámbito académico. Las dimensiones de autoría, declaración, verificación, evaluación, equidad y privacidad, y debido proceso permiten relacionar los principios de integridad académica con mecanismos concretos de control y evidencias verificables. Se evidencia que el uso adecuado de estas herramientas no depende únicamente de declarar su utilización, sino también de garantizar que el estudiante comprenda y pueda defender el trabajo realizado, verifique la información obtenida, proteja los datos utilizados y asuma la responsabilidad sobre el producto académico final. Asimismo, se destaca la necesidad de una evaluación humana sustentada en diversas evidencias para prevenir errores, falsos positivos y sanciones injustificadas.

Tabla 2. Marco operativo de integridad académica para el uso de IAG.

Dimensión	Pregunta de control	Evidencia esperada	Riesgo si se omite
Autoría	¿El estudiante comprende y puede defender el producto?	Defensa, borradores, decisiones justificadas.	Presentar contenido no comprendido como propio.
Declaración	¿La contribución de IA es visible y proporcional?	Nota de uso: herramienta, propósito y etapa.	Ocultamiento y ambigüedad sobre responsabilidad.
Verificación	¿Se contrastaron hechos, fuentes y referencias?	Fuentes primarias, correcciones y registro de contraste.	Alucinaciones, citas inexistentes y errores no detectados.
Evaluación	¿La tarea hace observable el aprendizaje individual?	Hitos, defensa oral, datos locales, reflexión.	Delegación completa del producto.
Equidad y privacidad	¿Existen condiciones seguras y comparables de acceso?	Alternativas institucionales y reglas de datos.	Brechas, filtración de datos y trato desigual.
Debido proceso	¿La sospecha se evalúa con evidencia múltiple?	Revisión humana, conversación y evidencia acumulada.	Falsos positivos y sanciones automatizadas.

Nota. El marco sintetiza problemas recurrentes del corpus y puede adaptarse por facultad, programa y tipo de evaluación.

RESULTADOS Y DISCUSIÓN

El primer resultado es la convergencia de la literatura hacia una idea: la IAG ya no puede tratarse como una excepción temporal. Los estudios de estudiantes muestran incorporación en escritura, investigación, tareas y apoyo al aprendizaje. Bailey et al. (2026) documentan usos de posgrado a lo largo del proceso de escritura, mientras Avdiu-Kryeziu & Kryeziu (2026) describen empleo en etapas de investigación. Verma & Kumar (2026) identifican factores que sostienen la intención de uso futuro. La consecuencia para las universidades latinoamericanas es que una política basada en esperar la desaparición de estas herramientas carece de fundamento. El escenario más probable es una convivencia prolongada con sistemas más capaces y accesibles, por lo que la integridad debe construirse dentro del uso y no solamente mediante exclusión.

El segundo resultado es que la frontera entre apoyo y sustitución depende del diseño pedagógico y de la transparencia. Mady et al. (2026) encuentran perfiles que combinan automatización y aprendizaje, lo que cuestiona clasificaciones binarias. Ebrahimzadeh et al. (2026) responden a este problema con el concepto de integridad de coautoría: lo fundamental es conservar validez de la evidencia de aprendizaje. Este principio permite definir niveles. Un uso de IA para lluvia de ideas con revisión humana no es equivalente a generar una respuesta completa y presentarla sin comprensión. La política institucional debería describir ejemplos y exigir mayor trazabilidad a medida que aumenta la contribución generativa.

El tercer resultado es que la declaración de uso continúa siendo una zona crítica. Qu et al. (2025) muestran que estudiantes pueden omitir la declaración por razones

estratégicas o por no considerar que cierto apoyo la requiera. Yıldız & Merzifonluoğlu (2026) enfatizan transparencia y responsabilidad en investigación de posgrado. Esto sugiere que la declaración debe normalizarse y dejar de estar asociada exclusivamente con sospecha. Una plantilla institucional sencilla puede preguntar qué herramienta se utilizó, para qué, en qué etapa y cómo se verificó. Cuando la declaración es rutinaria, la universidad obtiene información para enseñar mejores prácticas y reduce la ambigüedad que favorece el ocultamiento.

