

Trayectorias en riesgo en educación superior en línea: soporte tecnopedagógico con IA generativa

MARIÁngeles CASTRO-SÁNCHEZ¹

ROMINA SILVETTI²

SONIA CALAMANTE³

DANIELA BERTUNI⁴

Universidad Austral - Argentina

Recibido el 15-07-26; primera evaluación el 13-08-26;
aceptado el 25-08-26

RESUMEN

En el ámbito de la educación superior en línea, las discontinuidades de desempeño y socialización estudiantiles funcionan como señales tempranas de rezago o deserción. Este artículo presenta un piloto institucional que integró IA generativa (TECgpt/Skill Studio) como soporte tecnopedagógico de un dispositivo

¹ Doctora en Comunicación Social (Universidad Austral, Facultad de Comunicación). Magister y especialista en Dirección de Instituciones Educativas (Universidad Austral, Escuela de Educación). Especialista en Educación y Nuevas Tecnologías (FLACSO Costa Rica). Profesora asociada y miembro del Consejo de Dirección del Instituto de Ciencias para la Familia de la Universidad Austral. Integrante del Steering Committee de la Artificial Intelligence Global Education Network (AIGEN). Líder del proyecto Estrategia de Educación a Distancia de la Universidad Austral. Correo electrónico: Mcastrosanchez@austral.edu.ar ORCID: <https://orcid.org/0000-0001-6874-6683>

² Magister en Tecnología Educativa (Universidad Abierta Interamericana). Licenciada en Orientación Familiar (Universidad Austral). Licenciada en Administración (Universidad de San Andrés). Profesora adjunta, asesora tecnopedagógica y profesora encargada de cohorte del Instituto de Ciencias para la Familia de la Universidad Austral. Correo electrónico: Rsilveti-ext@austral.edu.ar ORCID: <https://orcid.org/0009-0000-5762-7267>

³ Magister en Tecnología Educativa (Universidad Abierta Interamericana). Diplomada superior en Ciencias Sociales y Gestión Educativa (FLACSO). Licenciada en Ciencias para la Familia (Universidad Austral). Profesora de enseñanza primaria. Profesora adjunta, asesora tecnopedagógica y profesora encargada de cohorte del Instituto de Ciencias para la Familia de la Universidad Austral. Correo electrónico: Scalamante-ext@austral.edu.ar ORCID: <https://orcid.org/0009-0001-2183-7980>

⁴ Especialista en Educación y Nuevas Tecnologías (FLACSO Costa Rica). Diploma Superior en Ciencias Sociales (FLACSO Argentina). Licenciada en Orientación Familiar (Universidad Austral). Asesora tecnopedagógica y profesora encargada de cohorte del Instituto de Ciencias para la Familia de la Universidad Austral. Correo electrónico: Dbertuni-ext@austral.edu.ar ORCID: <https://orcid.org/0009-0000-5772-6943>



de valoración de estado académico (VEA), usado para detectar trayectorias en riesgo en una carrera a distancia. Se diseñó un ecosistema de cinco asistentes configurables para producir informes a nivel estudiante, cohorte y carrera, evaluado mediante metodología de dominancia cualitativa con el equipo de gestión académica, en cuatro cohortes (N=198 estudiantes activos). Los resultados muestran que la herramienta sistematizó el proceso y mejoró la trazabilidad, aunque hubo variabilidad de outputs y recomendaciones poco diferenciadas. Se concluye que aporta valor cuando estandariza y escala el acompañamiento, sin sustituir la mediación humana.

Palabras clave: inteligencia artificial generativa, educación superior en línea, deserción estudiantil, asesoramiento académico.

At-Risk Trajectories In Online Higher Education: Technopedagogical Support With Generative Ai

ABSTRACT

In online higher education, discontinuities in student performance and socialization function as early signs of academic delay or dropout. This article presents an institutional pilot that integrated generative AI (TECgpt/Skill Studio) as technopedagogical support for an academic status assessment tool (VEA), used to detect at-risk trajectories in an online degree program. An ecosystem of five configurable assistants was designed to generate reports at the student, cohort, and program levels. It was evaluated using a qualitatively dominant methodology with the academic management team across four cohorts (N = 198 active students). Results indicate that the tool systematized the process and improved traceability, although output variability was observed and recommendations lacked sufficient differentiation. The tool provides value by standardizing and scaling academic support without replacing human mediation.

Keywords: generative artificial intelligence, online higher education, student dropout, academic advising.

Trajétórias em risco na educação superior on-line: suporte tecnopedagógico com IA generativa

RESUMO

Na educação superior on-line, descontinuidades no desempenho e na socialização estudantil funcionam como sinais precoces de atraso acadêmico ou evasão. Este artigo apresenta um piloto institucional que integrou IA generativa (TECgpt/Skill Studio) como suporte tecnopedagógico ao dispositivo de avaliação do estado acadêmico (VEA), usado para detectar trajetórias em risco em um curso a distância. Um ecossistema de cinco assistentes configuráveis foi desenvolvido para gerar relatórios em nível de estudante, coorte e curso. A iniciativa foi avaliada por

meio de uma metodologia de predominância qualitativa com a equipe de gestão acadêmica em quatro coortes (N = 198 estudantes ativos). Os resultados indicam que a ferramenta sistematizou o processo e melhorou a rastreabilidade, embora tenha apresentado variabilidade nos resultados e recomendações pouco diferenciadas. A ferramenta agrega valor ao padronizar e ampliar o acompanhamento, sem substituir a mediação humana.

Palavras-chave: inteligência artificial generativa, educação superior on-line, evasão estudantil, orientação acadêmica.

1. INTRODUCCIÓN

1.1. Contexto y problema

La retención y el acompañamiento de estudiantes en educación superior —especialmente en modalidades mediadas por tecnologías digitales— constituyen un desafío compartido a nivel global. La detección temprana de patrones asociados al riesgo académico, a través de modelos predictivos basados en el desempeño del estudiante, permite anticipar situaciones que, de no intervenir a tiempo, incrementan las posibilidades de rezago o abandono (Bañeres et al., 2020). En este escenario, la capacidad institucional para detectar trayectorias educativas en riesgo y activar intervenciones oportunas se vuelve un componente crítico de la calidad académica y del cuidado del estudiantado.

En la institución donde se desarrolló este estudio, este desafío se abordó desde un modelo pedagógico centrado en las personas, en el que el acompañamiento forma parte estructural de la propuesta formativa. El asesoramiento académico personal constituye un factor clave para sostener la orientación y el seguimiento de cada estudiante, y se apoya en la figura del profesor o profesora encargada de cohorte (PEC), quien es responsable del vínculo cercano con un grupo determinado de estudiantes a lo largo del año. En carreras con modalidad predominantemente en línea, este acompañamiento requiere procesos sistemáticos que permitan monitorear el estado de cada trayectoria sin incrementar de manera desproporcionada la carga del equipo de gestión educativa.

