

# USO DE INTELIGENCIA ARTIFICIAL EN EDUCACIÓN SUPERIOR:

DESARROLLO Y VALIDACIÓN  
DE UN MODELO CONDUCTUAL  
EN ESTUDIANTES  
UNIVERSITARIOS



AUTORAS:

Fabiola Lydie Rochin Berumen  
Carla Beatriz Capetillo Medrano



**Uso de inteligencia artificial en educación superior: desarrollo y validación de un modelo conductual en estudiantes universitarios**

**Fabiola Lydie Rochin Berumen**

**Carla Beatriz Capetillo Medrano**

# **Uso de inteligencia artificial en educación superior: desarrollo y validación de un modelo conductual en estudiantes universitarios**

Copyright © 2026 Autores.

Fabiola Lydie Rochin Berumen, Carla Beatriz Capetillo Medrano

Edición: Omniscens

Diseño de cubierta: Omniscens

Diseño interior: Omniscens

Primera edición: 2026

ISBN digital: 978-970-96207-0-2

físico: 978-970-96207-1-9

DOI: <https://doi.org/10.71112/c6a01e76>

Sello editorial: Omniscens Publishing (978-970-96928)

Categoría: Investigación

Tipo de Contenido: Texto académico

Lugar de publicación: Mérida, Yucatán, México

Esta obra fue dictaminada positivamente mediante revisión por pares doble ciego externos, a solicitud del Comité Editorial; está bajo una licencia internacional Creative Commons Atribución 4.0.

<https://creativecommons.org/licenses/by/4.0/>



**Omniscens Publishing**

[www.publishing.omniscens.com](http://www.publishing.omniscens.com)



## **Dedicatoria**

*A nuestros estudiantes universitarios, que con sus preguntas, sus dudas y su curiosidad ante la inteligencia artificial nos enseñaron que comprender el comportamiento humano es siempre el primer paso para transformar la educación.*

## Agradecimientos

A nuestras familias, por su paciencia incommensurable ante los ritmos y las exigencias propias de la vida académica, y por su apoyo silencioso e indispensable que hace posible cada proyecto de investigación.

A todas las personas que creen que entender cómo aprenden los estudiantes universitarios en la era de la inteligencia artificial no es un lujo académico, sino una responsabilidad científica y pedagógica de primer orden.

*Las autoras*

*Zacatecas, México, 2026*

## Prólogo

◆◆|-----|◆◆

Escribir el prólogo de un libro que una misma ha concebido, investigado y escrito en colaboración implica una paradoja singular: se trata de mirar desde afuera lo que se ha construido desde adentro, de describir con la perspectiva del lector aquello que se vivió con la intensidad del proceso de investigación. Esta distancia es, sin embargo, necesaria y reveladora, porque permite identificar con mayor claridad los hilos conductores que atraviesan la obra y los propósitos que la animaron desde su concepción.

Este libro nació de una pregunta que surgió en el aula universitaria, no en el escritorio académico. En el transcurso de los ciclos escolares 2024 y 2025, ambas autoras observamos en nuestras respectivas prácticas docentes un fenómeno que nos resultaba al mismo tiempo fascinante e inquietante: nuestros estudiantes estaban incorporando herramientas de inteligencia artificial en sus actividades académicas de manera acelerada, cotidiana y mayoritariamente autónoma, sin orientación pedagógica específica y sin marcos normativos institucionales claros que guiaran esa incorporación. Nos preguntamos qué sabía realmente la investigación científica sobre este comportamiento: por qué lo adoptaban, cómo lo hacían, qué consecuencias producía sobre su aprendizaje y qué podíamos hacer pedagógicamente al respecto.

La respuesta, como frecuentemente ocurre en la investigación científica, fue a la vez más compleja y más interesante de lo que habíamos anticipado. Descubrimos que la mayor parte de la investigación disponible sobre el uso de la inteligencia artificial en educación superior provenía de contextos anglosajones que no capturaban las especificidades del entorno universitario

latinoamericano. Descubrimos también que los modelos teóricos disponibles para comprender la adopción tecnológica en contextos educativos no estaban suficientemente articulados con las tradiciones de las ciencias de la conducta que, desde nuestra formación académica, nos parecían indispensables para comprender el fenómeno en toda su complejidad. Y descubrimos, sobre todo, que había una brecha real y significativa entre lo que los estudiantes universitarios mexicanos hacían con la inteligencia artificial y lo que las instituciones educativas sabían sobre ese comportamiento y estaban haciendo para orientarlo.

De esas tres constataciones nació el proyecto de investigación que da sustento a este libro, y de ese proyecto nació el Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior (MCUIA-ES) que constituye su aporte central. El modelo no es el resultado de una reflexión teórica abstracta, sino de un proceso de investigación empírica rigurosa que involucró a 1,247 estudiantes universitarios de tres instituciones públicas del estado de Zacatecas, México, y que articuló métodos cuantitativos y cualitativos para capturar tanto la distribución estadística de los patrones de comportamiento como los significados y las experiencias que los estudiantes asocian a su uso de la inteligencia artificial.

Lo que encontramos en ese proceso de investigación nos sorprendió y nos comprometió. Nos sorprendió la heterogeneidad real de los patrones de uso: no existe un único estudiante universitario ante la inteligencia artificial, sino una diversidad de perfiles conductuales que reflejan diferencias profundas en motivación, autonomía intelectual, valores éticos y condiciones contextuales. Nos comprometió el hallazgo consistente de que los estudiantes no perciben la ausencia de orientación pedagógica

institucional como neutralidad, sino como un abandono que los deja navegando sin criterios en un territorio normativamente complejo. Y nos motivó profundamente constatar que el perfil de uso académicamente más productivo y éticamente más responsable —el que denominamos usuario adaptativo reflexivo— no era una aspiración pedagógica idealista, sino una realidad conductual documentable en casi una quinta parte de la población estudiantil estudiada.

Este libro está organizado para acompañar al lector en un recorrido progresivo que va de lo conceptual a lo empírico y de lo descriptivo a lo interventivo. Los primeros capítulos establecen los marcos teóricos necesarios para comprender el fenómeno del uso de la inteligencia artificial en la educación superior desde las ciencias de la conducta. Los capítulos intermedios describen con rigor metodológico los instrumentos de medición desarrollados y los hallazgos del estudio empírico. Los últimos capítulos presentan las implicaciones de esos hallazgos y el modelo conductual integrado con su protocolo de intervención.

Escribimos este libro convencidas de que la inteligencia artificial no va a desaparecer de los entornos universitarios, y de que la pregunta relevante no es si los estudiantes deben usarla o no, sino cómo pueden usarla de manera que potencie genuinamente su aprendizaje, preserve su autonomía intelectual y sea coherente con los valores de la integridad académica. Responder esa pregunta con evidencia empírica, con marcos teóricos sólidos y con orientaciones pedagógicas concretas es el propósito que animó cada página de esta obra.

Confiamos en que las páginas que siguen resulten útiles a quienes, como nosotras, creen que comprender el comportamiento de los estudiantes universitarios es una condición indispensable para enseñarles bien en el presente y prepararlos para un futuro que ya está aquí.

