


La Nueva **Taxonomía** del Aprendizaje con **Inteligencia Artificial**



**Danilo Sarabia, Miguel Sandoval,
Alex Castro & William Satama**

La Nueva Taxonomía del Aprendizaje con Inteligencia Artificial




Autor:

MSc. Danilo Pedro Sarabia Guevara

Md. Miguel Santiago Sandoval Romo

MSc. Alex Bolívar Castro Michuy

MSc. William Iván Satama Pereira



Datos bibliográficos

ISBN:	978-9907-803-75-4
Título del libro:	La Nueva Taxonomía del Aprendizaje con Inteligencia Artificial
Autores:	Sarabia Guevara, Danilo Pedro Sandoval Romo, Miguel Santiago Castro Michuy, Alex Bolívar Satama Pereira, William Iván
Editorial:	SAGA
Materia:	370 - Educación
Público objetivo:	Profesional / académico
Publicado:	2026-09-16
Número de edición:	1
Tamaño:	5Mb
Soporte:	Libro digital descargable
Formato:	Pdf (.pdf)
Idioma:	Español
DOI:	https://doi.org/10.63415/saga.2026.132

Hecho En el Ecuador / Made in Ecuador

Autores



MSc. Danilo Pedro Sarabia Guevara

Universidad Estatal Amazónica

✉ dsarabiag@uea.edu.ec

id <https://orcid.org/0000-0002-1101-987X>

Puyo, Ecuador

Danilo Pedro Sarabia Guevara, es un profesional ecuatoriano con más de 15 años de experiencia en gestión empresarial, educación superior, investigación científica y desarrollo sostenible, con formación académica orientada a la educación superior, al manejo ambiental, la producción agropecuaria y la sostenibilidad, nacido el 25 de julio de 1986 en la ciudad de Puyo. Es Ingeniero Agropecuario por la Universidad Estatal Amazónica, base que consolidó conocimientos técnicos vinculados al uso responsable del suelo, la producción agrícola y el equilibrio ecológico. Posteriormente obtuvo el grado de Magíster en Ingeniería Ambiental con mención en Saneamiento Ambiental en la misma universidad, fortaleciendo competencias para la gestión de residuos, el control ambiental y la protección de los recursos naturales, con una visión científica, aplicada y comprometida con el bienestar colectivo.

Su preparación se amplía con la Maestría en Agroecología y Ambiente otorgada por la Universidad Técnica de Ambato, formación que profundiza enfoques sustentables en sistemas productivos y desarrollo rural. Además, es Especialista en Entornos Virtuales de Aprendizaje por la Universidad Técnica de Ambato, lo que fortalece su desempeño en procesos educativos mediados por tecnología. Esta combinación de saberes técnicos, ambientales y pedagógicos sustenta una labor académica orientada a la innovación, la responsabilidad social y la formación integral, promoviendo prácticas conscientes, pensamiento crítico y una relación armónica entre producción, educación y naturaleza.

De igual manera con miras a fortalecer su formación académica en educación superior, se encuentra estudiando el Doctorado en Educación e Innovación en la Universidad de Investigación e Innovación de México. Actualmente es Gerente General de la Empresa Pública Amazónica UEA-EP, posee amplia trayectoria en dirección académica, planificación estratégica, gestión de proyectos y cooperación internacional.

Md. Miguel Santiago Sandoval Romo

Escuela Politécnica de Chimborazo
Universidad Regional Autónoma de los Andes

✉ llucoman@gmail.com

 <https://orcid.org/0009-0004-1001-5991>

Puyo, Ecuador



Miguel Santiago Sandoval Romo desarrolla una trayectoria profesional vinculada con la medicina, la salud pública y la formación universitaria, campos desde los cuales articula conocimientos clínicos con responsabilidades docentes orientadas a la preparación de futuros profesionales.

Es médico graduado por la Universidad Central del Ecuador y especialista en Medicina Familiar y Comunitaria por la Pontificia Universidad Católica del Ecuador, formación que respalda una visión integral de la atención sanitaria centrada en las personas, las familias y las comunidades. Su actividad académica se vincula con la Escuela Superior Politécnica de Chimborazo, dentro de la Facultad de Salud Pública, donde ejerce docencia ocasional en la carrera de Medicina. También participa como profesor de Psicología Clínica en la sede Puyo de la Universidad Regional Autónoma de los Andes. La convergencia entre medicina y docencia configura un perfil interdisciplinario que favorece el diálogo entre ciencias de la salud y procesos formativos.

Su experiencia permite relacionar fundamentos biomédicos con dimensiones familiares, comunitarias y educativas. Desde esa perspectiva profesional, Sandoval Romo aporta una mirada sustentada en la práctica clínica, la prevención, la promoción de la salud y la enseñanza superior, con atención al desarrollo humano y a la formación responsable de profesionales, en escenarios profesionales contemporáneos.



MSc. Alex Bolívar Castro Michuy

Escuela de Educación Básica

Francisco Javier Salazar



alexcastro336@hotmail.com



<https://orcid.org/0009-0000-0437-0007>

Quito, Ecuador

Alex Bolívar Castro Michuy posee una trayectoria académica dedicada a la educación, la docencia, la administración educativa y el liderazgo institucional. Su formación reúne niveles de preparación pedagógica que evidencian continuidad profesional dentro del campo educativo.

Obtuvo el grado de Magíster en Docencia Universitaria y Administración Educativa por la Universidad Tecnológica Indoamérica, preparación orientada al fortalecimiento de la enseñanza superior y de los procesos de gestión en instituciones educativas. Cuenta además con un Diploma Superior en Liderazgo Educativo otorgado por la Universidad Tecnológica San Antonio de Machala. Su formación de grado corresponde a la Licenciatura en Ciencias de la Educación con mención en Educación Básica, cursada en la Universidad Técnica de Babahoyo. A ello se suma el título de Profesor de Educación Primaria, de nivel técnico superior, obtenido en el Instituto Superior Pedagógico Manuela Cañizares. La progresión de su recorrido formativo refleja una relación sostenida entre práctica pedagógica, dirección educativa y preparación universitaria.

Castro Michuy integra saberes procedentes de la educación primaria con perspectivas propias de la gestión y la docencia superior. Tal combinación favorece una comprensión amplia de los procesos de enseñanza y aprendizaje, junto con criterios para orientar instituciones, acompañar comunidades académicas y promover prácticas educativas fundamentadas.

MSc. William Iván Satama Pereira

Universidad de Especialidades Espíritu Santo



wsatama@outlook.com



<https://orcid.org/0009-0001-6801-7680>

Machala, Ecuador



William Iván Satama Pereira construye su trayectoria en la convergencia entre educación, gestión académica, informática e investigación. Cursa estudios doctorales en Educación en la Universidad Central de Querétaro, México, etapa que amplía su preparación para el análisis de fenómenos educativos y la producción de conocimiento especializado. Posee el grado de Magíster en Gestión Educativa por la Universidad Particular de Especialidades Espíritu Santo. Su formación previa comprende la Licenciatura en Ciencias de la Educación con mención en Docencia en Informática y el título de Analista de Sistemas, ambos obtenidos en la Universidad Técnica de Machala. La articulación entre pedagogía y tecnología caracteriza un perfil orientado al estudio de los procesos educativos mediados por recursos digitales.

Su producción académica aborda asuntos vinculados con las inteligencias múltiples en la educación básica mediante revisión sistemática de literatura. También ha trabajado sobre integración de inteligencia artificial en la educación latinoamericana, atendiendo perspectivas emergentes y proyecciones futuras. Satama Pereira reúne competencias provenientes de la gestión educativa, la docencia informática y el análisis de sistemas. Su recorrido académico favorece una aproximación interdisciplinaria a la innovación pedagógica, con interés por la investigación educativa, la transformación digital y el fortalecimiento de prácticas docentes sustentadas en evidencia y reflexión crítica.



El contenido y las ideas expuestas en esta obra se encuentran protegidos por la normativa vigente en materia de propiedad intelectual y constituyen derechos exclusivos de su(s) autor(es)

Todos los derechos reservados © 2026

Sinopsis

La Nueva Taxonomía del Aprendizaje con IA propone una reinterpretación crítica de Bloom y de otros modelos cognitivos ante la incorporación de inteligencia artificial generativa en la educación. La obra examina la transformación de operaciones como recordar, comprender, aplicar, analizar, evaluar y crear cuando estudiantes y sistemas algorítmicos participan conjuntamente en la producción, revisión y validación del conocimiento. Desde una perspectiva interdisciplinaria, articula aportes de la psicología cognitiva, la pedagogía, la metacognición y la cognición distribuida para distinguir pensamiento autónomo, cognición aumentada, interacción dialógica, delegación algorítmica, supervisión epistémica y regulación metagenerativa. El argumento central desplaza la atención desde la ejecución observable hacia la arquitectura intelectual que sostiene cada desempeño. También examina la descarga cognitiva, la agencia del estudiante, la verificación de contenidos sintéticos y la fricción cognitiva deliberada como variables para diseñar experiencias formativas. A partir de dicha reformulación, el libro plantea criterios para construir resultados de aprendizaje, actividades, rúbricas y evaluaciones capaces de diferenciar producción automatizada, coautoría humano-máquina y dominio intelectual verificable. La propuesta culmina en una matriz multidimensional que relaciona complejidad cognitiva, autonomía, mediación algorítmica, responsabilidad epistémica, transferencia y evidencia, ofreciendo un lenguaje renovado para investigar, diseñar y evaluar el aprendizaje universitario contemporáneo en ecosistemas educativos mediados digitalmente.

Palabras clave: inteligencia artificial, aprendizaje, cognición, tecnología educacional, evaluación de la educación

Synopsis

The New Taxonomy of Learning with AI offers a critical reinterpretation of Bloom and other cognitive models in response to the integration of generative artificial intelligence into education. The book examines the transformation of operations such as remembering, understanding, applying, analyzing, evaluating, and creating when learners and algorithmic systems jointly participate in the production, revision, and validation of knowledge. From an interdisciplinary perspective, it connects contributions from cognitive psychology, pedagogy, metacognition, and distributed cognition to distinguish autonomous thinking, augmented cognition, dialogic interaction, algorithmic delegation, epistemic supervision, and metagenerative regulation. Its central argument shifts attention from observable execution toward the intellectual architecture underlying each performance. It also examines cognitive offloading, learner agency, verification of synthetic content, and deliberate cognitive friction as variables for designing educational experiences. Building on that reformulation, the book proposes criteria for constructing learning outcomes, activities, rubrics, and assessments capable of differentiating automated production, human-machine co-authorship, and verifiable intellectual mastery. The proposal culminates in a multidimensional matrix connecting cognitive complexity, autonomy, algorithmic mediation, epistemic responsibility, transfer, and evidence, providing a renewed language for researching, designing, and assessing contemporary university learning within digitally mediated educational ecosystems.

Keywords: artificial intelligence, learning, cognition, educational technology, educational evaluation

Índice General

Sinopsis.....	ix
Índice General	11
Índice de Tablas	14
Índice de Figuras.....	15
Introducción	17
Capítulo I De la taxonomía cognitiva a la cognición mediada por IA	21
1.1. Genealogía de las taxonomías del aprendizaje y sus arquitecturas cognitivas.....	25
1.2. La revisión de Bloom ante la externalización de operaciones cognitivas.....	28
1.3. Cognición distribuida entre estudiante, modelo y entorno digital	31
1.4. Del verbo cognitivo a la arquitectura de la actividad intelectual	34
1.5. Carga cognitiva, descarga cognitiva y delegación algorítmica .	38
1.6. Hacia una taxonomía pos-Bloom para ecosistemas educativos generativos.....	41
Capítulo II Reconfiguración de los niveles cognitivos en interacción con IA generativa	47
2.1. Recordar en la era de la recuperación generativa.....	51
2.2. Comprender mediante explicación, contraste y reconstrucción conceptual.....	54
2.3. Aplicar con asistencia algorítmica y transferencia situada.....	57
2.4. Analizar outputs generativos como objetos epistemológicos....	60

2.5. Evaluar la IA: juicio crítico, evidencia y calibración de confianza	64
2.6. Crear después de la generación automática.....	67
Capítulo III Nueva taxonomía de la cognición humano-IA.....	73
3.1. Cognición autónoma: pensar antes de consultar a la IA	77
3.2. Cognición aumentada: ampliar capacidades sin sustituir el razonamiento	80
3.3. Cognición dialógica: aprender interrogando al modelo	83
3.4. Cognición delegada: cartografía de lo que el estudiante transfiere a la máquina	86
3.5. Cognición supervisora: verificar, corregir y gobernar outputs generativos	90
3.6. Cognición metagenerativa: comprender y regular el propio sistema humano-IA	93
Capítulo IV Diseño del aprendizaje y evaluación bajo la nueva taxonomía	99
4.1. Resultados de aprendizaje resistentes a la automatización superficial	103
4.2. Ingeniería de tareas según grados de mediación de IA	106
4.3. Evidencias de aprendizaje en procesos de coautoría humano-IA	109
4.4. Evaluación del proceso cognitivo y no solamente del producto final.....	112
4.5. Rúbricas para autonomía, verificación y sofisticación cognitiva	116
4.6. Validez de la evaluación cuando la IA puede ejecutar la tarea.....	119
Capítulo V Del pensamiento de orden superior a la agencia cognitiva	125
5.1. Agencia cognitiva como nivel superior del aprendizaje mediado por IA	129

5.2. Metacognición aumentada y regulación de la interacción humano-IA	132
5.3. Vigilancia epistémica frente a conocimiento sintético	136
5.4. Fricción cognitiva deliberada como principio pedagógico	139
5.5. Transferencia pos-IA: demostrar competencia más allá del asistente	142
5.6. La Nueva Taxonomía del Aprendizaje con IA: matriz de niveles, mediaciones y evidencias	145
Conclusiones	151
Referencias Bibliográficas	155

Índice de Tablas

Tabla 1 <i>Transformaciones del aprendizaje desde la taxonomía cognitiva hacia la cognición mediada por inteligencia artificial</i>	44
Tabla 2 <i>Reconfiguración de los niveles cognitivos en interacción con inteligencia artificial generativa</i>	70
Tabla 3 <i>Configuraciones cognitivas en la interacción humano-IA generativa</i>	96
Tabla 4 <i>Componentes del diseño del aprendizaje y la evaluación bajo la nueva taxonomía</i>	122
Tabla 5 <i>Articulación de la agencia cognitiva en el aprendizaje mediado por inteligencia artificial generativa</i>	148

Índice de Figuras

Figura 1 <i>De la taxonomía cognitiva al aprendizaje mediado por IA ...</i>	23
Figura 2 <i>Reconfiguración cognitiva ante la externalización</i>	29
Figura 3 <i>Arquitectura de la actividad intelectual</i>	37
Figura 4 <i>Reconfiguración cognitiva ante la IA generativa.....</i>	49
Figura 5 <i>Procesos para la comprensión conceptual.....</i>	55
Figura 6 <i>Análisis epistemológico de outputs generativos.....</i>	63
Figura 7 <i>Nueva taxonomía de la cognición humano-IA</i>	75
Figura 8 <i>Cognición aumentada y ampliación del razonamiento</i>	81
Figura 9 <i>Cognición aumentada y ampliación del razonamiento</i>	89
Figura 10 <i>Arquitectura del aprendizaje y evaluación con IA.....</i>	101
Figura 11 <i>Grados de mediación de IA en las tareas.....</i>	107
Figura 12 <i>Evaluación del proceso cognitivo</i>	115
Figura 13 <i>Agencia cognitiva y aprendizaje mediado por IA</i>	127
Figura 14 <i>Regulación metacognitiva de la interacción humano-IA ...</i>	133
Figura 15 <i>Fricción cognitiva para el aprendizaje profundo</i>	141

Introducción

Las taxonomías del aprendizaje han ofrecido durante décadas un vocabulario para ordenar operaciones cognitivas y orientar la enseñanza. Sin embargo, la expansión de la inteligencia artificial generativa altera la relación entre tarea observable y actividad mental. Hwang et al. (2020) advirtieron que la investigación educativa sobre IA necesitaba marcos capaces de vincular tecnología, pedagogía y procesos humanos. Tal necesidad adquiere nueva intensidad cuando un modelo redacta, resume, compara o argumenta junto al estudiante.

La disponibilidad cotidiana de asistentes generativos ha desplazado la discusión desde el acceso a información hacia la distribución de la autoría intelectual. Kasneci et al. (2023) reconocen oportunidades de personalización y apoyo inmediato, aunque también señalan riesgos vinculados con errores, dependencia y evaluación. La pregunta ya no reside en determinar si una respuesta parece compleja. Importa reconocer qué operaciones realizó el estudiante, cuáles delegó y bajo qué criterios aceptó, corrigió o rechazó la producción algorítmica.

La literatura reciente muestra una tensión fértil entre aumento y sustitución. Darvishi et al. (2024) comprobaron que la asistencia de IA puede modificar la agencia estudiantil, mientras Fan et al. (2024) identificaron una posible pereza metacognitiva cuando el apoyo generativo reduce la implicación reflexiva. Ambas aportaciones obligan a distinguir alivio de carga y pérdida de elaboración. Una ayuda puede liberar recursos para razonar mejor. También puede ocultar vacíos conceptuales detrás de un producto convincente.

La cuestión posee relevancia académica porque las categorías heredadas suelen clasificar el desempeño a partir de verbos y productos. Tal criterio resulta insuficiente ante tareas que

una máquina ejecuta con fluidez. Ng et al. (2021) sitúan la alfabetización en IA en la intersección de conocimientos, usos, evaluación y ética. Holmes y Tuomi (2022) amplían la mirada al reclamar una pedagogía informada por las capacidades reales de los sistemas. Hace falta una arquitectura analítica más precisa.

El libro responde a dicha necesidad mediante una reinterpretación crítica de Bloom y de otras taxonomías cognitivas para escenarios universitarios mediados por IA generativa. Su objetivo general consiste en formular un lenguaje que diferencie pensamiento autónomo y cognición aumentada; diálogo con modelos y delegación; supervisión epistémica y regulación metagenerativa. También busca traducir tales distinciones en resultados de aprendizaje, actividades y rúbricas. La evaluación resultante deberá demostrar dominio intelectual más allá de la calidad aparente del producto.

La indagación se organiza alrededor de preguntas enlazadas. ¿Qué significa recordar, comprender, aplicar, analizar, evaluar y crear cuando parte del trabajo puede transferirse a un modelo? ¿Qué evidencia permite atribuir aprendizaje al estudiante? ¿Qué grados de mediación favorecen la transferencia sin debilitar la autonomía? ¿Qué criterios sostienen la confianza ante conocimiento sintético? Yan et al. (2023) muestran que las respuestas requieren integrar dimensiones pedagógicas, éticas y prácticas, en lugar de tratar la IA como herramienta neutral.

El primer capítulo reconstruye la genealogía de las taxonomías y examina la externalización de operaciones cognitivas. Luego propone estudiar la unidad formada por estudiante, modelo y entorno digital. El segundo capítulo reconsidera los niveles clásicos mediante tres pares: recuperación y explicación; aplicación y análisis; juicio y creación. Cooper (2023) demuestra que las respuestas plausibles de ChatGPT exigen evaluación disciplinar y vigilancia sobre errores persistentes. Tal evidencia obliga a mirar detrás del desempeño visible.

El tercer capítulo presenta una taxonomía de la cognición humano-IA articulada en tres pares: modalidad autónoma y aumentada; dialógica y delegada; supervisora y metagenerativa. Cada modalidad describe una distribución distinta del esfuerzo, la decisión y la responsabilidad. Barrett y Pack (2023) hallaron que estudiantes y docentes negocian usos generativos dentro del proceso de escritura mediante expectativas diversas. Por ello, la clasificación propuesta atiende tanto al producto obtenido cuanto a las decisiones que sostienen su elaboración y revisión.

El cuarto capítulo traslada el modelo al diseño del aprendizaje y a la evaluación. Aborda resultados resistentes a la automatización superficial junto con grados de mediación y huellas de coautoría. Incluye defensa oral y rúbricas centradas en autonomía y verificación. Cotton et al. (2023) muestran que la integridad académica demanda revisar tareas y acuerdos institucionales. Banihashem et al. (2024) comparan retroalimentación humana y generada. Sus resultados refuerzan la necesidad de valorar proceso, criterio y revisión.

El quinto capítulo sitúa la agencia cognitiva como horizonte formativo y reúne metacognición con vigilancia epistémica. También vincula fricción deliberada y transferencia más allá del asistente. Doshi y Hauser (2024) evidencian que la IA puede elevar la creatividad individual mientras reduce la diversidad colectiva. Tal hallazgo recuerda que mayor producción no equivale necesariamente a mayor aprendizaje. La obra culmina con una matriz que relaciona complejidad y autonomía; mediación y responsabilidad; transferencia y evidencia.

Capítulo I

De la taxonomía cognitiva a la cognición mediada por IA

Durante décadas, las taxonomías del aprendizaje ofrecieron un lenguaje compartido para ordenar propósitos educativos y reconocer grados de elaboración intelectual. Su influencia alcanzó currículos, evaluaciones y prácticas docentes muy diversas. Aquella arquitectura permitió nombrar operaciones que antes aparecían dispersas. Sin embargo, la expansión de la inteligencia artificial generativa obliga a mirar nuevamente sus categorías. Chen et al. (2020) señalan que el crecimiento de la inteligencia artificial educativa mantiene brechas entre desarrollo tecnológico y fundamentación pedagógica.


La cuestión adquiere profundidad cuando una herramienta deja de funcionar como recurso periférico y participa directamente en tareas asociadas con aprender. Recupera información, redacta explicaciones, compara argumentos y genera productos complejos. Hwang et al. (2020) advirtieron que la incorporación educativa de inteligencia artificial modifica funciones tradicionalmente asignadas a docentes, estudiantes y sistemas tecnológicos. Bajo tal condición, observar una respuesta correcta ya no permite atribuir de manera inmediata la operación intelectual a quien presenta el resultado.

Bloom conserva valor precisamente porque proporciona un punto de referencia reconocible desde el cual examinar la transformación. El problema no radica en declarar obsoleta su taxonomía, sino en reconocer que las condiciones de ejecución han cambiado. Una acción denominada analizar puede realizarse mediante razonamiento independiente o mediante una respuesta algorítmica aceptada sin examen. Chen et al. (2020) sostienen que la inteligencia artificial educativa necesita mayor articulación entre aplicaciones disponibles y marcos capaces de explicar pedagógicamente sus efectos.

La distinción entre desempeño y aprendizaje cobra entonces una relevancia particular. Un producto elaborado puede reflejar comprensión profunda, una buena estrategia de interacción

con un modelo o una combinación difícil de separar entre ambas posibilidades. Allí aparece una tensión que atraviesa todo el capítulo. Darvishi et al. (2024) muestran que la asistencia mediante inteligencia artificial mantiene relaciones significativas con la agencia estudiantil. Evaluar aprendizaje requiere atender, por tanto, a la participación intelectual que permanece bajo gobierno humano.

Figura 1
De la taxonomía cognitiva al aprendizaje mediado por IA



También cambia la relación con el esfuerzo. La educación ha utilizado tecnologías para descargar memoria y automatizar procedimientos durante mucho tiempo. La inteligencia artificial generativa amplía considerablemente el alcance de aquella externalización porque interviene en operaciones vinculadas con interpretación, argumentación y producción. Fan et al. (2024) documentan riesgos de pereza metacognitiva cuando la asistencia generativa altera procesos de aprendizaje y motivación. La facilidad técnica adquiere valor pedagógico cuando libera recursos sin cancelar la elaboración que forma competencia.

Mirar la actividad intelectual desde tal perspectiva desplaza el interés desde los verbos hacia la organización del trabajo

cognitivo. Recordar, comprender o crear dicen menos cuando desconocemos quién ejecutó cada operación y bajo qué grado de asistencia. Li et al. (2024) compararon apoyo humano y ChatGPT considerando pensamiento crítico, rendimiento y carga cognitiva. Sus resultados permiten advertir que la mediación tecnológica no constituye una variable neutra. Puede modificar tanto el esfuerzo requerido como la naturaleza del aprendizaje producido.

La cuestión se vuelve todavía más delicada cuando el modelo entrega respuestas plausibles con una fluidez capaz de ocultar errores. Aprender junto a sistemas generativos demanda algo más que obtener información pertinente. Requiere mantener criterios para contrastarla y decidir cuándo confiar. Liu et al. (2021) encontraron valor en mecanismos orientados a promover pensamiento reflexivo dentro de ambientes educativos apoyados por inteligencia artificial. La reflexión adquiere entonces una función reguladora frente a producciones que pueden parecer convincentes antes de ser comprendidas.

A medida que la mediación algorítmica gana presencia, la autorregulación deja de referirse únicamente a planificar tiempos o controlar estrategias personales. También comprende decisiones acerca del momento apropiado para consultar una herramienta, la ayuda que conviene solicitar y la respuesta que merece ser cuestionada. Chang et al. (2023) vinculan los chatbots educativos con principios de autorregulación relacionados con metas, retroalimentación y personalización. Gobernar la interacción pasa a formar parte del propio acto de aprender con inteligencia artificial.

Desde allí, la arquitectura jerárquica tradicional comienza a mostrar límites que no se resuelven agregando nuevos verbos. Una operación considerada compleja puede quedar ampliamente automatizada mientras otra aparentemente elemental exige vigilancia, contraste y decisión humana. Xu et al. (2025) destacan que el apoyo metacognitivo puede fortalecer la autorregulación

dentro de ambientes generativos. La complejidad educativa necesita leerse entonces desde varias dimensiones: demanda cognitiva, grado de mediación, agencia ejercida, calidad del juicio y capacidad de transferencia independiente.

El capítulo desarrolla esa transición conceptual sin romper innecesariamente con la tradición que le da origen. La genealogía taxonómica permite reconocer lo que permanece; la externalización cognitiva muestra aquello que cambia. Luego, la mediación generativa obliga a reconsiderar actividad, esfuerzo, autoría y evidencia. Desde esa convergencia se abre la posibilidad de una taxonomía pos-Bloom. No busca reemplazar un esquema por otro, sino ofrecer categorías capaces de describir aprendizaje humano cuando pensar también implica regular una inteligencia algorítmica.

1.1. Genealogía de las taxonomías del aprendizaje y sus arquitecturas cognitivas

Las taxonomías del aprendizaje nacieron del deseo de nombrar aquello que ocurre mientras una persona aprende. Durante parte del siglo veinte, la psicología educativa buscó ordenar capacidades visibles mediante categorías estables. La clasificación permitió conversar sobre metas, tareas y evaluación con un lenguaje compartido. También fijó una arquitectura: cada desempeño remitía a operaciones mentales presumiblemente identificables. Tal herencia continúa presente, aunque la inteligencia artificial obliga a leerla desde una mirada histórica menos lineal y atenta.

Bloom y sus colaboradores convirtieron aquella aspiración en una jerarquía de objetivos cognitivos. Recordar ocupaba la base, mientras evaluar representaba una elaboración superior. El modelo ganó autoridad porque vinculaba planificación curricular y observación del desempeño. Su sencillez ayudó a docentes de diversas disciplinas. Sin embargo, toda taxonomía expresa la época

que la produce. Ordenar capacidades mediante niveles implicaba concebir la mente como sede principal del conocimiento y al estudiante como ejecutor reconocible de cada operación.

La revisión de Anderson y Krathwohl desplazó los sustantivos hacia verbos y separó tipos de conocimiento de procesos cognitivos. El cambio pareció menor, pero alteró la lógica pedagógica. Aprender pasó a entenderse como actividad y no como acumulación estática. Aplicar, analizar, evaluar y crear adquirieron movimiento. Aun con tal renovación, la arquitectura conservó un agente humano relativamente delimitado. La acción observada seguía funcionando como indicio de complejidad mental y como base para atribuir dominio personal.

Otros modelos discutieron la linealidad jerárquica. Biggs y Collis atendieron la calidad estructural de las respuestas y describieron avances desde formulaciones fragmentarias hacia integraciones relacionales. Marzano también incorporó sistemas vinculados con cognición, metacognición y disposiciones personales. Cada propuesta ensanchó el mapa sin abandonar la pregunta central: qué organización mental sostiene un desempeño. Chen et al. (2020) muestran que la inteligencia artificial educativa amplía dicha pregunta al conectar procesos cognitivos con sistemas técnicos y decisiones pedagógicas.

La genealogía revela que las taxonomías nunca fueron inventarios neutrales. Funcionaron como teorías condensadas acerca de la mente, el conocimiento y la enseñanza. Hwang et al. (2020) sostienen que la investigación sobre inteligencia artificial educativa requiere articular funciones tecnológicas con papeles humanos y propósitos formativos. Desde tal perspectiva, una categoría cognitiva adquiere sentido dentro de una red de decisiones. Clasificar significa definir quién actúa, con qué recursos y bajo qué responsabilidad intelectual durante una tarea.

La expansión digital modificó gradualmente las fronteras de aquella arquitectura individual. Buscadores, plataformas adaptativas y tutores inteligentes distribuyeron operaciones antes concentradas en memoria, cálculo o consulta documental. Crompton y Burke (2023) describen un campo universitario donde la IA participa en enseñanza, apoyo y evaluación mediante funciones diversas. La novedad no reside únicamente en la herramienta. Cambia la unidad de análisis, pues una actuación puede depender de intercambios continuos entre persona, interfaz, datos y reglas algorítmicas.

La aparición de modelos generativos intensificó la transformación. Una instrucción breve puede producir explicaciones, argumentos y síntesis que antes servían como señales de elaboración avanzada. Dwivedi et al. (2023) señalan que la conversación generativa altera prácticas educativas y criterios de autoría. La genealogía taxonómica alcanza entonces un punto de inflexión. Ya no basta ordenar productos según su complejidad aparente. Resulta necesario reconocer las capas históricas que hicieron del producto una evidencia y revisar sus límites.