Para responder a esta necesidad, se utiliza un dispositivo interno denominado VEA (valoración de estado académico), que organiza la lectura del estado estudiantil a partir de dos dimensiones: el desempeño académico (evaluaciones, calificaciones, cumplimiento de actividades) y la socialización académica (interacción social, relación docente-estudiante, participación en actividades cocurriculares). El cruce de ambas variables ubica a cada estudiante

en uno de cuatro cuadrantes de un diagrama de dispersión y permite identificar además los casos fronterizos, es decir, aquellos próximos a los ejes divisorios que requieren seguimiento preventivo de un potencial desplazamiento hacia cuadrantes más críticos.

Sin embargo, como ocurre en diversos sistemas de alerta temprana (Bañeres et al., 2020), el dispositivo VEA enfrentaba tensiones prácticas: la producción de informes a partir de esta información podría costar tiempo y, al depender de múltiples fuentes y de la disponibilidad de cada PEC, requería mecanismos que aseguraran estandarización, trazabilidad y comparabilidad entre cohortes. El problema que motivó este estudio no fue, entonces, de diagnóstico, que ya había sido realizado por la aplicación del dispositivo VEA, sino el de sistematizar y escalar su uso, de modo que pudiera aplicarse de manera consistente a nivel de cohorte y de carrera, para apoyar los procesos de seguimiento estudiantil y la toma de decisiones de los equipos directivos y de gestión.

La oportunidad de abordar este problema surgió de una convocatoria institucional para incorporar la IA generativa a través de una plataforma de asistentes configurables (TECgpt/Skill Studio), en la que el proyecto fue seleccionado como caso de uso. La propuesta consistió en integrar esta tecnología como soporte tecnopedagógico del dispositivo VEA, con el propósito de ordenar, sintetizar y mapear los procesos de acompañamiento, en coherencia con un principio rector del modelo educativo de la institución: la tecnología debe estar al servicio de las personas y del cuidado de cada trayectoria formativa. Como advierten García Peñalvo et al. (2024), la discusión actual en torno a la IA generativa en educación pasa menos por decidir si se adopta y más por definir con qué velocidad y bajo qué esquemas de uso responsable se la incorpora a la práctica educativa; una discusión que exige, además, un plan explícito de desarrollo profesional docente para sostener esa integración [Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (Unesco), 2024b].

1.2. Objetivos y pregunta de investigación

Como se ha mencionado previamente, este artículo presenta los resultados de un piloto institucional que exploró el aporte de una plataforma de IA generativa como el soporte tecnopedagógico de un dispositivo de detección de trayectorias en riesgo en educación superior en línea. La pregunta que guio el trabajo fue la siguiente: ¿De qué manera la IA generativa puede fortalecer un dispositivo de acompañamiento estudiantil ya existente, sin sustituir la mediación humana? De ella se derivaron tres objetivos específicos: (a) diseñar

e implementar un ecosistema de asistentes de IA generativa que estandarizara la producción de informes de seguimiento en distintos niveles de decisión (estudiante, cohorte y carrera); (b) evaluar, con dominancia cualitativa, la experiencia de uso, la utilidad percibida y las condiciones institucionales para sostener esta integración; y, (c) identificar aprendizajes y recomendaciones, tanto para el dispositivo de acompañamiento como para la herramienta tecnológica, que orienten un eventual escalamiento.

2. MARCO CONCEPTUAL

2.1. Detección temprana y acompañamiento en educación superior en línea

La preocupación por identificar tempranamente el riesgo de abandono estudiantil tiene una larga trayectoria en la investigación sobre educación superior. Desde los modelos clásicos de integración académica y social (Tinto, 1993), se reconoce que la permanencia estudiantil depende tanto del desempeño académico como del grado de vinculación del estudiante con la institución, sus pares y sus docentes. Trabajos posteriores del propio autor trasladaron el foco de las causas del abandono hacia la acción institucional: Tinto (2012) sostiene que la persistencia estudiantil mejora cuando las instituciones combinan expectativas claras de éxito con apoyo académico, social y financiero estructurado, retroalimentación frecuente sobre el desempeño y espacios de involucramiento activo con pares y docentes. Esta doble dimensión (desempeño y socialización) constituye el fundamento conceptual de numerosos sistemas de alerta temprana (*early warning systems*) desarrollados en las últimas dos décadas, que combinan indicadores de actividad, calificaciones e interacción para anticipar discontinuidades en las trayectorias (Bañeres et al., 2020). Estudios más recientes muestran aplicaciones concretas de este enfoque: sistemas de predicción basados en IA que identifican estudiantes en riesgo a partir de su desempeño en instancias de evaluación (Latif et al., 2022), e incluyen a las implementaciones en universidades en línea que generan predicciones diarias de riesgo y activan mensajes de intervención personalizados (Bañeres et al., 2023).

En paralelo, el campo de la analítica de aprendizaje (*learning analytics*) documenta que estos sistemas aportan valor cuando logran traducir datos dispersos en información accionable para quienes toman decisiones a distintos niveles. Una revisión sistemática reciente sobre analítica de aprendizaje orientada al éxito académico advierte, sin embargo, que persiste una brecha entre la disponibilidad de indicadores y la evidencia rigurosa sobre su efectividad real

para sostener intervenciones oportunas (Ifenthaler & Yau, 2020). En modalidades en línea, donde la interacción presencial es limitada o inexistente, esta traducción resulta particularmente sensible: los indicadores de socialización deben construirse a partir de huellas digitales de participación, y el vínculo docente-estudiante requiere de dispositivos intencionales que lo sostengan a distancia.

A escala global, los organismos de referencia coinciden en señalar tanto el potencial como los riesgos de este tipo de sistemas. El informe Artificial Intelligence Index 2024 (Stanford Institute for Human-Centered Artificial Intelligence, 2024) documenta patrones de uso creciente de herramientas de IA generativa como ChatGPT entre docentes y estudiantes, mientras que el Banco Mundial (Molina et al., 2024), el informe *Shaping the Future of Learning: The Role of AI in Education 4.0* (World Economic Forum, 2024) y observatorios institucionales específicos del sector (Universidad Europea, Observatorio de Inteligencia Artificial en Educación Superior, 2024) advierten que su impacto positivo depende de capacidades institucionales —infraestructura, formación docente y marcos de gobernanza— que no siempre están disponibles de manera homogénea. Experiencias de integración institucional de IA generativa en educación superior, como las sistematizadas por Minerva Project (2023), coinciden en señalar que los mejores resultados se obtienen cuando la tecnología se incorpora a flujos de trabajo ya existentes, en lugar de sustituirlos.