## Resumen

Este libro presenta el desarrollo, la fundamentación empírica y la validación del Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior (MCUIA-ES), primera propuesta de este tipo construida en el contexto universitario latinoamericano desde las ciencias de la conducta. El modelo integra cinco tradiciones teóricas —análisis conductual aplicado, teoría cognitivo-social, teoría del comportamiento planificado, teoría de la autodeterminación y UTAUT2— en un marco de cinco componentes articulados que identifica los determinantes del uso de la IA, describe cinco dimensiones observables del comportamiento, predice sus consecuencias en tres horizontes temporales y orienta intervenciones pedagógicas e institucionales. Se reportan los hallazgos de un estudio empírico mixto con 1,247 estudiantes universitarios de instituciones públicas de Zacatecas, México, que valida empíricamente cinco perfiles conductuales y establece que la motivación intrínseca es el predictor más robusto de la calidad del uso de la IA. Se presenta el Inventario de Comportamiento de Uso de IA en Educación Superior (ICUIA-ES), instrumento de 52 ítems validado psicométricamente (CFI = .93, RMSEA = .058). Los resultados tienen implicaciones directas para el diseño de políticas educativas, la formación docente y el rediseño pedagógico en universidades latinoamericanas.

**Palabras clave:** Inteligencia artificial en la educación superior; modelo conductual; motivación académica; aprendizaje autorregulado; MCUIA-ES; contexto latinoamericano.

## Abstract

This book presents the development, empirical foundation, and validation of the Behavioral Model of Artificial Intelligence Use in Higher Education (MCUIA-ES), the first proposal of its kind built within the Latin American university context from a behavioral sciences perspective. The model integrates five theoretical traditions—applied behavior analysis, social cognitive theory, theory of planned behavior, self-determination theory, and UTAUT2—into a five-component framework that identifies determinants of AI use, describes five observable behavioral dimensions, predicts consequences across three temporal horizons, and guides pedagogical and institutional interventions. Findings from a mixed-methods empirical study with 1,247 university students from public institutions in Zacatecas, Mexico are reported, empirically validating five behavioral profiles and establishing that intrinsic motivation is the most robust predictor of AI use quality. The Inventory of AI Use Behavior in Higher Education (ICUIA-ES), a 52-item psychometrically validated instrument (CFI = .93, RMSEA = .058), is presented. Results have direct implications for educational policy design, teacher training, and pedagogical redesign in Latin American universities.

**Keywords:** Artificial intelligence in higher education; behavioral model; academic motivation; self-regulated learning; MCUIA-ES; Latin American context.

## Contenido

<b>INTRODUCCIÓN</b>	15
Aporte científico original de esta obra	16
<b>CAPÍTULO 1</b>	
<b>Transformación de la educación superior en la era de la inteligencia artificial</b>	19
1.1 La educación superior ante el cambio tecnológico acelerado	19
1.2 Caracterización de la inteligencia artificial en contextos educativos	21
1.3 El debate global sobre la IA en la educación superior	24
1.4 La perspectiva conductual como marco de análisis privilegiado	27
1.5 El contexto latinoamericano: particularidades y desafíos	29
1.6 Implicaciones para el modelo conductual	32
<b>CAPÍTULO 2</b>	
<b>Inteligencia artificial y procesos de aprendizaje en estudiantes universitarios</b>	33
2.1 El aprendizaje universitario como objeto de estudio conductual	33
2.2 Teorías del aprendizaje y su relación con la mediación tecnológica	35
2.3 Impacto de la inteligencia artificial en los procesos cognitivos del aprendizaje	37
2.4 Autorregulación del aprendizaje en entornos mediados por IA	39
2.5 Motivación académica y uso de la inteligencia artificial	41
2.6 Aprendizaje personalizado mediado por IA y retroalimentación	42
2.7 Implicaciones para el modelo conductual	44
<b>CAPÍTULO 3</b>	
<b>Comportamiento académico en entornos mediados por inteligencia artificial</b>	47
3.1 Conceptualización del comportamiento académico universitario	47
3.2 Variables del modelo: dependiente, independientes y mediadoras	48
3.2.1 Variable dependiente: el comportamiento de uso de la IA (CUIA)	48
3.2.2 Variables independientes	49
3.2.3 Variables mediadoras	50
3.3 Patrones de uso de la IA en la vida académica universitaria	50
3.4 Tipología conductual del estudiante universitario ante la IA	52
3.5 Comportamiento de estudio, escritura académica e integridad	54
3.6 Implicaciones para el modelo conductual	56

<b>CAPÍTULO 4</b>	
<b>Factores que influyen en el uso de inteligencia artificial en estudiantes universitarios</b>	<b>59</b>
4.1 Marco explicativo multifactorial del uso de la IA	59
4.2 Factores cognitivos individuales	60
4.3 Factores afectivos y disposicionales	61
4.4 Factores motivacionales	63
4.5 Factores sociales y normativos	64
4.6 Factores institucionales, pedagógicos y tecnológicos	66
4.7 Interacciones entre factores y moderadores relevantes	67
4.8 Implicaciones para el modelo conductual	69
<b>CAPÍTULO 5</b>	
<b>Medición del comportamiento académico y uso de inteligencia artificial</b>	<b>71</b>
5.1 El problema de la medición en ciencias de la conducta aplicadas a la educación	71
5.2 Enfoques metodológicos para el estudio del comportamiento mediado por IA	72
5.3 Construcción y validación del instrumento ICUIA-ES	73
5.4 El cuestionario ICUIA-ES: instrumento completo	74
5.5 Validez y confiabilidad en la medición del comportamiento académico mediado por IA	82
5.6 Interpretación de las puntuaciones del ICUIA-ES	83
5.7 Metodología de la investigación empírica	84
5.8 Sesgos metodológicos y estrategias de control	87
5.9 Implicaciones para el modelo conductual	87
<b>CAPÍTULO 6</b>	
<b>Análisis del uso de inteligencia artificial en estudiantes universitarios</b>	<b>89</b>
6.1 Diseño y contexto del estudio empírico	89
6.2 Participantes y procedimiento de muestreo	90
6.3 Análisis psicométrico de los instrumentos en la muestra del estudio	90
6.4 Estadística descriptiva: prevalencia y patrones de uso	91
6.5 Diferencias según variables sociodemográficas y disciplinarias	92
6.6 Correlaciones entre variables del modelo	93
6.7 Análisis de regresión múltiple: predictores del comportamiento de uso	94
6.8 Análisis de conglomerados: validación empírica de los perfiles conductuales	95
6.9 Hallazgos cualitativos: experiencias y significados del uso de IA	96
6.10 Integración de hallazgos cuantitativos y cualitativos	98
6.11 Implicaciones para el modelo conductual	99
<b>CAPÍTULO 7</b>	
<b>Implicaciones del uso de inteligencia artificial en el comportamiento académico</b>	<b>101</b>