La alfabetización en inteligencia artificial añadió otra pieza a la arquitectura cognitiva. Ng et al. (2021) la conciben mediante conocimientos, prácticas y criterios éticos que exceden la destreza instrumental. Dicha ampliación enlaza con tradiciones metacognitivas, aunque introduce una diferencia decisiva: el aprendiz regula la intervención de un agente algorítmico. La genealogía deja de narrar niveles internos de una mente aislada y comienza a describir relaciones entre juicio humano, producción automatizada y responsabilidad sobre resultados compartidos.

Las revisiones recientes confirman que el lenguaje taxonómico necesita conservar continuidad sin volverse rígido. Lo (2023) identifica efectos educativos de ChatGPT ligados al aprendizaje, la evaluación y la integridad académica. Yan et al. (2023) añaden consideraciones prácticas y éticas sobre los modelos

lingüísticos. Ambas lecturas permiten comprender una transición histórica: las categorías cognitivas mantienen todavía valor orientador, pero deben dialogar con nuevas formas de mediación. La tradición permanece viva cuando acepta examinar sus propios presupuestos.

Reconstruir la genealogía cumple una función teórica y también pedagógica. Permite reconocer que ninguna clasificación aparece fuera de una concepción del aprendizaje. Bloom organizó objetivos; revisiones posteriores dinamizaron procesos; otros marcos atendieron estructuras, regulación y disposiciones. La inteligencia artificial introduce una arquitectura donde ejecución y comprensión pueden separarse con facilidad. Desde allí cobra sentido una nueva taxonomía. Su legitimidad dependerá de conservar la memoria disciplinar mientras formula categorías capaces de describir agencia, mediación y responsabilidad.

1.2. La revisión de Bloom ante la externalización de operaciones cognitivas


La revisión de Bloom ante la inteligencia artificial generativa comienza con una alteración discreta: ciertas operaciones cognitivas ya pueden ejecutarse fuera de la mente del estudiante. Recordar un dato, resumir una lectura o proponer una respuesta dejó de depender enteramente de recursos internos. La taxonomía conserva utilidad descriptiva, pero el verbo pierde transparencia. Una acción visible ya no revela quién realizó el trabajo intelectual ni permite atribuir aprendizaje sin examinar decisiones, apoyos y criterios empleados.

Externalizar no significa abandonar toda actividad mental. Consiste en trasladar una parte del procesamiento hacia artefactos capaces de almacenar, recuperar o transformar información. Chen et al. (2020) describen la inteligencia artificial educativa como un campo donde funciones técnicas y propósitos pedagógicos definidos se relacionan estrechamente. Tal relación modifica el

valor probatorio de una tarea. Cuando una herramienta completa una operación, el interés educativo pasa del resultado aislado a la participación humana que orientó su producción.

Figura 2

Reconfiguración cognitiva ante la externalización



Recordar ofrece el caso más evidente. Durante años, calculadoras, buscadores y repositorios redujeron la necesidad de conservar información disponible externamente. Los modelos generativos añaden síntesis y adaptación lingüística a dicha memoria extendida. Hwang et al. (2020) vinculan la IA educativa con funciones de apoyo que modifican papeles dentro de la enseñanza. Por ello, recuperar información mediante una respuesta fluida no demuestra retención. La evidencia requiere distinguir acceso oportuno, reconocimiento conceptual y disponibilidad personal del conocimiento.

Comprender también puede aparentarse con facilidad. Un modelo produce explicaciones ordenadas, analogías pertinentes y reformulaciones adaptadas a distintos públicos. Sin embargo, recibir una explicación no equivale a construir significado. Lo (2023) documenta beneficios educativos asociados con ChatGPT junto a preocupaciones sobre exactitud y aprendizaje superficial. La revisión taxonómica necesita separar comprensión prestada de

comprensión demostrada. Parafrasear sin asistencia, establecer relaciones propias o responder objeciones imprevistas aporta señales más fiables sobre elaboración conceptual genuina del estudiante.

Aplicar parecía ofrecer una evidencia directa porque exigía usar conocimientos en tareas. La generación automática complica tal lectura. Una instrucción puede producir procedimientos, códigos o soluciones con escasa comprensión del usuario. Chen et al. (2020) advierten brechas entre teoría y aplicación dentro de la inteligencia artificial educativa. Frente a tal distancia, aplicar debe abarcar selección del procedimiento, adaptación a restricciones y explicación de errores. Ejecutar representa una parte del desempeño, pero no agota su significado.

Analizar requiere descomponer información y reconocer relaciones relevantes. Ahora una plataforma puede identificar patrones, clasificar argumentos o comparar posiciones en segundos. Tal velocidad resulta seductora. Gao et al. (2023) comprobaron que textos generados podían confundirse con producciones científicas humanas bajo evaluación ciega. El hallazgo obliga a desconfiar de la apariencia analítica. Una evidencia más exigente debe mostrar criterios explícitos de segmentación, razones para priorizar variables y capacidad para detectar omisiones en la salida algorítmica recibida.

Evaluar adquiere una doble condición. Continúa siendo un nivel de juicio, aunque también se convierte en requisito transversal para trabajar con IA. Ng et al. (2021) relacionan la alfabetización algorítmica con comprensión, aplicación y consideraciones éticas. Laupichler et al. (2022) amplían dicha perspectiva en educación superior. Desde allí, valorar una respuesta implica revisar evidencia, reconocer incertidumbre y calibrar confianza. La operación evaluativa deja de aparecer después del análisis y acompaña cada intercambio con el sistema.

Crear pierde parte de su antigua condición distintiva cuando una máquina genera imágenes, ensayos o diseños en pocos instantes. Dwivedi et al. (2023) describen repercusiones para la investigación, la práctica y la autoría. La revisión de Bloom debe evitar identificar producción novedosa con aprendizaje avanzado. Crear exige ahora formular intenciones, seleccionar alternativas y justificar transformaciones. También demanda reconocer aportes ajenos. La originalidad educativa reside menos en producir material y más en gobernar decisiones con sentido.

La externalización afecta de manera desigual a estudiantes y disciplinas. Una misma ayuda puede ampliar posibilidades para quien posee criterios bien formados y ocultar carencias en quien carece de bases conceptuales. Chan (2023) propone políticas universitarias que articulan enseñanza, aprendizaje y uso responsable de IA. Tal orientación reclama acuerdos visibles sobre asistencia permitida. También exige tareas capaces de revelar participación cognitiva. La equidad depende de ofrecer apoyos sin confundir disponibilidad tecnológica con competencia intelectual adquirida.

Revisar Bloom no requiere desechar sus categorías, sino modificar la pregunta que las acompaña. Ya no basta preguntar qué verbo ejecuta el estudiante. Conviene identificar dónde ocurre la operación, qué parte fue delegada y quién responde por el resultado. Yan et al. (2023) destacan dimensiones prácticas y éticas asociadas con modelos lingüísticos en educación. La taxonomía renovada deberá registrar grados de autonomía, calidad de supervisión y transferencia posterior. Allí comienza una lectura mediada del aprendizaje.

1.3. Cognición distribuida entre estudiante, modelo y entorno digital

Pensar con inteligencia artificial implica reconocer que la actividad cognitiva ya no queda contenida dentro de una persona.

El estudiante formula propósitos, aporta conocimientos previos y decide qué merece atención. El modelo transforma instrucciones en representaciones provisionales. El entorno digital conserva rastros, conecta fuentes y habilita nuevas acciones. La unidad nace de tales intercambios. Hablar de cognición distribuida permite estudiar el aprendizaje como coordinación entre aportes distintos sin borrar la responsabilidad del sujeto que aprende.

La distribución cognitiva posee antecedentes en prácticas ordinarias. Escribir una nota, consultar un diagrama o usar una calculadora desplaza parte del procesamiento hacia artefactos externos. La diferencia actual reside en la capacidad generativa del sistema. Holmes y Tuomi (2022) describen la IA educativa como una relación entre técnicas computacionales y decisiones pedagógicas. El artefacto ya no guarda información pasivamente. Propone respuestas, reorganiza materiales y modifica el curso de la actividad mientras participa activamente en ella.

El estudiante conserva un papel conductor, aunque su intervención adopta formas menos visibles. Define el problema, aporta restricciones y reconoce cuándo una respuesta se aparta del propósito. También conecta la producción algorítmica con saberes disciplinares. Romero-Rodríguez et al. (2023) observaron que universitarios perciben utilidad de ChatGPT para tareas vinculadas con pensamiento complejo. Tal percepción cobra sentido cuando la herramienta amplía relaciones posibles. Sin dirección humana, la abundancia de alternativas puede convertirse en dispersión bien redactada.

El modelo participa mediante patrones aprendidos y probabilidades lingüísticas. No comparte la experiencia biográfica ni la pertenencia académica del estudiante. Aun con tal límite, puede reformular ideas, contrastar opciones y ofrecer andamiajes inmediatos. Kasneci et al. (2023) vinculan tales capacidades con oportunidades educativas y riesgos de dependencia o error. Considerarlo participante cognitivo no equivale a atribuirle

conciencia. Significa reconocer que sus operaciones en ocasiones alteran las decisiones humanas y la trayectoria seguida durante el aprendizaje.

El entorno digital cumple una función menos llamativa pero decisiva. Allí operan interfaces, bases documentales, sistemas de recomendación y reglas de acceso. Cada componente organiza lo que puede verse y también aquello que permanece fuera del campo de atención. Halaweh (2023) plantea estrategias responsables para integrar ChatGPT en educación mediante decisiones institucionales y pedagógicas. La cognición distribuida depende de una infraestructura. Sus condiciones técnicas orientan posibilidades, límites y formas de participación dentro de cada tarea.

La coordinación entre estudiante y modelo ocurre mediante ciclos de formulación, respuesta y revisión. Una pregunta modifica la salida; la salida transforma la pregunta. Chiu (2023) analiza repercusiones de la IA generativa en prácticas y políticas educativas. Desde la mirada, la conversación funciona como espacio de elaboración compartida. Sin embargo, la calidad del intercambio depende de criterios. Cuando faltan metas claras, el diálogo puede avanzar con fluidez mientras se aleja del problema que debía resolver.

Distribuir operaciones no reparte la autoridad intelectual. Una plataforma puede producir gran parte del texto, pero el estudiante continúa respondiendo por la selección y el uso de sus contenidos. O'Connor y ChatGPT (2023) mostraron mediante una colaboración poco convencional las tensiones que acompañan la autoría algorítmica en educación profesional. La escena resulta reveladora. La responsabilidad no desaparece cuando la producción se comparte. Cambia de lugar y exige declarar aportes, revisar afirmaciones y justificar decisiones.

La distribución también modifica el tiempo del pensamiento. Noy y Zhang (2023) comprobaron que la IA generativa puede acelerar tareas de escritura y elevar su calidad. La ganancia productiva libera minutos para revisar, comparar o profundizar. Sin embargo, ninguna mejora temporal garantiza aprendizaje. Todo depende del uso dado al tiempo recuperado. Si la rapidez elimina pausas de elaboración, el sistema gana eficiencia mientras el estudiante pierde oportunidades para construir relaciones conceptuales duraderas y reconocer errores.

Las diferencias entre usuarios recuerdan que la unidad humano-máquina nunca es homogénea. Chan y Lee (2023) encontraron variaciones generacionales en la disposición hacia herramientas generativas dentro de la enseñanza. Ivanov et al. (2024) identificaron factores que orientan su adopción universitaria. Experiencia, confianza y expectativas cambian la participación de cada actor. Por ello, una misma plataforma produce configuraciones cognitivas distintas. Analizar la distribución requiere atender capacidades previas, normas institucionales y posibilidades reales de acceso para aprender.

Una taxonomía destinada a escenarios generativos debe representar relaciones y no únicamente acciones aisladas. Conviene registrar quién inicia una operación, qué recurso la transforma y quién valida su pertinencia. Yan et al. (2024) destacan promesas educativas junto a riesgos para el aprendizaje humano. La cognición distribuida ofrece una base para ordenar tal complejidad. No diluye al estudiante dentro de la red digital. Le exige comprenderla, dirigirla y responder por el conocimiento producido mediante su participación.

1.4. Del verbo cognitivo a la arquitectura de la actividad intelectual

Durante décadas, los objetivos se redactaron mediante verbos que prometían hacer visible el pensamiento. Analizar,

evaluar o crear parecían indicar grados de complejidad. Tal convención aportó claridad curricular y facilitó acuerdos entre docentes. Sin embargo, el verbo nombra una acción sin revelar la organización intelectual que la sostiene. Dos estudiantes pueden evaluar un argumento mediante procesos profundamente distintos. Uno aplica criterios razonados. Otro reproduce una valoración generada sin comprender sus fundamentos ni asumir su autoría.

La insuficiencia aparece cuando una acción admite rutas cognitivas divergentes. Resumir puede exigir selección conceptual, jerarquización y reformulación propia. También puede reducirse a copiar una salida automática. Chen et al. (2020) documentan la expansión de funciones educativas atribuidas a la inteligencia artificial. Tal amplitud obliga a mirar más allá del producto observable. La complejidad reside en las decisiones tomadas, en los saberes movilizados y en la capacidad de explicar por qué la respuesta resulta defendible.

Hablar de arquitectura de la actividad intelectual permite reunir componentes que el verbo deja ocultos. Cada desempeño articula una meta, operaciones mentales, recursos externos y criterios de control. También posee una distribución de iniciativa y responsabilidad. Chen et al. (2020) advierten brechas entre el desarrollo teórico y las aplicaciones educativas de la IA. Una arquitectura bien descrita conecta ambos planos. Explica quién plantea el problema, qué procesos delega y qué evidencias conserva para demostrar dominio.

La distinción cobra fuerza ante los modelos generativos. Redactar, comparar o argumentar ya no certifica por sí mismo una elaboración humana equivalente. Gao et al. (2023) comprobaron que lectores expertos podían confundir resúmenes científicos generados con textos auténticos. La apariencia del producto pierde entonces valor diagnóstico. Importa reconstruir la actividad que lo produjo. Las preguntas formuladas, las fuentes consultadas y las

correcciones realizadas muestran una trama cognitiva visible que ningún verbo aislado alcanza a representar.

Una arquitectura intelectual también permite diferenciar asistencia, colaboración y sustitución. La asistencia aporta ejemplos o retroalimentación mientras preserva las decisiones centrales. La colaboración efectiva distribuye operaciones y requiere coordinación consciente. La sustitución entrega al sistema partes necesarias para aprender. Lo (2023) identifica oportunidades pedagógicas junto con riesgos asociados al uso de ChatGPT. La diferencia entre beneficio y pérdida formativa depende menos de la herramienta que del lugar asignado a cada operación dentro de la tarea.

El análisis debe incorporar la responsabilidad epistémica. No basta producir una respuesta correcta; importa saber quién verificó sus afirmaciones y bajo qué criterios. Ng et al. (2021) vinculan la alfabetización en inteligencia artificial con comprensión técnica, uso aplicado y consideración ética. Desde tal enfoque, evaluar una respuesta implica revisar evidencia, reconocer límites y justificar confianza. La actividad adquiere mayor complejidad cuando el estudiante además gobierna tales decisiones, aunque una máquina haya contribuido a la redacción.


También cambia el diseño de consignas. Pedir que el alumnado analice un caso ofrece poca información sobre la arquitectura esperada. Conviene precisar qué relaciones debe establecer, qué alternativas necesita contrastar y qué decisiones deberá defender. Chan (2023) propone un marco universitario que articula dimensiones pedagógicas, éticas y operativas para orientar políticas de IA. Esa articulación puede trasladarse al aula mediante tareas que hagan claramente visibles las fases del pensamiento y los grados permitidos de mediación.

Las evidencias de aprendizaje deben corresponder con esa descripción rica. Un producto pulido aporta información limitada

cuando parte de su elaboración procede de un modelo. Resultan valiosas las versiones, las anotaciones de decisión y la defensa oral. Yan et al. (2023) señalan problemas prácticos y éticos vinculados con modelos lingüísticos en educación. Registrar el proceso permite examinar la intervención humana sin convertir la vigilancia en el centro de la experiencia formativa ni reducirla a control.

Figura 3

Arquitectura de la actividad intelectual



La arquitectura propuesta no abandona los verbos cognitivos. Los coloca dentro de una estructura multidimensional. Analizar continúa siendo una operación relevante, aunque su nivel depende de la autonomía ejercida y de la profundidad conceptual alcanzada. También cuentan la transferencia, la verificación y el grado de mediación algorítmica. Díaz-Rodríguez et al. (2023) relacionan confianza en IA con principios, requisitos y mecanismos de gobernanza. En educación, dicha relación se traduce en desempeños trazables y responsables de aprendizaje.

El desplazamiento desde el verbo hacia la arquitectura renueva la lectura de la complejidad intelectual. No pregunta qué acción aparece en la consigna. Indaga quién la realiza, con qué

apoyos y mediante qué decisiones. Tal cambio prepara una taxonomía para distinguir ejecución automática, cooperación regulada y dominio demostrable. También abre el análisis de la carga y de la delegación algorítmica. El aprendizaje recupera su espesor: proceso, criterio, responsabilidad y capacidad de actuar fuera del asistente.

1.5. Carga cognitiva, descarga cognitiva y delegación algorítmica

La carga cognitiva adquiere un significado cuando parte del trabajo intelectual puede trasladarse a sistemas generativos. La cuestión pedagógica ya no reside únicamente en reducir demandas mentales, sino en decidir qué esfuerzo merece conservarse porque produce aprendizaje. Una herramienta puede aliviar operaciones rutinarias y liberar recursos atencionales. Sin embargo, cuando elimina la elaboración necesaria para comprender, comparar o justificar, la eficiencia inmediata puede empobrecer la formación de estructuras conceptuales duraderas y debilitar el juicio propio.

La descarga cognitiva describe el traslado de operaciones mentales hacia apoyos externos. Cuadernos, calculadoras y buscadores ya cumplían funciones semejantes antes de la inteligencia artificial generativa. La diferencia actual reside en la amplitud de tareas transferibles: recordar, resumir, formular argumentos o producir alternativas. Chang et al. (2023) vinculan el apoyo algorítmico con procesos de autorregulación que requieren metas y retroalimentación. Descargar trabajo mental puede ser productivo cuando el estudiante conserva dirección sobre su actividad intelectual.

Delegar una operación no equivale necesariamente a renunciar al aprendizaje. La delegación puede funcionar como una distribución estratégica del esfuerzo cuando permite reservar atención para relaciones, inferencias o decisiones de mayor complejidad. En experiencias de aprendizaje de lenguas, Wei (2023)

relaciona la asistencia basada en inteligencia artificial con resultados académicos, motivación y autorregulación. El punto educativo relevante radica en distinguir entre apoyo que amplía capacidades y sustitución que vuelve prescindible la participación cognitiva del aprendiz.

Esa distinción conduce a una pregunta: ¿qué debe permanecer en manos del estudiante? No toda dificultad posee valor formativo. Copiar datos, corregir detalles mecánicos o reorganizar información puede consumir recursos sin aportar comprensión proporcional. Pero explicar una decisión, reconocer una contradicción o reconstruir una idea exige actividad generativa. Liu et al. (2021) muestran la importancia de mecanismos que promueven pensamiento reflexivo dentro de entornos apoyados por inteligencia artificial, precisamente para preservar elaboración durante la asistencia.

El riesgo aparece cuando la comodidad tecnológica modifica el umbral de esfuerzo que una persona considera aceptable. Una respuesta puede convertir la consulta en reflejo antes de que exista un intento. Essel et al. (2024) examinan efectos de respuestas instantáneas de modelos conversacionales sobre habilidades cognitivas. Entonces, la preocupación no radica en usar ayuda externa, sino en perder oportunidades de recuperación, anticipación y razonamiento que fortalecen la disponibilidad futura del conocimiento y la confianza epistémica.

La delegación algorítmica altera la agencia porque desplaza decisiones acerca de qué información seleccionar, qué procedimiento seguir y cuándo detener una búsqueda. Darvishi et al. (2024) analizan la relación entre asistencia de inteligencia artificial y agencia estudiantil, una conexión relevante cuando la herramienta participa en decisiones. Cuanto mayor sea la cesión de operaciones, debe ser la capacidad del aprendiz para reconocer qué ha delegado, por qué lo hizo y qué responsabilidad conserva sobre el resultado.

Hay, además, una diferencia entre reducir carga innecesaria y eliminar fricción cognitiva fértil. La primera facilita que la atención alcance el núcleo de una tarea. La segunda puede privar al estudiante de momentos donde el conocimiento se reorganiza mediante duda, contraste o corrección. Fan et al. (2024) advierten sobre formas de pereza metacognitiva asociadas con inteligencia artificial generativa. Una pedagogía cuidadosa necesita proteger ciertos esfuerzos aun cuando la tecnología permita evitarlos con rapidez y precisión.

Desde una perspectiva de diseño, conviene tratar la asistencia algorítmica como una variable graduable y no como una presencia binaria. Puede ofrecer pistas, ejemplos, preguntas o retroalimentación antes de entregar una solución completa. Li et al. (2024) comparan apoyos humanos y ChatGPT considerando pensamiento crítico, desempeño y carga cognitiva. Tal evidencia invita a diseñar secuencias donde la ayuda cambie según la tarea, el dominio alcanzado y la capacidad del estudiante para supervisar su propio razonamiento.

La regulación de la descarga cognitiva requiere conciencia sobre el momento de consultar y sobre la profundidad de la intervención solicitada. Un aprendiz experto no necesariamente utiliza menos inteligencia artificial; puede utilizarla con mayor selectividad. Xu et al. (2025) destacan el papel del apoyo metacognitivo para fortalecer autorregulación y experiencia de aprendizaje en entornos generativos. La competencia relevante consiste en administrar la frontera entre pensamiento y asistencia externa sin convertir dicha frontera en una separación.

Por ello, carga, descarga y delegación forman un continuo de decisiones antes que tres fenómenos independientes. El aprendizaje mediado por inteligencia artificial exige valorar qué esfuerzo conviene aliviar, cuál debe sostenerse y qué operaciones pueden compartirse bajo supervisión. La medida no es la cantidad de trabajo cedido a la máquina, sino la calidad de la actividad

mental que permanece. Allí se juega una transición: pasar de recibir asistencia a gobernar conscientemente la propia arquitectura cognitiva.

1.6. Hacia una taxonomía pos-Bloom para ecosistemas educativos generativos

Una taxonomía pos-Bloom requiere abandonar la idea de que el aprendizaje puede describirse mediante una secuencia fija de operaciones individuales. La inteligencia artificial generativa introduce mediaciones capaces de ejecutar tareas antes consideradas evidencia de dominio. Chen et al. (2020) identifican brechas entre aplicaciones educativas y marcos teóricos de inteligencia artificial. Tal distancia obliga a revisar qué significa recordar, comprender, aplicar, analizar, evaluar o crear cuando parte de la actividad intelectual puede compartirse con agentes algorítmicos.

La revisión no implica desechar a Bloom, cuya arquitectura conserva valor para ordenar propósitos educativos, reconocer diferencias entre demandas intelectuales. El cambio consiste en desplazar la atención desde el verbo observable hacia la configuración de la actividad que lo produce. Hwang et al. (2020) plantean nuevos papeles para la inteligencia artificial educativa y para quienes participan en ella. Una misma acción verbal puede expresar autonomía, asistencia, supervisión o dependencia según la distribución del trabajo cognitivo.

Bajo esa perspectiva, los niveles dejan de representar únicamente complejidad creciente y comienzan a expresar formas de agencia. Un estudiante puede producir un ensayo sofisticado mediante instrucciones mínimas al modelo y demostrar poco dominio del asunto. También puede utilizar una respuesta generada como material para contrastar argumentos, localizar errores y reconstruir explicaciones. Ng et al. (2021) vinculan la alfabetización en inteligencia artificial con capacidades técnicas,

críticas y éticas, dimensiones necesarias para interpretar tales diferencias educativas.

La taxonomía pos-Bloom necesita distinguir desempeño visible de competencia atribuible al aprendiz. Esa separación cobra importancia cuando una producción de calidad puede resultar de una colaboración opaca entre persona y modelo. Gao et al. (2023) comprobaron que textos científicos generados por ChatGPT podían confundirse con escritos humanos bajo evaluaciones. El producto pierde entonces parte de su poder diagnóstico. Importa conocer decisiones, verificaciones, revisiones y argumentos mediante los cuales el estudiante hace intelectualmente suyo el resultado.

Otro desplazamiento afecta la noción de creación situada en la cúspide de revisiones contemporáneas de Bloom. Generar ya no garantiza una exigencia cognitiva elevada cuando un modelo produce alternativas en segundos. Kasneci et al. (2023) señalan oportunidades educativas de los grandes modelos lingüísticos junto con riesgos vinculados a su empleo. Crear adquiere mayor densidad formativa cuando exige formular criterios, orientar iteraciones, seleccionar posibilidades, justificar descartes y transformar materiales generados mediante decisiones que revelen comprensión disciplinar.

Una arquitectura renovada también debe reconocer que evaluar cambia de posición funcional. El juicio deja de operar únicamente como etapa previa a crear y adquiere presencia transversal durante la interacción generativa. Yan et al. (2023) destacan problemas prácticos y éticos asociados con grandes modelos lingüísticos en educación. Verificar fuentes, calibrar confianza, detectar inconsistencias y decidir cuándo rechazar una respuesta constituyen acciones recurrentes. Su valor depende menos del orden jerárquico que de la responsabilidad epistémica ejercida.

La propuesta pos-Bloom tampoco puede limitarse a añadir una categoría llamada inteligencia artificial sobre la clasificación heredada. Requiere describir relaciones entre capacidad humana, mediación algorítmica y evidencia de aprendizaje. Giannakos et al. (2024) plantean que la inteligencia artificial generativa ofrece posibilidades educativas acompañadas por tensiones que demandan investigación y diseño cuidadoso. Por ello, cada nivel debería indicar qué puede delegarse, qué necesita supervisión humana y qué desempeño debe demostrarse sin asistencia para acreditar dominio transferible.

Tal reorganización conduce hacia una taxonomía matricial antes que escalonada. Una dimensión puede representar la naturaleza de la operación cognitiva; otra, el grado de mediación algorítmica; una tercera, la agencia ejercida por el aprendiz. Romero-Rodríguez et al. (2023) relacionan el uso universitario de ChatGPT con percepciones favorables respecto del pensamiento complejo. La cuestión pedagógica consiste en traducir tales posibilidades en evidencias donde pueda distinguirse producción asistida, razonamiento propio, supervisión crítica y transferencia independiente plenamente verificable.

La dimensión ética merece una posición estructural dentro de la nueva arquitectura. No constituye un añadido normativo posterior al aprendizaje, pues intervenir sobre resultados generativos implica decisiones acerca de autoría, transparencia, sesgo, privacidad y responsabilidad. Nguyen et al. (2022) organizan principios éticos para la inteligencia artificial educativa que permiten comprender tales decisiones educativas relevantes. Una taxonomía pertinente debe reconocer que aprender con modelos generativos también exige gobernar sus usos mediante criterios justificables y responsabilidad intelectual.

Desde esa base, una taxonomía pos-Bloom puede concebir el aprendizaje como coordinación progresivamente consciente entre pensamiento humano y capacidad generativa. Su propósito

no sería clasificar verbos nuevos, sino hacer visible quién realiza cada operación, con qué mediación, bajo qué criterios y mediante qué evidencia. Yan et al. (2024) examinan promesas y tensiones de la inteligencia artificial generativa para el aprendizaje humano. La pregunta cambia: importa determinar qué competencia permanece disponible cuando desaparece la asistencia algorítmica.

Tabla 1

Transformaciones del aprendizaje desde la taxonomía cognitiva hacia la cognición mediada por inteligencia artificial

Eje conceptual	Planteamiento central
Herencia de las taxonomías cognitivas	Bloom y sus revisiones aportan un lenguaje para organizar procesos cognitivos. Su vigencia requiere reconsiderar la atribución del desempeño cuando intervienen sistemas generativos.
Cambio en la unidad de análisis	El verbo cognitivo pierde capacidad explicativa cuando se observa de manera aislada. Resulta necesario examinar la actividad intelectual, la participación humana y el grado de mediación algorítmica.
Cognición mediada por IA	La inteligencia artificial generativa participa en operaciones vinculadas con recuperación, interpretación, análisis, evaluación y producción. Tal intervención modifica las condiciones bajo las cuales una tarea puede considerarse evidencia de aprendizaje.
Desempeño y aprendizaje	Un producto elaborado no demuestra necesariamente dominio cognitivo equivalente. La valoración educativa necesita reconocer qué operaciones realizó el estudiante y cuáles fueron ejecutadas o ampliadas mediante asistencia algorítmica.
Agencia del aprendiz	La competencia incorpora decisiones relacionadas con cuándo utilizar inteligencia artificial, para qué emplearla y hasta dónde delegar operaciones. La supervisión consciente adquiere relevancia frente a la aceptación automática de resultados.

Eje conceptual	Planteamiento central
Carga y descarga cognitiva	Externalizar determinadas operaciones puede liberar recursos mentales para actividades de mayor elaboración. La descarga pierde valor formativo cuando elimina esfuerzos necesarios para comprender, recuperar conocimientos o construir criterios propios.
Delegación algorítmica	Delegar no equivale necesariamente a abandonar el razonamiento. Su valor educativo depende de la capacidad para conservar dirección intelectual, revisar resultados y asumir responsabilidad sobre las decisiones adoptadas.
Metacognición y autorregulación	Aprender con sistemas generativos requiere planificar la interacción, calibrar la ayuda solicitada y evaluar la calidad de las respuestas. La regulación pasa a abarcar tanto procesos internos como relaciones con recursos algorítmicos.
Evidencia de competencia	La evaluación necesita distinguir producción asistida, razonamiento independiente, supervisión crítica y transferencia. El interés se desplaza desde la calidad aparente del producto hacia la trazabilidad de la actividad cognitiva desarrollada.
Proyección pos-Bloom	Una taxonomía renovada puede articular demanda cognitiva, agencia humana, mediación algorítmica, juicio y transferencia. La clasificación deja de depender de una jerarquía lineal y avanza hacia una arquitectura multidimensional del aprendizaje.