2.2. IA generativa en educación superior: entre la promesa y la prudencia

La incorporación de inteligencia artificial en educación superior no es un fenómeno reciente, pero la aparición de modelos de lenguaje de gran escala (LLM) y de plataformas de IA generativa ha ampliado significativamente el rango de tareas que estas herramientas pueden apoyar, desde la retroalimentación personalizada hasta la generación de reportes institucionales. Una revisión sistemática sobre aplicaciones de inteligencia artificial en educación superior identificó que, aunque la investigación sobre el tema ha crecido de forma sostenida, la voz y el rol de los propios educadores en el diseño de estas aplicaciones ha estado relativamente ausente, lo que limita su pertinencia pedagógica y su apropiación en las prácticas de enseñanza (Zawacki-Richter et al., 2019). Esta observación resulta especialmente relevante para pilotos como el que aquí se describe, en los que el equipo de gestión académica, y no un equipo técnico externo, participó directamente en el diseño, la configuración y la evaluación de la herramienta.

La irrupción de la IA generativa ha disparado tanto expectativas como resistencias. Por un lado, se reconoce su potencial para reforzar capacidades institucionales, ordenar procesos y liberar tiempo docente para tareas de mayor valor relacional, siempre que su integración esté guiada por pautas de uso responsable y por un plan de desarrollo profesional del profesorado (Unesco, 2024b, 2024c), en línea con los marcos de competencias en IA propuestos tanto para docentes como para estudiantes de educación superior (Unesco, 2024a, 2024b; Digital Education Council, 2025) y con instrumentos que permiten medir esa alfabetización de manera válida y confiable (Jin et al., 2025).

Por otro lado, distintas perspectivas críticas advierten sobre el riesgo de que la automatización de tareas de acompañamiento termine por desplazar, en lugar de complementar, el juicio profesional y el vínculo humano que sostienen los procesos educativos, en particular, cuando se trata de decisiones sensibles sobre trayectorias estudiantiles. Como sostienen García-Peñalvo et al. (2024), la pregunta relevante hoy no es si la IA generativa debe incorporarse a la práctica educativa, sino con qué velocidad y bajo qué esquemas de gobernanza institucional conviene hacerlo, de modo que la tecnología amplíe, y no reemplace, las capacidades humanas existentes.

Este piloto se inscribe en esa segunda perspectiva: la IA generativa se concibió no como un sustituto del criterio docente, sino como recurso de mejora de un proceso institucional preexistente, en sintonía con un modelo educativo centrado en las personas. Esta orientación dialoga, además, con críticas recientes a la noción de “personalización” en IA educativa, que advierten sobre el riesgo de reducirla a una lógica de eficiencia y consumo individual en lugar de una lectura situada y dialógica del estudiante (Bellomo & Sun, 2026).

2.3. El dispositivo VEA como base

El dispositivo VEA que da marco a este piloto, fue definido como un instrumento interno de seguimiento que organiza la información disponible sobre cada estudiante en dos dimensiones, desempeño y socialización, y la traduce en una ubicación dentro de una matriz de cuadrantes (Castro-Sánchez y Silvetti, 2025). Antes de la integración de IA generativa, el dispositivo ya cumplía su función diagnóstica, ya que permitía identificar los estudiantes en situación de riesgo y los casos fronterizos. La limitación no residía, por tanto, en la capacidad de detección, sino en la escalabilidad y estandarización del proceso de traducción de esos datos en informes utilizables por distintos niveles de decisión —el propio PEC, a nivel cohorte, y la dirección de la carrera y de la unidad académica, a nivel macro— de manera consistente y con un esfuerzo

de producción razonable. Este antecedente es el que estructura el problema abordado en el presente estudio y el diseño metodológico que se describe a continuación.

3. METODOLOGÍA

3.1. Diseño y enfoque

Se adoptó un diseño de estudio de caso (Yin, 2018), de tipo piloto institucional, con una metodología de evaluación de dominancia cualitativa, complementada con indicadores descriptivos simples. Esta elección respondió a dos características del diseño. En primer lugar, el grupo de usuarios de la herramienta correspondía al universo completo del equipo de gestión académica de la carrera (es decir, tanto población como muestra coincidían), por lo que se buscó una comprensión en profundidad antes que inferencia estadística.

En segundo lugar, el objetivo principal del piloto fue comprender la experiencia de uso, la utilidad percibida, las barreras y los facilitadores de adopción, así como las condiciones necesarias para sostener una integración de IA generativa de esta naturaleza. Las métricas cuantitativas simples (tiempos de producción, consistencia entre versiones, claridad y accionabilidad percibida, grado de implementación de recomendaciones) se incorporaron como insumos complementarios para triangular y reforzar la interpretación de los hallazgos cualitativos, y no como base de generalización estadística.

3.2. Contexto y participantes

El piloto se desarrolló en una carrera de grado en modalidad predominantemente en línea (95%), de cuatro años de duración, organizada mediante un esquema de seguimiento por cohortes de estudiantes. Participaron cuatro cohortes, con un total de 198 estudiantes activos, y se trabajó en dos cortes temporales sucesivos (septiembre y noviembre de 2025).

Los participantes, usuarios de la plataforma de IA generativa, fueron: (a) profesoras encargadas de cohorte (PEC, N=8), responsables del vínculo personalizado con cada grupo de estudiantes; y (b) un equipo de diseño, implementación y evaluación (N=4), el cual se encontraba a cargo de la configuración de los asistentes, la elaboración de guías y tutoriales, la capacitación del equipo PEC y el seguimiento del piloto. En este grupo se incluyó una especialista del área institucional de innovación educativa, que realizó tareas de apoyo tecnopedagógico.

Los criterios de inclusión fueron los siguientes: integrar el equipo de gestión educativa de la carrera durante el período del piloto y participar de las instancias de capacitación, implementación y registro definidas. El cuestionario de percepción aplicado al cierre del piloto registró diez respuestas iniciadas; de estas, nueve fueron marcadas como completas por la plataforma, aunque dos de ellas no incluyeron respuesta a ningún ítem evaluativo, y una respuesta adicional quedó inconclusa. En consecuencia, los indicadores descriptivos reportados en la sección de Resultados se basan en las siete respuestas que registraron datos sustantivos.