7.1 De los patrones de uso a sus consecuencias: un marco analítico	101
7.2 Implicaciones sobre el rendimiento académico	102
7.3 Implicaciones sobre el desarrollo de competencias cognitivas	103
7.4 Implicaciones sobre la autorregulación y la autonomía del aprendizaje	105
7.5 Implicaciones sobre la motivación académica	106
7.6 Implicaciones sobre la integridad académica y el desarrollo moral	107
7.7 Implicaciones sobre la identidad del estudiante universitario	108
7.8 Implicaciones para la equidad educativa	109
7.9 Implicaciones para la formación docente y el diseño pedagógico	110
7.10 Implicaciones para la política educativa institucional	111
7.11 Implicaciones para el modelo conductual	112
<b>CAPÍTULO 8</b>	
<b>Propuesta de modelo conductual del uso de inteligencia artificial en educación superior</b>	115
8.1 Fundamentos y aporte científico del modelo MCIUA-ES	115
8.2 Bases teóricas integradas del MCIUA-ES	117
8.2.1 El análisis conductual aplicado como base fundamental	117
8.2.2 La teoría cognitivo-social como mecanismo de mediación	118
8.2.3 La teoría del comportamiento planificado como marco de la intención	118
8.2.4 La teoría de la autodeterminación como fundamento motivacional	119
8.2.5 La UTAUT2 como marco de adopción tecnológica	120
8.3 Arquitectura del MCIUA-ES: cinco componentes articulados	120
8.4 Componente 1: Sistema de antecedentes multifactoriales	122
8.5 Componente 2: Proceso de mediación cognitivo-motivacional	123
8.6 Componente 3: Comportamiento de uso diferenciado	125
8.7 Componente 4: Sistema de consecuencias multinivel	126
8.8 Componente 5: Sistema de retroalimentación recursiva	128
8.9 Postulados del MCIUA-ES	130
8.10 Operacionalización estadística del MCIUA-ES	133
8.11 Protocolo de intervención derivado del MCIUA-ES	134
8.11.1 Intervenciones a nivel individual	135
8.11.2 Intervenciones a nivel pedagógico	136
8.11.3 Intervenciones a nivel institucional	137
8.12 Alcances, limitaciones y agenda de investigación futura	138
8.13 El MCIUA-ES como contribución a las ciencias de la conducta y la educación superior	141
<b>CONCLUSIONES</b>	144
<b>REFERENCIAS</b>	147



## INTRODUCCIÓN

La irrupción de la inteligencia artificial (IA) en los entornos de educación superior representa uno de los fenómenos de transformación más acelerados y profundos que ha enfrentado la universidad contemporánea (Rochin, 2026). En un lapso de apenas tres años, herramientas de IA generativa han pasado de ser un objeto de interés especializado a convertirse en recursos cotidianos para millones de estudiantes universitarios en todo el mundo, modificando de manera sustantiva la forma en que aprenden, producen conocimiento académico, resuelven problemas y toman decisiones en sus trayectorias formativas (Crompton & Burke, 2023; Baidoo-Anu & Ansah, 2023). Esta transformación, sin embargo, no ha sido acompañada en la misma proporción por investigación científica sistemática que permita comprenderla desde las ciencias de la conducta y la educación, y menos aún desde el contexto universitario latinoamericano donde las condiciones de acceso, las tradiciones pedagógicas y las estructuras institucionales tienen características propias que los modelos desarrollados en otros contextos no capturan.

El presente libro surge precisamente de esa necesidad. Su propósito central es doble: por un lado, ofrecer un análisis teórico integrado y actualizado de los factores conductuales, cognitivos, motivacionales y contextuales que inciden en el uso de la inteligencia artificial entre estudiantes universitarios; por otro, presentar el desarrollo, la validación y las implicaciones de un modelo conductual original que permita comprender, predecir e intervenir en los patrones de uso de la IA en el ámbito de la educación superior. Este modelo no se concibe como un esquema rígido ni como una solución

definitiva, sino como un marco heurístico con vocación científica y utilidad práctica, que articula tradiciones teóricas consolidadas con evidencia empírica obtenida en contextos universitarios mexicanos (Molina-Gómez et al., 2024; Romero-García et al., 2023).

### **Aporte científico original de esta obra**

El aporte científico central de este libro es el desarrollo, la fundamentación empírica y la validación del Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior (MCUIA-ES). Este modelo constituye la primera propuesta de este tipo construida y validada en el contexto universitario latinoamericano desde la perspectiva articulada de las ciencias de la conducta. El MCUIA-ES integra cinco tradiciones teóricas complementarias: el análisis conductual aplicado, la teoría cognitivo-social, la teoría del comportamiento planificado, la teoría de la autodeterminación y la teoría unificada de aceptación y uso de tecnología en un marco explicativo de cinco componentes articulados que identifica los determinantes del comportamiento de uso de la IA, describe sus dimensiones observables en cinco variables medibles, predice sus consecuencias sobre el aprendizaje universitario en tres horizontes temporales y orienta el diseño de un protocolo de intervención tripartito con especificaciones accionables.

La contribución al contexto latinoamericano reside en que el MCUIA-ES fue construido y validado con evidencia empírica obtenida en universidades públicas mexicanas con una muestra de 1,247 estudiantes universitarios de tres instituciones del estado de Zacatecas, atendiendo a condiciones específicas de ese contexto que los modelos desarrollados en contextos anglosajones no capturan: la ambigüedad normativa institucional prevalente, las desigualdades de

acceso tecnológico, las tradiciones pedagógicas propias de la universidad pública latinoamericana y el perfil socioeconómico y cultural de la población estudiantil. El libro establece además el Inventario de Comportamiento de Uso de IA en Educación Superior (ICUIA-ES), un instrumento de medición con 52 ítems en escala Likert organizados en cinco dimensiones y tres escalas complementarias, validado psicométricamente con excelentes índices de ajuste ( $CFI = .93$ ,  $RMSEA = .058$ ) y coeficientes de confiabilidad omega entre  $.81$  y  $.89$ , disponible para su uso y adaptación en futuras investigaciones de la región. El MCUIA-ES y el ICUIA-ES están diseñados para generar tres a cuatro artículos científicos derivados que contribuyan a la agenda investigativa sobre IA y educación superior desde el contexto latinoamericano.

Abordar el uso de la inteligencia artificial en la educación superior desde la perspectiva de las ciencias de la conducta implica reconocer que esta adopción tecnológica es, antes que cualquier otra cosa, un comportamiento humano. Como tal, está sujeto a los mismos principios que gobiernan cualquier forma de comportamiento: se aprende, se refuerza, se extingue, se modela socialmente, está mediado por creencias, actitudes e intenciones, y produce consecuencias sobre el individuo y su entorno que retroalimentan el comportamiento futuro (Skinner, 1953; Bandura, 1986; Ajzen, 1991). Esta perspectiva, que puede parecer elemental en su formulación, tiene implicaciones metodológicas y pedagógicas de gran alcance que este libro busca explorar con el rigor y la profundidad que el fenómeno exige.

La obra está dirigida a investigadores en educación y ciencias del comportamiento, a docentes universitarios que buscan comprender cómo la IA está reconfigurando el entorno de aprendizaje de sus

estudiantes, y a tomadores de decisiones institucionales que enfrentan el desafío de regular, orientar o promover el uso de estas tecnologías en contextos académicos. Asimismo, constituye una referencia metodológica para estudiantes de posgrado interesados en la intersección entre tecnología educativa, comportamiento académico e investigación cuantitativa y cualitativa en el contexto latinoamericano.

El recorrido del libro está organizado de manera progresiva y coherente. Los primeros capítulos establecen el marco conceptual y contextualizan la transformación que la inteligencia artificial produce en la educación superior desde la perspectiva de las ciencias de la conducta. Los capítulos intermedios examinan los procesos de aprendizaje mediados por IA, el comportamiento académico de los estudiantes en sus dimensiones observables, y los factores individuales, sociales e institucionales que condicionan el uso de estas tecnologías. Los capítulos finales presentan el instrumento de medición completo con todos sus ítems, el análisis empírico detallado con los resultados estadísticos del estudio, las implicaciones conductuales del uso de la IA sobre el aprendizaje universitario, y el modelo conductual integrado con su protocolo de intervención derivado (Zawacki-Richter et al., 2019; Holmes et al., 2022). Las páginas que siguen no solo buscan describir qué ocurre cuando los estudiantes universitarios usan la inteligencia artificial; se proponen explicar por qué ocurre, bajo qué condiciones se refuerza o se extingue ese comportamiento, y qué consecuencias produce sobre la trayectoria académica y el desarrollo intelectual de los estudiantes. En esa explicación, fundamentada en evidencia empírica y en marcos teóricos validados, reside el aporte central de esta obra.