Nota. La tabla organiza los principales desplazamientos conceptuales desarrollados en el Capítulo 1 y muestra la transición desde una clasificación centrada en operaciones cognitivas hacia una arquitectura que considera la distribución de la actividad intelectual entre aprendiz e inteligencia artificial.

Capítulo II

Reconfiguración de los niveles cognitivos en interacción con IA generativa

La inteligencia artificial generativa ha alterado una premisa silenciosa de muchas taxonomías educativas: que las operaciones cognitivas pertenecen enteramente al aprendiz. Cuando un sistema recuerda datos, explica conceptos, propone procedimientos y redacta argumentos, la relación entre tarea y aprendizaje deja de ser transparente. Chen et al. (2020) advirtieron brechas entre las aplicaciones educativas de la inteligencia artificial y sus fundamentos teóricos. Tal distancia obliga a reconsiderar qué significa demostrar una capacidad cognitiva bajo mediación algorítmica.

La taxonomía de Bloom conserva potencia pedagógica porque ofrece un lenguaje reconocible para organizar objetivos y actividades. Sin embargo, la generación automática introduce una variable que altera la lectura tradicional de sus niveles. Una acción observable puede ser ejecutada parcialmente por el estudiante y parcialmente por el modelo. Holmes y Tuomi (2022) describen una educación con inteligencia artificial donde las funciones tecnológicas adoptan papeles diversos. Por ello, clasificar una tarea por su verbo resulta cada vez menos suficiente.

El problema no radica en decidir si la inteligencia artificial facilita o perjudica el aprendizaje de manera general. La cuestión es más precisa: qué parte de la actividad intelectual permanece en manos del aprendiz y qué parte ha sido transferida al sistema. Kim et al. (2022) destacan la necesidad de diseños que favorezcan una colaboración productiva entre estudiantes e inteligencia artificial. Desde tal perspectiva, la mediación deja de ser un añadido técnico y pasa a modificar la arquitectura cognitiva de la actividad.


Recordar, comprender y aplicar adquieren nuevos matices cuando la información puede recuperarse, reformularse y ponerse en uso mediante instrucciones breves. El cambio no vuelve prescindibles las operaciones básicas. Al contrario, exige determinar qué conocimientos deben permanecer disponibles y qué comprensiones permiten orientar la asistencia recibida. Seo et

al. (2021) mostraron que la inteligencia artificial puede modificar dinámicas de interacción educativa. La pregunta pedagógica se desplaza entonces desde la disponibilidad de respuestas hacia la calidad de la participación intelectual.

Figura 4

Reconfiguración cognitiva ante la IA generativa

2. Reconfiguración de los niveles cognitivos en interacción con IA generativa



En niveles de mayor elaboración ocurre una transformación igualmente profunda. Analizar ya no consiste únicamente en descomponer información proporcionada por una fuente humana. También requiere examinar producciones sintéticas cuya fluidez puede ocultar debilidades epistémicas. Cooper (2023) documenta capacidades relevantes de ChatGPT en educación científica junto con limitaciones que demandan atención. La producción algorítmica se convierte, por ello, en material susceptible de examen y no en una respuesta que merezca aceptación por su apariencia discursiva.

Evaluar introduce una responsabilidad adicional. Frente a sistemas capaces de producir afirmaciones persuasivas, el juicio necesita apoyarse en evidencia y criterios explícitos. Ng et al. (2021) relacionan la alfabetización en inteligencia artificial con capacidades necesarias para comprender y valorar críticamente tales tecnologías. La confianza tampoco puede operar como una

decisión binaria. Debe graduarse según la calidad de las fuentes, la naturaleza de la tarea y las consecuencias asociadas con aceptar una producción generativa como válida.

Crear plantea quizá la ruptura más visible con la secuencia tradicional. Generar texto, imágenes o alternativas dejó de ser evidencia suficiente de una actividad creadora compleja cuando una herramienta puede producirlas de inmediato. Doshi y Hauser (2024) encontraron que la IA generativa puede favorecer la creatividad individual mientras reduce la diversidad colectiva de las producciones. La autoría educativa necesita atender entonces a la intención, la selección, la transformación y la responsabilidad asumida durante el proceso creador.

A lo largo del capítulo, los niveles cognitivos serán tratados como configuraciones de actividad y no como casillas cerradas. Cada nivel conserva vínculos con la tradición taxonómica, aunque su significado cambia cuando interviene un agente generativo. Laupichler et al. (2022) muestran que la alfabetización en inteligencia artificial requiere conocimientos y competencias que exceden el manejo instrumental. De ahí que la reconfiguración propuesta atienda tanto a operaciones mentales como a decisiones de delegación, supervisión y apropiación.

Tal mirada también modifica la evaluación educativa. Si una herramienta puede ejecutar acciones antes consideradas evidencia directa de aprendizaje, el producto terminado pierde parte de su capacidad para revelar quién pensó y qué aprendió. Nguyen et al. (2022) destacan principios éticos vinculados con el uso educativo de inteligencia artificial. La trazabilidad del proceso adquiere relevancia: interesa conocer decisiones, verificaciones y transformaciones mediante las cuales el estudiante conserva agencia frente a una tecnología que participa activamente en la producción.

El propósito del capítulo consiste en reconstruir la progresión cognitiva bajo una condición nueva: aprender junto a sistemas capaces de realizar porciones significativas del trabajo intelectual visible. La secuencia que va de recordar a crear permanece reconocible, pero cada nivel necesita criterios renovados para distinguir ejecución automática de aprendizaje humano. Tal relectura prepara una taxonomía donde la complejidad no depende únicamente de la tarea realizada, sino del grado de agencia, juicio y apropiación que el aprendiz conserva.

2.1. Recordar en la era de la recuperación generativa

Recordar dejó de equivaler a conservar datos disponibles para una evocación posterior. La inteligencia artificial generativa altera esa relación porque ofrece información inmediata, reformulada y adaptable a cada consulta. El nivel cognitivo más básico adquiere entonces una función distinta: construir referencias internas que permitan reconocer pertinencia, detectar inconsistencias y orientar búsquedas. La memoria conserva valor, pero cambia su centro de gravedad. Importa menos acumular respuestas que disponer de conocimientos capaces de sostener decisiones intelectuales propias.

La recuperación generativa introduce una paradoja pedagógica. Cuanto más accesible resulta una respuesta, menor puede ser el incentivo para fijar ciertos contenidos en la memoria; sin embargo, juzgar la respuesta exige saber algo antes de recibirla. Chan y Hu (2023) documentan que estudiantes universitarios perciben beneficios académicos en la IA generativa junto con preocupaciones vinculadas al aprendizaje. Recordar pasa a funcionar como reserva cognitiva para interrogar, contrastar y reconocer aquello que merece confianza razonada propia.

Desde una perspectiva taxonómica, la disponibilidad de modelos lingüísticos no elimina la memoria declarativa. Modifica las condiciones bajo las cuales demuestra su utilidad. Un estudiante

puede obtener fechas, definiciones o clasificaciones en segundos, aunque la disponibilidad externa no garantiza apropiación intelectual. Kasneci et al. (2023) advierten que los modelos lingüísticos ofrecen oportunidades educativas y riesgos asociados con dependencia y errores. La enseñanza necesita distinguir entre información recuperada por la máquina y conocimiento disponible para pensar.

Tal distinción obliga a revisar qué significa demostrar que se recuerda. Repetir una definición producida por un asistente carece de fuerza probatoria cuando la fuente generativa permanece disponible durante la tarea. Cobran mayor valor evidencias: reconocer un concepto entre distractores plausibles, recuperar principios sin asistencia, establecer relaciones desde la memoria o advertir una omisión en una respuesta automática. La evidencia de recuerdo se desplaza desde la reproducción hacia la disponibilidad cognitiva que sostiene acciones posteriores.

La memoria interna también cumple una función de anclaje frente a la fluidez verbal de los modelos. Una respuesta bien redactada puede parecer familiar incluso cuando contiene afirmaciones dudosas. Hicks et al. (2024) cuestionan la relación entre la producción lingüística de ChatGPT y un compromiso genuino con la verdad. Para el aprendizaje, la consecuencia es relevante: recordar conceptos, fuentes, reglas o relaciones fundamentales ofrece puntos de apoyo para resistir la aceptación automática de formulaciones convincentes.

No todo contenido merece idéntico esfuerzo de memorización. La recuperación generativa vuelve más visible una decisión curricular determinar qué conocimientos deben permanecer disponibles sin mediación y cuáles pueden consultarse legítimamente. Datos efímeros, listados extensos o información verificable admiten mayor apoyo externo. En cambio, vocabulario disciplinar, principios estructurantes y referentes que permiten interpretar problemas requieren disponibilidad mental frecuente.

El criterio pedagógico reside en la función cognitiva del conocimiento, no en su mera posibilidad de almacenamiento externo.

La práctica de recuperación conserva un lugar, aunque necesita propósitos renovados. Evocar sin asistencia puede servir para formar una base desde la cual conversar con sistemas generativos de manera activa. Fan et al. (2024) hallaron efectos vinculados con pereza metacognitiva cuando la IA generativa interviene en procesos de aprendizaje. La cuestión no consiste en prohibir apoyos, sino en diseñar momentos donde el esfuerzo de recordar preceda a la consulta y haga visible la contribución humana.

Una secuencia didáctica coherente puede alternar recuperación autónoma y acceso generativo. Primero, el estudiante registra lo que recuerda sobre un problema. Después consulta al modelo y compara ambas producciones. Más tarde identifica vacíos, corrige asociaciones y reconstruye una versión propia. Xu et al. (2025) muestran relevancia del apoyo metacognitivo en ambientes de aprendizaje con IA generativa. La memoria deja de operar como depósito y participa en ciclos de anticipación, contraste y revisión deliberada del conocimiento.

También cambia la relación entre olvido y aprendizaje. Olvidar un dato consultable no representa una pérdida equivalente a olvidar un principio que organiza múltiples decisiones. La educación mediada por IA requiere graduar ambos fenómenos con precisión. Yan et al. (2024) plantean que la IA generativa puede ampliar oportunidades para aprender, pero también modificar procesos cognitivos. Por ello, evaluar el recuerdo demanda atender al valor estructural de aquello que permanece disponible cuando desaparece la asistencia algorítmica.

Reinterpretado de ese modo, recordar constituye la infraestructura de una cognición capaz de trabajar con generación

sin quedar absorbida por ella. Su valor no proviene de competir con la capacidad de almacenamiento o recuperación de una máquina. Proviene de ofrecer continuidad intelectual al sujeto: referencias para preguntar, criterios para discriminar y conocimientos disponibles para enlazar ideas. En la taxonomía revisada, recordar permanece en la base, pero su significado pasa de retener información a sostener agencia.

2.2. Comprender mediante explicación, contraste y reconstrucción conceptual

Comprender adquiere una configuración distinta cuando la inteligencia artificial generativa puede producir explicaciones plausibles en segundos. La evidencia cognitiva ya no reside en recibir una formulación clara ni en reproducirla con fidelidad. Comprender exige apropiarse de relaciones, causas y límites mediante operaciones visibles de elaboración. Explicar con palabras propias, confrontar interpretaciones y reconstruir una idea después del intercambio permiten distinguir entre familiaridad verbal y comprensión genuina. Allí comienza una diferencia pedagógica de gran alcance actual.


La explicación cumple una función diagnóstica porque obliga a organizar significados antes de delegar la formulación. Cuando una persona explica un concepto debe seleccionar relaciones relevantes, establecer jerarquías y hacer explícitos nexos que una lectura fluida puede ocultar. Liu et al. (2021) encontraron beneficios al incorporar mecanismos orientados al pensamiento reflexivo en ambientes educativos apoyados por inteligencia artificial. Explicar adquiere valor cuando revela la arquitectura conceptual construida por quien aprende y no una paráfrasis automatizada.

El contraste añade una segunda operación. Frente a una producción generativa, comprender implica comparar lo recibido con saberes previos, fuentes disciplinares y formulaciones

alternativas. La divergencia deja de percibirse como ruido y puede convertirse en materia para aprender. Barrett y Pack (2023) describen percepciones de docentes y alumnos que muestran una relación matizada con la IA generativa durante la escritura. Contrastar obliga a tomar posición intelectual ante opciones que llegan ya articuladas con aparente coherencia.

Figura 5

Procesos para la comprensión conceptual



Reconstruir lleva la comprensión un paso más lejos. Después de consultar una explicación generada, quien aprende debería poder reorganizarla sin copiar su estructura ni depender de su secuencia. La reconstrucción requiere decidir qué ideas permanecen, cuáles cambian de lugar y qué vínculos necesitan reformulación. Kim et al. (2022) destacan la relevancia del diseño del aprendizaje para favorecer colaboración entre personas e inteligencia artificial. La comprensión aparece entonces en las transformaciones realizadas sobre el material recibido.

La conversación con un modelo puede favorecer comprensión cuando las preguntas modifican progresivamente el objeto estudiado. Pedir ejemplos, excepciones, analogías o

contraargumentos convierte la interacción en una cadena de operaciones intelectuales. Seo et al. (2021) observaron que la inteligencia artificial puede alterar las dinámicas de interacción y la percepción de apoyo. El beneficio cognitivo depende de que el diálogo provoque elaboración y no derive en una sucesión de explicaciones aceptadas sin examen por quien aprende.

Una explicación generada también puede funcionar como objeto de intervención didáctica. El docente puede pedir que se reduzca, amplíe, corrija o reorganice según un criterio disciplinar definido. Cada modificación exige interpretar antes de actuar. Banihashem et al. (2024), al comparar fuentes de retroalimentación para escritura, muestran que el origen del comentario incide en procesos vinculados con su aprovechamiento. Comprender implica trabajar sobre el significado recibido hasta convertirlo en una representación intelectualmente defendible y personalmente articulada.

La reconstrucción conceptual cobra especial importancia cuando el modelo ofrece versiones demasiado ordenadas de asuntos complejos. Una formulación impecable puede borrar tensiones, controversias o zonas de incertidumbre que forman parte del conocimiento disciplinar. Tlili et al. (2023) documentan oportunidades y riesgos educativos asociados con ChatGPT desde una mirada amplia. Pedir al aprendiz que identifique simplificaciones y restituya matices convierte la comprensión en una práctica de elaboración que preserva complejidad en lugar de reducirla prematuramente didácticamente.

También conviene diferenciar comprensión asistida de comprensión transferible. Durante una conversación generativa, una persona puede seguir argumentos sofisticados gracias a preguntas sucesivas y apoyos inmediatos. La prueba aparece cuando debe explicar la misma relación desde otra perspectiva o reconocerla bajo una formulación nueva. Wu y Yu (2023) reportan en su metaanálisis efectos favorables de chatbots sobre resultados

de aprendizaje. Tales beneficios requieren tareas que permitan comprobar apropiación conceptual más allá del intercambio con la herramienta.

Evaluar comprensión requiere entonces observar transformaciones y no productos lingüísticos aislados. Una tarea puede presentar dos explicaciones generadas con diferencias sutiles y solicitar una comparación razonada. Otra puede exigir reconstruir un concepto para públicos distintos sin perder precisión disciplinar. Nguyen et al. (2024) identifican patrones diversos de colaboración humano-IA en escritura académica. Tales hallazgos refuerzan la necesidad de atender decisiones, revisiones y justificaciones mediante las cuales el aprendiz convierte apoyo generativo en elaboración cognitiva propia.

Dentro de una taxonomía renovada, comprender deja de ocupar un peldaño definido por resumir o interpretar información disponible. Su núcleo pasa a ser la capacidad de producir significado mediante explicación, contraste y reconstrucción bajo condiciones de abundancia generativa. Esa tríada permite reconocer comprensión cuando el lenguaje puede ser producido externamente con facilidad. El aprendizaje se hace visible en la reorganización conceptual que una persona sostiene, justifica y transfiere aun cuando la mediación deja de acompañarla.

2.3. Aplicar con asistencia algorítmica y transferencia situada

Aplicar deja de significar la ejecución mecánica de un procedimiento conocido cuando un sistema generativo puede proponer pasos, completar operaciones y producir soluciones plausibles. El nivel cognitivo se desplaza hacia la capacidad de seleccionar recursos, adaptar procedimientos y actuar bajo condiciones particulares sin perder control intelectual. Chen et al. (2020) señalan brechas entre tecnología y fundamentos educativos

de la inteligencia artificial. La aplicación requiere demostrar que la asistencia amplía la acción sin reemplazar el dominio.

La asistencia algorítmica modifica la relación entre saber un procedimiento y llevarlo a cabo. Un aprendiz puede solicitar código, fórmulas, protocolos o secuencias operativas y obtener una respuesta funcional. Sin embargo, ejecutar mediante apoyo no equivale necesariamente a dominar la acción. Kung et al. (2023) mostraron un desempeño notable de ChatGPT en preguntas del ámbito médico. Ese rendimiento obliga a distinguir con cuidado la capacidad del sistema y la competencia atribuible a quien lo utiliza.

Aplicar con competencia implica decidir cuándo aceptar una propuesta generada, cuándo modificarla y cuándo prescindir de ella. Cada decisión demanda reconocer las condiciones del problema y vincularlas con principios previamente comprendidos. La herramienta puede acelerar operaciones rutinarias, pero la responsabilidad cognitiva permanece en la elección del procedimiento pertinente. En términos educativos, la evidencia ya no puede limitarse al producto obtenido. Debe revelar las decisiones que conectan conocimiento disciplinar, asistencia disponible y acción ejecutada con sentido.

La transferencia situada introduce una exigencia adicional: emplear lo aprendido ante variaciones que alteran datos, restricciones, destinatarios o propósitos. Cooper (2023) observó capacidades de ChatGPT para responder cuestiones científicas junto con limitaciones que reclaman vigilancia educativa. Una aplicación transferible requiere advertir cuándo una solución generada pierde pertinencia al cambiar las condiciones. El aprendiz competente no traslada respuestas intactas; ajusta principios y procedimientos según las particularidades de cada situación concreta sin abandonar criterios disciplinares previamente adquiridos.

La mediación generativa puede convertirse en andamiaje cuando acompaña una ejecución que permanece intelectualmente dirigida por el aprendiz. Pedir alternativas, solicitar comprobaciones o ensayar variaciones permite ampliar el espacio de actuación. Abd-alrazaq et al. (2023) describen oportunidades de los grandes modelos lingüísticos para la educación médica junto con riesgos y necesidades formativas. El valor pedagógico aparece cuando la interacción fortalece juicio operativo y permite actuar posteriormente con apoyos distintos, reducidos o ausentes ante problemas comparables.

Una tarea de aplicación debería incorporar fricción suficiente para impedir que la respuesta generada cierre prematuramente el problema. Puede requerir adaptar una solución a recursos limitados, justificar cambios frente a una restricción inesperada o ejecutar nuevamente el procedimiento bajo condiciones diferentes. Meskó (2023) destaca la ingeniería de instrucciones como habilidad relevante para profesionales médicos que trabajan con modelos generativos. Formular buenas peticiones importa, aunque aplicarlas exige interpretar sus resultados y asumir responsabilidad sobre la ejecución.

La transferencia también permite observar dónde termina la ayuda y dónde comienza la competencia personal. Si una persona resuelve una tarea con un asistente, conviene introducir después una variante que altere elementos relevantes o limite determinadas funciones del sistema. Wu y Yu (2024) encontraron efectos positivos de los chatbots sobre resultados de aprendizaje mediante un metaanálisis. Tales resultados adquieren mayor significado pedagógico cuando pueden mantenerse frente a situaciones nuevas sin depender del mismo soporte tecnológico.

En disciplinas profesionales, aplicar implica además atender consecuencias que trascienden la corrección técnica inmediata. Una recomendación generada puede ser viable y aun resultar inadecuada por razones éticas, comunicativas o

procedimentales. Lee (2023) examina posibilidades de ChatGPT en educación médica y plantea consideraciones ligadas a su incorporación formativa. La transferencia situada demanda integrar saber disciplinar con juicio práctico. Actuar bien requiere comprender qué procedimiento conviene, bajo qué condiciones y con qué responsabilidad ante los otros actores.

La evaluación de la aplicación necesita registrar procesos que antes podían permanecer implícitos. Resulta pertinente observar qué parte resolvió el aprendiz, qué delegó al sistema, qué modificaciones introdujo y mediante qué criterios validó el resultado. Tlili et al. (2023) muestran que ChatGPT reúne oportunidades educativas y riesgos que requieren una aproximación equilibrada. Documentar la interacción permite valorar competencia distribuida sin confundir productividad asistida con dominio transferible ni convertir la ausencia de herramientas en criterio universal.

Dentro de la taxonomía renovada, aplicar representa convertir conocimiento comprendido en acción pertinente mientras se regula la participación algorítmica. Su nivel de logro aumenta cuando la persona puede adaptar procedimientos, justificar decisiones y transferir principios hacia situaciones diferentes. La asistencia deja de ser un indicador de menor competencia por sí. La cuestión reside en quién gobierna la ejecución intelectual y si el aprendizaje conserva plena eficacia cuando cambian la tarea, los recursos o las condiciones.

2.4. Analizar outputs generativos como objetos epistemológicos

Analizar adquiere una densidad distinta cuando los productos generativos dejan de tratarse como respuestas terminadas y pasan a examinarse como objetos epistemológicos. Cada output contiene afirmaciones, relaciones, omisiones y grados variables de plausibilidad que requieren descomposición

intelectual. La tarea analítica consiste en reconocer la arquitectura del contenido producido, rastrear sus premisas y distinguir evidencia de formulación persuasiva. El estudiante ya no observa únicamente qué dice la máquina, sino desde qué bases puede sostenerse lo dicho.

Tal desplazamiento demanda separar fluidez lingüística y validez del conocimiento. Los modelos pueden articular explicaciones convincentes sin mantener una relación verificable con las fuentes que permitirían fundamentarlas. Cooper (2023) documentó capacidades de ChatGPT en educación científica junto con limitaciones asociadas a exactitud y referencias. Analizar una producción generativa requiere entonces desarmar su apariencia de unidad para localizar afirmaciones comprobables, inferencias discutibles y vacíos que una redacción elegante puede volver menos perceptibles durante la lectura académica.

Considerar el output como objeto epistemológico implica preguntar por las condiciones de producción del conocimiento presentado. No basta identificar errores manifiestos. Interesa examinar qué autoridad parece asumir el texto, qué relaciones causales propone y qué elementos permanecen fuera de la respuesta. Chen et al. (2020) señalaron brechas entre aplicaciones educativas de inteligencia artificial y sus fundamentos teóricos. Tal distancia invita a convertir cada producción algorítmica en material susceptible de interrogación disciplinar crítica sistemática y argumentada.

La descomposición analítica puede comenzar por unidades pequeñas y avanzar hacia relaciones de mayor alcance. Una afirmación se examina por su precisión; un argumento, por la conexión entre premisas y conclusiones; una explicación, por su capacidad para representar adecuadamente el fenómeno estudiado. Holmes y Tuomi (2022) distinguen funciones atribuidas a la inteligencia artificial educativa. Esa diversidad recuerda que el

análisis debe atender tanto al contenido generado como a la función cognitiva delegada durante su producción.

Otra dimensión reside en rastrear ausencias. Los sistemas generativos responden a partir de patrones aprendidos y de instrucciones formuladas por quien consulta. Por ello, aquello que no aparece puede resultar tan informativo como aquello que ocupa la superficie textual. Analizar implica localizar perspectivas omitidas, categorías insuficientemente diferenciadas y relaciones que fueron simplificadas. La ausencia deja de ser un vacío cuando afecta la interpretación. Se convierte en evidencia para examinar los límites epistémicos de la producción.


En campos profesionales, el análisis de outputs demanda especial atención porque una formulación plausible puede orientar decisiones posteriores. Abd-alrazaq et al. (2023) describen oportunidades de los grandes modelos lingüísticos en educación médica junto con riesgos relacionados con información inexacta y sesgos. La actividad formativa puede presentar respuestas generadas para que el alumnado identifique supuestos, clasifique afirmaciones según su verificabilidad y determine qué elementos requieren respaldo externo antes de incorporarlos a una decisión disciplinar clínica responsable.

El análisis también alcanza la procedencia del contenido. Un modelo puede ofrecer referencias inexistentes, atribuciones imprecisas o síntesis cuya genealogía documental permanece opaca. Kung et al. (2023) mostraron que ChatGPT alcanzó resultados destacados en evaluaciones médicas, aunque su desempeño no equivale a transparencia epistemológica. Frente a ello, analizar requiere diferenciar respuesta correcta, justificación suficiente y trazabilidad. Las tres dimensiones pueden coincidir, pero ninguna garantiza automáticamente la presencia de las otras en una producción algorítmica dada.

La comparación entre outputs abre otra vía formativa. Variar una instrucción, cambiar un término o solicitar perspectivas contrapuestas permite observar desplazamientos en énfasis y argumentación. O'Connor y ChatGPT (2023) plantean interrogantes sobre el uso académico de plataformas de inteligencia artificial en educación de enfermería. Comparar versiones ayuda a reconocer que la respuesta generada no constituye una representación neutral del conocimiento. Cada versión puede revelar dependencias respecto de la formulación empleada y decisiones probabilísticas del sistema.

Figura 6

Análisis epistemológico de outputs generativos



Evaluar el nivel analítico exige mirar operaciones realizadas sobre el output y no la mera detección de fallos. Un estudiante puede señalar una inexactitud por intuición o azar sin comprender su origen. Mayor profundidad aparece cuando clasifica componentes, establece relaciones y explica por qué una afirmación modifica el sentido del conjunto. Lee (2023) examina posibilidades educativas de ChatGPT en medicina. Su incorporación formativa

reclama actividades donde la producción generativa sea interrogada con criterios disciplinares explícitos.

En la taxonomía renovada, analizar significa abrir la producción generativa para revelar su estructura epistemológica. La competencia se manifiesta cuando quien aprende distingue afirmaciones de evidencias, identifica relaciones internas y reconoce silencios. También cuando rastrea procedencia y detecta dependencias entre instrucciones y respuestas. El output deja de ocupar el lugar de solución para convertirse en material de examen. Tal giro prepara el paso hacia operaciones de juicio donde verificar, valorar y calibrar confianza adquirirán protagonismo.

2.5. Evaluar la IA: juicio crítico, evidencia y calibración de confianza

Evaluar la inteligencia artificial representa un cambio cualitativo dentro de la progresión cognitiva. Tras descomponer un output y reconocer su arquitectura epistemológica, corresponde emitir juicios fundamentados sobre calidad, pertinencia y confiabilidad. La evaluación ya no recae únicamente sobre una respuesta académica producida por otra persona. También alcanza sistemas capaces de formular argumentos convincentes con velocidad extraordinaria. Ng et al. (2021) vinculan la alfabetización en IA con capacidades críticas necesarias para comprender y valorar sus resultados.

El juicio crítico comienza donde termina la aceptación intuitiva. Una respuesta generativa puede parecer correcta por su claridad, extensión o seguridad retórica, aunque tales rasgos no constituyen evidencia. Jakesch et al. (2023) encontraron que las heurísticas humanas para reconocer lenguaje generado por IA presentan limitaciones. La apariencia verbal pierde entonces valor como criterio suficiente. Evaluar requiere formular preguntas verificables, identificar estándares disciplinares y establecer

razones explícitas antes de conceder credibilidad a una afirmación producida algorítmicamente.

La evidencia ocupa una posición central porque permite transformar impresión en juicio justificable. Evaluar una producción generativa demanda contrastar afirmaciones con fuentes pertinentes, examinar consistencia interna y valorar la suficiencia del respaldo disponible. Laupichler et al. (2022) relacionan la alfabetización en inteligencia artificial con conocimientos y competencias que permiten interactuar críticamente con tales sistemas. Desde una perspectiva educativa, verificar no constituye una operación accesorio. Es parte del aprendizaje cuando la información llega acompañada de incertidumbre.

Calibrar confianza añade una exigencia más fina. No toda respuesta merece aceptación plena ni rechazo absoluto. Entre ambos extremos existe un rango de confianza que debe ajustarse según evidencia, dominio disciplinar y consecuencias de una decisión. Díaz-Rodríguez et al. (2023) articulan principios éticos y requisitos vinculados con inteligencia artificial confiable. Para quien aprende, calibrar significa reconocer grados de certeza y modificar su confianza cuando aparecen datos nuevos, contradicciones o límites previamente inadvertidos durante la evaluación.

La confianza excesiva puede convertir eficiencia en dependencia intelectual. La desconfianza indiscriminada produce el efecto contrario y desaprovecha apoyos valiosos. Evaluar competentemente exige evitar ambos extremos mediante criterios que varían según la tarea. Yan et al. (2023) identifican problemas éticos asociados con grandes modelos lingüísticos en educación. Tal panorama reclama usuarios capaces de decidir qué aceptar, qué verificar con mayor profundidad y qué descartar cuando la incertidumbre supera los márgenes admisibles para una decisión responsable.