Todos los datos de estudiantes utilizados durante el piloto fueron seudonimizados; se trabajó con identificadores (ID) contruidos a partir de una combinación breve derivada del nombre y un sufijo del año de cohorte, sin exposición de los nombres reales en los archivos operativos ni en los informes generados.

3.3. El ecosistema de asistentes de IA generativa (S1-S5)

La integración de IA generativa se diseñó e implementó como un ecosistema de cinco asistentes configurables (*skills*), basados en el dispositivo VEA y pensados para distintos niveles de decisión. El diseño buscó (a) generar diagnósticos de cohorte consistentes (S1); (b) reducir la variabilidad entre outputs mediante una síntesis integrada (S2); (c) orientar intervenciones individualizadas en casos priorizados (S3); (d) consolidar resultados a nivel de carrera (S4); y, (e) comparar evoluciones entre cortes temporales (S5).

En términos operativos, S1 tomó como insumo los datos de desempeño y socialización de una cohorte y generó una versión preliminar de un informe ejecutivo, con distribución de estudiantes por cuadrante, fortalezas colectivas, casos emergentes y casos fronterizos. Por su parte, S2 recibió tres versiones preliminares de S1 y produjo una síntesis integrada, señalada como capa de control de calidad, con el objetivo de conservar lo valioso de cada versión, reducir redundancias y resolver ambigüedades; mientras que S3 operó a nivel individual. A partir del informe de S2 y, opcionalmente, de las observaciones contextuales del PEC, generó un informe de seguimiento personalizado y un modelo de mensaje breve que el PEC podía adaptar para iniciar el contacto con el estudiante. S4 consolidó los informes de las cuatro cohortes en un informe general de carrera, dirigido a la dirección académica. Finalmente, S5 permitió comparar la evolución entre dos períodos a nivel de estudiante, cohorte o carrera, mediante matrices de transición e indicadores de mejora, estabilidad o retroceso.

El recorrido del piloto se organizó en cuatro fases: diseño (junio-agosto de 2025), en la que se configuraron los cinco asistentes, se definieron protocolos y

nomenclaturas, y se produjeron guías y tutoriales; implementación del primer corte (septiembre de 2025), con aplicación de la secuencia S1→S2→S3; implementación del segundo corte (noviembre de 2025), repitiendo la misma secuencia; y evaluación final (diciembre de 2025), con la aplicación de S4 y S5 y la administración de un cuestionario de percepción al equipo docente participante.

3.4. Procedimiento y técnicas de análisis

Se analizaron temáticamente la bitácora del equipo y las respuestas abiertas del cuestionario de percepción, de acuerdo con las fases propuestas por Braun y Clarke (2006): familiarización con los datos, codificación inicial, identificación y revisión de temas, definición y denominación, y elaboración del informe. El análisis se centró en la utilidad percibida, las barreras y los facilitadores para la adopción, la confianza en los resultados generados y las oportunidades de mejora. La bitácora se abordó de manera inductiva, para recuperar los patrones emergentes de los registros narrativos. En el cuestionario predominó una codificación deductiva, sobre la base de las dimensiones evaluativas definidas en el instrumento.

El cuestionario de percepción combinó escalas Likert de 1 a 5, preguntas dicotómicas y campos de respuesta abierta. Se consultó sobre la consistencia entre las versiones de S1; la claridad, pertinencia y factibilidad de S2; la inclusión de los componentes esperados en los informes de S3; y la implementación de las recomendaciones y los motivos asociados. También se indagó en qué medida el dispositivo contribuía a la detección temprana y al acompañamiento de los estudiantes. Cada bloque incluía un espacio para justificar las respuestas.

Como complemento, se calcularon estadísticos descriptivos sobre un conjunto acotado de indicadores operativos. La consistencia entre las versiones de S1 se evaluó mediante una rúbrica comparativa de cuatro dimensiones: fortalezas destacadas, focos de riesgo identificados, recomendaciones formuladas y nivel de detalle. Se utilizó una escala de cinco niveles, desde “no coinciden” hasta “coincidencia total”. También se analizaron la claridad y la capacidad de S2 para sugerir acciones, mediante una escala Likert de 1 a 5; la presencia de los componentes esperados en los informes de S3, a través de una lista de cotejo dicotómica; y la proporción de recomendaciones implementadas. Para los indicadores expresados mediante escalas se calcularon promedios simples, sin ponderación ni imputación de datos faltantes. Por último, estos resultados se triangularon con la evidencia cualitativa de la bitácora y las respuestas abiertas del cuestionario.

3.5. Consideraciones éticas

El piloto utilizó datos estrictamente necesarios para valorar el estado académico de los estudiantes y formular recomendaciones de acompañamiento. Antes de ser incorporados al entorno de IA, los registros fueron seudonimizados: los archivos de trabajo y los informes generados no contenían nombres ni otros identificadores directos. La correspondencia entre los códigos asignados y la identidad de los estudiantes se mantuvo por separado, bajo resguardo institucional y con un acceso restringido. Los informes producidos por los asistentes fueron revisados por el equipo antes de proceder a una intervención, por lo que no se tomaron decisiones académicas automatizadas ni se sustituyó el criterio profesional. Los archivos se conservan en un espacio institucional de Microsoft Teams, al que solo accede el equipo, como respaldo documental del trabajo realizado. La participación docente en el cuestionario de percepción fue voluntaria y las respuestas se analizaron de forma agregada.

4. RESULTADOS

Los hallazgos del piloto se organizan en tres dimensiones interrelacionadas —proceso, calidad y orientación a la intervención—, como respuesta a los objetivos a y b, planteados en el apartado 1.2 de este artículo, y se complementan con las percepciones reportadas por el equipo docente.

4.1. Proceso: de la fragmentación al flujo

La secuencia $S1 \rightarrow S2 \rightarrow S3$ sistematizó el circuito de trabajo del dispositivo VEA: informe de cohorte, síntesis integrada y derivación a informes individuales. En la práctica, el ecosistema de asistentes ayudó a mejorar un procedimiento que podía quedar fragmentado —múltiples fuentes de información, reportes heterogéneos y decisiones poco documentadas— en una dinámica más organizada, sin reemplazar el criterio profesional del PEC. El valor estuvo, entonces, no en sustituir el dispositivo VEA, sino en hacerlo más ejecutable: facilitar la producción de informes, sostener una secuencia común de análisis entre las cuatro cohortes y dejar mejor registrada la ruta que va desde el diagnóstico hasta la decisión de intervención. La disponibilidad de un repositorio compartido y de tutoriales paso a paso facilitó la apropiación inicial de este flujo por parte del equipo PEC.