## CAPÍTULO 1

### Transformación de la educación superior en la era de la inteligencia artificial

#### 1.1 La educación superior ante el cambio tecnológico acelerado

La relación entre la universidad y las tecnologías del conocimiento ha definido, en gran medida, la historia de la educación superior. Desde la introducción de la imprenta en el siglo XV, que democratizó el acceso al texto escrito y transformó radicalmente las prácticas de enseñanza y aprendizaje, hasta la masificación de internet a finales del siglo XX, que redibujó los contornos del acceso al conocimiento y la comunicación académica, cada revolución tecnológica ha reconfigurado las formas en que el conocimiento se produce, se transmite y se aprende en los contextos universitarios (Selwyn, 2022). Sin embargo, la transformación que introduce la inteligencia artificial generativa en la segunda década del siglo XXI presenta características sin precedentes que la distinguen cualitativamente de todas las innovaciones tecnológicas anteriores en el ámbito educativo.

A diferencia de tecnologías previas que ampliaron el acceso a la información o facilitaron la comunicación, la inteligencia artificial generativa tiene la capacidad de intervenir directamente en procesos cognitivos que hasta hace muy poco se consideraban exclusivamente humanos: razonar sobre problemas complejos, producir texto coherente y argumentado, sintetizar grandes volúmenes de información, generar soluciones creativas y mantener conversaciones en lenguaje natural con un nivel de sofisticación que desafía las distinciones convencionales entre la cognición humana y la

computacional (Holmes et al., 2022; Crompton & Burke, 2023). Esta capacidad de intervención directa en los procesos cognitivos del aprendizaje es lo que convierte a la inteligencia artificial en un fenómeno cualitativamente distinto para la educación superior, y lo que justifica la necesidad de marcos conceptuales y empíricos específicos para comprenderla.

La aceleración de este proceso es documentable con cifras concretas. Herramientas de IA conversacional como ChatGPT alcanzaron cien millones de usuarios en menos de dos meses tras su lanzamiento en noviembre de 2022, una velocidad de adopción sin precedentes en la historia de las tecnologías digitales que tardó décadas en lograr cifras equivalentes (Tlili et al., 2023). En el contexto de la educación superior, encuestas realizadas en múltiples países durante 2023 y 2024 reportaron que entre el 60 y el 80 por ciento de los estudiantes universitarios había utilizado herramientas de IA generativa para actividades académicas durante el último año académico, con independencia de si sus instituciones contaban o no con políticas explícitas al respecto (Perkins et al., 2023; Farhi et al., 2023). Este dato, por sí solo, revela la urgencia de contar con investigación sistemática y fundada sobre el fenómeno.

Este ritmo de adopción ha superado ampliamente la capacidad de respuesta de las instituciones de educación superior, que en su mayoría se encuentran todavía elaborando políticas, revisando sistemas de evaluación y debatiendo las implicaciones pedagógicas de una tecnología que sus estudiantes ya utilizan de manera cotidiana (Zawacki-Richter et al., 2019; Rudolph et al., 2023). Este desfase entre la adopción espontánea por parte de los estudiantes y la respuesta institucional constituye uno de los desafíos más urgentes que enfrentan las universidades contemporáneas, y es uno de los

fenómenos que este libro busca comprender, explicar e intervenir desde una perspectiva conductual.

Desde las ciencias de la conducta, esta situación puede analizarse como un caso paradigmático de comportamiento de adopción tecnológica en condiciones de ambigüedad normativa: los estudiantes adoptan una herramienta que perciben como útil y accesible, en ausencia de señales institucionales claras sobre su uso apropiado, guiados por el reforzamiento inmediato que proporciona la reducción del esfuerzo cognitivo y el cumplimiento de tareas académicas (Davis et al., 2020; Sindre & Moody, 2022). Comprender este comportamiento en sus dimensiones cognitivas, motivacionales y contextuales es el primer paso para diseñar respuestas pedagógicas e institucionales que sean a la vez realistas y pedagógicamente fundamentadas.

## **1.2 Caracterización de la inteligencia artificial en contextos educativos**

Para analizar el impacto de la inteligencia artificial en la educación superior desde una perspectiva conductual, resulta indispensable precisar a qué se refiere este concepto en el contexto educativo contemporáneo. La inteligencia artificial, en sentido amplio, designa el conjunto de sistemas computacionales capaces de realizar tareas que, si fueran ejecutadas por seres humanos, requerirían inteligencia (Russell & Norvig, 2020). En el ámbito educativo, esta definición general se concreta en una tipología de sistemas con propiedades y efectos conductuales diferenciados que es importante distinguir para evitar generalizaciones que confundan fenómenos cualitativamente distintos.

Holmes et al. (2022) proponen una clasificación de los sistemas de IA en educación en tres grandes categorías con implicaciones pedagógicas diferenciadas. La primera comprende los sistemas de tutoría inteligente (STI), diseñados específicamente para el contexto educativo con el propósito de personalizar la instrucción, adaptando el contenido, el ritmo y la retroalimentación a las características individuales del estudiante. Estos sistemas tienen una trayectoria de investigación de más de cuatro décadas y cuentan con una base empírica sólida sobre su efectividad en dominios específicos como las matemáticas, la física y las ciencias de la computación (VanLehn, 2011; Ma et al., 2020). La segunda categoría incluye los sistemas de análisis del aprendizaje (learning analytics), que procesan grandes volúmenes de datos sobre el comportamiento de los estudiantes en plataformas digitales para identificar patrones, predecir resultados y generar intervenciones tempranas orientadas a reducir la deserción y mejorar el rendimiento académico.

La tercera categoría, y la más relevante para los propósitos de este libro, abarca los modelos de lenguaje de gran escala (Large Language Models, LLM) y los sistemas de IA generativa, capaces de producir textos, resolver problemas, generar código y mantener conversaciones en lenguaje natural con un nivel de sofisticación que no tiene precedentes en la historia de la inteligencia artificial aplicada. Es esta tercera categoría la que ha producido la transformación más visible y disruptiva en los entornos universitarios actuales, en gran medida porque no fue diseñada específicamente para contextos educativos, sino que emergió en el mercado de consumo masivo y fue adoptada de manera espontánea por los estudiantes antes de que las instituciones educativas pudieran

anticipar sus implicaciones (Baidoo-Anu & Ansah, 2023; Farhi et al., 2023).

La disponibilidad de herramientas como ChatGPT, Claude, Gemini, Copilot y otras plataformas similares ha colocado en manos de cualquier estudiante universitario con acceso a internet un conjunto de capacidades que anteriormente requerían conocimientos técnicos especializados o el acceso a recursos institucionales costosos: síntesis de información compleja, generación de textos académicos en múltiples géneros, resolución de problemas matemáticos y lógicos, programación en múltiples lenguajes, traducción de alta calidad, análisis de datos y generación de visualizaciones, entre muchas otras (Baidoo-Anu & Ansah, 2023; Farhi et al., 2023). Esta democratización tecnológica tiene consecuencias conductuales de gran alcance que este libro examina en profundidad a lo largo de sus capítulos.

Desde la perspectiva de las ciencias de la conducta, lo relevante no es únicamente qué pueden hacer estas herramientas en términos técnicos, sino cómo los estudiantes universitarios las incorporan a sus repertorios conductuales, qué contingencias refuerzan o inhiben su uso, qué creencias y actitudes median su adopción y sus patrones de utilización, y qué consecuencias produce su uso sobre el comportamiento académico a corto, mediano y largo plazo (Skinner, 1953; Bandura, 1986; Tlili et al., 2023). Estas preguntas constituyen el núcleo de la agenda investigativa que da sustento a esta obra y que se articula en torno al Modelo Conductual del Uso de la IA en Educación Superior (MCUIA-ES) presentado en el Capítulo 8.