El error generativo posee valor pedagógico cuando se convierte en materia de juicio. Presentar respuestas parcialmente correctas permite pedir al alumnado que localice afirmaciones problemáticas, reúna evidencia y determine la gravedad de cada falla. Guo y Lee (2023) examinan el potencial de ChatGPT para favorecer pensamiento crítico mediante actividades. La riqueza de la tarea reside menos en encontrar una equivocación que en justificar por qué importa y qué consecuencias tendría mantenerla dentro de una argumentación.

En ámbitos de alto impacto, calibrar confianza demanda criterios rigurosos. Hager et al. (2024) evaluaron limitaciones de grandes modelos lingüísticos en decisiones clínicas y analizaron estrategias de mitigación. Una respuesta técnicamente plausible puede resultar insuficiente cuando sus consecuencias afectan bienestar, derechos o decisiones profesionales. La formación necesita enseñar a graduar exigencias de verificación según el riesgo implicado. Cuanto mayor sea el costo potencial del error, mayor deberá ser la calidad de evidencia requerida para actuar.

Evaluar también involucra también dimensiones éticas que exceden la exactitud factual. Una producción puede contener información correcta y resultar problemática por sesgo, opacidad o tratamiento inadecuado de intereses humanos. Nguyen et al. (2022) organizaron principios éticos para la inteligencia artificial educativa y destacaron preocupaciones recurrentes en su adopción. El juicio académico necesita integrar precisión, equidad y responsabilidad. Valorar una respuesta implica considerar aquello que afirma junto con los efectos derivados de utilizarla en decisiones reales.

La evaluación formativa puede hacer visible la calibración mediante registros de confianza. Antes de verificar una respuesta, el estudiante asigna un grado de credibilidad y explica sus razones. Después consulta evidencia y revisa su valoración. Tam et al. (2024) proponen un marco para evaluación humana de grandes modelos

lingüísticos en salud basado en literatura. Comparar juicio inicial y juicio revisado permite observar aprendizaje epistémico: no basta acertar; importa ajustar racionalmente la confianza ante evidencia disponible.

En la taxonomía renovada, evaluar la IA significa ejercer autoridad epistémica sobre una producción que puede superar al aprendiz en fluidez o amplitud informativa. La competencia aparece al establecer criterios, buscar evidencia y graduar confianza sin delegar el juicio. Walter (2024) vincula alfabetización en IA, ingeniería de instrucciones y pensamiento crítico dentro de la educación. Evaluar ocupa entonces una posición: convierte la interacción generativa en una relación gobernada por razones y no por deferencia automática.

2.6. Crear después de la generación automática

Crear después de la generación automática exige redefinir la autoría como capacidad para orientar, transformar y responder por una obra. Producir algo nuevo ya no comienza necesariamente ante una página vacía. Puede iniciarse frente a materiales propuestos por un sistema. La exigencia cognitiva reside entonces en formular una intención, reconocer posibilidades y descartar caminos previsibles. El acto creativo conserva su valor cuando las decisiones humanas gobiernan la dirección, el sentido y la pertinencia del producto.

La abundancia de propuestas generadas modifica el punto de partida de la creación. Tener diez alternativas disponibles en segundos facilita la ideación, aunque también puede estrechar el horizonte si todas proceden de patrones semejantes. Doshi y Hauser (2024) encontraron que la IA generativa puede aumentar la creatividad individual mientras reduce la diversidad colectiva de contenidos novedosos. Crear requiere, por tanto, resistir la comodidad de la primera respuesta y buscar diferencias que expresen intención intelectual propia.

La autoría adquiere profundidad cuando el aprendiz interviene sobre lo generado en lugar de limitarse a seleccionarlo. Puede combinar fragmentos, alterar estructuras, introducir restricciones o abandonar por completo una propuesta inicial. Kim et al. (2022) destacan la importancia de diseñar formas de colaboración entre estudiantes e inteligencia artificial que preserven participación activa. Desde esa perspectiva, crear significa ejercer dirección sobre un proceso distribuido y mantener capacidad para explicar cada decisión incorporada deliberadamente al producto resultante.

La creatividad mediada requiere momentos de distancia respecto del asistente. Pensar antes de solicitar alternativas permite formar orientación que después puede confrontarse con propuestas algorítmicas. Chang et al. (2023) vinculan el diseño de chatbots educativos con autorregulación, establecimiento de metas y retroalimentación. Una meta formulada por quien aprende actúa como criterio de selección. Sin ella, la generación abundante puede convertir la actividad creadora en navegación entre opciones atractivas pero escasamente vinculadas con una intención personal.

Crear también implica revisar la relación entre originalidad y transformación. Ninguna producción adquiere valor educativo por presentar rasgos novedosos de manera superficial. La novedad necesita responder a un propósito, reorganizar elementos con sentido y mostrar decisiones reconocibles. Barrett y Pack (2023) documentan percepciones diversas de docentes y estudiantes ante la IA generativa durante la escritura. Tales percepciones permiten advertir que la autoría se negocia mediante grados distintos de intervención, apropiación y responsabilidad intelectual y situada.

La retroalimentación algorítmica puede ampliar el proceso creador cuando funciona como interlocución y no como mandato. Escalante et al. (2023) encontraron que estudiantes valoran comentarios generados por IA en tareas de escritura, aunque su aprovechamiento depende de la interacción con tales

observaciones. Quien crea necesita decidir qué comentario acepta, cuál modifica y cuál rechaza. Cada elección reabre el producto y obliga a defender una orientación propia razonada frente a recomendaciones formuladas con aparente seguridad verbal.

En escritura académica, la generación automática vuelve especialmente visible la diferencia entre producir texto y construir una contribución. Song y Song (2023) reportaron mejoras vinculadas con ChatGPT en habilidades y motivación de estudiantes de inglés como lengua extranjera. El rendimiento textual puede beneficiarse del apoyo, pero la creación académica demanda algo adicional de fondo: articular una pregunta, organizar una posición y desarrollar una voz capaz de sostener decisiones más allá de la corrección formal obtenida.

La coautoría humano máquina introduce grados de participación que conviene hacer visibles. Nguyen et al. (2024) identifican patrones diferentes de colaboración durante la escritura académica asistida por inteligencia artificial. Una taxonomía renovada necesita distinguir entre aceptar, editar, recombinar y dirigir conceptualmente. Las cuatro acciones pueden producir documentos competentes, aunque representan inversiones cognitivas distintas. Crear alcanza mayor densidad cuando el aprendiz establece propósito, estructura y criterios mientras utiliza la generación como material transformable bajo su dirección.

Evaluar la creación requiere observar huellas del proceso y no únicamente la calidad aparente del producto. Versiones intermedias, decisiones descartadas y justificaciones permiten reconstruir la contribución intelectual del aprendiz. Banihashem et al. (2024) compararon retroalimentación producida por pares y por IA en escritura de ensayos, mostrando diferencias relevantes entre fuentes. Tales evidencias invitan a valorar la creación mediante trazas que revelen apropiación, revisión y capacidad para convertir apoyos externos en decisiones expresivas propias de autoría.

Dentro de la taxonomía renovada, crear ya no ocupa la cima por equivaler a producir un artefacto desde cero. Su complejidad reside en ejercer agencia creadora cuando generar contenido dejó de ser una barrera técnica significativa. La competencia se reconoce al concebir propósitos, provocar variaciones, seleccionar con criterio y transformar materiales hasta alcanzar una configuración defendible. Crear después de la automatización significa aportar dirección intelectual donde la máquina aporta posibilidades, sin confundir abundancia con originalidad.

Tabla 2

Reconfiguración de los niveles cognitivos en interacción con inteligencia artificial generativa

Nivel cognitivo reconfigurado	Sentido formativo en interacción con IA generativa
Recordar en la era de la recuperación generativa	La memoria funciona como base interna para reconocer información pertinente y detectar inconsistencias. Permite orientar consultas y sostener decisiones intelectuales sin convertir la recuperación automatizada en sustituto del conocimiento disponible.
Comprender mediante explicación, contraste y reconstrucción conceptual	La comprensión se evidencia al explicar relaciones con elaboración propia. También requiere contrastar perspectivas y reconstruir significados después de interactuar con producciones generativas. La fluidez verbal del sistema no equivale a apropiación conceptual por parte del aprendiz.
Aplicar con asistencia algorítmica y transferencia situada	La aplicación implica seleccionar procedimientos y adaptarlos ante condiciones particulares. El aprendiz regula la asistencia recibida y justifica sus decisiones. La transferencia adquiere relevancia cuando puede actuar ante variaciones de la tarea con apoyos distintos o reducidos.

Nivel cognitivo reconfigurado	Sentido formativo en interacción con IA generativa
Analizar outputs generativos como objetos epistemológicos	El análisis convierte la producción algorítmica en objeto de examen. Requiere distinguir afirmaciones y evidencias. También demanda identificar premisas, omisiones y relaciones internas. La atención se dirige hacia la estructura epistemológica que sostiene la respuesta y hacia sus posibles límites.
Evaluar la IA mediante juicio crítico, evidencia y calibración de confianza	La evaluación exige establecer criterios antes de conceder credibilidad a una producción generativa. El aprendiz contrasta afirmaciones con evidencia pertinente y gradúa su confianza según la calidad del respaldo. También considera el riesgo asociado con aceptar información incorrecta.
Crear después de la generación automática	La creación se redefine mediante agencia y dirección intelectual. El valor formativo reside en formular propósitos y provocar variaciones. También importa seleccionar alternativas y transformar materiales generados. La autoría se reconoce en las decisiones que dan sentido al producto y permiten responder por él.

Nota. La tabla presenta la reconfiguración de los seis niveles cognitivos abordados en el capítulo. La progresión desplaza el énfasis desde la ejecución observable hacia la agencia del aprendiz, la regulación de la asistencia algorítmica y la responsabilidad epistémica. En escenarios mediados por inteligencia artificial generativa, el nivel cognitivo depende tanto de la tarea realizada como de las operaciones intelectuales que permanecen bajo dirección humana.

Capítulo III

Nueva taxonomía de la cognición humano-IA

La presencia de inteligencia artificial generativa en la educación altera una pregunta que durante décadas pareció relativamente estable: ¿qué significa pensar cuando parte del trabajo intelectual puede realizarse con una máquina? La cuestión rebasa el dominio técnico. Afecta la manera de comprender aprendizaje, autoría y competencia. Holmes y Tuomi (2022) plantean que la inteligencia artificial educativa obliga a reconsiderar relaciones entre tecnología y pedagogía. Desde ahí nace la necesidad de revisar nuestras categorías cognitivas habituales.

Las taxonomías educativas han permitido ordenar procesos mentales mediante niveles, verbos y resultados esperados. Sin embargo, los sistemas generativos introducen una variable difícil de contener dentro de clasificaciones centradas enteramente en el individuo. Una tarea puede conservar el mismo verbo y cambiar profundamente su exigencia intelectual según la participación algorítmica. Giannakos et al. (2024) destacan la necesidad de comprender las relaciones entre inteligencia artificial y aprendizaje atendiendo tanto a oportunidades educativas como a posibles efectos cognitivos.

El problema adquiere mayor nitidez cuando dos estudiantes entregan productos comparables mediante procesos intelectuales muy diferentes. Uno puede haber elaborado argumentos, contrastado fuentes y utilizado la IA para ampliar alternativas. Otro puede haber transferido buena parte de tales operaciones al modelo. El resultado visible dice poco acerca de esa diferencia. Kim et al. (2022) muestran que la colaboración entre personas e inteligencia artificial requiere comprender la distribución de funciones. Importa saber quién realizó cognitivamente cada parte.

Por ello, una taxonomía destinada a escenarios generativos necesita desplazar la mirada desde el verbo aislado hacia la arquitectura de la actividad intelectual. Recordar, analizar o crear

continúan siendo operaciones relevantes. Lo novedoso reside en que pueden ejecutarse bajo configuraciones diversas de participación humana y algorítmica. Kasneci et al. (2023) advierten que los grandes modelos lingüísticos ofrecen oportunidades educativas junto con riesgos relacionados con dependencia y fiabilidad. La mediación modifica la naturaleza del desempeño observado.

Figura 7
Nueva taxonomía de la cognición humano-IA



Dicha transformación tampoco autoriza a interpretar toda asistencia como pérdida cognitiva. Una herramienta puede liberar recursos, ofrecer perspectivas inesperadas o facilitar operaciones que permiten dedicar mayor atención a decisiones complejas. Doshi y Hauser (2024) encontraron que la inteligencia artificial generativa puede favorecer ciertos resultados creativos individuales aunque también afecte la diversidad de las producciones. La cuestión educativa exige abandonar respuestas binarias. Entre rechazo y aceptación existe un amplio territorio de relaciones cognitivas que merece diferenciación conceptual.

Dentro de ese territorio, la agencia adquiere especial relevancia. El estudiante puede iniciar una tarea por cuenta propia, apoyarse en el modelo, conversar con él, transferir determinadas operaciones o examinar críticamente sus respuestas. Cada configuración moviliza responsabilidades distintas. Darvishi et al. (2024) relacionan la asistencia mediante inteligencia artificial con la agencia estudiantil y muestran que el diseño de la interacción importa para el aprendizaje. Pensar con IA implica decidir también quién conduce cada momento del proceso.

A la agencia se añade una cuestión menos visible: la distribución del esfuerzo. No toda dificultad merece preservarse ni toda facilidad representa progreso. Ciertas fricciones obligan a recuperar conocimientos, formular hipótesis o sostener incertidumbre antes de recibir ayuda. Fan et al. (2024) encontraron indicios de pereza metacognitiva asociada con formas de asistencia generativa. La educación necesita distinguir entre descarga funcional y desplazamiento de operaciones formativas. Ahorrar esfuerzo adquiere sentido cuando no empobrece aquello que debe aprenderse.

Otro cambio afecta la relación con el conocimiento producido. Una respuesta generada puede ser fluida y persuasiva sin ofrecer garantías equivalentes de precisión. En consecuencia, recibir información deja de bastar. Hace falta juzgarla. Ng et al. (2021) vinculan la alfabetización en inteligencia artificial con capacidades de comprensión y evaluación crítica de tales sistemas. La competencia educativa incorpora entonces vigilancia epistémica: contrastar evidencias, reconocer límites y mantener responsabilidad sobre aquello que se acepta como válido.

La relación humano-IA también reclama una mirada reflexiva sobre su propio funcionamiento. Con el uso reiterado aparecen hábitos: consultar demasiado pronto, delegar ciertas tareas, confiar más de lo conveniente o recurrir al modelo cuando una pausa intelectual sería formativa. Xu et al. (2025) muestran que

el apoyo metacognitivo puede fortalecer procesos de autorregulación en ambientes generativos. Aprender con IA requiere percibir tales patrones y modificarlos cuando dejan de servir a los propósitos formativos perseguidos.

A partir de esas tensiones, el capítulo propone una nueva taxonomía de la cognición humano-IA articulada mediante seis configuraciones relacionadas pero distinguibles: autónoma, aumentada, dialógica, delegada, supervisora y metagenerativa. No constituyen una escalera rígida ni una secuencia obligatoria. Funcionan como lentes para reconocer dónde reside la iniciativa y qué papel ocupa la máquina. Yan et al. (2024) reclaman una comprensión equilibrada de las posibilidades y riesgos generativos. Clasificar permitirá diseñar experiencias educativas con mayor precisión.

3.1. Cognición autónoma: pensar antes de consultar a la IA

La cognición autónoma designa la capacidad de elaborar respuesta propia antes de recurrir a sistemas generativos. No implica rechazo tecnológico ni nostalgia por prácticas previas. Expresa una decisión pedagógica: preservar un momento de elaboración interna donde el aprendiz recupera saberes, formula hipótesis y reconoce vacíos. Pensar primero convierte la consulta posterior en un acto intencional. La herramienta deja de inaugurar el razonamiento y pasa a intervenir cuando existe una posición intelectual desde la cual dialogar.

Ese momento previo cumple una función formativa que suele pasar inadvertida. Cuando una respuesta algorítmica aparece pronto, puede ocupar el espacio donde habría ocurrido la búsqueda mental, la duda productiva o el ensayo de una explicación. Dar tiempo al pensamiento propio protege tales operaciones. Fan et al. (2024) advierten que la asistencia generativa puede asociarse con pereza metacognitiva cuando desplaza procesos de regulación. La

autonomía comienza, entonces, con demora deliberada frente a la respuesta disponible.

La demora no debe confundirse con prohibición. Su valor reside en ordenar la secuencia cognitiva para que la persona llegue a la IA con una idea inicial, aunque incompleta. Un borrador mental permite comparar, discrepar y preguntar con precisión. Chang et al. (2023) vinculan el aprendizaje autorregulado con metas, retroalimentación y personalización. Desde esa perspectiva, pensar antes de consultar favorece que la interacción responda a propósitos definidos por el aprendiz y no por la herramienta.

Una taxonomía orientada a escenarios humano-IA necesita distinguir entre producir pensamiento y administrar respuestas disponibles. La cognición autónoma pertenece al primer ámbito: exige activar conocimientos sin apoyo generativo inmediato y sostener provisionalmente una interpretación propia. Tal exigencia ofrece una referencia para reconocer qué aporta después la máquina. Sin una producción previa, resulta difícil identificar si hubo ampliación, sustitución o mera aceptación. La autonomía proporciona entonces un punto de comparación interno para valorar la contribución algorítmica.

También importa la calidad de la pregunta que nace antes del prompt. Quien intenta resolver un problema por cuenta propia descubre incertidumbres que una consulta inmediata podría ocultar. Ese descubrimiento modifica la relación con la IA: ya no se pide una respuesta indiferenciada, sino ayuda sobre una dificultad reconocida. Darvishi et al. (2024) analizan la asistencia artificial en relación con la agencia estudiantil. Tal vínculo invita a preservar decisiones intelectuales antes de cualquier intervención automatizada posterior.

En términos didácticos, pensar primero puede materializarse mediante predicciones, explicaciones preliminares, mapas conceptuales o soluciones tentativas breves. Lo relevante no

es el formato, sino la existencia de una huella cognitiva anterior a la consulta. Esa huella permite al docente observar razonamientos que quedarían invisibles tras una respuesta generada. Liu et al. (2021) muestran el valor de mecanismos que promueven pensamiento reflexivo en entornos apoyados por inteligencia artificial. La autonomía requiere oportunidades concretas para hacerse observable.

La cognición autónoma también preserva la experiencia del error propio. Equivocarse antes de recibir asistencia permite advertir límites, revisar intuiciones y reconocer por qué una alternativa resulta insuficiente. Si la solución aparece al comienzo, ese trabajo puede quedar cancelado. Essel et al. (2024) examinan efectos de respuestas instantáneas de modelos conversacionales sobre habilidades cognitivas universitarias. La cuestión pedagógica no consiste en negar rapidez, sino en decidir cuándo conviene introducirla prudentemente dentro del proceso de aprendizaje.

Pensar antes de consultar adquiere relevancia cuando el estudiante enfrenta tareas abiertas. En ellas no existe una ruta única y la primera formulación condiciona decisiones posteriores. Una posición inicial ayuda a conservar autoría intelectual frente a propuestas convincentes. Wei (2023) relaciona el uso educativo de inteligencia artificial con aprendizaje autorregulado y motivación. La autonomía, desde tal mirada, se expresa cuando la persona mantiene capacidad de orientar su actividad aun cuando dispone de asistencia potente.

La frontera entre apoyo y sustitución depende de la presencia de IA que del momento en que interviene. Una consulta posterior al esfuerzo inicial puede ampliar nuevas perspectivas, ofrecer contraste y revelar alternativas. Una consulta prematura puede fijar el marco desde el cual se piensa. Li et al. (2024) comparan apoyos humanos y ChatGPT atendiendo pensamiento crítico, desempeño y carga cognitiva. Sus resultados refuerzan

examinar toda arquitectura pedagógica de la asistencia, no únicamente su disponibilidad.

Dentro de la nueva taxonomía, la cognición autónoma funciona como condición de partida para relaciones exigentes con sistemas generativos. Primero se produce una voz propia; después se abre el intercambio con una voz algorítmica. Xu et al. (2025) destacan el papel del apoyo metacognitivo en ambientes de IA generativa y aprendizaje autorregulado. La secuencia importa porque conserva mayor iniciativa intelectual. Pensar antes de preguntar no reduce el potencial tecnológico: crea condiciones para usarlo con propósito y discernimiento.


3.2. Cognición aumentada: ampliar capacidades sin sustituir el razonamiento

La cognición aumentada describe una relación en la que la inteligencia artificial extiende posibilidades intelectuales sin ocupar el lugar del juicio humano. Tras formular una base, el aprendiz incorpora recursos generativos para ampliar perspectivas, contrastar argumentos o acceder a representaciones alternativas. La ganancia cognitiva no proviene de recibir más información, sino de trabajar mejor con ella. Holmes y Tuomi (2022) sitúan la IA educativa como mediación cuyo valor depende de decisiones pedagógicas deliberadas y humanas.

Aumentar una capacidad implica conservar la operación intelectual que se pretende fortalecer. Si una herramienta propone ejemplos, el aprendiz todavía debe examinarlos; si ofrece explicaciones, necesita relacionarlas con conocimientos previos; si genera alternativas, corresponde valorar su pertinencia. Kim et al. (2022) destacan que la colaboración entre estudiantes e inteligencia artificial requiere diseños donde las funciones de cada participante estén diferenciadas. La ampliación ocurre cuando la máquina ensancha el campo de acción sin clausurar la actividad.

La diferencia entre asistencia y reemplazo puede observarse en quién conserva las decisiones de mayor densidad cognitiva. Una persona puede pedir a un modelo que reorganice información abundante y mantener para sí la interpretación de relaciones, causas o implicaciones. Kasneci et al. (2023) señalan oportunidades educativas de los modelos lingüísticos junto con riesgos vinculados a dependencia y errores. La cognición aumentada requiere, por ello, una distribución del trabajo donde eficiencia y responsabilidad intelectual permanezcan separadas.

Figura 8
Cognición aumentada y ampliación del razonamiento



Hay tareas cuya complejidad excede temporalmente los recursos disponibles del aprendiz. Allí la IA puede funcionar como apoyo para sostener operaciones que antes demandaban tiempo o experiencia técnica. Noy y Zhang (2023) encontraron mejoras de productividad en tareas profesionales realizadas con inteligencia artificial generativa. En educación, aquella ventaja adquiere sentido cuando el tiempo liberado se reinvierte en interpretar, argumentar, revisar o crear. Ganar velocidad carece de valor formativo cuando también desaparece el esfuerzo intelectual relevante.

La ampliación cognitiva posee además una dimensión dialógica. Interrogar una respuesta generada, pedir otra perspectiva o confrontar explicaciones convierte al modelo en contraparte del pensamiento. Guo y Lee (2023) vinculan ChatGPT con oportunidades para fortalecer pensamiento crítico mediante actividades orientadas al cuestionamiento y la evaluación. La clave reside en evitar que la fluidez verbal sea confundida con autoridad epistémica. Una respuesta convincente puede abrir una investigación, pero no debe cerrar prematuramente la deliberación del aprendiz.

En procesos de escritura, la cognición aumentada resulta visible cuando la asistencia amplía repertorios sin borrar la voz del autor. Un modelo puede ofrecer estructuras, reformulaciones o retroalimentación. La persona decide qué conservar, qué rechazar y por qué. Nguyen et al. (2024) identifican patrones de colaboración humano-IA en escritura académica. Tales hallazgos permiten comprender que usar una misma herramienta no produce una relación cognitiva equivalente: importa la distribución de iniciativa y control en la producción.

La creatividad permite advertir una tensión. Generar muchas alternativas puede expandir el espacio de posibilidades y ayudar a superar bloqueos. Sin embargo, abundancia no equivale necesariamente a diversidad intelectual. Doshi y Hauser (2024) observaron que la IA generativa puede elevar la creatividad individual mientras reduce la diversidad colectiva de los contenidos producidos. Aumentar exige entonces utilizar la generación como material para transformar y combinar, evitando convertir patrones frecuentes del modelo en límites propios para pensar.

Desde una perspectiva, la ampliación requiere que el aprendiz reconozca qué capacidad está potenciando y cuál permanece bajo su responsabilidad. Pedir apoyo sin identificar esa frontera favorece una dependencia difícil. Yan et al. (2024) plantean que la inteligencia artificial generativa ofrece oportunidades para el

aprendizaje humano junto con riesgos que reclaman regulación consciente. Saber cuándo solicitar ayuda importa tanto como saber examinarla. La competencia aumentada combina aprovechamiento instrumental con vigilancia sobre el propio proceso intelectual.

El diseño puede favorecer dicha relación mediante tareas que hagan visible la contribución humana después de cada intervención algorítmica. Comparar versiones, justificar elecciones o explicar modificaciones permite distinguir entre producto generado y aprendizaje construido. Banihashem et al. (2024) muestran que las fuentes de retroalimentación producen experiencias en la escritura académica. Una actividad diseñada no premia la mera incorporación de recomendaciones. Exige evidenciar criterio para seleccionar, adaptar o descartar lo que la IA pone a disposición.

En la taxonomía, la cognición aumentada ocupa un lugar distinto de la autonomía previa como de la delegación de operaciones. Representa una cooperación donde la capacidad permanece activa mientras gana alcance mediante asistencia generativa. Giannakos et al. (2024) destacan la necesidad de orientar la integración educativa de tales sistemas hacia beneficios verificables. El criterio central no es cuánto hace la IA, sino cuánto mejor puede pensar la persona gracias a una interacción que conserva agencia.

3.3. Cognición dialógica: aprender interrogando al modelo

La cognición dialógica entiende la interacción con inteligencia artificial como intercambio orientado a producir comprensión mediante preguntas sucesivas. El aprendiz no entrega su pensamiento al modelo: lo pone en movimiento frente a respuestas que son examinadas, reformuladas o contradichas. A diferencia de la ampliación instrumental, aquí el valor reside en la conversación. Cada intervención abre una posibilidad de revisión.

Preguntar deja de ser un trámite para obtener información y se convierte en operación cognitiva deliberada.

El diálogo adquiere valor educativo cuando la primera respuesta no clausura la indagación. Una explicación puede provocar una réplica, una petición de fundamento o una pregunta dirigida a revelar inconsistencias. Seo et al. (2021) encontraron que la inteligencia artificial modifica las formas de interacción dentro del aprendizaje en línea y puede aportar oportunidades de comunicación. Bajo una perspectiva dialógica, aquella mediación cobra sentido cuando el estudiante conserva iniciativa para conducir el intercambio hacia necesidades intelectuales.

Interrogar bien exige algo más que redactar instrucciones eficaces. Requiere identificar qué se desea comprender, reconocer qué falta en una respuesta y decidir cuál pregunta puede hacer avanzar el razonamiento. Meskó (2023) presenta la ingeniería de prompts como una habilidad relevante para profesionales que interactúan con modelos generativos. En educación, dicha competencia alcanza mayor profundidad cuando formular instrucciones deja paso a encadenar preguntas capaces de precisar conceptos, solicitar razones y poner a prueba afirmaciones reflexivas.

La secuencia de preguntas importa porque cada turno puede modificar la representación mental del problema. Una consulta inicial quizá busque una definición. La siguiente puede pedir relaciones entre conceptos; otra puede introducir una objeción. En ese movimiento, el estudiante reorganiza progresivamente aquello que entiende. El modelo aporta respuestas contingentes al intercambio, pero la dirección intelectual propia permanece vinculada a las decisiones del interlocutor. Aprender dialogando implica construir una trayectoria de indagación, no acumular respuestas aisladas.

También existe una dimensión epistémica en el acto de repreguntar. Los modelos producen lenguaje fluido que puede transmitir una apariencia de certeza mayor que su fundamento. Tlili et al. (2023) describen oportunidades educativas de ChatGPT junto con riesgos asociados a información incorrecta y usos poco reflexivos. Por ello, una conversación formativa necesita preguntas que soliciten justificaciones, fuentes, contraargumentos o límites. La duda razonada transforma la interacción desde recepción pasiva hacia examen activo de lo generado.

La cognición dialógica encuentra una expresión fértil cuando el aprendiz pide al modelo adoptar perspectivas contrapuestas. Una cuestión histórica puede revisarse desde interpretaciones distintas; un problema científico admite hipótesis rivales; una decisión ética puede enfrentarse a objeciones razonables. La conversación adquiere entonces espesor intelectual. No interesa multiplicar voces por ornamentación, sino hacer visibles tensiones que obliguen a precisar criterios. Cada contraste ofrece material para que el estudiante revise argumentos y construya una posición mejor fundamentada.

Conviene distinguir conversación de dependencia conversacional. Encadenar muchos turnos no garantiza aprendizaje si cada pregunta busca que el modelo resuelva la siguiente operación. Wu y Yu (2023), mediante un metaanálisis sobre chatbots educativos, identifican efectos favorables en resultados de aprendizaje bajo determinadas condiciones de uso. La cantidad de interacción, por tanto, ofrece una medida insuficiente. Importa observar qué hace cognitivamente el estudiante entre turnos: interpretar, cuestionar, relacionar, decidir y reformular antes de continuar el diálogo.

Desde la enseñanza, pueden diseñarse intercambios donde cada pregunta deba nacer de una evaluación de la respuesta anterior. El estudiante podría localizar una afirmación discutible, pedir evidencia y luego contrastar la réplica con conocimientos

disciplinares. También puede solicitar una explicación destinada a públicos diferentes para reconocer variaciones conceptuales. Tales prácticas convierten el prompt en parte de una cadena razonada. La calidad del aprendizaje queda vinculada a la profundidad de las decisiones que organizan cada turno.

La conversación con un modelo también puede hacer visible el pensamiento del aprendiz. Las preguntas elegidas revelan qué relaciones reconoce, dónde encuentra incertidumbre y qué criterios utiliza para avanzar. King y ChatGPT (2023) mostraron mediante una conversación académica que el formato dialógico permite poner en escena tensiones relacionadas con autoría, evaluación y uso educativo. Pedagógicamente, registrar secuencias de preguntas ofrece evidencia procesual valiosa: permite atender no únicamente a la respuesta obtenida, sino al razonamiento desplegado.