La propia bitácora del equipo, en sus observaciones sobre flujo y adopción, sintetiza este hallazgo: “el ecosistema $S1 \rightarrow S2 \rightarrow S3$ funciona como andamiaje:

ordena el proceso y hace más ejecutable el VEA, sin sustituir el juicio del PEC”. Además, agrega una precisión importante sobre dónde reside el aporte: “en un modelo con acompañamiento fuerte, el aporte de la herramienta no se percibe tanto en ‘descubrir’ casos nuevos como en sistematizar, homogeneizar criterios y dejar mejor documentadas decisiones”.

4.2. Calidad: variabilidad de outputs ante insumos equivalentes


El hallazgo más relevante del piloto fue la variabilidad de *outputs* ante insumos equivalentes. Al comparar las tres versiones de S1 generadas para una misma cohorte y un mismo corte temporal, el promedio de coincidencia fue de 3.24 sobre cinco, con un valor algo más alto en las recomendaciones formuladas y en el nivel de detalle (3.33 en ambos casos) y algo más bajo en las fortalezas destacadas y los focos de riesgo identificados (3,14 y 3,17, respectivamente).

Figura 1. *Coincidencia entre las tres versiones de S1 por dimensión*



Sumado a lo anterior, la bitácora del equipo registró que, entre versiones, se mantenían el marco conceptual y el tono, pero variaban la distribución por cuadrantes y el listado de casos fronterizos, un aspecto crítico porque de él se deriva la priorización de intervenciones. Esta variabilidad no se limitaba al plano narrativo: para la cohorte 2025, el número de estudiantes asignados al Cuadrante I por las tres versiones de S1 osciló entre diez y 32, lo que muestra que la inconsistencia puede alcanzar la categorización misma de los casos y no solo su descripción.

Figura 2. Variabilidad en la asignación de cuadrantes, cohorte 2025, corte 1




Este fenómeno es consistente con una limitación conocida de los sistemas basados en modelos de lenguaje de gran escala: estos pueden producir salidas distintas ante insumos equivalentes. Y esta condición se transforma en un impedimento directo de uso cuando el output se destina a priorizar intervenciones. De ahí que, ante esta situación, el equipo incorporó S2 para integrar las tres versiones en un único informe. La bitácora aporta evidencia sobre la efectividad de esta decisión de diseño ya que se registra en ella que S2 produce un informe “más ordenado y coherente” y facilita la lectura ejecutiva. Pero también se señala que, en la práctica, “no siempre queda claro qué tomó de cada versión”, y que persisten diferencias entre las versiones base de S1 y la distribución final de S2. En consecuencia, la mejora en claridad narrativa de S2 no equivale a una resolución del problema, lo que refuerza la necesidad de que el PEC revise y valide los casos antes de proseguir la secuencia y traducir diagnósticos en intervenciones.

4.3. Orientación a la intervención: focalización y accionabilidad

A partir de S2 y dejando registro de las inconsistencias del sistema, el equipo seleccionó los casos que requerían un informe individual (S3), en consonancia con la orientación del dispositivo VEA hacia intervenciones personalizadas. El cuestionario de evaluación mostró que la estructura esperada en los informes

de S3 estuvo presente: la situación general del estudiante en el 100% de los casos evaluados, y las fortalezas destacadas, las áreas de mejora, las sugerencias concretas de acción y el tono empático y no punitivo en el 85.7% de los casos.

Figura 3. *Componentes presentes en los informes individuales (S3)*



Cabe resaltar el cómo S3 tendía a proponer acciones similares entre estudiantes, un patrón que emergió tanto del análisis de los informes como de las respuestas a las preguntas abiertas del cuestionario. La bitácora del equipo registra esta misma observación de forma casi literal: el asistente “tiende a proponer acciones similares entre estudiantes, incluso cuando los perfiles no son idénticos”.

Un dato relevante en esta dimensión es que el 57% de las acciones recomendadas por S3 ya habían sido implementadas con anterioridad por el equipo PEC; es decir, el equipo ya había desplegado una acción similar con esos estudiantes antes de que la herramienta la señalara. Este dato se refuerza con los testimonios recogidos; en palabras de las propias PEC, “las recomendaciones y sugerencias de acción que realiza el sistema son aquellas que nosotras ya llevamos a cabo como parte del acompañamiento académico y personal de los alumnos”; “ya se había trabajado durante el año con los casos en riesgo, dado el acercamiento que tenemos con los alumnos”. Otras respuestas señalaron que las medidas sugeridas “coinciden con las que tomamos habitualmente cuando detectamos una falta de participación o participación inadecuada de los alumnos”.

Figura 4. Vista del panel de configuración

The image shows a web application interface for 'Tecnológico de Monterrey Skill Studio'. The header is dark blue with the logo and a help icon. A sidebar on the left contains five square icons. The main content area is divided into two columns. The left column, titled 'Skill Studio | Probar skill', contains a section for 'S3 - Informe individual VEA'. Below the title, there is a paragraph explaining the purpose: 'Ingresá los puntajes obtenidos por e/lla estudiante en desempeño académico y socialización. El sistema generará automáticamente un informe breve con observaciones, fortalezas, áreas de mejora y una sugerencia de intervención.' This is followed by five input fields: 'ID del estudiante', 'Cohorte', 'Matriz de socialización del estudiante', 'Matriz de desempeño del estudiante', and 'Observaciones adicionales del docente'. At the bottom of this section are a 'Limpiar' button and a blue '¡Vamos!' button. The right column, titled 'Resultado', shows a text box with 'GPT 4.0', a rocket icon, and the text 'Aquí verás el resultado al ejecutar tu skill.'

Nota. Interfaz de configuración de una *skill* en Skill Studio (*mockup* ilustrativo elaborado por las autoras a partir de capturas reales de la plataforma).

4.4. Escalamiento a nivel de carrera y comparación entre cortes

El asistente S4 permitió consolidar, en un informe único, los resultados de las cuatro cohortes para el uso de la dirección académica, al identificar patrones transversales (alto desempeño general e interacción docente-estudiante) como fortalezas comunes, así como notar las particularidades por cohorte que habrían quedado invisibilizadas en reportes aislados.

El asistente S5, por su parte, permitió comparar la evolución entre los dos cortes temporales del piloto mediante una matriz de transición, lo que permitió habilitar una lectura longitudinal (a nivel de estudiante, cohorte o carrera) que resulta difícil de sostener manualmente con la periodicidad requerida. Este tipo de comparación constituye uno de los aportes más claros del escalamiento habilitado por el ecosistema de asistentes, aunque su fiabilidad depende de la consistencia de los informes que le sirven de insumo, como se discutió en el apartado 4.2.