### **1.3 El debate global sobre la IA en la educación superior**

La irrupción de la inteligencia artificial en los entornos universitarios ha desencadenado un debate global que involucra a instituciones académicas, organismos internacionales, gobiernos, empresas tecnológicas, docentes y estudiantes. Este debate no es homogéneo ni está cerca de resolverse; atraviesa posturas que van desde el entusiasmo tecnológico más optimista, que ve en la IA la herramienta que finalmente permitirá personalizar el aprendizaje a escala masiva, hasta la resistencia pedagógica más cautelosa, que advierte sobre los riesgos de erosionar competencias cognitivas fundamentales e impactar negativamente la integridad académica y la equidad educativa (Selwyn, 2022; Rudolph et al., 2023). Comprender la complejidad y la legitimidad de ambas posiciones es condición indispensable para adoptar una perspectiva analítica rigurosa sobre el fenómeno.

Entre los argumentos que sostienen el potencial positivo de la IA en la educación superior, la literatura reciente destaca un conjunto de contribuciones documentadas empíricamente. La personalización del aprendizaje a una escala antes imposible representa quizás el argumento más poderoso: los sistemas de tutoría inteligente han demostrado ser capaces de adaptar la instrucción a las necesidades individuales de los estudiantes con efectividad comparable a la de la tutoría humana uno a uno, un modelo que Benjamin Bloom identificó en 1984 como el más efectivo para el aprendizaje pero que siempre había resultado inaccesible a escala masiva (Bloom, 1984; VanLehn, 2011). A este argumento se añaden el apoyo a estudiantes con necesidades educativas específicas, la retroalimentación inmediata y contextualizada que puede acelerar el proceso de aprendizaje, la posibilidad de liberar tiempo docente para actividades de mayor

valor pedagógico como el diálogo socrático y la mentoría personalizada, y la reducción de barreras de acceso al conocimiento especializado en contextos con recursos limitados (Crompton & Burke, 2023; Baidoo-Anu & Ansah, 2023).

La UNESCO (2023) ha señalado que, utilizada de manera reflexiva y equitativa, la inteligencia artificial puede contribuir significativamente a la calidad, pertinencia e inclusión de la educación superior en el siglo XXI, articulando objetivos de desarrollo sostenible con las potencialidades tecnológicas disponibles. Este posicionamiento institucional no implica una adopción acrítica de la tecnología, sino el reconocimiento de que ignorar sus potencialidades en nombre de la cautela puede perpetuar desigualdades educativas que la tecnología podría contribuir a reducir.

Sin embargo, el debate recoge también preocupaciones documentadas y fundamentadas científicamente que sería imprudente ignorar. La integridad académica es quizás la más inmediata y la que ha capturado mayor atención mediática e institucional: la posibilidad de que los estudiantes deleguen en sistemas de IA tareas que deberían realizar de manera autónoma ha generado una crisis en las formas tradicionales de evaluación universitaria que ninguna institución de educación superior puede ignorar (Perkins et al., 2023; Rudolph et al., 2023). Investigaciones recientes han mostrado que entre el 30 y el 50 por ciento de los estudiantes universitarios reconoce haber utilizado IA generativa en evaluaciones sin declararlo, lo que plantea desafíos inéditos para la cultura de integridad académica institucional y para la validez de las calificaciones como indicadores del aprendizaje (Farhi et al., 2023; Chaudhry et al., 2023).

Más allá de la integridad académica, los análisis críticos señalan riesgos de mayor profundidad y de más difícil detección: la posible erosión del pensamiento crítico y la creatividad cuando el esfuerzo cognitivo es sistemáticamente externalizado a sistemas automatizados, la dependencia tecnológica que puede reducir progresivamente la autonomía intelectual de los estudiantes, la reproducción y amplificación de sesgos presentes en los datos de entrenamiento de los sistemas de IA, y la concentración de datos educativos sensibles en plataformas comerciales con regulación aún insuficiente (Bender et al., 2021; Tlili et al., 2023; Selwyn, 2022). Estos riesgos no son hipotéticos; la investigación empírica reciente ha comenzado a documentarlos en poblaciones universitarias concretas, aunque con la limitación de que muchos de sus efectos más profundos solo serán visibles a mediano y largo plazo (Molina-Gómez et al., 2024).

Este panorama de tensiones y posibilidades sitúa a las instituciones de educación superior ante un desafío de gran complejidad: cómo responder de manera fundamentada, pedagógicamente coherente y éticamente responsable ante una transformación tecnológica de tal magnitud. La respuesta a este desafío no puede basarse en la intuición ni en la extrapolación de experiencias pasadas con tecnologías que tenían propiedades radicalmente distintas; requiere investigación empírica sistemática sobre el comportamiento de los estudiantes universitarios en entornos mediados por inteligencia artificial, y marcos teóricos suficientemente sofisticados para interpretar esa investigación (Zawacki-Richter et al., 2019; Holmes et al., 2022). Esa es precisamente la contribución que este libro busca ofrecer.

## **1.4 La perspectiva conductual como marco de análisis privilegiado**

Frente a la complejidad del fenómeno descrito, este libro adopta la perspectiva de las ciencias de la conducta como marco primario de análisis. Esta elección responde a la convicción, fundamentada en la evidencia disponible, de que el uso de la inteligencia artificial en contextos educativos es, antes que cualquier otra cosa, un comportamiento humano. Como tal, está sujeto a los mismos principios que gobiernan cualquier forma de comportamiento: se aprende, se refuerza, se extingue, se modela socialmente, está mediado por creencias, actitudes e intenciones, y produce consecuencias sobre el individuo y su entorno que, a su vez, retroalimentan el comportamiento futuro (Skinner, 1953; Bandura, 1986; Ajzen, 1991). Esta afirmación, que puede parecer elemental, tiene implicaciones metodológicas y pedagógicas de gran alcance que este libro busca explorar con rigor.

El marco conductual adoptado en esta obra integra múltiples tradiciones teóricas complementarias cuya articulación se fundamenta en una lógica de complementariedad explicativa, no de eclecticismo teórico. Del conductismo operante de Skinner (1953) y del análisis conductual aplicado de Cooper et al. (2020) recupera los principios de reforzamiento, extinción y control de estímulos que permiten analizar cómo los contextos académicos moldean el comportamiento de uso de la IA a través de las contingencias que establecen. De la teoría cognitivo-social de Bandura (1986, 1997) incorpora los conceptos de autoeficacia, modelamiento social y expectativas de resultado, que han demostrado ser predictores robustos de la adopción y el mantenimiento de comportamientos tecnológicos en contextos educativos (Scherer et al., 2019).

De la teoría del comportamiento planificado de Ajzen (1991) retoma la articulación entre actitudes, normas subjetivas, control conductual percibido e intención de comportamiento, que constituye uno de los marcos predictivos más sólidos para comprender la adopción tecnológica en contextos universitarios. En el campo específico de la adopción tecnológica, el Modelo de Aceptación Tecnológica (TAM) de Davis (1989) y la Teoría Unificada de Aceptación y Uso de Tecnología (UTAUT2) de Venkatesh et al. (2012) han constituido los referentes más influyentes para comprender por qué las personas adoptan o rechazan nuevas tecnologías, y sus contribuciones se integran en el MCUIA-ES de manera articulada con las tradiciones conductuales y cognitivo-sociales. Finalmente, la teoría de la autodeterminación de Deci y Ryan (2000) proporciona el marco para comprender la dimensión motivacional del comportamiento de uso y sus consecuencias sobre el bienestar académico y el aprendizaje a largo plazo.