El cuarto resultado afecta a la evaluación. Gao et al. (2025); y Kofinas et al. (2025) coinciden en la necesidad de reconsiderar tareas susceptibles de externalización. La respuesta más consistente no es aumentar la vigilancia, sino mejorar el diseño de la evidencia. Las evaluaciones pueden incorporar datos del contexto local, interacción, defensa, revisión de decisiones y productos parciales. Este enfoque tiene una ventaja para universidades con recursos limitados: depende más de pedagogía que de software costoso. Al mismo tiempo, exige tiempo docente, coordinación y criterios de evaluación que reconozcan el proceso.

El quinto resultado es una advertencia sobre detectores. Sun et al. (2026) muestran que su rendimiento varía según tarea y disciplina y que pueden fallar ante modificaciones. La literatura sobre política añade que la aplicación desigual de controles puede generar ansiedad y resistencia. Tsao (2025) documenta cómo ambigüedades y condiciones materiales afectan la forma en que estudiantes y docentes interpretan las normas. Por tanto, la detección automática no debería convertirse en el centro de una estrategia de integridad. Su lugar, si se utiliza, es subsidiario y sujeto a revisión humana.

El sexto resultado es la necesidad de gobernanza y alfabetización conjunta. Jin et al. (2025) muestran diversidad internacional de políticas; Karkoulían et al. (2025) reclaman reglas claras, apoyo y formación; Madleňák et al. (2026) articulan riesgos de integridad, privacidad, equidad y agencia. Estas fuentes convergen en que la política efectiva no es un documento aislado. Requiere capacitación, apoyo docente, ajustes en evaluación, procedimientos de consulta, revisión periódica y mecanismos de protección de datos. Para América Latina, esta lectura es especialmente pertinente porque las diferencias entre instituciones pueden hacer inviable una única solución tecnológica.

El séptimo resultado es que la formación docente puede convertir la IAG en objeto de pensamiento crítico. Martín-Gómez & González Ruiz (2025) muestran una experiencia en la que el trabajo con varias herramientas se estructura mediante comparación, verificación y reflexión. Este tipo de secuencia ofrece una alternativa al uso pasivo. En lugar de pedir a estudiantes que no utilicen IA, puede pedírseles detectar errores, justificar por qué aceptan o rechazan una salida y documentar cómo mejoraron una respuesta. El aprendizaje de integridad se vuelve entonces práctico y evaluable.

Finalmente, la literatura identifica una tensión de equidad. Beckman et al. (2025) muestran perfiles diferentes de alfabetización y experiencia. En América Latina, donde existen brechas de conectividad y financiamiento, la aparición de versiones pagadas con mejores prestaciones puede convertir la IAG en un nuevo mecanismo de diferenciación. Las políticas deben evitar exigir herramientas que no estén disponibles para todos y ofrecer alternativas

institucionales cuando una actividad dependa de ellas. La integridad incluye también condiciones justas para participar.

Instrumento propuesto para validación latinoamericana

La revisión permitió construir un cuestionario breve para docentes, estudiantes de grado y estudiantes de maestría. Su propósito no es clasificar personas como íntegras o no íntegras, sino describir prácticas y necesidades de formación. Se recomienda aplicar el instrumento de forma anónima, separar claramente investigación de control disciplinario y solicitar consentimiento informado según las reglas de cada institución. Las respuestas deben analizarse por perfil, campo disciplinar y nivel de familiaridad con IAG. Tres indicadores merecen especial atención en una futura aplicación: proporción de usuarios que emplean IA en la mayoría de sus actividades, proporción que aplica prácticas de uso responsable y proporción que declara explícitamente la asistencia de IA en trabajos entregados.

Para la etapa de planificación se establecieron tres umbrales de contraste: un uso intensivo cercano al 70 %, una proporción de uso correcto inferior al 50 % y una declaración explícita inferior al 10 %. Estos umbrales no se presentan como resultados del estudio porque la base individual que permitiría auditarlos no está disponible. Su función es orientar el tamaño de muestra, la codificación y las hipótesis descriptivas de una nueva aplicación. Esta precaución es coherente con el objeto del propio artículo: la integridad académica exige distinguir entre evidencia observada, datos reconstruidos y expectativas de investigación (Tabla 3).

Tabla 3. Dimensiones e ítems del cuestionario propuesto.