4.5. Percepción global del equipo docente

En términos generales, el equipo docente valoró positivamente el aporte del dispositivo apoyado en IA generativa para la detección y ubicación de estudiantes en los cuadrantes, en particular, para la identificación de casos fronterizos, como resumió una de las PEC en el cuestionario: “la detección y ubicación de los alumnos en cuadrantes, junto con la identificación de quienes se encuentran en posición fronteriza, es una herramienta clave para que las tutoras puedan intervenir de manera preventiva y reducir el riesgo de abandono”.

Al mismo tiempo, el equipo identificó con claridad los límites del aporte: la cercanía cotidiana que las PEC mantienen con sus estudiantes, a través del seguimiento de entregas, la comunicación directa y el conocimiento acumulado de cada trayectoria, sigue siendo, para varias de ellas, una fuente de detección más sensible que la que ofrece el sistema en su configuración actual. Estas apreciaciones no invalidan el aporte de la herramienta, pero sí delimitan con precisión su rol: un dispositivo que sistematiza y hace comparable un proceso de acompañamiento que ya se viene construyendo, y no un sustituto de la lectura experta que realiza cada PEC.

5. DISCUSIÓN Y CONCLUSIONES

5.1. Discusión de los hallazgos

Los resultados de este piloto sugieren que, en instituciones con un modelo de acompañamiento estudiantil ya consolidado, la IA generativa aporta un valor mayor cuando se orienta a estandarizar y escalar el seguimiento, más que cuando se espera de ella una función de detección novedosa. Ifenthaler y Yau (2020) advierten que en la literatura de analítica de aprendizaje existe una brecha entre la disponibilidad de indicadores y la evidencia de que esos indicadores sirven para disparar intervenciones oportunas. Este piloto se sitúa en un escenario distinto: el VEA ya existía y había sido evaluado en una experiencia previa, por lo que la cuestión no giraba en torno a la validez del indicador, sino a qué capacidad adicional era necesaria para traducirlo en acompañamiento sistemático. De ahí que el aporte de la IA generativa se concentró en esa capa de organización y comparabilidad de la información —el proceso institucional que, según los propios autores, rara vez se documenta en la literatura— y no en la identificación de riesgo en sí misma.

La variabilidad de *outputs* ante insumos equivalentes constituye la limitación observada más significativa. Esta tensión conecta con el planteo de García-Peñalvo et al. (2024). El dilema que subyace no es si se adopta o no la IA generativa, sino bajo qué esquemas de gobernanza hay que hacerlo. Así, S2 puede leerse como una acción en esa línea, en tanto es un ajuste de diseño de baja complejidad, definido e implementado por el propio equipo de gestión académica. Que S2 haya mejorado la percepción de orden y claridad de los informes sin neutralizar la inestabilidad diagnóstica de fondo (ya que la bitácora registra discrepancias persistentes entre las versiones base y la síntesis final) sugiere que la gobernanza que reclaman García-Peñalvo et al. (2024) no se resuelve con un ajuste de flujo de trabajo: las plataformas que albergan ecosistemas de asistentes de IA generativa vinculados a decisiones institucionales sensibles necesitan, como principio de diseño, mecanismos de control de consistencia verificables. Esto significa implementar la gobernanza en un sentido más pleno del que S2, por sí solo, puede ofrecer. Esta urgencia por desarrollar mecanismos verificables, más que ajustes puntuales de diseño, se encuentra en sintonía con recientes llamados a una gobernanza de la IA basada en evidencia, antes que en la mera disponibilidad de la herramienta (Bommasani et al., 2025).

En relación con la personalización de las recomendaciones, el hallazgo de que S3 tiende a proponer acciones similares entre estudiantes con perfiles distintos dialoga directamente con la distinción que proponen Bellomo (2024) y Bellomo y Sun (2026) entre personalización extrínseca (la adaptación de un sistema externo a partir de datos disponibles sobre el comportamiento del usuario) y personalización intrínseca (el proceso situado y dialógico de construcción de sentido en torno a un estudiante concreto). Los resultados del piloto ofrecen evidencia empírica de esa distinción: cuando el insumo se limita a rúbricas estructuradas de desempeño y socialización, S3 opera en el registro de la personalización extrínseca, suficiente para ubicar y priorizar casos, pero insuficiente para orientar una intervención puntual.

Lo anterior es consistente, además, con el hallazgo de Latif et al. (2022) respecto de que el desempeño de estos modelos depende en gran medida de la riqueza de los insumos de evaluación disponibles. En este caso, parte importante del conocimiento contextual sobre cada estudiante reside en la experiencia acumulada del PEC y no se encuentra sistematizado en datos estructurados, lo que impone un techo a la personalización alcanzable con independencia de la calidad del modelo. Retomando esta hipótesis, la propia bitácora del equipo señala una vía posible de mejora que consiste en enriquecer la derivación de S2 hacia S3 con un conjunto mínimo de contexto cualitativo

ya existente en el trabajo de asesoramiento (sin exponer datos sensibles), como notas de seguimiento, situaciones registradas, respuestas a contactos previos o hitos en la trayectoria del estudiante. En términos de Bellomo y Sun (2026), esto equivaldría a acercar la personalización extrínseca del sistema a la lectura intrínseca que ya realiza el PEC, en vez de esperar que el modelo la sustituya. Esto sugiere que la mejora de la accionabilidad no depende solo del ajuste de las instrucciones (*prompts*), sino que reside en la preexistencia de un trabajo de sistematización de protocolos y repertorios de intervención validados por los equipos de gestión educativa, que la IA pueda recibir y adaptar, y no generar desde cero.

Por último, el dato de que más de la mitad de las recomendaciones no se concretaron porque ya habían sido implementadas previamente por el equipo docente es, en sí mismo, un hallazgo relevante. Leído a la luz del modelo de integración académica y social de Tinto (1993, 2012), particularmente su bajo su enfoque de énfasis en el involucramiento (*involvement*) como sostén de la permanencia, el resultado confirma que la dimensión de vinculación (el trabajo relacional que el PEC ya sostiene con cada estudiante⁹ era funcional antes de la incorporación del ecosistema de asistentes. En modelos educativos con fuerte acompañamiento humano, la IA generativa no debería evaluarse principalmente por su capacidad de descubrir lo desconocido, sino por su capacidad de sistematizar, documentar y volver comparable un trabajo de cuidado que ya se viene realizando. Esta es una función más cercana a la integración que recomienda Minerva Project (2023), incorporar tecnología a los flujos ya existentes sin sustituir el criterio profesional. En este sentido, el valor del ecosistema de asistentes no reside en reemplazar la tarea del PEC, sino en expandir capacidades en el trabajo de acompañamiento que el equipo docente ya asume.