Sin embargo, la adopción de la inteligencia artificial generativa en contextos de educación superior presenta características que los modelos clásicos de aceptación tecnológica no capturan plenamente. A diferencia de herramientas digitales previas, la IA generativa puede reemplazar, complementar o transformar procesos cognitivos que hasta ahora se consideraban consustanciales al aprendizaje universitario: la búsqueda y síntesis crítica de información, la escritura académica argumentada, la resolución de problemas complejos, la generación de ideas originales y el razonamiento discursivo (Crompton & Burke, 2023; Rudolph et al., 2023). Esto implica que los factores conductuales que inciden en su adopción trascienden la percepción de utilidad y facilidad de uso para incluir dimensiones éticas, identitarias, motivacionales y contextualmente

situadas de mayor complejidad que exigen un modelo específico para este fenómeno (Tlili et al., 2023; Molina-Gómez et al., 2024).

Esta complejidad justifica el desarrollo del Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior (MCUIA-ES) que constituye el propósito central de esta obra. Ese modelo, presentado en el Capítulo 8, integra contribuciones de las cinco tradiciones teóricas mencionadas y se fundamenta en evidencia empírica obtenida mediante instrumentos validados en el contexto universitario mexicano, lo que le confiere pertinencia específica para los escenarios latinoamericanos contemporáneos.

### **1.5 El contexto latinoamericano: particularidades y desafíos**

La mayor parte de la investigación científica sobre el uso de la inteligencia artificial en educación superior proviene de contextos anglosajones, con una concentración notable en Estados Unidos, el Reino Unido, Australia y los países del norte de Europa (Zawacki-Richter et al., 2019; Holmes et al., 2022). Esta asimetría geográfica en la producción científica introduce sesgos significativos en la comprensión del fenómeno que no pueden ser ignorados: las condiciones de acceso tecnológico, las tradiciones pedagógicas, las estructuras institucionales, los marcos normativos y los contextos socioculturales de los países latinoamericanos difieren sustancialmente de los contextos en que se ha generado la mayor parte del conocimiento disponible sobre el uso de la IA en educación superior.

América Latina presenta un panorama heterogéneo pero crecientemente relevante en lo que respecta a la adopción de la IA en la educación superior. Datos recientes de la CEPAL (2022) indican que la región ha experimentado un crecimiento acelerado en la conectividad digital universitaria durante los últimos cinco años, impulsado en parte por la transformación forzosa provocada por la pandemia de COVID-19, aunque persisten brechas significativas vinculadas al estrato socioeconómico de los estudiantes, la región geográfica de las instituciones, el tipo de institución educativa y las condiciones de infraestructura tecnológica. Estas brechas no son simplemente brechas de acceso; son brechas de aprovechamiento que determinan de manera significativa la calidad del uso que los estudiantes pueden hacer de las herramientas de IA cuando acceden a ellas.

En México específicamente, investigaciones recientes señalan que más del 65 por ciento de los estudiantes universitarios en instituciones públicas urbanas utiliza herramientas de IA generativa al menos una vez a la semana para actividades académicas, un porcentaje que se incrementa en las universidades con mayor acceso a dispositivos y conectividad de alta velocidad (Romero-García et al., 2023; Molina-Gómez et al., 2024). Sin embargo, la mayoría de estos estudiantes reporta que su uso de la IA se desarrolla en ausencia de orientación pedagógica específica por parte de sus instituciones o sus docentes, lo que crea condiciones para el desarrollo de patrones de uso que pueden ser académicamente improductivos o éticamente problemáticos.

Las universidades públicas mexicanas enfrentan el reto de incorporar la IA en sus procesos académicos en un marco de recursos limitados, políticas institucionales incipientes y formación docente insuficiente para abordar pedagógicamente las implicaciones de esta tecnología (Secretaría de Educación Pública, 2023). Los estudiantes universitarios mexicanos, como sus pares latinoamericanos, han adoptado la inteligencia artificial de manera predominantemente informal y autónoma, sin orientación pedagógica sistemática que les ayude a desarrollar un uso crítico, ético y académicamente productivo de estas herramientas. Esta situación no es simplemente un rezago institucional que se resolverá con el tiempo; es un problema activo que tiene consecuencias sobre la calidad del aprendizaje universitario que requiere atención investigativa y pedagógica urgente.

La singularidad del contexto latinoamericano en relación con el uso de la IA en educación superior no radica únicamente en las condiciones materiales de acceso, aunque estas son importantes. Radica también en características culturales e institucionales específicas: las relaciones de autoridad en el aula universitaria, que pueden modular de manera distinta la influencia de las expectativas docentes sobre el comportamiento de los estudiantes; las normas culturales sobre el trabajo intelectual y la meritocracia académica, que pueden dar forma diferente a las presiones sociales hacia el uso de la IA; y las tradiciones pedagógicas propias de la región, que pueden ser más o menos receptivas a la integración de la IA en los diseños curriculares (Molina-Gómez et al., 2024; Romero-García et al., 2023). El modelo propuesto en este libro busca capturar estas especificidades contextuales en sus componentes y en las orientaciones de intervención que propone.

## 1.6 Implicaciones para el modelo conductual

Los elementos contextuales y teóricos analizados en este capítulo configuran las bases conceptuales sobre las que se construye el MCUIA-ES y establecen tres implicaciones directas para su arquitectura. La primera implicación es la necesidad de un modelo específicamente diseñado para el contexto latinoamericano: los modelos de adopción tecnológica desarrollados en contextos anglosajones no capturan las especificidades culturales, institucionales y materiales que condicionan el comportamiento de uso de la IA en las universidades públicas de México y América Latina. Esto justifica que el MCUIA-ES incorpore como antecedentes específicos las condiciones de acceso tecnológico y la ambigüedad normativa institucional, que tienen un peso predictivo desproporcionadamente alto en este contexto. La segunda implicación es que la perspectiva conductual integradora —que articula reforzamiento, autoeficacia, normas subjetivas y motivación intrínseca— es el marco más adecuado para comprender un comportamiento que es simultáneamente individual, social e institucionalmente condicionado. La tercera implicación es que el modelo debe tener explícitamente en cuenta el desfase entre la adopción espontánea de la IA por parte de los estudiantes y la respuesta institucional, ya que ese desfase configura una condición de ambigüedad normativa que tiene efectos específicos y predecibles sobre el tipo de comportamiento de uso que los estudiantes desarrollan.

## CAPÍTULO 2

### Inteligencia artificial y procesos de aprendizaje en estudiantes universitarios

#### 2.1 El aprendizaje universitario como objeto de estudio conductual

El aprendizaje en la educación superior ha sido estudiado desde múltiples perspectivas teóricas que, lejos de ser excluyentes, ofrecen lentes complementarios para comprender un fenómeno de gran complejidad. Desde el conductismo hasta el constructivismo, desde la psicología cognitiva hasta los enfoques socioculturales, cada tradición ha aportado elementos conceptuales que permiten explicar cómo los estudiantes universitarios adquieren, procesan, organizan y aplican el conocimiento en contextos académicos formales (Biggs & Tang, 2011). La irrupción de la inteligencia artificial en estos contextos no invalida ninguno de estos marcos; los resignifica y los somete a nuevas pruebas empíricas que en muchos casos revelan tanto sus potencialidades como sus límites explicativos.