Dimensión	Ítems sugeridos	Escala	Indicador
Frecuencia de uso	Uso IAG para estudiar, preparar clases, escribir, resumir, analizar o investigar.	Nunca–Siempre (1–5)	Uso intensivo = 4 o 5.
Uso responsable	Verifico información; reviso referencias; identifico errores; mantengo responsabilidad sobre el producto.	Nunca–Siempre (1–5)	Correcto = promedio ≥4.
Declaración	Informo cuando la IAG contribuye de forma sustantiva a un trabajo entregado.	Nunca–Siempre (1–5)	Declaración consistente = 4 o 5.
Conocimiento normativo	Conozco qué usos están permitidos y cuáles deben declararse.	Nada–Mucho (1–5)	Alfabetización normativa.
Percepción de riesgos	Reconozco riesgos de errores, dependencia, privacidad y autoría.	Desacuerdo–Acuerdo (1–5)	Conciencia de riesgo.
Oportunidad pedagógica	La IAG puede apoyar retroalimentación, ideación y aprendizaje si se verifica.	Desacuerdo–Acuerdo (1–5)	Aceptación condicionada.

Nota. El instrumento debe ser sometido a validez de contenido y prueba piloto antes de una aplicación inferencial.

La principal implicación de la revisión es que la integridad académica no puede sostenerse con una definición de autoría diseñada para un entorno sin coescritura algorítmica. Ebrahimzadeh et al. (2026) ofrecen una salida al desplazar la atención hacia la comprensión y la

responsabilidad. Este cambio resulta especialmente útil para América Latina porque permite evitar respuestas extremas. Una universidad no necesita declarar que todo uso de IA es plagio ni aceptar cualquier uso por ser tecnológicamente inevitable. Puede exigir que el estudiante

conservar dominio del contenido y aportar evidencia suficiente del proceso. La integridad se convierte así en una relación entre herramienta, propósito, transparencia y aprendizaje.

La declaración proporcional aparece como mecanismo central. La evidencia de Qu et al. (2025) muestra que las obligaciones vagas pueden producir no declaración, mientras Yıldız & Merzifonluoğlu (2026) enfatizan responsabilidad compartida en posgrado. En consecuencia, las universidades deberían publicar ejemplos por niveles: usos libres que no requieren declaración, usos permitidos con declaración y usos restringidos porque sustituyen la competencia evaluada. Esta taxonomía reduce incertidumbre y permite que estudiantes y docentes discutan casos concretos. También facilita que las políticas sean revisables cuando cambian las capacidades de los modelos.

La segunda implicación es pedagógica. Gao et al. (2025); y Kofinas et al. (2025) sugieren que la fortaleza de una evaluación depende de la evidencia que captura, no de la imposibilidad técnica de utilizar IA. En la región, donde muchas instituciones enfrentan grupos numerosos, el rediseño debe ser viable. No todas las materias pueden incorporar defensas individuales extensas, pero sí pueden utilizar muestras aleatorias de defensa, entregas parciales, ejercicios presenciales breves, fuentes locales o reflexiones sobre decisiones. El principio es distribuir la evidencia de aprendizaje de forma que el producto final no sea el único punto de observación.

La tercera implicación es procedimental. La evaluación de detectores realizada por Sun et al. (2026) obliga a tratar sus resultados como indicios y no como pruebas concluyentes. Un procedimiento de integridad debería especificar que ninguna sanción se basa únicamente en una estimación automática. Esta regla protege al estudiante y también a la institución, porque reduce decisiones difíciles de justificar técnicamente. Además, en una región lingüísticamente diversa, la fiabilidad debe evaluarse localmente antes de incorporar cualquier detector a procesos formales.

La cuarta implicación es de política pública universitaria. Jin et al. (2025) muestran una adopción institucional desigual, y Tsao (2025) evidencia que las políticas se reinterpretan en la práctica. Para América Latina, una estrategia regional podría compartir principios y recursos sin imponer uniformidad. Redes universitarias pueden desarrollar modelos de declaración, casos disciplinares, cursos de alfabetización y guías de privacidad en español y portugués. Compartir materiales reduciría costos y permitiría a instituciones con menor capacidad evitar respuestas improvisadas.

La quinta implicación es de equidad. Beckman et al. (2025) advierten que la IAG puede reproducir una nueva

brecha entre estudiantes. Una política de integridad que exige herramientas avanzadas sin garantizar acceso puede resultar injusta; una política que las prohíbe también puede perjudicar a quienes necesitan apoyos de accesibilidad o lenguaje. La proporcionalidad exige identificar el propósito pedagógico y ofrecer alternativas equivalentes. Esto incluye atención a estudiantes que trabajan, estudian a distancia o se encuentran en contextos con conectividad limitada.