Resulta pertinente, además, situar este piloto frente a otras formas de integrar la IA generativa en instituciones educativas. Existen plataformas de IA conversacional que resultan eficaces para tareas particulares de análisis, redacción o retroalimentación, pero cuya configuración queda librada al criterio de cada usuario, en línea con lo que Minerva Project (2023) describe como el riesgo de una adopción fragmentada, dependiente de la iniciativa individual más que de un diseño institucional. La experiencia de este piloto sugiere que un ecosistema de asistentes estructurados en torno a un flujo de trabajo —con campos definidos, formatos de salida esperados y una secuencia pautada— aporta un diferencial en contextos donde múltiples actores (en este caso, ocho PEC) deben producir informes comparables entre sí, algo que la configuración aislada de un asistente genérico no garantiza. No obstante, como lo

mencionamos, la plataforma utilizada depende de la actualización periódica del modelo de lenguaje subyacente: la plataforma utilizada operaba sobre una versión que no correspondía a la más reciente disponible, lo que probablemente incidió en la magnitud de la variabilidad reportada en la sección 4.2.

Finalmente, destacamos que este piloto puede contribuir, aunque sea en pequeña medida, a cerrar la brecha que detectan Ifenthaler y Yau (2020) para la falta de evidencia sobre la efectividad de la analítica de aprendizaje para sostener intervenciones oportunas. Este trabajo documenta un caso de uso institucional concreto al registrar cómo un dispositivo ya validado (VEA) funciona en la práctica al combinarse con un ecosistema de asistentes de IA generativa.

Más allá de las características del dispositivo VEA, de la carrera de aplicación y de la plataforma utilizada, el caso permite identificar condiciones de diseño transferibles a otros sistemas institucionales de alerta y acompañamiento estudiantil. Entre ellas, la existencia de un modelo previo que explicita los criterios de análisis, la validación profesional de los resultados y la incorporación de mecanismos para comprobar su consistencia antes de utilizarlos como insumo en procesos de toma de decisiones. Tales condiciones pueden inspirar desarrollos similares en otras carreras y modalidades, siempre que se adapten los indicadores, las fuentes de información y los circuitos de intervención a las características de cada institución. De ahí que la transferencia no supone una reproducción exacta del ecosistema S1-S5, sino la recuperación de una estructura de trabajo en la que la IA organiza y escala tareas de análisis, mientras que la interpretación de los resultados y las decisiones de acompañamiento permanecen bajo responsabilidad humana. Cabe destacar que su alcance en otros contextos deberá examinarse a través de nuevas implementaciones.

5.2. Límites del estudio

Se trata de un estudio de caso con diseño de dominancia cualitativa: los indicadores descriptivos reportados cumplen apenas una función de triangulación con los hallazgos cualitativos, y no se pretende establecer correlaciones entre variables ni generalizar a otras poblaciones.

Asimismo, el piloto se desarrolló en una sola carrera de una única institución, con un modelo de asesoramiento personalizado fuerte, lo que condiciona la transferibilidad de los resultados a contextos con estructuras de tutoría menos desarrolladas.

Otra limitación por mencionar es que la plataforma de IA generativa utilizada operaba sobre una versión de modelo de lenguaje que, al momento del piloto, no correspondía a la más actualizada disponible en el mercado, lo

que constituye una condición técnica que pudo haber incidido en la variabilidad observada, aunque el diseño del estudio no permite determinar su efecto (apartado 4.2).

Finalmente, la comparación longitudinal entre cortes (S5) hereda la consistencia de los informes que le sirven de insumo: en la medida en que estos presenten inestabilidad diagnóstica, sus resultados deben interpretarse con la misma cautela.

5.3. Conclusiones y líneas futuras

El piloto confirma que la IA generativa fue útil como soporte tecnopedagógico para fortalecer un dispositivo de detección de trayectorias en riesgo ya existente, sin sustituir la mediación humana. En un modelo educativo centrado en las personas y con un rol de acompañamiento cercano ya instalado, el valor diferencial de la herramienta radicó en sistematizar y escalar el proceso: ordenar insumos, estandarizar informes, mejorar la comparabilidad entre cohortes y aportar trazabilidad. Todo ello, orientado a asistir la toma de decisiones a distintos niveles.

El estudio nos deja aprendizajes. Primero, la variabilidad de *outputs* ante insumos equivalentes afecta aspectos decisionales (como la ubicación diagnóstica de un estudiante), por lo que estos sistemas requieren revisión profesional obligatoria antes de traducirse en intervenciones.

Por otra parte, la capa de integración incorporada (S2) mejoró la percepción de orden y claridad de los informes, pero el piloto no aporta evidencia de que haya resuelto la inestabilidad diagnóstica que la motivó. De hecho, se necesitó de la mirada experta del PEC antes de avanzar en la secuencia y traducirse en intervenciones. De ahí que se recomienda profundizar en la búsqueda de mecanismos de consistencia verificables y en una mayor transparencia de los criterios que se aplican, antes de asumir que la integración narrativa equivale a estabilidad diagnóstica. Adicionalmente, con el fin de que las recomendaciones individuales resulten pertinentes, se sugiere incorporar insumos contextuales cualitativos ya disponibles en el sistema de asesoramiento académico institucional, sin exponer datos sensibles, y un repertorio de acciones validadas que el modelo pueda seleccionar y adaptar, para neutralizar su tendencia de brindar soluciones genéricas.

Como líneas de investigación futuras, se propone construir un registro acumulativo de informes obtenidos en la secuencia S1-S4, que habilite lecturas longitudinales de las trayectorias estudiantiles individuales y grupales (S5). Del mismo modo, investigar la incidencia de estos *outputs* en las decisiones de

gestión efectivamente adoptadas. En su conjunto, la experiencia documentada en este artículo sugiere que, en modelos educativos con fuerte acompañamiento personal, la IA generativa aporta valor cuando expande las capacidades del equipo docente, y no cuando se espera de ella que reemplace el criterio profesional o la cercanía del vínculo interpersonal, que continúan siendo insustituibles.

AGRADECIMIENTOS

Este trabajo forma parte del proyecto Integrar IA en la universidad: un modelo pedagógico centrado en las personas, financiado por el Vicerrectorado de Investigación de la Universidad Austral, Argentina, en el marco del 21.º Concurso Interno de Proyectos de Investigación Científica. El piloto analizado fue seleccionado en 2025 como caso de uso institucional en la convocatoria impulsada por el Tecnológico de Monterrey (México) para la incorporación de inteligencia artificial generativa en universidades de América Latina mediante TECgpt Open Edition y su entorno de configuración de asistentes Skill Studio.