Desde la perspectiva conductual, el aprendizaje universitario puede concebirse como un conjunto de comportamientos académicos que se adquieren, se mantienen y se modifican en función de las contingencias de reforzamiento presentes en el entorno educativo (Skinner, 1953). Estudiar, leer, escribir, resolver problemas, participar en clase, buscar información y producir conocimiento son, en este sentido, comportamientos que responden a estímulos antecedentes y que generan consecuencias que retroalimentan su probabilidad de ocurrencia futura. La inteligencia artificial modifica de manera sustantiva estas contingencias, al alterar tanto los estímulos que preceden al comportamiento académico como las

consecuencias que lo siguen. Un estudiante que sabe que puede obtener un borrador de ensayo en segundos experimenta un contexto de estímulos completamente distinto al de un estudiante que debe construir ese borrador desde cero; las contingencias que moldean el comportamiento de escritura académica se transforman de manera profunda cuando la IA está disponible como alternativa (Ouyang & Jiao, 2021; Zawacki-Richter et al., 2019).

Desde la perspectiva cognitivo-social, el aprendizaje universitario implica procesos de autorregulación que van más allá del condicionamiento operante e incluyen la planificación, el monitoreo, la evaluación y la adaptación estratégica del comportamiento académico en función de metas y estándares internalizados (Zimmerman, 2000; Pintrich, 2004). La teoría de la autoeficacia de Bandura (1997) ha demostrado ser especialmente relevante para comprender cómo las creencias de los estudiantes sobre su propia competencia mediatizan la adopción de nuevas estrategias de aprendizaje, incluyendo las mediadas por tecnología. Investigaciones recientes han extendido este marco al análisis del uso de la inteligencia artificial, encontrando que la autoeficacia tecnológica y la autoeficacia académica general son predictores significativos de la frecuencia y la calidad del uso de herramientas de IA en contextos universitarios: los estudiantes que confían en su capacidad para utilizar estas herramientas de manera efectiva tienden a hacerlo con mayor sofisticación y con mejores resultados académicos (Scherer et al., 2019; Yue et al., 2023).

La integración de estas perspectivas teóricas resulta necesaria para comprender la complejidad del aprendizaje universitario mediado por inteligencia artificial. Un enfoque puramente conductual captaría los patrones de uso observable pero perdería de vista los procesos

cognitivos y metacognitivos que los sustentan y que determinan en buena medida la calidad y el impacto del uso. Un enfoque exclusivamente cognitivo podría subvalorar el papel de las contingencias ambientales y sociales que moldean el comportamiento, ignorando el hecho de que los mismos estudiantes muestran patrones de uso cualitativamente distintos en contextos académicos con contingencias diferentes. La perspectiva integradora adoptada en este capítulo busca articular ambas dimensiones en un análisis que haga justicia a la complejidad del fenómeno estudiado (Ouyang & Jiao, 2021; Roll & Wylie, 2016).

## **2.2 Teorías del aprendizaje y su relación con la mediación tecnológica**

La relación entre las teorías del aprendizaje y la mediación tecnológica ha sido objeto de un debate sostenido durante las últimas décadas. La teoría del aprendizaje potenciado por inteligencia artificial ha comenzado a articularse como un marco específico para comprender las formas en que los sistemas de IA pueden amplificar, complementar o transformar los procesos de aprendizaje humano (Luckin & Cukurova, 2019). Este enfoque no concibe la IA como un sustituto del aprendiz humano, sino como un socio cognitivo que puede asumir funciones de andamiaje, retroalimentación y personalización que históricamente han sido responsabilidad exclusiva del docente.

La noción de zona de desarrollo próximo de Vygotsky (1978) ha sido recuperada en este contexto para argumentar que los sistemas de IA pueden funcionar como andamiajes dinámicos que ajustan su nivel de apoyo a las necesidades específicas de cada estudiante, operando precisamente en ese espacio entre lo que el estudiante

puede hacer de manera autónoma y lo que puede lograr con apoyo externo (Roll & Wylie, 2016; Ouyang & Jiao, 2021). Esta analogía es poderosa pero requiere matizaciones importantes: los andamiajes efectivos en el sentido vygotskiano están diseñados para ser progresivamente retirados a medida que el estudiante desarrolla las competencias correspondientes, mientras que las herramientas de IA están diseñadas para mantenerse disponibles de manera permanente sin que ese proceso de retirada gradual esté integrado en su diseño pedagógico.

La teoría de la carga cognitiva, desarrollada originalmente por Sweller (1988) y refinada en décadas posteriores, ofrece otro marco especialmente relevante. Esta teoría postula que la memoria de trabajo humana tiene una capacidad limitada y que el diseño de entornos de aprendizaje debe gestionar la carga cognitiva de manera que los recursos atencionales se orienten hacia los procesos de aprendizaje genuino y no hacia tareas periféricas (Sweller et al., 2019). Las herramientas de IA generativa pueden reducir la carga cognitiva extrínseca al automatizar tareas de búsqueda, síntesis y formateo de información, liberando recursos cognitivos para procesos de orden superior. Sin embargo, investigaciones recientes advierten que esta reducción puede tener consecuencias paradójicas: al externalizar procesos cognitivos que son parte constitutiva del aprendizaje, las herramientas de IA pueden inhibir el desarrollo de las competencias que buscan potenciar (Kalyuga, 2023; Westphal et al., 2023).

La teoría del aprendizaje multimedia de Mayer (2009) aporta principios adicionales relevantes. Sus principios sobre la integración de múltiples modalidades de representación han sido extendidos al análisis de entornos mediados por IA, encontrando que la efectividad

de estas herramientas depende en gran medida de cómo se integran en el diseño pedagógico y de la capacidad del estudiante para regular activamente su interacción con los sistemas de IA, evaluando críticamente los outputs generados en lugar de adoptarlos de manera pasiva (Mayer & Fiorella, 2022; Schneider et al., 2022).

### **2.3 Impacto de la inteligencia artificial en los procesos cognitivos del aprendizaje**

El impacto de la inteligencia artificial en los procesos cognitivos del aprendizaje universitario es uno de los temas más debatidos y menos comprendidos en la literatura científica reciente. La investigación disponible sugiere que este impacto es multidimensional, heterogéneo y fuertemente dependiente del tipo de herramienta utilizada, la naturaleza de la tarea académica y las características individuales del estudiante (Kalyuga, 2023; Ouyang & Jiao, 2021).

En lo que respecta a los procesos de memoria y retención, investigaciones previas habían documentado el fenómeno de la descarga cognitiva digital, que describe la tendencia de los estudiantes a externalizar en dispositivos digitales información que anteriormente habrían almacenado en la memoria, con consecuencias ambiguas sobre la calidad del aprendizaje (Sparrow et al., 2011). Con la generalización del uso de la IA generativa, este fenómeno se ha intensificado y ha adoptado formas nuevas y más complejas: los estudiantes no solo externalizan el almacenamiento de información, sino también los procesos de síntesis, elaboración y generación de texto que son fundamentales para la consolidación del aprendizaje en la memoria a largo plazo. La pregunta que plantean estos hallazgos no es simplemente si los estudiantes recuerdan

menos información, sino si están desarrollando los procesos cognitivos que el aprendizaje universitario profundo requiere (Westphal et al., 2023; Kalyuga, 2023).