Los indicadores planteados para una futura encuesta — uso intensivo cercano al 70 %, uso correcto inferior al 50 % y declaración inferior al 10 % — son plausibles como hipótesis a la luz de una literatura que documenta alta adopción, tensiones éticas y problemas de transparencia, pero no pueden aceptarse sin recolección verificable. Precisamente porque el artículo trata de integridad, reconstruir una base individual para obtener esos porcentajes y presentarla como observada sería metodológicamente incompatible con sus conclusiones. La siguiente fase debe reapplicar el cuestionario o recuperar registros auditables, y solo entonces comparar perfiles de docentes, grado y maestría.

Recomendaciones institucionales

La primera recomendación es adoptar una política de tres niveles. El nivel uno comprendería usos permitidos sin declaración cuando la intervención sea equivalente a apoyo mecánico menor; el nivel dos incluiría usos permitidos con declaración cuando la IA influya en contenido, análisis, estructura o código; y el nivel tres abarcaría usos restringidos cuando la herramienta sustituya la competencia que la evaluación pretende medir. Cada asignatura debería comunicar el nivel aplicable antes de la tarea. Esta arquitectura convierte una regla abstracta en una decisión pedagógica observable.

La segunda recomendación es sustituir la dependencia de detectores por evidencia del proceso. Los programas deberían incorporar, de manera proporcional, borradores, historial de cambios, fuentes, defensas, decisiones justificadas o bitácoras. Cuando se utilice un detector, su resultado solo puede activar revisión adicional. La política debe incluir derecho a explicación y posibilidad de que el estudiante demuestre conocimiento mediante medios alternativos.

La tercera recomendación es implementar alfabetización obligatoria y diferenciada. Los estudiantes necesitan formación sobre verificación, referencias, privacidad, sesgos y declaración; el profesorado necesita además diseño de evaluación, supervisión de investigación y criterios de evidencia. Las unidades de posgrado requieren orientaciones específicas sobre análisis de datos, redacción, revisión bibliográfica y uso de información confidencial. La capacitación debe renovarse periódicamente porque las capacidades de los modelos cambian con rapidez.

La cuarta recomendación es crear un formato institucional breve de declaración de IAG. El formato debería registrar herramienta, propósito, etapa de uso y verificación realizada. No debe exigir la entrega de conversaciones completas cuando ello comprometa privacidad; bastará con conservar evidencia proporcional al riesgo y al tipo de trabajo. Para tesis o proyectos de investigación puede agregarse como anexo metodológico.

La quinta recomendación es evaluar la política. Las universidades deberían medir conocimiento de reglas, frecuencia de declaración, percepción de justicia, tipos de uso, incidentes, apelaciones y necesidades de formación. El instrumento propuesto en este artículo puede servir como punto inicial después de validación. Comparar docentes, estudiantes de grado y maestría permitiría identificar diferencias que una política uniforme podría ocultar (Tabla 4).

Tabla 4. Hoja de ruta institucional para integridad académica e IAG.

Acción	Responsable	Evidencia	Indicador	Horizonte
Definir niveles de uso y declaración	Rectorado / académica / facultades	Política y ejemplos disciplinares	% asignaturas con regla explícita	0–6 meses
Formar docentes y estudiantes	Desarrollo docente / bibliotecas	Cursos y microcredenciales	% participantes certificados	0–12 meses
Rediseñar evaluaciones prioritarias	Carreras / coordinaciones	Tareas con evidencia de proceso	% evaluaciones críticas rediseñadas	6–18 meses
Establecer debido proceso para sospechas	Integridad / asesoría jurídica	Protocolo sin sanción automática	% casos con evidencia múltiple	0–6 meses
Medir uso, declaración y alfabetización	Investigación institucional	Encuesta validada y tablero	Tendencias por perfil y programa	Anual

Nota. Los horizontes son orientativos y deben adaptarse al tamaño, normativa y capacidades de cada institución.