Dentro de la nueva taxonomía, la cognición dialógica representa una forma de aprendizaje basada en conducción interrogativa de la interacción humano-IA. Su rasgo distintivo no reside en conversar por conversar, sino en utilizar cada turno para transformar la comprensión. El estudiante pregunta, examina y vuelve a preguntar desde una posición renovada. La IA funciona como interlocutor, mientras la responsabilidad epistémica permanece. La calidad cognitiva se reconoce en la evolución de las preguntas y del juicio.

3.4. Cognición delegada: cartografía de lo que el estudiante transfiere a la máquina

La cognición delegada aparece cuando el estudiante transfiere a la inteligencia artificial una operación que podría realizar mediante esfuerzo propio. Tal transferencia no constituye necesariamente una renuncia intelectual. Puede responder a criterios de eficiencia, dificultad o distribución del trabajo. El problema pedagógico comienza al precisar qué actividad fue cedida

y qué capacidad permanece activa. Cartografiar la delegación permite distinguir entre apoyo funcional y desplazamiento cognitivo, una diferencia relevante para interpretar aprendizajes mediados por sistemas generativos.

Delegar admite grados diferentes. Un estudiante puede encargar la corrección formal de un texto mientras conserva la argumentación, o pedir una síntesis y reservarse la valoración de sus implicaciones. Chan y Hu (2023) documentan percepciones estudiantiles donde los beneficios de la IA conviven con inquietudes sobre dependencia y aprendizaje. La pregunta pertinente no consiste en determinar si hubo uso tecnológico, sino en identificar qué operaciones cambiaron de agente durante la actividad y bajo qué propósito.

Una cartografía cognitiva de la delegación necesita atender al tipo de operación transferida. Recuperar datos, resumir materiales, generar ejemplos, organizar ideas o redactar fragmentos comprometen demandas intelectuales distintas. Chiu (2023) advierte que la IA generativa transforma prácticas educativas y obliga a reconsiderar políticas y formas de enseñanza. Desde tal perspectiva, registrar la tarea cedida permite observar de manera qué parte del trabajo intelectual continúa perteneciendo al aprendiz y cuál queda temporalmente confiada al sistema generativo.

La ubicación de la delegación dentro de una tarea importa tanto como su magnitud. Transferir una operación periférica puede liberar recursos para atender decisiones de mayor complejidad. Ceder la formulación del argumento central produce una consecuencia distinta porque desplaza el núcleo formativo. Farrelly y Baker (2023) señalan que la incorporación de IA generativa en educación superior requiere considerar implicaciones pedagógicas y académicas. La delegación debe valorarse según la función cognitiva que ocupa en cada actividad.

También conviene distinguir delegación reversible de delegación habitual. En la primera, el estudiante conserva capacidad para retomar la operación cuando resulta necesario. En la segunda, la práctica reiterada puede reducir oportunidades de ejercitar habilidades que antes formaban parte del aprendizaje. Rahman y Watanobe (2023) describen oportunidades y amenazas educativas asociadas con ChatGPT. Una taxonomía humano-IA necesita registrar no únicamente qué se transfiere, sino con qué frecuencia y bajo qué condiciones se recupera posteriormente dicha función.


La delegación adquiere otra dimensión cuando el estudiante desconoce el procedimiento que entrega a la máquina. Encargar una tarea dominada puede ser una decisión estratégica; encargar aquello que nunca se aprendió puede ocultar una carencia detrás de un producto competente. Romero-Rodríguez et al. (2023) relacionan el uso universitario de ChatGPT con percepciones favorables sobre pensamiento complejo. Sin embargo, el rendimiento visible requiere diferenciarse de forma del dominio personal que permanece disponible sin asistencia tecnológica inmediata.

Desde la evaluación, cartografiar transferencias obliga a mirar más allá del producto académico entregado. Dos textos semejantes pueden provenir de distribuciones cognitivas muy diferentes: uno quizá fue construido por el estudiante con apoyo puntual y otro generado mediante amplias cesiones. La evidencia del proceso cobra entonces valor pedagógico. Borradores, decisiones justificadas y registros de intervención permiten reconstruir quién realizó cada operación. Evaluar aprendizaje requiere reconocer la arquitectura de autoría cognitiva que sostuvo la producción presentada.

La aceptación creciente de herramientas generativas vuelve especialmente importante desarrollar conciencia sobre la propia delegación. Strzelecki (2023) muestra que diversas variables

influyen en la aceptación estudiantil de ChatGPT en educación superior. Adoptar una tecnología, sin embargo, no equivale a comprender qué funciones personales propias modifica su uso. El estudiante necesita reconocer cuándo transfiere memoria, redacción, análisis o decisión. Nombrar esas cesiones favorece una relación más deliberada con la asistencia y permite revisar hábitos antes inadvertidos.

Figura 9
Cognición aumentada y ampliación del razonamiento



La cartografía propuesta puede representarse como un mapa dinámico y no como una frontera fija entre persona y máquina. Una misma operación cambia de agente según la meta, el nivel de dominio o la fase del trabajo. Giannakos et al. (2024) plantean que la integración educativa de IA generativa demanda diseños atentos a sus efectos sobre el aprendizaje. Por ello, delegar debe entenderse como decisión situada cuya conveniencia depende de aquello que se pretende aprender.

Dentro de la nueva taxonomía, la cognición delegada permite nombrar una zona que las categorías tradicionales

difícilmente captaban: el aprendizaje puede involucrar operaciones intelectuales realizadas fuera del estudiante por un agente generativo. Yan et al. (2024) examinan promesas y riesgos de dicha tecnología para el aprendizaje humano. La cuestión taxonómica consiste en determinar qué permanece disponible tras la transferencia. Delegar con criterio exige saber qué entregar, por qué hacerlo y qué capacidad conviene preservar activa.

3.5. Cognición supervisora: verificar, corregir y gobernar outputs generativos

La cognición supervisora aparece cuando el estudiante deja de tratar la respuesta generativa como producto terminado y la convierte en objeto de examen. Su tarea consiste en verificar afirmaciones, detectar inconsistencias y decidir qué merece conservarse. La autoridad intelectual vuelve entonces al usuario, aunque la producción inicial provenga de la máquina. Ng et al. (2021) vinculan la alfabetización en inteligencia artificial con capacidades para comprender, utilizar y evaluar críticamente sistemas de intervenir en decisiones humanas.

Supervisar exige separar fluidez lingüística de validez epistémica. Una respuesta bien redactada puede contener datos imprecisos, relaciones causales débiles o referencias inexistentes. Jakesch et al. (2023) muestran que las heurísticas humanas empleadas para reconocer lenguaje producido por inteligencia artificial resultan falibles. Por ello, la apariencia de naturalidad no constituye evidencia suficiente. El estudiante necesita contrastar afirmaciones con fuentes pertinentes y examinar de forma la consistencia interna antes de incorporar cualquier contenido a su trabajo académico.

La verificación no equivale a buscar errores de manera mecánica. Implica establecer criterios antes de aceptar una respuesta: precisión fáctica, pertinencia disciplinar, respaldo documental y coherencia argumentativa. Laupichler et al. (2022)

sitúan la alfabetización en inteligencia artificial como campo formativo necesario en educación superior y de adultos. Bajo esa mirada, supervisar requiere conocimientos que permitan juzgar la producción algorítmica. Además, quien carece de referentes disciplinares dispone también de menos recursos para reconocer una respuesta defectuosa.

Corregir un output generativo añade una operación distinta. Después de localizar una falla, el estudiante debe reconstruir la respuesta mediante conocimiento, evidencia externa o nuevas consultas dirigidas. Guo y Lee (2023) relacionan ChatGPT con oportunidades para fortalecer pensamiento crítico cuando las actividades promueven evaluación razonada. La corrección adquiere valor formativo precisamente porque obliga a justificar cambios. No basta reemplazar una frase dudosa; hace falta comprender por qué era insuficiente y qué fundamento respalda la modificación.

Gobernar la producción generativa va más allá de verificar y corregir. Significa definir condiciones de uso, límites y criterios para detener una cadena de respuestas. Nguyen et al. (2022) identifican principios éticos relevantes para integrar inteligencia artificial en educación. La supervisión incorpora una dimensión normativa: decidir cuándo una salida puede utilizarse, cuándo requiere revisión adicional y cuándo debe descartarse. El estudiante actúa como responsable de aquello que acepta y convierte en parte de su producción.

La supervisión también reclama calibrar la confianza. Desconfiar de todo contenido generado impediría aprovechar capacidades útiles; aceptarlo sin examen convertiría la asistencia en autoridad. Hicks et al. (2024) cuestionan la relación entre fluidez discursiva y compromiso con la verdad en modelos conversacionales. Entre credulidad y rechazo existe una práctica más exigente: asignar confianza proporcional a la evidencia disponible. Aprender a graduarla permite decidir qué afirmaciones

requieren comprobación inmediata y cuáles admiten una revisión menos intensiva.

En tareas académicas, la trazabilidad fortalece la supervisión porque permite reconstruir de dónde procede una afirmación y qué transformaciones recibió. Yan et al. (2023) identifican problemas prácticos y éticos asociados con modelos lingüísticos en educación. Registrar consultas relevantes, fuentes y correcciones realizadas ofrece evidencia del juicio ejercido. La transparencia no persigue convertir cada interacción en burocracia documental. Busca hacer visible la responsabilidad intelectual del estudiante frente a materiales que pueden parecer convincentes sin ser confiables.

El dominio disciplinar condiciona la calidad de toda supervisión. Cuanto mayor es el conocimiento del estudiante, más posibilidades tiene de advertir omisiones, simplificaciones o relaciones improbables. Hager et al. (2024), al estudiar limitaciones de modelos lingüísticos en decisiones clínicas, destacan la necesidad de evaluar y mitigación antes de confiar en sus resultados. La lección educativa resulta: una herramienta capaz no elimina la necesidad de saber. En muchos casos vuelve más importante disponer de criterio experto.

Desde la evaluación educativa, supervisar puede convertirse en desempeño observable. El docente puede presentar una respuesta generada con errores deliberados y pedir que sea auditada, corregida y justificada mediante evidencia. Tam et al. (2024) proponen un marco de evaluación humana de modelos lingüísticos que organiza dimensiones relevantes para juzgar sus resultados. Trasladada al aprendizaje, dicha lógica permite valorar competencias que una respuesta convencional oculta: detectar fallas, ponderar riesgos y fundamentar decisiones frente a producción sintética.

Dentro de la nueva taxonomía, la cognición supervisora designa el nivel donde el estudiante gobierna aquello que la IA produce. Ya no importa únicamente generar, consultar o delegar. Importa ejercer autoridad epistémica sobre el resultado. Walter (2024) vincula alfabetización en inteligencia artificial, diseño de prompts y pensamiento crítico dentro de la educación contemporánea. Supervisar reúne tales capacidades en una práctica de control razonado: verificar antes de aceptar, corregir cuando corresponde y responder por cada decisión.

3.6. Cognición metagenerativa: comprender y regular el propio sistema humano-IA

La cognición metagenerativa designa la capacidad de observar y regular la relación que una persona construye con la inteligencia artificial durante el aprendizaje. Su objeto ya no es únicamente una respuesta ni operación transferida, sino la configuración del trabajo compartido. El estudiante reconoce cuándo consulta, qué delega, dónde interviene y qué efectos produce cada decisión. Liu et al. (2021) muestran que mecanismos orientados al pensamiento reflexivo pueden favorecer procesos de aprendizaje apoyados por inteligencia artificial.

Pensar sobre el sistema humano-IA exige advertir patrones que suelen permanecer invisibles durante el uso cotidiano. Una persona puede descubrir que consulta demasiado pronto, acepta ciertas respuestas con facilidad o reserva para la máquina tareas que antes resolvía personalmente. Chang et al. (2023) vinculan el aprendizaje autorregulado apoyado por chatbots con establecimiento de metas, retroalimentación y personalización. La regulación metagenerativa comienza cuando tales hábitos dejan de operar automáticamente y pasan a convertirse en decisiones examinables.

La metacognición tradicional dirige la atención hacia conocimientos, estrategias y procesos propios. La cognición

metagenerativa amplía ese foco porque parte del trabajo intelectual ocurre mediante una relación con un agente generativo. Ya no basta preguntarse qué sé o qué estrategia utilizo. También importa reconocer qué aporta la máquina y qué cambia en mi manera de pensar cuando interviene. Darvishi et al. (2024) vinculan la asistencia basada en IA con variaciones relevantes en la agencia estudiantil.

Regular la interacción requiere identificar momentos de entrada y salida de la asistencia generativa. Hay ocasiones en que conviene trabajar sin apoyo para recuperar conocimientos o elaborar una posición. En otras, la consulta permite ampliar alternativas y contrastar perspectivas. Después puede resultar necesario retirar la ayuda para comprobar qué permanece disponible personalmente. Essel et al. (2024) examinan efectos de respuestas instantáneas sobre habilidades cognitivas, recordando que la oportunidad temporal de la asistencia tiene consecuencias formativas.

Una dimensión de la cognición metagenerativa reside en calibrar el esfuerzo. La eficiencia tecnológica puede reducir cargas innecesarias, pero también puede retirar operaciones cuya práctica resulta formativa. Fan et al. (2024) advierten sobre pereza metacognitiva asociada con ciertos usos de inteligencia artificial generativa. Regular no significa maximizar dificultad ni comodidad. Significa decidir qué esfuerzo merece conservarse porque produce aprendizaje y qué carga puede transferirse sin empobrecer la construcción de capacidades que deberán permanecer disponibles después.

El estudiante metagenerativo aprende también a leer su dependencia. No toda frecuencia de uso expresa pérdida de autonomía, pues algunas tareas requieren apoyo por razones legítimas. La señal aparece cuando disminuye la capacidad de iniciar, sostener o revisar una actividad sin intervención algorítmica. Wei (2023) relaciona la inteligencia artificial aplicada a

la enseñanza de lenguas con motivación, logro y aprendizaje autorregulado. Tales relaciones invitan a observar efectos acumulativos, no únicamente resultados inmediatos de cada consulta.

La regulación requiere memoria del propio proceso. Registrar decisiones, cambios de estrategia y momentos de dependencia permite reconocer regularidades difíciles de percibir durante una sesión aislada. Un diario de interacción puede revelar qué preguntas fueron productivas, qué delegaciones resultaron innecesarias y cuándo la asistencia desplazó razonamientos valiosos. Li et al. (2024) comparan apoyo humano y ChatGPT atendiendo pensamiento crítico, rendimiento y carga cognitiva. Tal evidencia refuerza la necesidad de observar simultáneamente desempeño y experiencia cognitiva.

También interviene una capacidad anticipatoria. Antes de recurrir al modelo, el estudiante puede prever qué efecto tendrá la ayuda sobre la tarea y sobre su aprendizaje. Esa previsión transforma el uso en una elección regulada. No pregunta únicamente si la IA puede ejecutar una operación, sino si conviene que la ejecute en ese momento. Xu et al. (2025) destacan el papel del apoyo metacognitivo para fortalecer aprendizaje autorregulado y experiencia formativa en ambientes generativos educativos.

Desde la enseñanza, la cognición metagenerativa puede promoverse mediante pausas de regulación en actividades con IA. El docente puede pedir que el estudiante explique por qué recurrió al modelo, qué cambió después de la consulta y qué haría después en una tarea semejante. Tales preguntas desplazan la atención desde el producto hacia la arquitectura de interacción. El propósito consiste en formar usuarios capaces de rediseñar conscientemente su relación con la asistencia según metas de aprendizaje.

Dentro de la nueva taxonomía, la cognición metagenerativa ocupa una función integradora. Permite observar

autonomía, aumento, diálogo, delegación y supervisión como componentes regulables de una misma arquitectura humano-IA. El aprendiz no administra únicamente tareas; gobierna la configuración cognitiva que construye con el modelo. Xu et al. (2025) muestran que el soporte metacognitivo puede mejorar la autorregulación en ambientes generativos. Comprender el sistema compartido permite modificarlo deliberadamente para preservar agencia, aprendizaje transferible y responsabilidad intelectual personal.

Tabla 3

Configuraciones cognitivas en la interacción humano-IA generativa

Configuración cognitiva	Caracterización dentro del aprendizaje mediado por IA
Cognición autónoma	Preserva un espacio de elaboración intelectual previo a la consulta. El estudiante recupera conocimientos, formula hipótesis y reconoce vacíos antes de recurrir al modelo. La IA interviene después de que existe una posición propia desde la cual contrastar sus aportes.
Cognición aumentada	Amplía capacidades intelectuales mediante asistencia generativa sin desplazar el razonamiento humano. La IA aporta alternativas, representaciones o apoyos operativos. El estudiante mantiene las decisiones de mayor exigencia cognitiva y emplea la asistencia para extender su campo de acción.
Cognición dialógica	Convierte la interacción con el modelo en una secuencia de indagación. Preguntar, repreguntar, objetar y solicitar fundamentos permiten transformar progresivamente la comprensión. La calidad cognitiva depende de la profundidad con que el estudiante conduce cada intercambio.
Cognición delegada	Describe la transferencia deliberada de determinadas operaciones intelectuales hacia la IA. Su análisis permite reconocer qué tareas ejecuta la máquina y cuáles

Configuración cognitiva	Caracterización dentro del aprendizaje mediado por IA
	permanecen bajo responsabilidad humana. La pertinencia de delegar depende del propósito formativo y del dominio que se busca desarrollar.
Cognición supervisora	Sitúa al estudiante como responsable epistémico de los outputs generativos. Implica verificar afirmaciones, contrastar evidencias, localizar errores y corregir respuestas. También requiere decidir cuándo aceptar, modificar o descartar una producción algorítmica mediante criterios disciplinares explícitos.
Cognición metagenerativa	Regula la arquitectura completa de interacción humano-IA. El estudiante observa sus patrones de consulta, asistencia, delegación y supervisión. A partir de dicha conciencia puede modificar la distribución del esfuerzo y decidir cuándo incorporar o retirar apoyo generativo para preservar agencia y aprendizaje transferible.

Nota. Las categorías representan configuraciones diferenciadas de participación cognitiva y no niveles rígidos ni una secuencia jerárquica obligatoria. Una actividad educativa puede movilizar varias configuraciones según la tarea, el propósito de aprendizaje y la distribución de funciones entre estudiante e inteligencia artificial.

Capítulo IV

Diseño del aprendizaje y evaluación bajo la nueva taxonomía

La incorporación de inteligencia artificial generativa altera una premisa largamente asentada en el diseño educativo: que la producción entregada por un estudiante constituye una representación razonable de aquello que sabe hacer. Cuando una herramienta redacta, sintetiza, argumenta o propone soluciones con notable fluidez, aquella relación pierde transparencia. Cotton et al. (2023) plantean que la expansión de ChatGPT obliga a reconsiderar prácticas académicas vinculadas con integridad y evaluación. El problema pedagógico adquiere, por ello, otra profundidad.

Tal transformación no vuelve obsoleta la evaluación. La obliga a precisar mejor sus propósitos. Durante décadas, numerosas actividades fueron diseñadas bajo condiciones donde ejecutar una tarea implicaba movilizar capacidades atribuibles principalmente a quien aprendía. La mediación generativa modifica aquella correspondencia. Kung et al. (2023) mostraron que ChatGPT podía alcanzar desempeños relevantes ante preguntas de un examen profesional médico. Ese hallazgo ilustra una cuestión educativa mayor: producir una respuesta adecuada ya no demuestra necesariamente dominio personal.


El cambio afecta también al diseño del aprendizaje porque enseñar y evaluar forman parte de una misma arquitectura formativa. Una actividad orienta aquello que merece atención. Una consigna distribuye responsabilidades y una evaluación comunica qué formas de pensamiento poseen valor. Chen et al. (2020) identificaron una distancia entre ciertas aplicaciones educativas de inteligencia artificial y los marcos pedagógicos que deberían orientarlas. Reducir dicha distancia requiere diseñar experiencias donde tecnología, propósito formativo y evidencia mantengan una relación intelectualmente defendible.

La cuestión tampoco puede resolverse mediante una oposición simple entre trabajo humano y producción algorítmica. Crawford et al. (2023) vinculan el uso educativo de ChatGPT con

consideraciones relacionadas con aprendizaje, evaluación y responsabilidad. Desde aquella perspectiva, interesa reconocer distintos grados de participación tecnológica sin confundir asistencia con sustitución. Habrá momentos para pensar sin apoyo generativo y otros donde colaborar con una herramienta constituya parte legítima de la competencia buscada. La diferencia dependerá del propósito educativo perseguido.

Figura 10

Arquitectura del aprendizaje y evaluación con IA



Cuando la colaboración forma parte del trabajo académico, la autoría adquiere matices que las categorías tradicionales capturan con dificultad. Barrett y Pack (2023) documentan percepciones de docentes y estudiantes ante herramientas generativas aplicadas a la escritura. La pregunta por quién escribió pierde parte de su alcance si permanece desligada de otra más pedagógica: quién seleccionó, verificó, transformó y defendió las decisiones incorporadas. Allí comienza a dibujarse una noción de agencia compatible con producciones intelectuales mediadas por sistemas generativos.

También cambia aquello que merece observarse durante una experiencia evaluativa. El documento entregado conserva importancia, aunque ya no puede cargar con toda la inferencia acerca del aprendizaje. Nguyen et al. (2024) identifican diversos patrones de colaboración entre personas e inteligencia artificial durante la escritura académica. Esa diversidad permite comprender por qué dos productos semejantes pueden provenir de procesos cognitivos profundamente diferentes. Evaluar requiere atender a señales que permitan interpretar razonamiento, regulación y apropiación durante el trabajo desarrollado.

La retroalimentación ofrece un ejemplo revelador. Recibir recomendaciones automatizadas puede mejorar una producción sin garantizar que quien aprende comprenda las razones de cada modificación. Banihashem et al. (2024) compararon retroalimentación proporcionada por pares y por inteligencia artificial en tareas de escritura. Su trabajo permite advertir que la procedencia de una ayuda influye en la experiencia formativa. La evaluación necesita distinguir entre incorporar una corrección y ejercer criterio suficiente para juzgar su pertinencia disciplinar académica.

A medida que cambia la naturaleza de la evidencia, también deben cambiar los criterios utilizados para interpretarla. Owan et al. (2023) examinan oportunidades de la inteligencia artificial en medición y evaluación educativa. Aquellas posibilidades requieren instrumentos capaces de reconocer autonomía, verificación y complejidad cognitiva sin premiar meramente la apariencia sofisticada de una producción. Una respuesta elegante puede esconder dependencia. Otra menos pulida puede revelar mayor dominio. La evaluación necesita criterios sensibles a diferencias de tal naturaleza.

Hay además una dimensión ética que atraviesa todo diseño evaluativo mediado por inteligencia artificial. Yusuf et al. (2024) describen tensiones entre integridad académica y reforma

educativa desde perspectivas multiculturales. La cuestión rebasa el establecimiento de permisos o prohibiciones. Implica decidir qué responsabilidades permanecen bajo control humano y qué usos tecnológicos resultan compatibles con los propósitos formativos. También exige comunicar reglas comprensibles para que estudiantes y docentes compartan expectativas acerca de autoría, asistencia y rendición intelectual de cuentas.

El capítulo aborda, desde esa problemática, una transición que afecta resultados de aprendizaje, diseño de tareas, evidencias, procesos cognitivos, rúbricas y validez evaluativa. Cooper (2023) advierte posibilidades y límites de ChatGPT en educación científica, recordando que ninguna herramienta posee significado pedagógico al margen del uso diseñado para ella. La nueva taxonomía ofrece un marco para reorganizar tales decisiones. Su propósito es preservar inferencias educativas significativas cuando pensar, producir y aprender pueden ocurrir mediante colaboración humano-IA.

4.1. Resultados de aprendizaje resistentes a la automatización superficial

En una taxonomía del aprendizaje atravesada por inteligencia artificial generativa, formular resultados exige desplazar la atención desde productos reproducibles hacia actuaciones que revelen juicio, decisión y responsabilidad intelectual. Un resultado resistente a la automatización superficial no se define por prohibir herramientas, sino por exigir al estudiante evidencias de comprensión que una respuesta generada no pueda acreditar por sí misma. La prioridad cambia: importa menos obtener un producto correcto y más demostrar dominio mediante decisiones justificadas.

La resistencia pedagógica comienza cuando el resultado de aprendizaje expresa una capacidad observable que demanda interpretación personal, selección de criterios y defensa razonada. Cotton et al. (2023) advierten que la disponibilidad de sistemas

generativos obliga a reconsiderar tareas cuya ejecución puede confundirse con aprendizaje auténtico. Por ello, verbos como describir o resumir pierden fuerza cuando aparecen aislados. Conviene vincularlos con acciones de contraste, argumentación, revisión o transferencia que permitan reconocer la intervención cognitiva del estudiante.

Un resultado bien formulado debe distinguir entre desempeño producido y competencia demostrada. La diferencia parece pequeña, pero reorganiza el diseño curricular. Un ensayo impecable puede provenir de una delegación extensa, mientras una defensa oral breve puede revelar comprensión, dudas razonables y capacidad para sostener decisiones. Crawford et al. (2023) relacionan la incorporación ética de ChatGPT con cambios en evaluación y aprendizaje. La autoría educativa adquiere entonces valor cuando puede rastrearse en razonamientos y elecciones intelectuales.

Desde esa perspectiva, la resistencia no equivale a diseñar actividades imposibles para una máquina. Tal pretensión envejece rápidamente ante sistemas más capaces. El propósito consiste en formular aprendizajes cuyo valor dependa de la participación intelectual verificable del estudiante. Puede pedirse que adapte una solución a restricciones inéditas, explique por qué descartó alternativas o revise una respuesta después de recibir objeciones. La evidencia relevante aparece en la calidad del criterio empleado, no en la dificultad mecánica.

También conviene evitar resultados centrados en la mera producción de textos, códigos, imágenes o respuestas cerradas. King y ChatGPT (2023) mostraron tempranamente que la conversación sobre plagio y autoría debía acompañarse de una revisión de las prácticas universitarias. Bajo esa premisa, el resultado de aprendizaje gana densidad cuando exige reconstruir decisiones, reconocer límites y explicar modificaciones. El estudiante deja una huella intelectual visible que permite valorar

apropiación, incluso cuando utiliza asistencia generativa durante el proceso.

La formulación puede incorporar condiciones que obliguen a movilizar conocimiento ante variaciones. No basta resolver un caso conocido si una herramienta puede replicar el procedimiento. Resulta más informativo pedir que el estudiante responda ante datos incompletos, criterios en tensión o restricciones cambiantes. Owan et al. (2023) señalan oportunidades de la inteligencia artificial en medición y evaluación educativa. Esa posibilidad refuerza la necesidad de resultados capaces de captar razonamiento, adaptación y juicio más allá del acierto.

Otro rasgo reside en hacer visible la relación entre decisión y consecuencia. Un aprendizaje resistente pide que quien aprende anticipe efectos, compare cursos de acción y asuma una posición defendible. Esa estructura reduce el valor de respuestas genéricas porque obliga a conectar conocimiento disciplinar con criterios. La inteligencia artificial puede colaborar en la generación de opciones, pero la competencia se manifiesta cuando el estudiante discrimina entre ellas, fundamenta su elección y responde por sus implicaciones.

La dimensión ética merece aparecer como desempeño y no como declaración decorativa. Yusuf et al. (2024) documentan perspectivas multiculturales que vinculan la IA generativa con tensiones entre integridad académica y reforma educativa. Un resultado de aprendizaje puede requerir reconocer riesgos de sesgo, atribuir fuentes, declarar usos de asistencia o justificar límites de delegación. Tales acciones convierten la responsabilidad en evidencia evaluable. La competencia deja de descansar en intenciones y pasa a expresarse mediante decisiones observables.

La resistencia a la automatización superficial también depende del grado de transferencia exigido. Cuando el resultado pide aplicar principios en situaciones nuevas, defender ajustes ante

retroalimentación o corregir errores, la respuesta deja de ser una pieza aislada. Se convierte en evidencia de una capacidad que persiste frente a cambios en la tarea. Esa persistencia importa porque una taxonomía renovada debe distinguir entre rendimiento asistido momentáneo y aprendizaje disponible para actuar con criterio en ocasiones posteriores.

En consecuencia, redactar resultados resistentes implica precisar qué debe permanecer en manos del estudiante aun cuando la IA participe. No se trata de preservar tareas por nostalgia, sino de proteger aquello que otorga sentido formativo al desempeño: comprender, decidir, verificar, justificar y transferir. La nueva taxonomía puede usar esa frontera como principio de diseño. Un resultado valioso describe una competencia cuya evidencia conserva significado aunque cambien las herramientas y cuya demostración permite reconocer agencia intelectual.

4.2. Ingeniería de tareas según grados de mediación de IA

La ingeniería de tareas adquiere un papel cuando la inteligencia artificial puede intervenir en diferentes momentos del trabajo. Diseñar ya no consiste en asignar una actividad y esperar una respuesta, sino en decidir qué operaciones pueden delegarse, cuáles requieren supervisión y cuáles deben permanecer bajo control humano. Cada tarea configura una relación particular entre estudiante, herramienta y conocimiento. Esa relación determina el grado de mediación permitido y orienta la evidencia que después podrá interpretarse pedagógicamente.


Un primer grado corresponde a tareas realizadas sin asistencia generativa durante la ejecución. Su valor no radica en rechazar la tecnología, sino en disponer de momentos donde capacidades puedan observarse sin apoyo algorítmico. Cotton et al. (2023) vinculan la expansión de ChatGPT con la necesidad de revisar prácticas de integridad y evaluación. Reservar espacios de

actuación independiente permite establecer una referencia del desempeño, útil para contrastarla después con producciones desarrolladas mediante distintos niveles de asistencia.