REFERENCIAS BIBLIOGRÁFICAS

- Castro-Sánchez, M. y Silvetti, R. (2025). Asesoramiento académico personalizado en educación superior en línea: dispositivo para la detección de trayectorias en riesgo. *IFE Conference Proceedings*, (2), 332-336.
- Bañeres, D., Rodríguez, M. E., Guerrero-Roldán, A. E., & Karadeniz, A. (2020). An early warning system to detect at-risk students in online higher education. *Applied Sciences*, 10(13). <https://doi.org/10.3390/app10134427>
- Bañeres, D., Rodríguez-González, M. E., Guerrero-Roldán, A. E., & Cortadas, P. (2023). An early warning system to identify and intervene online dropout learners. *International Journal of Educational Technology in Higher Education*, 20. <https://doi.org/10.1186/s41239-022-00371-5>
- Bellomo, S. T. (2024). Extrinsic and intrinsic personalization in the digital transformation of education. *Journal of Ethics in Higher Education*, (5), 1-34. <https://doi.org/10.26034/fr.jehe.2024.6861>
- Bellomo, S. T., & Sun, K. (2026). Can artificial intelligence foster deep personalization in education? *Future Humanities*, 4. <https://doi.org/10.1002/fhu2.70028>
- Bommasani, R., Arora, S., Chayes, J., Choi, Y., Cuéllar, M.-F., Fei-Fei, L., Ho, D. E., Jurafsky, D., Koyejo, S., Lakkaraju, H., Narayanan, A., Nelson, A., Pierson, E., Pineau, J., Singer, S., Varoquaux, G., Venkatasubramanian, S., Stoica, I., Liang, P., & Song, D. (2025). Advancing science- and evidence-

- based AI policy. *Science*, 389(6758), 459-461. <https://doi.org/10.1126/science.adu8449>
- Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3(2), 77-101. <https://doi.org/10.1191/1478088706qp063oa>
- Digital Education Council. (2025). *DEC AI literacy framework: AI literacy for all*. Digital Education Council. <https://www.digitaleducationcouncil.com/>
- García-Peñalvo, F. J., Llorens-Largo, F., & Vidal, J. (2024). La nueva realidad de la educación ante los avances de la inteligencia artificial generativa. *RIED, Revista Iberoamericana de Educación a Distancia*, 27(1), 9-39. <https://doi.org/10.5944/ried.27.1.37716>
- Ifenthaler, D., & Yau, J. Y.K. (2020). Utilising learning analytics to support study success in higher education: A systematic review. *Educational Technology Research and Development*, 68(4), 1961-1990. <https://doi.org/10.1007/s11423-020-09788-z>
- Jin, Y., Martinez-Maldonado, R., Gašević, D., & Yan, L. (2025). GLAT: The generative AI literacy assessment test. *Computers and Education: Artificial Intelligence*, 9. <https://doi.org/10.1016/j.caeai.2025.100436>
- Latif, G., Alghazo, R., Pilotti, M. A. E., & Ben Brahim, G. (2022). Identifying “at-risk” students: An AI-based prediction approach. *International Journal of Computing and Digital Systems*, 11(1), 1-11. <https://dx.doi.org/10.12785/ijcds/110184>
- Minerva Project. (2023). *Integrating artificial intelligence: Key strategies for higher education*. Minerva Project Insights. <https://www.minervaproject.com/white-paper/integrating-artificial-intelligence>
- Molina, E., Cobo, C., Pineda, J., & Rovner, H. (2024). *AI revolution in education: What you need to know* (Digital Innovations in Education, Brief N.º 1). World Bank. <https://documents1.worldbank.org/curated/en/099734306182493324/pdf/IDU152823b13109c514ebd19c241a289470b6902.pdf>
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura. (Unesco). (2024a). *AI competency framework for students*. (N.º 12690) Unesco. <https://unesdoc.unesco.org/ark:/48223/pf0000391105>
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (Unesco). (2024b). *AI competency framework for teachers*. (N.º 12690) Unesco. <https://unesdoc.unesco.org/ark:/48223/pf0000391104>
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (Unesco). (2024c). *Guía para el uso de IA generativa en educación e investigación*. (N.º 12690). Unesco. <https://unesdoc.unesco.org/ark:/48223/pf0000389227>

- Stanford Institute for Human-Centered Artificial Intelligence. (2024). *Artificial Intelligence Index Report 2024*. Stanford University. <https://hai.stanford.edu/ai-index/2024-ai-index-report>
- Tinto, V. (1993). *Leaving college: Rethinking the causes and cures of student attrition* (2.^a ed.). University of Chicago Press.
- Tinto, V. (2012). *Completing college: Rethinking institutional action*. University of Chicago Press.
- Universidad Europea; Observatorio de Inteligencia Artificial en Educación Superior. (2024). *La universidad en la era de la inteligencia artificial* (Informe OIAES N.º 2). Universidad Europea. https://universidadeuropea.com/resources/media/documents/OBSERVATORIO_IA_-_Informe_Abril_24.pdf
- World Economic Forum. (2024). *Shaping the future of learning: The role of AI in Education 4.0*. (Insight report). <https://www.weforum.org/publications/shaping-the-future-of-learning-the-role-of-ai-in-education-4-0/>
- Yin, R. K. (2018). *Case study research and applications: Design and methods* (6.^a ed.). Sage.
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education -where are the educators? *International Journal of Educational Technology in Higher Education*, 16. <https://doi.org/10.1186/s41239-019-0171-0>

Roles de autor: Castro-Sánchez, M.: Conceptualización. Metodología. Investigación. Escritura – Borrador original. Escritura – Revisión y edición. Visualización. Supervisión. Silvetti, R.: Investigación. Escritura – Revisión y edición. Calamante, S.: Investigación. Escritura – Revisión y edición. Bertuni, D.: Metodología. Investigación. Curación de datos.

Cómo citar este artículo: Castro-Sánchez, M., Silvetti, R., Calamante, S., & Bertuni, D. (2026) Trayectorias en riesgo en educación superior en línea: soporte tecnopedagógico con IA generativa. *Educación*, XXXV(69), 54-76. <https://doi.org/10.18800/educacion.202602.M004>

Primera publicación: 14 de septiembre de 2026.

Este es un artículo de acceso abierto distribuido bajo los términos de Licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0), que permite el uso, la distribución y la reproducción sin restricciones en cualquier medio, siempre que se cite correctamente la obra original.