CONCLUSIONES

La revisión de veinte artículos recientes confirma que la inteligencia artificial generativa ha convertido la integridad académica en un problema de gobernanza universitaria. La cuestión ya no puede resolverse mediante una oposición simple entre permitir y prohibir. Estudiantes y docentes incorporan estas herramientas con finalidades diversas, y la misma tecnología puede apoyar comprensión, escritura o retroalimentación y, al mismo tiempo, facilitar delegación de tareas que deberían evidenciar aprendizaje. La respuesta institucional debe concentrarse en responsabilidad, transparencia y validez de la evaluación.

Los principales riesgos identificados son la autoría opaca, la no declaración, la dependencia cognitiva, las brechas de alfabetización y acceso, la ambigüedad normativa y el uso disciplinario de detectores con confiabilidad limitada. Frente a ellos, las oportunidades se encuentran en la evaluación auténtica, la evidencia del proceso, la alfabetización en IA, la formación docente, la declaración proporcional y una concepción de coautoría en la que el estudiante conserva comprensión y responsabilidad. Estas medidas son más sostenibles que una estrategia centrada exclusivamente en vigilancia tecnológica.

Para las universidades latinoamericanas se propone una arquitectura adaptable con principios comunes y especificación disciplinar. Toda institución debería definir qué usos son libres, cuáles requieren declaración y cuáles se restringen porque sustituyen la competencia evaluada; asegurar debido proceso; proteger datos; ofrecer formación; y medir periódicamente cómo se utiliza la IAG. El estudio reconoce como limitación que el corpus aportado

es predominantemente internacional, por lo que las conclusiones requieren validación regional.

La siguiente etapa debe ser empírica. El cuestionario propuesto permite comparar docentes, estudiantes de grado y maestría en frecuencia de uso, uso responsable, conocimiento normativo y declaración. Los umbrales de referencia considerados para planificación —uso intensivo cercano al 70 %, uso correcto inferior al 50 % y declaración inferior al 10 %— deben contrastarse con una nueva base verificable antes de publicarse como resultados. Mantener esa distinción entre hipótesis y evidencia constituye, en sí misma, una condición de integridad académica.

REFERENCIAS

Alshamy, A., Al-Harthi, A. S. A., & Abdullah, S. (2025). Perceptions of generative AI tools in higher education: Insights from students and academics at Sultan Qaboos University. *Education Sciences*, 15(4), 501. <https://doi.org/10.3390/educsci15040501>

Avdiu-Kryeziu, S., & Kryeziu, V. (2026). Students’ use of artificial intelligence in academic research: Benefits, challenges, and academic integrity. *Praxis Educativa*, 21, 1-18. <https://revistas.uepg.br/index.php/praxiseducativa/en/article/view/26164/209209220574>

Bailey, D., Byrne, J., He, H., McConnell, J. R., & Bruster, B. (2026). Generative AI across the writing process in higher education: Graduate students’ perceived appropriateness, utility, and self-reported use. *Technology, Knowledge and Learning*. <https://doi.org/10.1007/s10758-026-10017-4>