En un segundo grado, la IA funciona como apoyo acotado para operaciones previamente definidas por el docente. Puede colaborar en búsquedas iniciales, generación de alternativas o revisión lingüística, mientras la estructura intelectual de la tarea permanece a cargo del estudiante. La consigna debe indicar con precisión qué usos resultan admisibles y qué evidencias deberán conservarse. Crawford et al. (2023) relacionan la adopción ética de ChatGPT con decisiones educativas que articulan carácter, aprendizaje y evaluación responsable.

Figura 11

Grados de mediación de IA en las tareas



Un tercer grado concede mayor participación al sistema generativo y convierte su producción en material de trabajo. El estudiante puede solicitar explicaciones, comparar propuestas o producir borradores que luego deberá examinar. La tarea cambia de naturaleza: ya no premia la obtención de contenido, sino la capacidad de intervenir sobre aquello que ofrece la herramienta. King y ChatGPT (2023) sitúan el problema de la autoría dentro de

una conversación más amplia sobre prácticas universitarias y plagio.

Cuando la mediación aumenta, la consigna necesita incorporar puntos de control que hagan visible el trabajo intelectual. Registrar instrucciones dadas al modelo puede ser útil, aunque resulta insuficiente si se evalúa de manera aislada. Conviene pedir anotaciones sobre elecciones, correcciones o descartes realizados durante el proceso. Tales rastros permiten reconstruir la relación entre asistencia y decisión. La tarea adquiere entonces una arquitectura por etapas, donde cada entrega parcial cumple una función probatoria y también formativa.

En grados avanzados de mediación, la IA puede operar como colaborador durante buena parte de la actividad. Allí cobra importancia diseñar encargos que requieran coordinación consciente entre capacidades humanas y algorítmicas. Owan et al. (2023) examinan posibilidades de la inteligencia artificial para la medición y la evaluación educativa. Desde una perspectiva de diseño, dicha expansión invita a distribuir funciones con intención: generar, contrastar, verificar, corregir y decidir deben ocupar lugares diferenciados dentro de la secuencia.

La gradación también permite evitar una dicotomía poco productiva entre permitir y prohibir. Una asignatura puede combinar tareas con mediación nula, restringida, guiada o amplia según el propósito formativo. Lo importante es que la decisión responda a la capacidad que se busca movilizar y no a una regla uniforme. Variar los grados ofrece además información comparativa sobre el desempeño del estudiante, pues permite observar qué cambia cuando recibe apoyo y qué conserva bajo actuación independiente.

La ingeniería de tareas requiere atender también a la transparencia del uso tecnológico. Yusuf et al. (2024) recogen perspectivas multiculturales que muestran tensiones entre

integridad académica y transformación educativa ante la IA generativa. Pedir declaraciones breves sobre herramientas empleadas, decisiones delegadas y verificaciones efectuadas ayuda a convertir la mediación en parte visible del trabajo. No se trata de acumular registros administrativos, sino de hacer legible la distribución de responsabilidad que sostuvo la producción académica presentada.

Otro criterio de diseño reside en ajustar la dificultad después de introducir asistencia generativa. Si una herramienta reduce el esfuerzo requerido para producir un borrador, la tarea puede trasladar exigencia hacia comparación, depuración, integración o defensa. Tal desplazamiento evita conservar actividades cuya complejidad desapareció con la automatización. La mediación bien planificada no rebaja la demanda cognitiva. Puede elevarla cuando libera operaciones rutinarias y dirige la atención hacia decisiones que requieren conocimiento, vigilancia y criterio argumentado.

Pensar las tareas mediante grados de mediación permite construir una arquitectura para el aprendizaje con IA. Cada grado define permisos, responsabilidades, evidencias y límites de delegación acordes con la intención educativa. La progresión puede variar entre actividades e incluso dentro de una secuencia. Con ello, el diseño deja de perseguir una frontera rígida entre trabajo humano y algorítmico. Pasa a organizar interacciones donde la herramienta amplía posibilidades sin volver invisible la participación intelectual del estudiante.

4.3. Evidencias de aprendizaje en procesos de coautoría humano-IA

En procesos de coautoría humano-IA, la evidencia de aprendizaje deja de residir exclusivamente en la pieza entregada. Interesa reconocer huellas que permitan atribuir decisiones, revisiones y criterios al estudiante durante la producción. La

colaboración con sistemas generativos vuelve insuficiente inferir dominio a partir de un texto pulido. Kim et al. (2022) sitúan el diseño del aprendizaje como soporte para una colaboración educativa con IA. Evaluar requiere, por tanto, observar aportes humanos dentro del proceso compartido.

Una evidencia pertinente puede mostrar qué aportó la herramienta y qué transformó quien aprende. Borradores sucesivos, anotaciones de revisión y justificaciones breves permiten reconstruir esa distribución sin convertir la evaluación en vigilancia. Barrett y Pack (2023) examinan perspectivas estudiantiles y docentes sobre inteligencia generativa durante la escritura. Desde tal mirada, documentar cambios adquiere valor pedagógico porque revela apropiación. No basta conservar versiones; importa explicar por qué una propuesta algorítmica fue aceptada, modificada o rechazada conscientemente.

Los registros de interacción cobran sentido cuando se interpretan como rastros de actividad cognitiva y no como pruebas automáticas de autoría. Una secuencia de instrucciones puede revelar búsqueda, pero también ensayo mecánico. Por ello conviene acompañarla con comentarios que expliciten criterios de selección y verificación. Nguyen et al. (2024) identifican patrones de colaboración humano-IA en escritura académica asistida. Tal diversidad invita a valorar la calidad de la relación construida con la herramienta, no su frecuencia.

La revisión constituye otra fuente especialmente fértil. Cuando el estudiante recibe una propuesta generada y detecta debilidades, la corrección realizada permite apreciar comprensión disciplinar. Escalante et al. (2023) analizan la retroalimentación producida por IA en escritura y las preferencias estudiantiles asociadas. Desde una perspectiva evaluativa, aceptar una recomendación carece de fuerza probatoria si no existe examen razonado. La evidencia gana espesor cuando puede verse qué cambió, bajo qué criterio y con qué efecto argumentativo posterior.

La comparación entre aportes humanos y algorítmicos permite observar formas de discernimiento difíciles de captar mediante una entrega única. Puede solicitarse al estudiante que contraste dos alternativas, señale errores o defienda una combinación propia. Marzuki et al. (2023) estudian el impacto de herramientas de escritura con IA sobre contenido y organización desde la perspectiva docente. Tales hallazgos respaldan una lectura procesual donde mejorar un escrito importa, aunque también importa reconocer quién tomó las decisiones decisivas.

También resulta útil recoger evidencias vinculadas con la retroalimentación. No toda observación recibida merece incorporarse y tampoco toda fuente orienta del mismo modo. Banihashem et al. (2024) comparan retroalimentación generada por pares y por inteligencia artificial en escritura de ensayos. La capacidad evaluable reside entonces en discriminar recomendaciones, ponderar su pertinencia y convertirlas en mejoras justificadas. Una nota reflexiva breve puede revelar más aprendizaje que una acumulación extensa de intercambios sin ningún examen intelectual posterior.

La coautoría plantea además una cuestión de originalidad que rebasa la identificación de fragmentos generados. Doshi y Hauser (2024) encontraron que la IA generativa puede favorecer la creatividad individual mientras reduce la diversidad colectiva del contenido novedoso. Por ello, una evidencia valiosa debe permitir apreciar la aportación singular del estudiante: asociaciones inesperadas, decisiones o variaciones argumentales que no provienen de aceptar pasivamente una propuesta. La creatividad evaluable aparece en la transformación consciente del material disponible.

En tareas de escritura asistida, el progreso entre versiones ofrece información especialmente rica. Song y Song (2023) estudiaron efectos de ChatGPT sobre habilidades de escritura académica y motivación en estudiantes de inglés como lengua

extranjera. Para la evaluación, interesa observar qué aprende una persona al revisar con apoyo y no meramente cuánto mejora el documento. Comparar borradores con comentarios metacognitivos permite distinguir corrección superficial, reorganización conceptual y decisiones que evidencian mayor control sobre la producción.

Las evidencias pueden distribuirse a lo largo de la actividad mediante pequeños hitos: una elección argumentada, una verificación documental, una revisión crítica o una defensa oral. Ninguna pieza necesita cargar con toda la demostración del aprendizaje. Su fuerza proviene de la convergencia. Cuando distintos rastros apuntan hacia un mismo dominio, la atribución resulta más convincente. Tal enfoque reduce la dependencia del producto terminado y permite valorar la agencia del estudiante aun bajo colaboración generativa intensa.

Bajo una taxonomía renovada, la coautoría humano-IA exige evidencias capaces de mostrar participación cognitiva sin fingir una autoría enteramente individual. El propósito evaluativo consiste en reconocer qué comprende, decide y transforma el estudiante cuando trabaja con una inteligencia externa. La evidencia deja entonces de funcionar como objeto aislado y pasa a formar una constelación de rastros interpretables. Versiones, justificaciones, contrastes y defensas permiten atribuir aprendizaje con fundamento mientras respetan la naturaleza colaborativa de la producción.

4.4. Evaluación del proceso cognitivo y no solamente del producto final

Evaluar el proceso cognitivo implica desplazar la mirada desde la calidad visible de una entrega hacia las operaciones intelectuales que permitieron construirla. En ambientes mediados por inteligencia artificial, un producto correcto puede ocultar trayectorias muy distintas de comprensión, dependencia o revisión.

Kim et al. (2022) destacan la necesidad de diseñar apoyos para la colaboración entre estudiantes e IA. La evaluación requiere captar decisiones, cambios de criterio y formas de regulación desplegadas durante la actividad académica.

La observación del proceso no exige registrar cada movimiento del estudiante. Conviene seleccionar momentos que posean valor diagnóstico central: formulación inicial del problema, elección de una estrategia, revisión de resultados y explicación de cambios. Barrett y Pack (2023) muestran que docentes y estudiantes perciben diferenciadamente la participación de la IA en la escritura. Tales diferencias recuerdan que evaluar procesos requiere interpretar acciones y razones, no acumular rastros digitales sin una pregunta pedagógica que los organice.

Pensar en voz alta, elaborar notas de decisión o responder preguntas durante una tarea permite acceder a dimensiones que el producto terminado ya no conserva. La evaluación puede atender a la manera en que una persona identifica información relevante, establece relaciones y modifica una hipótesis. Tales manifestaciones hacen visible el pensamiento en movimiento. Su valor reside en mostrar la estructura del razonamiento mientras ocurre, especialmente cuando una herramienta generativa ofrece respuestas plausibles con enorme rapidez.

La retroalimentación constituye un punto privilegiado para observar aprendizaje porque obliga a decidir qué merece ser conservado y qué debe modificarse. Escalante et al. (2023) estudiaron la eficacia de comentarios generados por IA y las preferencias de estudiantes de inglés. Desde una mirada procesual, recibir una recomendación importa menos que examinar la respuesta intelectual ante ella. Aceptar, cuestionar o reformular una observación ofrece indicios sobre comprensión disciplinar académica y capacidad de autorregulación durante el trabajo.

Evaluar el proceso también permite distinguir mejora textual de desarrollo cognitivo. Una producción puede ganar claridad gracias a una herramienta sin que exista avance equivalente en comprensión. Marzuki et al. (2023) documentan percepciones docentes sobre efectos de herramientas de escritura con IA en contenido y organización. Por ello, comparar versiones debe acompañarse de explicaciones sobre cambios. La pregunta evaluativa pasa de cuánto mejoró el documento a qué aprendió quien lo revisó y mediante qué decisiones.

Las secuencias de revisión ofrecen otra ventaja: permiten reconocer errores productivos. Una respuesta descartada, una hipótesis corregida o una estrategia abandonada pueden contener más información sobre aprendizaje que una ejecución impecable. Song y Song (2023) encontraron efectos favorables del uso de ChatGPT en habilidades de escritura académica y motivación. Evaluar procesos permite valorar el ajuste consciente que ocurre durante la actividad, sin penalizar automáticamente las vacilaciones que forman parte de una comprensión académica en desarrollo.


La procedencia de la retroalimentación también modifica el proceso que conviene evaluar. Banihashem et al. (2024) compararon comentarios producidos por pares y por inteligencia artificial en escritura de ensayos, mostrando que las fuentes de apoyo pueden generar experiencias diferenciadas. El interés evaluativo reside en observar qué hace el estudiante con cada aporte. Contrastar recomendaciones, detectar inconsistencias y justificar una elección convierte la recepción de ayuda en una oportunidad para evidenciar juicio y regulación del aprendizaje.

En actividades creativas, valorar únicamente la obra presentada puede ocultar la naturaleza del razonamiento que la originó. Doshi y Hauser (2024) hallaron que la IA generativa puede aumentar la creatividad individual mientras reduce la diversidad colectiva de contenidos novedosos. Una evaluación procesual

puede atender a la generación de alternativas, los criterios de selección y las transformaciones efectuadas. Interesa saber si hubo búsqueda deliberada y personal de posibilidades o aceptación temprana de una propuesta algorítmica convincente.

Figura 12

Evaluación del proceso cognitivo



La evaluación procesual requiere instrumentos capaces de combinar información sin convertir la experiencia educativa en una sucesión de controles. Conversaciones breves, diarios reflexivos, mapas de decisiones y defensas pueden aportar datos complementarios. Nguyen et al. (2024) identifican diversos patrones de colaboración humano-IA en escritura académica. Tal variedad aconseja evitar un indicador único de participación cognitiva. La interpretación gana consistencia cuando varias evidencias convergen y permiten reconstruir el razonamiento con claridad para emitir un juicio pedagógico.

Bajo la nueva taxonomía, evaluar el proceso significa reconocer que aprender ocurre también en las decisiones tomadas antes de entregar una respuesta. El producto conserva valor, pero deja de funcionar como representación completa del dominio

alcanzado. La atención se dirige hacia comprensión, regulación, revisión y transferencia observables durante la actividad. Tal enfoque permite valorar el pensamiento que permanece bajo mediación tecnológica y ofrece una base más justa para interpretar qué capacidades pertenecen realmente al estudiante.

4.5. Rúbricas para autonomía, verificación y sofisticación cognitiva

Una rúbrica orientada a escenarios mediados por inteligencia artificial debe valorar capacidades que permanezcan atribuibles al estudiante aun cuando exista asistencia generativa. La autonomía ocupa un lugar central, pero no equivale a trabajar sin herramientas. Expresa la capacidad para decidir cuándo recurrir a ellas, delimitar su intervención y conservar control intelectual sobre la tarea. Cotton et al. (2023) vinculan integridad académica y rediseño evaluativo, relación que invita a formular criterios atentos al desempeño verificable posterior.

La autonomía puede traducirse en descriptores que distingan dependencia, uso dirigido y gobierno consciente de recursos generativos. Un desempeño inicial requiere apoyo frecuente para orientar decisiones. Un nivel intermedio muestra selección razonada de ayudas. El nivel avanzado evidencia capacidad para prescindir de ellas cuando dejan de aportar valor. La rúbrica gana cuando describe conductas observables y evita premiar independencia aparente. Importa quién conduce el trabajo intelectual y con qué grado de control durante el desarrollo.

La verificación constituye un segundo eje porque una respuesta fluida puede contener errores, omisiones o referencias inexistentes. Crawford et al. (2023) relacionan el uso ético de ChatGPT con decisiones sobre carácter, aprendizaje y evaluación. En una rúbrica, verificar debe significar contrastar afirmaciones con fuentes pertinentes, examinar consistencia y corregir resultados cuando sea necesario. Los niveles de logro pueden diferenciar

aceptación acrítica, comprobación parcial y validación sistemática sustentada en criterios disciplinares antes de incorporar contenido generado.

Conviene evaluar la calidad de la verificación y no la cantidad de comprobaciones registradas. Consultar fuentes carece de mérito cuando ninguna resulta pertinente para resolver la duda. Un descriptor avanzado puede reconocer la selección de evidencia confiable, la identificación de discrepancias y la revisión consecuente de una respuesta. King y ChatGPT (2023) sitúan el plagio y la autoría dentro de la discusión universitaria sobre IA. Verificar también implica asumir responsabilidad por aquello que se entrega.

La sofisticación cognitiva aporta un tercer eje y evita confundir complejidad verbal con profundidad intelectual. Una producción extensa puede mantener razonamientos elementales, mientras una respuesta breve puede integrar relaciones conceptuales exigentes. La rúbrica debe atender al tipo de operaciones desplegadas: distinguir, relacionar, inferir, cuestionar, transferir o reformular. Interesa valorar la organización del pensamiento frente a problemas abiertos. El criterio superior corresponde a actuaciones donde varias operaciones se articulan con propósito y generan decisiones justificadas disciplinariamente.

Los tres ejes adquieren potencia cuando se leen de manera integrada. Un estudiante puede actuar con autonomía y, sin embargo, verificar deficientemente. También puede comprobar datos con rigor mientras mantiene una elaboración conceptual limitada. Owan et al. (2023) examinan posibilidades de la IA en medición y evaluación educativa. Su planteamiento permite advertir que los instrumentos requieren criterios diferenciados. La rúbrica debe preservar perfiles de desempeño sin reducir capacidades distintas a una puntuación indiferenciada o compensatoria.

La redacción de descriptores merece especial cuidado porque términos vagos producen juicios inconsistentes. Expresiones como excelente, adecuado o profundo dicen poco si no remiten a actuaciones reconocibles. Resulta preferible describir decisiones que puedan observarse en la tarea: contrasta una afirmación, explica un descarte, modifica una estrategia o fundamenta una elección. Tal precisión facilita retroalimentación útil y permite al estudiante anticipar qué calidad de actuación se espera cuando trabaja con apoyo generativo en una actividad académica.

Las rúbricas también pueden incorporar la responsabilidad sobre el uso de IA sin convertirla en una sanción encubierta. Yusuf et al. (2024) documentan tensiones entre integridad académica y transformación educativa desde miradas multiculturales. Un criterio pertinente puede valorar transparencia sobre apoyos utilizados, límites reconocidos y decisiones conservadas bajo responsabilidad humana. El nivel superior no correspondería a usar menos tecnología, sino a gobernarla con criterio, declarar su participación cuando corresponda y responder intelectualmente por el resultado presentado.

Otro cuidado consiste en evitar rúbricas excesivamente detalladas que fragmenten el desempeño hasta volverlo mecánico. Demasiados indicadores pueden inducir al estudiante a cumplir casillas sin comprender la relación entre ellas. Conviene trabajar con pocos criterios de alto valor interpretativo y descriptores que expresen progresión auténtica. La autonomía, la verificación y la sofisticación cognitiva funcionan mejor cuando cada dimensión conserva identidad propia. El juicio docente puede integrar luego las evidencias sin perder matices del aprendizaje observado.

Una rúbrica concebida bajo la nueva taxonomía no busca medir cuánto trabajo realizó una máquina frente a una persona. Busca determinar la calidad del gobierno cognitivo ejercido durante una actuación mediada. Autonomía, verificación y sofisticación

permiten observar quién orienta las decisiones, con qué rigor se examina la información y qué profundidad alcanza el razonamiento. Al articular dichas dimensiones, la evaluación reconoce aprendizaje atribuible y ofrece criterios capaces de conservar valor ante herramientas generativas más competentes.

4.6. Validez de la evaluación cuando la IA puede ejecutar la tarea

La validez evaluativa entra en tensión cuando una inteligencia artificial puede resolver con suficiencia la misma tarea asignada al estudiante. La pregunta ya no consiste en determinar si la respuesta entregada es correcta, sino si permite inferir el aprendizaje que pretendía medir. Chen et al. (2020) identifican brechas entre aplicaciones educativas de IA y sus fundamentos teóricos. Tal distancia obliga a revisar la relación entre desempeño observado, capacidad atribuida y significado de la puntuación obtenida.

Una evaluación pierde fuerza inferencial cuando el producto admite explicaciones alternativas igualmente plausibles. Puede reflejar dominio personal, asistencia parcial o ejecución delegada. Cotton et al. (2023) vinculan la expansión de ChatGPT con problemas de integridad académica que demandan revisar las prácticas evaluativas. El asunto rebasa la detección de uso tecnológico. Si una calificación pretende representar competencia del estudiante, la evidencia recogida debe permitir distinguir aprendizaje demostrado de rendimiento producido mediante apoyo externo durante la actividad.

La capacidad de los modelos generativos para responder pruebas profesionales vuelve visible un problema que antes permanecía menos expuesto. Kung et al. (2023) documentaron el desempeño de ChatGPT en preguntas del examen de licencia médica estadounidense. Cuando una máquina alcanza respuestas aceptables en instrumentos diseñados para personas, acertar deja

de constituir evidencia suficiente de dominio humano. La validez requiere entonces preguntar qué inferencia autoriza cada respuesta y qué parte del desempeño permanece atribuible al examinado.

La cuestión adquiere especial relevancia en campos donde una respuesta correcta puede coexistir con razonamientos inseguros. Abd-alrazaq et al. (2023) analizan oportunidades y limitaciones de los grandes modelos lingüísticos en educación médica. Una evaluación válida debe captar capacidades vinculadas con interpretación, verificación y transferencia cuando tales capacidades forman parte del dominio profesional. Medir aquello que una herramienta ejecuta automáticamente puede conservar utilidad diagnóstica, aunque pierde valor si se atribuye directamente al conocimiento personal del estudiante.

La validez tampoco se recupera mediante prohibiciones generales. Restringir herramientas puede resultar pertinente en determinados momentos, pero no resuelve la pregunta sobre aquello que una prueba representa. Cooper (2023) mostró posibilidades y limitaciones de ChatGPT en educación científica mediante un estudio exploratorio. Si la práctica profesional incorpora sistemas generativos, evaluar competencia también requiere observar desempeño con asistencia. La clave reside en separar aquello que debe dominarse internamente de aquello que puede realizarse mediante colaboración tecnológica.

Conviene distinguir validez de dificultad. Una tarea puede ser ardua y aun ofrecer evidencia pobre sobre la capacidad buscada. También puede ser breve y permitir inferencias relevantes si exige una actuación difícil de delegar sin comprensión. Lee (2023) examina el potencial de ChatGPT dentro de la educación médica y advierte transformaciones asociadas con su incorporación. El diseño evaluativo necesita alinear la inferencia pretendida con condiciones de ejecución capaces de hacer visible el dominio humano requerido.

La atribución constituye, por tanto, un componente central de la validez. No basta conocer quién produjo cada frase; interesa determinar quién realizó las operaciones intelectuales que justifican la calificación. King y ChatGPT (2023) sitúan autoría y plagio dentro del debate universitario provocado por los sistemas conversacionales. Una prueba conserva significado cuando permite relacionar la evidencia observada con capacidades del estudiante mediante argumentos defendibles, incluso cuando parte de la producción material proviene de una herramienta generativa.

Otra amenaza aparece cuando el instrumento recompensa conductas periféricas y deja fuera capacidades relevantes. Owan et al. (2023) examinan posibilidades de la inteligencia artificial para medición y evaluación educativa. Su incorporación amplía recursos disponibles, pero también obliga a revisar qué representa una puntuación obtenida bajo mediación algorítmica. La validez mejora cuando las condiciones de evaluación corresponden con el dominio declarado y cuando las inferencias reconocen el grado de asistencia permitido durante cada actuación del estudiante.

La validez posee además una dimensión ética porque decisiones descansan sobre interpretaciones de evidencias. Yusuf et al. (2024) muestran que la IA generativa plantea tensiones entre integridad y reforma educativa desde perspectivas multiculturales. Calificar un producto altamente automatizable como prueba directa de competencia puede generar inferencias injustas entre estudiantes con diferentes estrategias de uso. Una evaluación responsable debe declarar qué capacidad representa la puntuación, bajo qué condiciones fue observada y cuáles son sus límites interpretativos.

Bajo la nueva taxonomía, la pregunta decisiva deja de ser si la IA puede completar una actividad. Importa saber si la actividad permite inferir aquello que interesa conocer del estudiante. Crawford et al. (2023) relacionan evaluación, aprendizaje y responsabilidad ética ante ChatGPT. La validez se preserva cuando

existe correspondencia entre capacidad pretendida, evidencia obtenida y condiciones de mediación. Tal principio permite rediseñar instrumentos sin perseguir una imposible carrera contra la capacidad de los sistemas generativos.

Tabla 4

Componentes del diseño del aprendizaje y la evaluación bajo la nueva taxonomía

Componente	Orientación pedagógica y evaluativa
Resultados de aprendizaje resistentes a la automatización superficial	Priorizan desempeños que revelan comprensión, juicio y transferencia. La evidencia debe permitir atribuir al estudiante decisiones intelectuales relevantes aun cuando emplee inteligencia artificial generativa.
Ingeniería de tareas según grados de mediación de IA	Organiza actividades con niveles diferenciados de asistencia algorítmica. Cada tarea delimita responsabilidades humanas y tecnológicas según el propósito formativo y la capacidad que se pretende desarrollar.
Evidencias de aprendizaje en procesos de coautoría humano-IA	Considera versiones, decisiones, justificaciones y transformaciones como huellas del aprendizaje. La atribución se apoya en evidencias que permiten reconocer la participación cognitiva del estudiante dentro de una producción compartida.
Evaluación del proceso cognitivo y no solamente del producto	Desplaza parte de la atención hacia razonamiento, regulación y revisión. Los cambios de estrategia y las respuestas ante retroalimentación permiten interpretar el aprendizaje con mayor profundidad que una entrega aislada.

Componente	Orientación pedagógica y evaluativa
Rúbricas para autonomía, verificación y sofisticación cognitiva	Articula criterios observables para valorar gobierno intelectual, comprobación rigurosa de información y profundidad del razonamiento. Los niveles de desempeño distinguen dependencia tecnológica de una mediación gobernada con criterio.
Validez de la evaluación cuando la IA puede ejecutar la tarea	Examina si la evidencia permite realizar inferencias defendibles acerca del aprendizaje humano. La validez depende de la correspondencia entre capacidad evaluada, desempeño observado y condiciones de mediación tecnológica.

Nota. La tabla articula los componentes desarrollados en el Capítulo 4 y muestra su relación con el diseño de experiencias educativas mediadas por inteligencia artificial generativa.

Capítulo V

Del pensamiento de orden superior a la agencia cognitiva

Durante décadas, el pensamiento de orden superior ofreció una referencia para describir aprendizajes que excedían la reproducción de información. Analizar, evaluar y crear señalaban formas de actividad intelectual asociadas con mayor elaboración. La inteligencia artificial generativa altera parte de aquella arquitectura. Una herramienta puede producir argumentos, comparaciones y propuestas con notable fluidez. Ante dicha capacidad, ubicar una tarea en un nivel elevado ya no garantiza que el estudiante haya ejercido personalmente las operaciones cognitivas atribuidas.


La cuestión adquiere profundidad cuando se distingue entre complejidad del producto y complejidad del pensamiento desplegado para obtenerlo. Una respuesta sofisticada puede surgir de una intervención humana mínima, mientras una producción breve puede condensar decisiones intelectuales exigentes. Lo (2023) advierte que ChatGPT introduce oportunidades y tensiones que afectan enseñanza, aprendizaje y evaluación. Por ello, la taxonomía necesita mirar más allá del resultado visible y atender la distribución de actividad cognitiva entre persona y sistema generativo.

Tal desplazamiento no invalida las categorías heredadas. Las obliga a dialogar con una realidad educativa donde ciertas operaciones pueden compartirse, delegarse o recuperarse durante una misma tarea. Hwang et al. (2020) señalaron que la incorporación de inteligencia artificial modifica roles vinculados con enseñanza y aprendizaje. La pregunta taxonómica cambia entonces de alcance. Ya no basta determinar qué operación demanda una actividad; importa reconocer quién la realiza, bajo qué mediación y con qué grado de dirección intelectual humana.

A partir de ahí aparece una distinción que atraviesa todo el capítulo: utilizar capacidades algorítmicas no equivale necesariamente a ampliar capacidades humanas. Darvishi et al. (2024) relacionan la asistencia mediante inteligencia artificial con

variaciones en la agencia estudiantil. El interés pedagógico se desplaza hacia la capacidad del aprendiz para gobernar su relación con la herramienta. Decidir cuándo recurrir a ella, limitar su intervención y conservar responsabilidad sobre el trabajo intelectual adquiere relevancia formativa dentro del aprendizaje mediado.

Figura 13
Agencia cognitiva y aprendizaje mediado por IA



Esa responsabilidad requiere observar el propio pensamiento mientras la interacción tecnológica modifica sus condiciones. La metacognición cobra una dimensión adicional porque debe abarcar tanto los procesos personales como las decisiones relacionadas con la asistencia recibida. Fan et al. (2024) vinculan determinados usos de inteligencia artificial generativa con riesgos de pereza metacognitiva. En consecuencia, planificar, supervisar y revisar dejan de referirse únicamente a la actividad interna del aprendiz y pasan a regular también una relación cognitiva compartida.

Pero regular la interacción no resuelve por completo el problema. Los sistemas generativos producen lenguaje convincente cuya apariencia de conocimiento puede exceder su fundamento. Hicks et al. (2024) examinan dicha separación entre fluidez discursiva y compromiso con la verdad en ChatGPT. La educación necesita formar un juicio capaz de interrogar procedencia, evidencia y confiabilidad. Creer, aceptar o reutilizar una respuesta se convierte entonces en decisión epistémica que reclama criterios propios antes de conceder autoridad al contenido sintético.

Al mismo tiempo, la facilidad de acceso a respuestas plantea una paradoja pedagógica. Reducir esfuerzo puede favorecer eficiencia y liberar recursos, pero también eliminar procesos que resultaban formativos precisamente porque exigían elaboración. Essel et al. (2024) analizan efectos de las respuestas inmediatas de modelos conversacionales sobre habilidades cognitivas universitarias. Cobra sentido preservar ciertas resistencias dentro del aprendizaje. No toda dificultad merece desaparecer. Algunas pausas, intentos previos y reconstrucciones mantienen activo un trabajo mental que conviene proteger.

La pregunta por el aprendizaje alcanza otra dimensión cuando la herramienta deja de estar disponible. Cooper (2023) analiza posibilidades y limitaciones de ChatGPT en educación científica, donde el rendimiento asistido obliga a reconsiderar qué cuenta como comprensión. Una competencia adquirida mediante mediación tecnológica necesita mostrar capacidad de permanencia y adaptación. Resolver una variación, explicar un principio o actuar sin apoyo permite observar si la interacción amplió recursos cognitivos personales o produjo una dependencia difícil de advertir durante el desempeño.

Evaluar bajo tales condiciones requiere abandonar equivalencias sencillas entre producto entregado y aprendizaje demostrado. Ng et al. (2021) vinculan la alfabetización en inteligencia artificial con dimensiones técnicas y críticas necesarias

para una participación informada. Las evidencias educativas deben mostrar algo más que corrección. Procesos de decisión, justificaciones, contrastes y actuaciones bajo diferentes grados de asistencia permiten reconocer con mayor precisión qué pertenece al estudiante, qué aportó la herramienta y qué competencia puede atribuirse razonablemente a la persona.

Desde esa perspectiva, el capítulo propone avanzar del pensamiento de orden superior hacia la agencia cognitiva como marco para interpretar aprendizaje humano en presencia de inteligencia artificial generativa. Tlili et al. (2023) muestran que la incorporación educativa de ChatGPT reúne posibilidades y riesgos que reclaman decisiones pedagógicas cuidadosas. La discusión reunirá agencia, regulación, vigilancia epistémica, fricción deliberada, transferencia y evidencia bajo una pregunta común: qué significa seguir siendo autor del propio aprendizaje cuando pensar puede hacerse acompañado.

5.1. Agencia cognitiva como nivel superior del aprendizaje mediado por IA

La agencia cognitiva representa un nivel superior del aprendizaje mediado por inteligencia artificial porque desplaza el énfasis desde la ejecución de operaciones mentales hacia la capacidad de dirigirlas con intención. El aprendiz no queda definido por aquello que recuerda, analiza o produce, sino por las decisiones que toma acerca de sus propios procesos. Elegir cuándo recurrir a una herramienta generativa, delimitar su participación y conservar autoridad intelectual convierte el aprendizaje en una práctica deliberadamente gobernada.

Desde una perspectiva taxonómica, la agencia cognitiva rebasa la idea de ascender por niveles cada vez más complejos de procesamiento. Su rasgo distintivo reside en gobernar la arquitectura de la actividad intelectual. Quien aprende decide qué tarea delegar, cuál preservar bajo control humano y cuándo

interrumpir la asistencia algorítmica. Darvishi et al. (2024) muestran que la asistencia basada en IA puede modificar la agencia estudiantil, de modo que su diseño requiere atender autonomía y participación.

La presencia de sistemas generativos introduce una diferencia decisiva entre realizar una tarea y conducir el proceso que permite resolverla. Una respuesta bien elaborada puede provenir de una interacción pobre en pensamiento. Por ello, el desempeño observable pierde parte de su valor como indicador aislado. La agencia exige rastrear decisiones, criterios y revisiones. Interesa saber quién formuló el problema, quién fijó los estándares de calidad y quién asumió la responsabilidad intelectual por el resultado alcanzado.

Bajo dicha perspectiva, aprender con IA implica conservar capacidad de iniciativa frente a una tecnología que ofrece respuestas inmediatas y plausibles. La disponibilidad puede favorecer eficiencia, aunque también reducir oportunidades de elaboración mental cuando la delegación ocurre demasiado pronto. Essel et al. (2024) relacionan el acceso a respuestas instantáneas con efectos sobre habilidades cognitivas universitarias. La cuestión educativa pasa entonces por formar estudiantes capaces de administrar la ayuda sin ceder la conducción de su pensamiento.

La agencia también se expresa en la posibilidad de sostener una intención intelectual a través de interacciones con la IA. Preguntar no basta. Hace falta orientar la conversación hacia una meta, reconocer desvíos y reformular instrucciones cuando la respuesta altera el propósito inicial. Chang et al. (2023) vinculan el apoyo de chatbots educativos con procesos de autorregulación mediante metas, retroalimentación y personalización. Desde allí, la interacción adquiere valor cuando permanece subordinada a decisiones del aprendiz.

Un aprendiz con agencia no mide el valor de la IA por la cantidad de trabajo que logra transferirle. Lo mide por la calidad de las decisiones que puede conservar, ampliar o revisar gracias a la interacción. Tal distinción resulta relevante porque una herramienta potente puede producir dependencia intelectual si reemplaza operaciones que el estudiante necesita ejercer. Fan et al. (2024) advierten sobre formas de pereza metacognitiva asociadas con IA generativa, aprendizaje, motivación y desempeño.

En términos educativos, la agencia cognitiva demanda cambiar aquello que se reconoce como evidencia de aprendizaje avanzado. El producto ofrece información insuficiente cuando parte del proceso ha sido mediado por generación automática. Cobran importancia las huellas de decisión: preguntas formuladas, alternativas descartadas, criterios y modificaciones justificadas. Evaluar dichas huellas permite distinguir entre uso instrumental y conducción intelectual. También devuelve visibilidad al estudiante como autor de elecciones que organizan el proceso y dan sentido al resultado.

La relación entre agencia y pensamiento de orden superior adquiere entonces una forma. Analizar, evaluar y crear continúan siendo operaciones relevantes, pero pueden ejecutarse parcialmente mediante sistemas generativos. La diferencia educativa reside en quién gobierna su activación y con qué propósito. Li et al. (2024), al comparar apoyos humanos y ChatGPT en formación STEM, examinan efectos sobre pensamiento crítico, desempeño y carga cognitiva. Tales hallazgos refuerzan la necesidad de mirar más allá del rendimiento inmediato.

La agencia cognitiva posee además una dimensión temporal. No se limita a decidir durante una interacción puntual, pues implica aprender de decisiones anteriores y ajustar futuras formas de colaboración con sistemas generativos. Xu et al. (2025) destacan el papel del apoyo metacognitivo para fortalecer autorregulación y experiencia de aprendizaje en entornos con IA

generativa. Cada episodio puede convertirse, por tanto, en fuente de criterios para regular mejor la asistencia y preservar márgenes de autonomía intelectual.

Situar la agencia en el nivel superior de una taxonomía renovada no implica convertirla en una destreza aislada ni en un peldaño que clausura otros procesos. Funciona como principio de gobierno sobre el repertorio cognitivo disponible, humano y algorítmico. Su madurez se reconoce cuando el aprendiz puede iniciar, orientar, supervisar y detener la colaboración con IA de acuerdo con propósitos razonados. Allí, aprender significa ejercer autoría sobre las decisiones que configuran el propio trabajo intelectual.

5.2. Metacognición aumentada y regulación de la interacción humano-IA


La metacognición aumentada designa una capacidad de regulación que se amplía cuando el aprendiz observa tanto su actividad mental como la intervención de la inteligencia artificial. Ya no basta reconocer qué se sabe o advertir una dificultad. También resulta necesario identificar qué parte del razonamiento ha sido delegada, qué apoyo conviene solicitar y cuándo recuperar control directo. La regulación adquiere una dimensión relacional: pensar sobre el propio pensamiento mientras se administra una colaboración cognitiva mediada.

Tal ampliación modifica el alcance de la planificación metacognitiva. Antes de consultar una herramienta generativa, el aprendiz necesita definir una meta, anticipar criterios de calidad y decidir qué operaciones requieren esfuerzo. Chang et al. (2023) vinculan el diseño de chatbots orientados al aprendizaje autorregulado con procesos de establecimiento de metas, retroalimentación y personalización. La planificación deja de organizar únicamente acciones humanas y pasa a distribuir

funciones dentro de una actividad intelectual compartida con sistemas generativos.

Figura 14

Regulación metacognitiva de la interacción humano-IA



Durante la interacción, la regulación requiere mantener conciencia sobre el curso del razonamiento. Una producción fluida de la IA puede inducir aceptación prematura si el aprendiz confunde coherencia verbal con comprensión propia. Fan et al. (2024) documentan riesgos de pereza metacognitiva cuando la asistencia generativa altera motivación, procesos de aprendizaje y desempeño. Regular implica detectar momentos en que la facilidad tecnológica comienza a sustituir el esfuerzo necesario para comprender, relacionar ideas o construir criterios independientes.

La supervisión metacognitiva también exige calibrar la confianza depositada en la herramienta. Confiar demasiado reduce la revisión; desconfiar de manera indiscriminada desperdicia apoyos que podrían enriquecer el aprendizaje. El punto formativo reside en ajustar la confianza según la tarea, la evidencia disponible y el grado de dominio personal. Li et al. (2024) encontraron

diferencias relevantes al comparar apoyo humano y ChatGPT en pensamiento crítico, rendimiento y carga cognitiva dentro de experiencias integradas de formación STEM.

Otra función reguladora consiste en administrar la carga cognitiva sin convertir la descarga mental en renuncia intelectual. Delegar búsquedas, reformulaciones o comparaciones puede liberar recursos para operaciones de exigencia. Sin embargo, la utilidad depende del momento y del propósito. Essel et al. (2024) analizan efectos de las interacciones con modelos conversacionales sobre habilidades cognitivas universitarias. Desde una perspectiva metacognitiva, la pregunta no es cuánto trabajo ahorra la IA, sino qué esfuerzo merece conservarse para aprender.

La metacognición aumentada incorpora además una lectura retrospectiva de la interacción. Tras utilizar IA, conviene reconstruir qué decisiones fueron propias, cuáles recibieron influencia algorítmica y dónde cambió el rumbo del razonamiento. Liu et al. (2021) mostraron el valor de mecanismos orientados a promover pensamiento reflexivo en entornos de escritura apoyados por inteligencia artificial. La revisión posterior transforma la interacción en objeto de aprendizaje y permite reconocer patrones personales de dependencia, precipitación, verificación o uso productivo.

Regular la interacción implica también saber modificarla mientras ocurre. Un aprendiz competente no permanece atado al primer modo de consulta. Puede restringir la ayuda, pedir contraargumentos, solicitar explicaciones parciales o suspender temporalmente la herramienta para elaborar una posición propia. Wei (2023) relaciona el uso de inteligencia artificial con logros de aprendizaje, motivación y autorregulación en enseñanza lingüística. La flexibilidad reguladora convierte cada intercambio en una decisión revisable y evita automatizar hábitos de consulta poco reflexivos.

La regulación adquiere mayor profundidad cuando el aprendiz reconoce que sus decisiones cambian por efecto de la propia herramienta. La IA no interviene como recurso neutral: orienta atención, ofrece formulaciones y vuelve más accesibles ciertas rutas de pensamiento. Darvishi et al. (2024) examinan el impacto de la asistencia artificial sobre la agencia estudiantil. La metacognición aumentada requiere percibir tales influencias mientras ocurren y valorar si favorecen la intención formativa o desplazan silenciosamente el control intelectual.

Por ello, el apoyo metacognitivo no debería reducirse a recomendaciones generales sobre verificar información o formular mejores instrucciones. Requiere dispositivos pedagógicos que hagan visible la regulación: pausas de predicción, registros de decisiones, justificaciones de delegación y contrastes entre razonamiento previo y producción algorítmica. Xu et al. (2025) destacan el papel del soporte metacognitivo para fortalecer aprendizaje autorregulado y experiencia formativa en entornos generativos. La mediación pedagógica puede convertir la interacción con IA en práctica consciente.

Dentro de una taxonomía renovada, la metacognición aumentada funciona como mecanismo operativo de la agencia cognitiva sin confundirse con ella. La agencia establece dirección y responsabilidad; la metacognición regula el vínculo que permite sostenerlas durante la actividad. Planificar, supervisar, recalibrar y revisar la colaboración humano-IA constituyen movimientos recurrentes, no una etapa terminal. Su dominio permite que la asistencia generativa permanezca bajo gobierno reflexivo y que cada decisión tecnológica responda a propósitos de aprendizaje intelectualmente defendibles.

5.3. Vigilancia epistémica frente a conocimiento sintético

La vigilancia epistémica adquiere una función propia cuando el conocimiento disponible ya no procede necesariamente de una fuente humana identificable. Los sistemas generativos producen formulaciones plausibles mediante relaciones estadísticas que pueden ocultar errores, invenciones o asociaciones débiles. Ante tal condición, aprender exige mantener una distancia crítica frente a la fluidez discursiva. La pregunta relevante deja de ser si una respuesta parece convincente y pasa a centrarse en qué razones permiten concederle valor como conocimiento educativo.

El conocimiento sintético introduce una dificultad particular: puede presentar apariencia de autoridad sin poseer experiencia, intención testimonial ni compromiso con la verdad. Hicks et al. (2024) analizan precisamente la capacidad de ChatGPT para generar discurso persuasivo sin orientación inherente hacia la veracidad. La vigilancia epistémica requiere reconocer dicha separación entre forma lingüística y fundamento. Una explicación elegante puede resultar útil para pensar, pero su coherencia interna nunca constituye por sí misma garantía suficiente de validez.

Vigilar epistémicamente no equivale a desconfiar de toda producción algorítmica. Implica graduar la aceptación mediante criterios relacionados con evidencia, procedencia, consistencia y posibilidad de contraste. Ng et al. (2021) sitúan la evaluación crítica entre las dimensiones relevantes de la alfabetización en inteligencia artificial. Desde tal perspectiva, el aprendiz necesita desarrollar una confianza calibrada: aceptar cuando existen razones, verificar cuando aumenta la incertidumbre y rechazar cuando las afirmaciones carecen de respaldo comprobable o contradicen conocimiento fundamentado.

La dificultad aumenta porque las personas no siempre reconocen con precisión el lenguaje generado por máquinas.

Jakesch et al. (2023) encontraron que las heurísticas humanas empleadas para identificar textos producidos por IA pueden resultar defectuosas. La vigilancia epistémica no debería descansar, por ello, en intuiciones acerca del tono, la naturalidad o la sofisticación verbal. Requiere procedimientos explícitos de contraste que permitan separar la impresión de autenticidad del examen razonado de las afirmaciones presentadas al lector.

Una práctica educativa orientada hacia dicha vigilancia desplaza la atención desde la detección de errores aislados hacia la interrogación de las bases que sostienen una respuesta. Importa preguntar de dónde procede una afirmación, qué evidencia podría confirmarla y qué información relevante quedó fuera. Laupichler et al. (2022) vinculan la alfabetización en IA con conocimientos y capacidades necesarios para relacionarse críticamente con tales tecnologías. El estudiante aprende entonces a tratar cada salida generativa como propuesta examinable.

La verificación adquiere mayor profundidad cuando deja de operar como comprobación mecánica posterior. Puede integrarse al razonamiento desde el momento en que aparece una afirmación relevante. Hager et al. (2024), al evaluar modelos lingüísticos en decisiones clínicas, documentan limitaciones que demandan estrategias humanas de evaluación y mitigación. En educación, tal principio invita a distinguir grados de riesgo epistémico. No toda afirmación requiere idéntica revisión, pero aquellas con mayores consecuencias reclaman fuentes independientes y criterios exigentes.

También resulta necesario reconocer que el problema no reside únicamente en datos falsos. Una respuesta puede contener información correcta y conducir, aun con ello, hacia interpretaciones pobres por omisión, encuadre parcial o relaciones causales injustificadas. Yan et al. (2023) describen preocupaciones prácticas y éticas asociadas con grandes modelos lingüísticos en educación. La vigilancia epistémica debe atender por igual aquello

que aparece en la respuesta y aquello que permanece ausente pese a ser intelectualmente relevante también.

La formación del juicio requiere además diferenciar utilidad de verdad. Una producción generativa puede servir para formular hipótesis, organizar perspectivas o abrir preguntas sin merecer aceptación como afirmación comprobada. Guo y Lee (2023) relacionan ChatGPT con oportunidades para fortalecer pensamiento crítico cuando su empleo promueve análisis y evaluación. Bajo una mirada epistémica, el valor pedagógico de una respuesta puede residir en provocar examen, contraste y argumentación antes que en ofrecer una conclusión para ser adoptada.

La vigilancia epistémica posee también una dimensión ética porque aceptar conocimiento sintético puede afectar decisiones propias y ajenas. Stahl y Eke (2024) examinan cuestiones de responsabilidad, transparencia y riesgos vinculados con ChatGPT. El aprendiz necesita comprender que verificar no constituye un gesto accesorio cuando una afirmación puede orientar acciones relevantes. A mayor impacto, mayor debe ser la exigencia de trazabilidad, corroboración y prudencia. La responsabilidad intelectual comienza antes de compartir o utilizar una respuesta generada.

Dentro de la taxonomía, la vigilancia epistémica ocupa un lugar distinto de la evaluación crítica ya tratada en niveles previos. No consiste únicamente en juzgar la calidad de un producto. Opera como disposición permanente ante un entorno donde producir lenguaje verosímil resulta fácil. Walter (2024) vincula alfabetización en IA y pensamiento crítico con una educación preparada para sistemas generativos. Aprender en tal escenario significa conservar autoridad para decidir qué merece ser creído, usado o descartado.

5.4. Fricción cognitiva deliberada como principio pedagógico

La fricción cognitiva deliberada parte de una premisa pedagógica incómoda pero necesaria: aprender requiere momentos en los que la respuesta no llega de inmediato. Frente a sistemas generativos capaces de reducir tiempos y simplificar tareas, la enseñanza puede preservar espacios de esfuerzo intelectual intencional. No se trata de dificultar por principio, sino de impedir que la facilidad tecnológica elimine operaciones formativas. Pensar antes de consultar, anticipar una respuesta y justificar decisiones devuelve espesor al aprendizaje.

La fricción adquiere valor cuando obliga al estudiante a movilizar recursos propios antes de recibir asistencia algorítmica. Una pausa breve puede activar conocimientos previos, revelar vacíos y hacer visibles intuiciones que luego serán contrastadas. Essel et al. (2024) examinan efectos de las respuestas instantáneas de modelos conversacionales sobre habilidades cognitivas universitarias. Desde una perspectiva pedagógica, demorar estratégicamente la ayuda permite que la interacción posterior encuentre una mente activa, con preguntas nacidas del esfuerzo precedente propio.

Diseñar fricción no significa celebrar la dificultad ni confundir aprendizaje con agotamiento. El esfuerzo resulta formativo cuando guarda relación con la operación cognitiva que se pretende desarrollar. Una barrera arbitraria consume recursos sin aportar comprensión. Chang et al. (2023) vinculan el apoyo mediante chatbots con principios de autorregulación como metas, retroalimentación y personalización. La intervención docente debe graduar entonces la resistencia necesaria, dejando apoyo disponible cuando la carga amenaza con desplazar la actividad intelectual buscada.

Una forma especialmente fértil de fricción consiste en exigir producción previa. Antes de pedir una explicación a la IA, el estudiante formula la propia; antes de solicitar argumentos, registra una posición; antes de generar una solución, ensaya un procedimiento. Tal secuencia crea un punto de comparación entre pensamiento humano y respuesta algorítmica. Liu et al. (2021) muestran el valor de mecanismos promotores de reflexión en ambientes de escritura apoyados por inteligencia artificial para favorecer procesos.


La fricción puede introducirse también después de recibir una respuesta generada. En lugar de aceptar el producto y continuar, el estudiante debe transformarlo mediante contraste, reconstrucción o defensa argumentada. Fan et al. (2024) advierten sobre la pereza metacognitiva asociada con ciertos usos de inteligencia artificial generativa. Pedir que una respuesta sea explicada con palabras propias, cuestionada desde otra perspectiva o reconstruida sin asistencia convierte la facilidad inicial en ocasión para recuperar esfuerzo cognitivo productivo genuino.

El momento de retirar o retrasar la ayuda merece tanta atención como el tipo de ayuda ofrecida. Una asistencia disponible desde el primer segundo puede alterar la disposición del aprendiz ante una tarea y reducir la persistencia necesaria para elaborar alternativas. Darvishi et al. (2024) relacionan la asistencia de IA con cambios en la agencia. Introducir umbrales de esfuerzo previo protege oportunidades para decidir, probar y equivocarse antes de incorporar una propuesta por el sistema.

También conviene distinguir fricción productiva de sobrecarga. La primera ralentiza una operación para favorecer elaboración; la segunda ocupa recursos mentales sin beneficio proporcional. Wei (2023) relaciona la incorporación de inteligencia artificial en enseñanza de lenguas con aprendizaje, motivación y autorregulación. Un diseño pedagógico cuidadoso regula intensidad y duración del esfuerzo según experiencia del aprendiz

y propósito de la tarea. La fricción pierde sentido cuando obstaculiza aquello que pretendía fortalecer o convierte la dificultad en castigo.

Figura 15
Fricción cognitiva para el aprendizaje profundo



En la práctica docente, la fricción puede adoptar formas discretas. Una consigna puede exigir una hipótesis antes de habilitar la IA, solicitar dos alternativas propias antes de generar otras o reservar la herramienta para una fase determinada. También puede pedir predicciones que luego sean confrontadas con la producción algorítmica. Xu et al. (2025) destacan la relevancia del apoyo metacognitivo en ambientes generativos para fortalecer autorregulación y experiencia de aprendizaje, principio compatible con tales interrupciones intencionadas.

La fricción deliberada modifica además la lógica de la eficiencia educativa. Terminar más rápido no equivale necesariamente a aprender mejor. Cuando la IA acorta una tarea, el tiempo liberado puede destinarse a profundizar decisiones, revisar argumentos o intentar vías alternativas. La cuestión pedagógica

consiste en decidir dónde conviene ahorrar esfuerzo y dónde conviene preservarlo. Tal distribución evita convertir la eficiencia en criterio absoluto y reconoce que ciertas demoras poseen valor porque mantienen al aprendiz comprometido.

Como principio pedagógico, la fricción cognitiva deliberada complementa la agencia, la regulación metacognitiva y la vigilancia epistémica sin reemplazarlas. Su función consiste en diseñar condiciones donde tales capacidades tengan oportunidad de ejercerse. Si cada dificultad recibe respuesta automática, disminuyen las ocasiones para sostener incertidumbre, elaborar criterios y perseverar. Una taxonomía orientada hacia aprendizaje con IA necesita reconocer el valor de la resistencia bien diseñada: aquella que protege el trabajo mental que merece seguir siendo humano.

5.5. Transferencia pos-IA: demostrar competencia más allá del asistente

La transferencia pos-IA plantea una prueba exigente para el aprendizaje mediado por sistemas generativos: aquello que una persona logra con asistencia debe conservar grado de disponibilidad cuando la asistencia desaparece. El rendimiento compartido no demuestra por sí mismo dominio individual. Importa comprobar si el aprendiz puede recuperar conceptos, reconstruir procedimientos y justificar decisiones ante una tarea nueva. La competencia adquiere valor cuando sobrevive al cambio de herramienta, de situación y de condiciones de apoyo tecnológico.

Tal criterio obliga a distinguir desempeño asistido y capacidad transferible. Una producción competente puede reflejar una buena coordinación con la IA sin revelar cuánto conocimiento permanece disponible para actuar de manera independiente. Chen et al. (2020) identifican brechas entre aplicaciones educativas de inteligencia artificial y marcos teóricos capaces de explicar sus

efectos. La transferencia pos-IA responde a dicha brecha al preguntar qué parte del aprendizaje puede movilizarse después de retirar la mediación algorítmica utilizada previamente.

La transferencia tampoco equivale a repetir sin ayuda aquello que antes se resolvió con una herramienta. Su exigencia aumenta cuando cambia el problema, aparecen restricciones inesperadas o resulta necesario adaptar un principio. Cooper (2023) analiza posibilidades y limitaciones de ChatGPT dentro de la educación científica. Desde una mirada transferencial, comprender se manifiesta cuando el aprendiz puede llevar una idea hacia situaciones distintas, reconocer sus límites y modificar su aplicación sin depender de una respuesta generada.

Evaluar dicha capacidad requiere diseñar momentos de retirada deliberada del asistente. Después de una fase de aprendizaje con IA, pueden proponerse tareas equivalentes bajo condiciones de autonomía, explicaciones orales o problemas con datos inéditos. Abd-alrazaq et al. (2023) examinan oportunidades y riesgos de los grandes modelos lingüísticos en educación médica. En campos donde una decisión posee consecuencias relevantes en escenarios, demostrar competencia fuera del sistema permite diferenciar apoyo formativo de sustitución inadvertida del conocimiento profesional.

La transferencia pos-IA también puede observarse mediante la reconstrucción. Un aprendiz que recibió una solución algorítmica debería poder explicar sus principios, detectar qué pasos resultan indispensables y generar una vía alternativa cuando cambian las condiciones. Kung et al. (2023) documentaron un rendimiento notable de ChatGPT en preguntas vinculadas con exámenes médicos. Precisamente porque una máquina puede ejecutar tareas académicas complejas, la evidencia educativa necesita desplazarse hacia capacidades que revelen apropiación y adaptación por parte humana.

Conviene evitar una interpretación purista de la autonomía. Transferir no significa prohibir herramientas ni convertir toda evaluación en ejercicio desconectado de la tecnología. Significa comprobar que la mediación dejó alguna huella cognitiva utilizable fuera de ella. Seo et al. (2021) muestran que la inteligencia artificial puede transformar las interacciones de aprendizaje en entornos. El criterio pertinente consiste en determinar si dichas interacciones amplían recursos personales que luego pueden movilizarse con flexibilidad ante nuevas demandas intelectuales.

Una competencia transferible se reconoce también por la capacidad de elegir cuándo volver a utilizar IA. Quien domina una tarea puede advertir qué parte resuelve por cuenta propia y qué parte merece apoyo externo. Meskó (2023) destaca la ingeniería de instrucciones como habilidad relevante para profesionales que interactúan con modelos generativos. Sin embargo, formular instrucciones adquiere mayor sentido cuando descansa sobre conocimiento suficiente para orientar la consulta, interpretar resultados y continuar trabajando ante ausencia tecnológica.

Desde la evaluación, la transferencia pos-IA reclama evidencias comparables entre condiciones de mediación distintas. Puede observarse el desempeño con asistencia, retirarla después y plantear una variación que exija reorganizar lo aprendido. King (2023) vincula la expansión de chatbots con interrogantes sobre autoría y plagio en educación superior actual. Frente a tales tensiones, una prueba de transferencia permite desplazar la atención desde quién produjo un texto hacia qué capacidades conserva y demuestra quien lo presenta académicamente.

La evidencia disponible invita además a evitar conclusiones simples sobre el beneficio educativo de los asistentes. Wu y Yu (2023), mediante un metaanálisis, encontraron efectos favorables de chatbots sobre resultados de aprendizaje. Sin embargo, una mejora durante la intervención no responde automáticamente por

la permanencia ni por la generalización posterior. La transferencia exige otra pregunta: qué puede hacer el aprendiz cuando cambian las condiciones, desaparecen apoyos y debe reorganizar conocimientos frente a una demanda inédita.

En el nivel superior de la taxonomía, la transferencia pos-IA funciona como prueba de autenticidad del desarrollo cognitivo alcanzado. No compite con la agencia ni con la metacognición; ofrece una evidencia de que ambas produjeron capacidad durable. Tlili et al. (2023) muestran que la incorporación educativa de ChatGPT reúne posibilidades y riesgos que requieren decisiones pedagógicas. Demostrar competencia más allá del asistente confirma que la colaboración tecnológica amplió el repertorio humano en lugar de reemplazarlo.

5.6. La Nueva Taxonomía del Aprendizaje con IA: matriz de niveles, mediaciones y evidencias

La matriz de niveles, mediaciones y evidencias cumple una función integradora dentro de la nueva taxonomía. Su propósito consiste en relacionar la complejidad del aprendizaje con el tipo de participación que asume la inteligencia artificial y con las pruebas necesarias para atribuir competencia al estudiante. La clasificación deja de descansar únicamente en verbos cognitivos. Cada nivel requiere observar quién ejecuta la operación, qué apoyo interviene y qué evidencia permite reconocer apropiación intelectual genuina y transferible.

Una matriz de tal naturaleza responde a la transformación del trabajo intelectual provocada por sistemas capaces de recordar, explicar, comparar, evaluar o producir contenidos. Chen et al. (2020) muestran la amplitud creciente de aplicaciones de inteligencia artificial en educación. Cuando varias operaciones tradicionalmente asociadas con niveles cognitivos pueden externalizarse, la dificultad aparente de una tarea pierde fuerza clasificatoria. Resulta necesario identificar la arquitectura de

participación humana que sostiene el desempeño y la mediación tecnológica involucrada.

El primer eje corresponde al nivel cognitivo que la actividad pretende movilizar. Recordar, comprender, aplicar, analizar, evaluar y crear conservan utilidad descriptiva, aunque requieren una lectura renovada cuando existe asistencia generativa. Hwang et al. (2020) plantean que la inteligencia artificial educativa redefine roles y asuntos de investigación. La matriz recoge dicha transformación mediante niveles que no representan escalones rígidos, sino configuraciones de actividad cuya exigencia depende también del grado de autonomía, supervisión y decisión humana.