- Beckman, K., Apps, T., Howard, S. K., Rogerson, C., Rogerson, A., & Tondeur, J. (2025). The GenAI divide among university students: A call for action. *The Internet and Higher Education*, 67, 101036. <https://doi.org/10.1016/j.iheduc.2025.101036>
- Ebrahimzadeh, M., Shibani, A., & Shum, S. B. (2026). Coauthorship integrity: Reconceptualising assessment validity for the age of generative artificial intelligence. *Computers and Education: Artificial Intelligence*, 10, 100609. <https://doi.org/10.1016/j.caeai.2026.100609>
- Gao, Y., Zhai, X., Li, M., Lee, G., & Liu, X. (2025). A multimodal interactive framework for science assessment in the era of generative artificial intelligence. *Journal of Research in Science Teaching*, 62(9), 2014–2028. <https://doi.org/10.1002/tea.70009>
- Harrington, B., Zlotnikova, I., Nadarajan, G., & Ekundayo, S. (2025). Did Alice do wrong? Cross-cultural differences in student perceptions of generative AI use in university computing education. *ACM Transactions on Computing Education*, 26(1), 1-23. <https://doi.org/10.1145/3776558>
- Isaeva, R., Caner, H. N., Caner, M., Giray, L., & Karadag, E. (2026). Students' engagement with generative AI in academic learning: A self-determination theory and epistemic network analysis study. *Computers and Education: Artificial Intelligence*, 10, 100606. <https://doi.org/10.1016/j.caeai.2026.100606>
- Jin, Y., Yan, L., Echeverria, V., Gašević, D., & Martinez-Maldonado, R. (2025). Generative AI in higher education: A global perspective of institutional adoption policies and guidelines. *Computers and Education: Artificial Intelligence*, 8, 100348. <https://doi.org/10.1016/j.caeai.2024.100348>
- Jurcec, L., Kolega, M., & Miljkovic Krecar, I. (2026). The chat dilemma: Usefulness, risk, ethics, and student intentions to use generative AI in higher education. *Technology in Society*, 87, 103427. <https://doi.org/10.1016/j.techsoc.2026.103427>
- Karkoulou, S., Sayegh, N., & Sayegh, N. (2025). ChatGPT unveiled: Understanding perceptions of academic integrity in higher education: A qualitative approach. *Journal of Academic Ethics*, 23(3), 1171–1188. <https://doi.org/10.1007/s10805-024-09543-6>
- Kofinas, A. K., Tsay, C. H.-H., & Pike, D. (2025). The impact of generative AI on academic integrity of authentic assessments within a higher education context. *British Journal of Educational Technology*, 56(6), 2522–2549. <https://doi.org/10.1111/bjet.13585>
- Madleňák, R., Madleňáková, L., Cvacho, V., & Gachulinec, D. (2026). Ethical challenges of artificial intelligence in higher education: A four-pillar student-activity framework for institutional governance. *Education Sciences*, 16(4), 555. <https://doi.org/10.3390/educsci16040555>
- Mady, M., Baadel, S., & Allam, Y. (2026). Beyond constructive vs. disruptive: An empirical typology of student engagement with generative AI, challenging binary constructs in academic integrity. *Journal of Information & Knowledge Management*, 2650042. <https://doi.org/10.1142/S0219649226500425>
- Martín-Gómez, S., & González Ruiz, C. J. (2025). AI in higher education: Initial teacher training in the critical and didactic use of artificial intelligence. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, 20, 302–309. <https://doi.org/10.1109/RITA.2025.3616509>
- Narimani, M. (2026). Digital transformation in higher education: challenges and opportunities. *Sophia Research Review*, 3(2), 48-55. <https://doi.org/10.64092/rvkw007>
- Qu, Y., Loo, H. E., & Wang, J. (2025). Generative artificial intelligence in higher education: Emotional tensions and ethical declaration. *British Journal of Educational Technology*. <https://doi.org/10.1111/bjet.70029>
- Rodríguez-Morales, A. (Comp.). (2026). *Inteligencia artificial y educación superior: Hacia ecosistemas de aprendizaje neurodiversos*. Sophia Editions.
- Sun, Y., Liao, Y., & Ma, X. (2026). Trusting AI to detect AI? A systematic evaluation of the reliability and robustness of current AIGC detection tools for student academic work. *Computers & Education*, 249, 105616. <https://doi.org/10.1016/j.compedu.2026.105616>
- Tsao, J. (2025). Trajectories of AI policy in higher education: Interpretations, discourses, and enactments of students and teachers. *Computers and Education: Artificial Intelligence*, 9, 100496. <https://doi.org/10.1016/j.caeai.2025.100496>
- Verma, C., & Kumar, D. (2026). An exploratory machine learning approach to understanding determinants of future ChatGPT use in higher education. *Computers and Education: Artificial Intelligence*, 10, 100613. <https://doi.org/10.1016/j.caeai.2026.100613>
- Yıldız, M., & Merzifonluoğlu, A. (2026). Ethical boundaries in GenAI-driven research: Language researchers' reactions to unethical use of GenAI in graduate education. *International Journal of Human-Computer Interaction*. <https://doi.org/10.1080/10447318.2026.2682912>

Conflictos de interés:

Los autores declaran no tener ningún conflicto de intereses.

Contribución de los autores:

Oscar José Alejo-Machado, Mario Enrique Vásquez-Jiménez, Stephanie Marcela Delgado-Estrada, Juan Carlos López-Gutiérrez: Concepción y diseño del estudio, adquisición de datos, análisis e interpretación, redacción del manuscrito, revisión crítica del contenido, análisis estadístico, supervisión general del estudio.

Declaración ética:

El estudio se basó en el análisis de fuentes documentales y datos de acceso público, por lo que no implicó la participación directa de seres humanos. No se manejó información personal identificable.