El segundo eje registra la mediación de la IA. No toda participación tecnológica posee igual peso cognitivo: recuperar información difiere de generar una explicación, proponer una estrategia o producir una solución completa. Crompton y Burke (2023) documentan diversos usos de inteligencia artificial en educación superior. La matriz necesita distinguir apoyo periférico, colaboración parcial y delegación amplia, pues cada modalidad modifica aquello que puede inferirse a partir del producto presentado por quien aprende en una actividad.

El tercer eje concierne a la evidencia. Un producto correcto puede demostrar dominio, coordinación eficaz con una herramienta o aceptación poco reflexiva de una salida generada. Por ello, la matriz vincula cada nivel con indicios observables de aprendizaje: explicaciones, decisiones justificadas, revisiones, contrastes, reconstrucciones y actuaciones sin asistencia. Ng et al. (2021) relacionan la alfabetización en IA con capacidades técnicas y críticas. Evaluar requiere reunir pruebas capaces de revelar desempeño observable, comprensión y gobierno intelectual.

La relación entre los tres ejes evita interpretar la mediación tecnológica como una variable secundaria. Una misma tarea puede representar exigencias educativas diferentes según el apoyo

disponible. Redactar una argumentación desde cero, revisar una propuesta generada o defender oralmente una versión asistida movilizan responsabilidades distintas. Chan (2023) plantea la necesidad de marcos educativos que orienten el uso universitario de IA. La matriz convierte tal necesidad en un dispositivo para diseñar actividades y anticipar evidencias pertinentes.

También resulta necesario incorporar criterios de confianza y responsabilidad dentro de la lectura matricial. Una mediación intensa exige evidencias que permitan rastrear decisiones humanas y valorar la calidad del juicio ejercido por aprendiz. Nguyen et al. (2023) articulan principios éticos para inteligencia artificial educativa sobre transparencia, responsabilidad y protección. Tales principios amplían la evaluación: ya no interesa alcanzar una respuesta adecuada, sino demostrar que el uso de la herramienta fue razonado, verificable y pedagógicamente defendible.

La matriz adquiere especial utilidad cuando permite comparar evidencias producidas bajo grados distintos de asistencia. Una explicación previa a la consulta, una revisión apoyada por IA y una tarea posterior sin apoyo pueden mostrar dimensiones del aprendizaje. Gao et al. (2023) evidenciaron dificultades para diferenciar textos científicos humanos y generados mediante ChatGPT. Ante productos lingüísticamente convincentes, la evaluación necesita apoyarse en trazas del proceso y actuaciones adicionales que permitan atribuir conocimiento con fundamento al estudiante.

Desde el diseño curricular, la matriz puede funcionar como instrumento de alineación entre propósitos, mediaciones permitidas y formas de evaluación. Lo (2023) identifica oportunidades y riesgos educativos vinculados con ChatGPT, entre ellos cambios en enseñanza, aprendizaje y evaluación. Definir de antemano qué participación algorítmica resulta compatible con cada propósito evita prohibiciones generales y permisos

indiscriminados. El docente puede seleccionar mediaciones según valor formativo y solicitar evidencias proporcionales al grado de asistencia concedido en actividad académica.

La matriz sintetiza, por tanto, una arquitectura evaluativa para la taxonomía renovada. Los niveles describen operaciones y grados de gobierno cognitivo; las mediaciones indican qué funciones comparte o delega el aprendiz; las evidencias permiten decidir qué competencia puede atribuirse razonablemente. Dwivedi et al. (2023) destacan implicaciones de la IA generativa para educación, práctica y política. Articular tales dimensiones permite abandonar equivalencias simples entre producto y aprendizaje, preservando una lectura más precisa de la autoría cognitiva.

Tabla 5

Articulación de la agencia cognitiva en el aprendizaje mediado por inteligencia artificial generativa

Dimensión del capítulo	Planteamiento integrador
Agencia cognitiva	Representa un nivel superior de actuación intelectual. El aprendiz dirige el proceso, delimita la participación de la IA y conserva responsabilidad sobre las decisiones que orientan su aprendizaje.
Metacognición aumentada	Amplía la regulación del pensamiento hacia la relación humano-IA. Comprende planificación, supervisión y recalibración del apoyo recibido. Permite reconocer cuándo la asistencia favorece el aprendizaje y cuándo desplaza operaciones que conviene preservar.
Vigilancia epistémica	Orienta el examen del conocimiento sintético mediante criterios de evidencia, procedencia y confiabilidad. Busca diferenciar fluidez discursiva de validez epistémica. También favorece una confianza calibrada frente a respuestas generadas algorítmicamente.
Fricción cognitiva deliberada	Introduce resistencias pedagógicas intencionales que protegen procesos de

Dimensión del capítulo	Planteamiento integrador
	elaboración. Pausas, intentos previos y reconstrucciones permiten conservar esfuerzo productivo frente a la disponibilidad inmediata de respuestas generativas.
Transferencia pos-IA	Examina si las capacidades desarrolladas permanecen disponibles cuando disminuye o desaparece la asistencia. La competencia se demuestra mediante adaptación, reconstrucción y actuación autónoma ante situaciones diferentes de aquellas trabajadas con IA.
Niveles, mediaciones y evidencias	Articula complejidad cognitiva, participación algorítmica y pruebas de aprendizaje. Permite distinguir desempeño asistido de competencia atribuible al aprendiz mediante productos, decisiones justificadas, trazas del proceso y actuaciones bajo grados diferentes de mediación.
Principio articulador	La complejidad educativa deja de depender únicamente de la operación cognitiva ejecutada. Adquieren relevancia la autoría intelectual, el gobierno de la mediación y la capacidad para sostener criterios propios durante la colaboración con sistemas generativos.
Implicación evaluativa	Evaluar aprendizaje mediado por IA requiere observar algo más que productos correctos. Resulta necesario reunir evidencias sobre decisiones, justificaciones, regulación y transferencia para determinar qué capacidades pertenecen efectivamente al aprendiz.

Nota. La tabla integra los componentes conceptuales desarrollados en el Capítulo 5 y muestra sus relaciones dentro de la nueva taxonomía del aprendizaje con inteligencia artificial.

Conclusiones

La incorporación de inteligencia artificial generativa transforma el significado educativo de recordar; comprender; aplicar; analizar; evaluar y crear. Ninguna operación conserva idéntico valor cuando puede ser ejecutada con apoyo algorítmico. El aprendizaje debe juzgarse por la arquitectura intelectual que sostiene el desempeño. Importan las decisiones previas, la selección de recursos, la revisión y la capacidad de explicar el camino seguido. El producto visible continúa siendo relevante, aunque deja de constituir una prueba suficiente de dominio.

La investigación desarrollada permite afirmar que la autonomía no equivale al rechazo de la tecnología. Consiste en conservar control sobre propósitos, criterios y decisiones durante la interacción. Un estudiante autónomo puede recurrir a un modelo sin entregar la conducción de su pensamiento. Formula una respuesta inicial, identifica necesidades de apoyo y examina cada resultado. También reconoce cuándo conviene interrumpir la asistencia. La independencia intelectual reside en gobernar la mediación y no en negar su existencia.

La atribución del aprendizaje exige evidencias que trasciendan la versión entregada. Una respuesta pulida puede ocultar comprensión limitada, mientras un proceso documentado revela elecciones y correcciones significativas. Por ello, las huellas de razonamiento adquieren valor pedagógico. Borradores, registros de interacción, defensas orales y reconstrucciones posteriores permiten reconocer con fiabilidad la participación cognitiva del estudiante. Tales recursos no persiguen vigilancia permanente. Buscan establecer una relación válida entre desempeño, autoría intelectual y competencia demostrable ante situaciones nuevas.

Los grados de mediación deben definirse a partir de la intención formativa. Algunas tareas requieren trabajo autónomo

para fortalecer memoria, razonamiento o formulación de hipótesis. Otras admiten apoyo restringido destinado a comparar perspectivas. También existen actividades de colaboración amplia donde la regulación del sistema humano-máquina constituye el aprendizaje esperado. La elección pedagógica necesita explicitar qué puede delegarse y qué debe conservarse. Una política uniforme empobrece la enseñanza porque ignora diferencias entre propósitos, disciplinas y momentos.

La confianza ante conocimiento sintético necesita vigilancia epistémica. La fluidez verbal no garantiza verdad, pertinencia ni suficiencia. Cada respuesta generada debe examinarse mediante criterios identificables y fuentes comprobables. El estudiante requiere distinguir evidencia de apariencia, reconocer incertidumbre y mantener juicios provisionales cuando faltan datos. Verificar no representa una fase secundaria. Forma parte del aprendizaje. La competencia intelectual incluye decidir qué aceptar, qué corregir y qué rechazar sin convertir la seguridad expresiva del modelo en autoridad.

La nueva taxonomía organiza la cognición humano-IA mediante modalidades autónoma; aumentada; dialógica; delegada; supervisora y metagenerativa. Las categorías no forman una escalera rígida. Describen configuraciones variables de participación y responsabilidad. Una misma actividad puede desplazarse entre modalidades durante su desarrollo. El valor analítico reside en observar quién formula el problema, quién produce alternativas y quién valida los resultados. Tal lectura permite diferenciar asistencia productiva de sustitución cognitiva sin reducir el aprendizaje a una dicotomía tecnológica.

La descarga puede favorecer aprendizajes complejos cuando libera recursos para comparar, modelar o argumentar. También puede debilitar capacidades necesarias si reemplaza prácticas de recuperación y elaboración. La diferencia depende del propósito y del momento. Por ello, la fricción deliberada cumple

una función formativa. Limitar la asistencia obliga a reconstruir conocimientos y detectar dependencias. Una pedagogía equilibrada combina apoyo con pausas reflexivas. El esfuerzo deja de verse como obstáculo y recupera su papel en la consolidación.

La evaluación necesita desplazarse desde la apariencia del producto hacia la calidad del proceso y la transferencia. Las rúbricas deben valorar autonomía, justificación, verificación, revisión y responsabilidad. Deben distinguir errores de fallas en el uso del modelo. Una tarea resistente a la automatización demanda interpretación y defensa de decisiones. La competencia se confirma cuando el estudiante adapta lo aprendido ante problemas diferentes. Repetir una respuesta generada no acredita comprensión ni capacidad para actuar sin asistencia.

La matriz multidimensional propuesta integra complejidad cognitiva; autonomía; mediación algorítmica; responsabilidad epistémica; transferencia y evidencia. Su propósito no radica en producir etiquetas inmutables. Ofrece un lenguaje para diseñar, investigar y evaluar experiencias educativas con mayor precisión real. Cada dimensión ilumina un aspecto del desempeño y evita conclusiones apresuradas. La combinación permite reconocer trayectorias variadas. También facilita comparar actividades y justificar decisiones pedagógicas. Su utilidad dependerá de revisiones empíricas en disciplinas, poblaciones y modalidades educativas diversas.

El horizonte formativo planteado sitúa la agencia cognitiva por encima de la mera eficiencia productiva. Aprender con inteligencia artificial implica dirigir recursos, conservar responsabilidad y explicar decisiones. Requiere saber usar la asistencia y también prescindir de ella cuando el propósito lo demanda. La educación universitaria debe proteger espacios de elaboración propia sin renunciar a capacidades ampliadas. Allí reside el compromiso: formar personas capaces de pensar con herramientas poderosas sin entregarles el gobierno de su juicio.

Referencias Bibliográficas

- Abd-alrazaq, A., AlSaad, R., Alhuwail, D., Ahmed, A., Healy, P. M., Latifi, S., Aziz, S., Damseh, R., Alabed Alrazak, S., & Sheikh, J. (2023). Large language models in medical education: Opportunities, challenges, and future directions. *JMIR Medical Education*, 9, e48291. <https://doi.org/10.2196/48291>
- Almazrou, S., Alanezi, F., Almutairi, S. A., AboAlsamh, H. M., Alsedrah, I. T., Arif, W. M., Alsadhan, A. A., AlSanad, D. S., Alqahtani, N. S., AlShammary, M. H., Bakhshwain, A. M., Almuhanha, A. F., Almulhem, M., Alnaim, N., Albelali, S., & Attar, R. W. (2024). Enhancing medical students critical thinking skills through ChatGPT: An empirical study with medical students. *Nutrition and Health*, 31(3), 1023-1033. <https://doi.org/10.1177/02601060241273627>
- Banihashem, S. K., Kerman, N. T., Noroozi, O., Moon, J., & Drachsler, H. (2024). Feedback sources in essay writing: Peer-generated or AI-generated feedback?. *International Journal of Educational Technology in Higher Education*, 21(1), 23. <https://doi.org/10.1186/s41239-024-00455-4>
- Barrett, A., & Pack, A. (2023). Not quite eye to A.I.: Student and teacher perspectives on the use of generative artificial intelligence in the writing process. *International Journal of Educational Technology in Higher Education*, 20(1), 59. <https://doi.org/10.1186/s41239-023-00427-0>
- Celik, I. (2023). Towards Intelligent-TPACK: An empirical study on teachers' professional knowledge to ethically integrate artificial intelligence (AI)-based tools into education. *Computers in Human Behavior*, 138, 107468. <https://doi.org/10.1016/j.chb.2022.107468>
- Chan, C. K. Y. (2023). A comprehensive AI policy education framework for university teaching and learning. *International Journal of Educational Technology in Higher Education*, 20(1), 38. <https://doi.org/10.1186/s41239-023-00408-3>
- Chan, C. K. Y., & Hu, W. (2023). Students' voices on generative AI: Perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher*

- Education*, 20(1), 43. <https://doi.org/10.1186/s41239-023-00411-8>
- Chan, C. K. Y., & Lee, K. K. W. (2023). The AI generation gap: Are gen z students more interested in adopting generative AI such as ChatGPT in teaching and learning than their gen x and millennial generation teachers?. *Smart Learning Environments*, 10(1), 60. <https://doi.org/10.1186/s40561-023-00269-3>
- Chang, D. H., Lin, M. P. C., Hajian, S., & Wang, Q. Q. (2023). Educational design principles of using AI chatbot that supports Self-Regulated learning in education: Goal setting, feedback, and personalization. *Sustainability*, 15(17), 12921. <https://doi.org/10.3390/su151712921>
- Chen, X., Xie, H., Zou, D., & Hwang, G. J. (2020). Application and theory gaps during the rise of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 1, 100002. <https://doi.org/10.1016/j.caeai.2020.100002>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/access.2020.2988510>
- Chiu, T. K. F. (2023). The impact of generative AI (GenAI) on practices, policies and research direction in education: A case of ChatGPT and Midjourney. *Interactive Learning Environments*, 32(10), 6187–6203. <https://doi.org/10.1080/10494820.2023.2253861>
- Cooper, G. (2023). Examining science education in ChatGPT: An exploratory study of generative artificial intelligence. *Journal of Science Education and Technology*, 32(3), 444–452. <https://doi.org/10.1007/s10956-023-10039-y>
- Cotton, D. R. E., Cotton, P. A., & Shipway, J. R. (2023). Chatting and cheating: Ensuring academic integrity in the era of ChatGPT. *Innovations in Education and Teaching International*, 61(2), 228–239. <https://doi.org/10.1080/14703297.2023.2190148>
- Crawford, J., Cowling, M., & Allen, K. A. (2023). Leadership is needed for ethical ChatGPT: Character, assessment, and learning using artificial intelligence (AI). *Journal of University Teaching and Learning Practice*, 20(3). <https://doi.org/10.53761/1.20.3.02>

- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal of Educational Technology in Higher Education*, 20(1), 22. <https://doi.org/10.1186/s41239-023-00392-8>
- Darvishi, A., Khosravi, H., Sadiq, S., Gašević, D., & Siemens, G. (2024). Impact of AI assistance on student agency. *Computers & Education*, 210, 104967. <https://doi.org/10.1016/j.compedu.2023.104967>
- Doshi, A. R., & Hauser, O. P. (2024). Generative AI enhances individual creativity but reduces the collective diversity of novel content. *Science Advances*, 10(28), eadn5290. <https://doi.org/10.1126/sciadv.adn5290>
- Dwivedi, Y. K., Kshetri, N., Hughes, L., Slade, E. L., Jeyaraj, A., Kar, A. K., Baabdullah, A. M., Koohang, A., Raghavan, V., Ahuja, M., Albanna, H., Albashrawi, M. A., Al-Busaidi, A. S., Balakrishnan, J., Barlette, Y., Basu, S., Bose, I., Brooks, L., Buhalis, D., ..., Wright, R. (2023). Opinion paper: “So what if ChatGPT wrote it?” multidisciplinary perspectives on opportunities, challenges and implications of generative conversational AI for research, practice and policy. *International Journal of Information Management*, 71, 102642. <https://doi.org/10.1016/j.ijinfomgt.2023.102642>
- Díaz-Rodríguez, N., Del Ser, J., Coeckelbergh, M., López de Prado, M., Herrera-Viedma, E., & Herrera, F. (2023). Connecting the dots in trustworthy artificial intelligence: From AI principles, ethics, and key requirements to responsible AI systems and regulation. *Information Fusion*, 99, 101896. <https://doi.org/10.1016/j.inffus.2023.101896>
- Escalante, J., Pack, A., & Barrett, A. (2023). AI-generated feedback on writing: Insights into efficacy and ENL student preference. *International Journal of Educational Technology in Higher Education*, 20(1), 57. <https://doi.org/10.1186/s41239-023-00425-2>
- Essel, H. B., Vlachopoulos, D., Essuman, A. B., & Amankwa, J. O. (2024). ChatGPT effects on cognitive skills of undergraduate students: Receiving instant responses from AI-based conversational large language models (LLMs). *Computers and Education: Artificial Intelligence*, 6, 100198. <https://doi.org/10.1016/j.caeai.2023.100198>

- Fan, Y., Tang, L., Le, H., Shen, K., Tan, S., Zhao, Y., Shen, Y., Li, X., & Gašević, D. (2024). Beware of metacognitive laziness: Effects of generative artificial intelligence on learning motivation, processes, and performance. *British Journal of Educational Technology*, 56(2), 489–530. <https://doi.org/10.1111/bjet.13544>
- Farrelly, T., & Baker, N. (2023). Generative artificial intelligence: Implications and considerations for higher education practice. *Education Sciences*, 13(11), 1109. <https://doi.org/10.3390/educsci1311109>
- Gao, C. A., Howard, F. M., Markov, N. S., Dyer, E. C., Ramesh, S., Luo, Y., & Pearson, A. T. (2023). Comparing scientific abstracts generated by ChatGPT to real abstracts with detectors and blinded human reviewers. *npj Digital Medicine*, 6(1), 75. <https://doi.org/10.1038/s41746-023-00819-6>
- Giannakos, M., Azevedo, R., Brusilovsky, P., Cukurova, M., Dimitriadis, Y., Hernandez-Leo, D., Järvelä, S., Mavrikis, M., & Rienties, B. (2024). The promise and challenges of generative AI in education. *Behaviour & Information Technology*, 44(11), 2518–2544. <https://doi.org/10.1080/0144929x.2024.2394886>
- Guo, Y., & Lee, D. (2023). Leveraging ChatGPT for enhancing critical thinking skills. *Journal of Chemical Education*, 100(12), 4876–4883. <https://doi.org/10.1021/acs.jchemed.3c00505>
- Hager, P., Jungmann, F., Holland, R., Bhagat, K., Hubrecht, I., Knauer, M., Vielhauer, J., Makowski, M., Braren, R., Kaissis, G., & Rueckert, D. (2024). Evaluation and mitigation of the limitations of large language models in clinical decision-making. *Nature Medicine*, 30(9), 2613–2622. <https://doi.org/10.1038/s41591-024-03097-1>
- Halaweh, M. (2023). ChatGPT in education: Strategies for responsible implementation. *Contemporary Educational Technology*, 15(2), ep421. <https://doi.org/10.30935/cedtech/13036>
- Hicks, M. T., Humphries, J., & Slater, J. (2024). ChatGPT is bullshit. *Ethics and Information Technology*, 26(2), 38. <https://doi.org/10.1007/s10676-024-09775-5>

- Holmes, W., & Tuomi, I. (2022). State of the art and practice in AI in education. *European Journal of Education*, 57(4), 542–570. <https://doi.org/10.1111/ejed.12533>
- Hwang, G. J., Xie, H., Wah, B. W., & Gašević, D. (2020). Vision, challenges, roles and research issues of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 1, 100001. <https://doi.org/10.1016/j.caeai.2020.100001>
- Ivanov, S., Soliman, M., Tuomi, A., Alkathiri, N. A., & Al-Alawi, A. N. (2024). Drivers of generative AI adoption in higher education through the lens of the theory of planned behaviour. *Technology in Society*, 77, 102521. <https://doi.org/10.1016/j.techsoc.2024.102521>
- Jakesch, M., Hancock, J. T., & Naaman, M. (2023). Human heuristics for AI-generated language are flawed. *Proceedings of the National Academy of Sciences*, 120(11), e2208839120. <https://doi.org/10.1073/pnas.2208839120>
- Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., ..., Kasneci, G. (2023). ChatGPT for good? on opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Kim, J., Lee, H., & Cho, Y. H. (2022). Learning design to support student-AI collaboration: Perspectives of leading teachers for AI in education. *Education and Information Technologies*, 27(5), 6069–6104. <https://doi.org/10.1007/s10639-021-10831-6>
- King, M. R., & ChatGPT. (2023). A conversation on artificial intelligence, chatbots, and plagiarism in higher education. *Cellular and Molecular Bioengineering*, 16(1), 1–2. <https://doi.org/10.1007/s12195-022-00754-8>
- Kung, T. H., Cheatham, M., Medenilla, A., Sillos, C., De Leon, L., Elepaño, C., Madriaga, M., Aggabao, R., Diaz-Candido, G., Maningo, J., & Tseng, V. (2023). Performance of ChatGPT on USMLE: Potential for AI-assisted medical education

- using large language models. *PLOS Digital Health*, 2(2), e0000198. <https://doi.org/10.1371/journal.pdig.0000198>
- Laupichler, M. C., Aster, A., Schirch, J., & Raupach, T. (2022). Artificial intelligence literacy in higher and adult education: A scoping literature review. *Computers and Education: Artificial Intelligence*, 3, 100101. <https://doi.org/10.1016/j.caeai.2022.100101>
- Lee, H. (2023). The rise of ChatGPT : exploring its potential in medical education. *Anatomical Sciences Education*, 17(5), 926–931. <https://doi.org/10.1002/ase.2270>
- Li, T., Ji, Y., & Zhan, Z. (2024). Expert or machine? comparing the effect of pairing student teacher with in-service teacher and ChatGPT on their critical thinking, learning performance, and cognitive load in an integrated-STEM course. *Asia Pacific Journal of Education*, 44(1), 45–60. <https://doi.org/10.1080/02188791.2024.2305163>
- Liu, C., Hou, J., Tu, Y. F., Wang, Y., & Hwang, G. J. (2021). Incorporating a reflective thinking promoting mechanism into artificial intelligence-supported english writing environments. *Interactive Learning Environments*, 31(9), 5614–5632. <https://doi.org/10.1080/10494820.2021.2012812>
- Lo, C. K. (2023). What is the impact of ChatGPT on education? a rapid review of the literature. *Education Sciences*, 13(4), 410. <https://doi.org/10.3390/educsci13040410>
- Marzuki,, Widiati, U., Rusdin, D., Darwin,, & Indrawati, I. (2023). The impact of AI writing tools on the content and organization of students' writing: EFL teachers' perspective. *Cogent Education*, 10(2), 2236469. <https://doi.org/10.1080/2331186x.2023.2236469>
- Meskó, B. (2023). Prompt engineering as an important emerging skill for medical professionals: Tutorial. *Journal of Medical Internet Research*, 25, e50638. <https://doi.org/10.2196/50638>
- Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., & Qiao, M. S. (2021). Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence*, 2, 100041. <https://doi.org/10.1016/j.caeai.2021.100041>
- Nguyen, A., Ngo, H. N., Hong, Y., Dang, B., & Nguyen, B. P. T. (2022). Ethical principles for artificial intelligence in

- education. *Education and Information Technologies*, 28(4), 4221–4241. <https://doi.org/10.1007/s10639-022-11316-w>
- Nguyen, A., Hong, Y., Dang, B., & Huang, X. (2024). Human-AI collaboration patterns in AI-assisted academic writing. *Studies in Higher Education*, 49(5), 847–864. <https://doi.org/10.1080/03075079.2024.2323593>
- Noy, S., & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381(6654), 187–192. <https://doi.org/10.1126/science.adh2586>
- Owan, V. J., Abang, K. B., Idika, D. O., Etta, E. O., & Bassey, B. A. (2023). Exploring the potential of artificial intelligence tools in educational measurement and assessment. *Eurasia Journal of Mathematics, Science and Technology Education*, 19(8), em2307. <https://doi.org/10.29333/ejmste/13428>
- O'Connor, S., & ChatGPT. (2023). Open artificial intelligence platforms in nursing education: Tools for academic progress or abuse?. *Nurse Education in Practice*, 66, 103537. <https://doi.org/10.1016/j.nepr.2022.103537>
- Rahman, M. M., & Watanobe, Y. (2023). ChatGPT for education and research: Opportunities, threats, and strategies. *Applied Sciences*, 13(9), 5783. <https://doi.org/10.3390/app13095783>
- Romero-Rodríguez, J. M., Ramírez-Montoya, M. S., Buenestado-Fernández, M., & Lara-Lara, F. (2023). Use of ChatGPT at university as a tool for complex thinking: Students' perceived usefulness. *Journal of New Approaches in Educational Research*, 12(2), 323–339. <https://doi.org/10.7821/naer.2023.7.1458>
- Seo, K., Tang, J., Roll, I., Fels, S., & Yoon, D. (2021). The impact of artificial intelligence on learner-instructor interaction in online learning. *International Journal of Educational Technology in Higher Education*, 18(1), 54. <https://doi.org/10.1186/s41239-021-00292-9>
- Song, C., & Song, Y. (2023). Enhancing academic writing skills and motivation: Assessing the efficacy of ChatGPT in AI-assisted language learning for EFL students. *Frontiers in Psychology*, 14, 1260843. <https://doi.org/10.3389/fpsyg.2023.1260843>

- Stahl, B. C., & Eke, D. (2024). The ethics of ChatGPT – exploring the ethical issues of an emerging technology. *International Journal of Information Management*, 74, 102700. <https://doi.org/10.1016/j.ijinfomgt.2023.102700>
- Strzelecki, A. (2023). Students' acceptance of ChatGPT in higher education: An extended unified theory of acceptance and use of technology. *Innovative Higher Education*, 49(2), 223–245. <https://doi.org/10.1007/s10755-023-09686-1>
- Tam, T. Y. C., Sivarajkumar, S., Kapoor, S., Stolyar, A. V., Polanska, K., McCarthy, K. R., Osterhoudt, H., Wu, X., Visweswaran, S., Fu, S., Mathur, P., Cacciamani, G. E., Sun, C., Peng, Y., & Wang, Y. (2024). A framework for human evaluation of large language models in healthcare derived from literature review. *npj Digital Medicine*, 7(1), 258. <https://doi.org/10.1038/s41746-024-01258-7>
- Tlili, A., Shehata, B., Adarkwah, M. A., Bozkurt, A., Hickey, D. T., Huang, R., & Agyemang, B. (2023). What if the devil is my guardian angel: ChatGPT as a case study of using chatbots in education. *Smart Learning Environments*, 10(1), 15. <https://doi.org/10.1186/s40561-023-00237-x>
- Walter, Y. (2024). Embracing the future of artificial intelligence in the classroom: The relevance of AI literacy, prompt engineering, and critical thinking in modern education. *International Journal of Educational Technology in Higher Education*, 21(1), 15. <https://doi.org/10.1186/s41239-024-00448-3>
- Wei, L. (2023). Artificial intelligence in language instruction: Impact on english learning achievement, L2 motivation, and self-regulated learning. *Frontiers in Psychology*, 14, 1261955. <https://doi.org/10.3389/fpsyg.2023.1261955>
- Wu, R., & Yu, Z. (2023). Do AI chatbots improve students learning outcomes? evidence from a meta-analysis. *British Journal of Educational Technology*, 55(1), 10–33. <https://doi.org/10.1111/bjet.13334>
- Xu, X., Qiao, L., Cheng, N., Liu, H., & Zhao, W. (2025). Enhancing self-regulated learning and learning experience in generative AI environments: The critical role of metacognitive support. *British Journal of Educational*

- Technology*, 56(5), 1842–1863.
<https://doi.org/10.1111/bjet.13599>
- Yan, L., Sha, L., Zhao, L., Li, Y., Martinez-Maldonado, R., Chen, G., Li, X., Jin, Y., & Gašević, D. (2023). Practical and ethical challenges of large language models in education: A systematic scoping review. *British Journal of Educational Technology*, 55(1), 90–112. <https://doi.org/10.1111/bjet.13370>
- Yan, L., Greiff, S., Teuber, Z., & Gašević, D. (2024). Promises and challenges of generative artificial intelligence for human learning. *Nature Human Behaviour*, 8(10), 1839–1850. <https://doi.org/10.1038/s41562-024-02004-5>
- Yang, W. (2022). Artificial intelligence education for young children: Why, what, and how in curriculum design and implementation. *Computers and Education: Artificial Intelligence*, 3, 100061. <https://doi.org/10.1016/j.caeai.2022.100061>
- Yusuf, A., Pervin, N., & Román-González, M. (2024). Generative AI and the future of higher education: A threat to academic integrity or reformation? evidence from multicultural perspectives. *International Journal of Educational Technology in Higher Education*, 21(1), 21. <https://doi.org/10.1186/s41239-024-00453-6>



Red de Investigación
Científica y Desarrollo
Tecnológico **Del Pacífico**

“Un marco renovado
para **pensar, diseñar**
y **evaluar** el aprendizaje
en la era de la
inteligencia artificial.”


EDITORIAL
SAGA

ISBN: 978-9907-803-75-4



9 789907 803754