En el ámbito del pensamiento crítico y el razonamiento argumentativo, la evidencia disponible es genuinamente ambivalente, lo que subraya la importancia de no adoptar posiciones categóricas en un campo donde la investigación está aún en sus etapas iniciales. Algunos estudios reportan que el uso reflexivo de herramientas de IA como interlocutor dialéctico puede estimular el pensamiento crítico al exponer a los estudiantes a perspectivas alternativas y al obligarlos a evaluar y seleccionar entre múltiples respuestas posibles, desarrollando así capacidades de evaluación crítica que tienen valor independiente del contenido específico que se aprende (Guo et al., 2023; Hwang et al., 2020). Sin embargo, otras investigaciones documentan que el uso no reflexivo de la IA generativa puede inhibir el desarrollo del pensamiento crítico al proveer respuestas elaboradas que los estudiantes adoptan sin cuestionar, reduciendo las oportunidades de práctica del razonamiento autónomo precisamente en los contextos donde esa práctica es más necesaria (Bender et al., 2021; Chaudhry et al., 2023).

El impacto de la IA en los procesos de resolución de problemas y creatividad académica constituye otro campo de investigación activa con hallazgos que desafían intuiciones simples. Estudios recientes han encontrado que los estudiantes universitarios que utilizan herramientas de IA para la resolución de problemas matemáticos o lógicos obtienen mejores resultados en el producto final a corto plazo, pero muestran un menor desarrollo de las estrategias metacognitivas de resolución de problemas en comparación con estudiantes que trabajan sin apoyo de IA (Westphal et al., 2023; Kalyuga, 2023). En

el campo de la escritura académica, investigaciones recientes documentan que el uso de IA generativa puede mejorar la calidad formal de los textos producidos en términos de coherencia, gramática y estructura, pero reduce la originalidad argumentativa y la voz autoral del estudiante cuando se utiliza de manera irrestricta como generador de contenido más que como herramienta de apoyo al proceso de escritura (Perkins et al., 2023; Rudolph et al., 2023).

Estos hallazgos no conducen a una conclusión simple de rechazo o aceptación de la IA en los procesos de aprendizaje universitario, sino a una comprensión más matizada: el impacto cognitivo de estas herramientas depende de manera crítica de cómo son utilizadas, en qué momentos del proceso de aprendizaje se introducen y con qué orientación pedagógica se acompañan. Esta constatación subraya la importancia central de comprender el comportamiento de uso de los estudiantes universitarios como la variable mediadora fundamental entre la disponibilidad de herramientas de IA y sus efectos sobre el aprendizaje.

## **2.4 Autorregulación del aprendizaje en entornos mediados por IA**

La autorregulación del aprendizaje constituye uno de los constructos más relevantes para comprender la relación entre el uso de la inteligencia artificial y la calidad del aprendizaje universitario. Definida como la capacidad del estudiante para planificar, monitorear y evaluar sus propios procesos de aprendizaje en función de metas establecidas, la autorregulación ha sido identificada consistentemente como uno de los predictores más robustos del rendimiento académico en la educación superior, con efectos que se mantienen incluso controlando variables como la capacidad

cognitiva general y el rendimiento académico previo (Zimmerman, 2000; Pintrich, 2004; Richardson et al., 2012).

La irrupción de la inteligencia artificial en los entornos de aprendizaje universitario plantea desafíos específicos para la autorregulación que van más allá de los identificados en investigaciones sobre tecnologías educativas previas. Por un lado, algunas investigaciones sugieren que las herramientas de IA pueden apoyar la autorregulación al proporcionar retroalimentación inmediata y personalizada que permite a los estudiantes identificar brechas en su comprensión y ajustar sus estrategias de estudio en consecuencia (Lim et al., 2023; Guo et al., 2023). Esta función de retroalimentación formativa ha sido históricamente una de las limitaciones más importantes de los entornos universitarios masificados, donde el número de estudiantes por docente hace imposible la retroalimentación individualizada y oportuna que la investigación sobre aprendizaje identifica como uno de los factores más potentes del rendimiento académico (Hattie & Timperley, 2007).

Por otro lado, investigaciones recientes advierten con evidencia creciente que el uso no regulado de herramientas de IA puede erosionar precisamente las capacidades de autorregulación que el aprendizaje universitario busca desarrollar. Cuando los estudiantes utilizan la IA para eludir etapas del proceso de aprendizaje en lugar de apoyarse en ella para atravesarlas de manera más efectiva, se produce lo que algunos autores denominan la paradoja de la asistencia: la herramienta diseñada para apoyar el aprendizaje termina sustituyéndolo, y el estudiante desarrolla el producto académico esperado sin haber realizado los procesos cognitivos que ese producto debía evidenciar (Westphal et al., 2023; Kalyuga, 2023). Esta paradoja es especialmente pronunciada en el contexto

universitario latinoamericano, donde las presiones académicas, la falta de orientación pedagógica sobre el uso de la IA y la ausencia de políticas institucionales claras crean condiciones que favorecen un uso instrumental y superficial de estas herramientas.

## **2.5 Motivación académica y uso de la inteligencia artificial**

La motivación académica constituye otro de los constructos centrales para comprender la relación entre el uso de la inteligencia artificial y los procesos de aprendizaje universitario. La teoría de la autodeterminación de Deci y Ryan (2000) distingue entre motivación intrínseca, orientada hacia el aprendizaje y el dominio por su valor inherente, y motivación extrínseca en sus diversas formas, orientada hacia la obtención de recompensas externas como calificaciones, reconocimiento social o evitación de consecuencias negativas. Esta distinción tiene implicaciones directas para comprender por qué y cómo los estudiantes universitarios utilizan la inteligencia artificial en sus actividades académicas, ya que el tipo de motivación dominante predice de manera significativa el perfil de uso.

Investigaciones recientes han encontrado asociaciones significativas y consistentes entre el perfil motivacional de los estudiantes universitarios y los patrones de uso de la inteligencia artificial. Los estudiantes con motivación predominantemente intrínseca tienden a utilizar la IA como herramienta de exploración y profundización del conocimiento: formulan preguntas complejas que les permiten explorar los límites de su comprensión, evalúan críticamente las respuestas obtenidas y las integran con sus propios marcos de comprensión como punto de partida para el pensamiento propio, no como producto terminado (Guo et al., 2023; Lim et al., 2023). Por el contrario, los estudiantes con motivación

predominantemente extrínseca tienden a utilizar la IA con un enfoque instrumental orientado a la producción eficiente de resultados académicos con el menor esfuerzo cognitivo posible, lo que se traduce en una mayor probabilidad de comportamientos que comprometen la integridad académica y de patrones de dependencia que erosionan el desarrollo de competencias a largo plazo (Chaudhry et al., 2023; Farhi et al., 2023).

La teoría de las metas de logro (Elliot & McGregor, 2001) ofrece un refinamiento adicional de este análisis que resulta especialmente útil para diseñar intervenciones pedagógicas. Esta teoría distingue entre orientaciones hacia el dominio, caracterizadas por el deseo de aprender y mejorar la propia competencia con independencia del desempeño de otros, y orientaciones hacia el rendimiento, caracterizadas por el deseo de demostrar competencia superior o de evitar la demostración de incompetencia. Investigaciones recientes han encontrado que los estudiantes con orientaciones hacia el dominio utilizan la IA de manera más reflexiva y académicamente productiva, mientras que los estudiantes con orientaciones de rendimiento-evitación muestran mayor tendencia a usar la IA para eludir el esfuerzo cognitivo que podría evidenciar sus limitaciones ante los docentes y los pares (Yue et al., 2023; Hwang et al., 2020).

## **2.6 Aprendizaje personalizado mediado por IA y retroalimentación**

Uno de los argumentos más recurrentes y mejor fundamentados en favor del uso de la inteligencia artificial en la educación superior es su potencial para personalizar el aprendizaje a una escala que ningún sistema educativo tradicional ha podido alcanzar. La idea de que cada estudiante puede tener acceso a una experiencia de

aprendizaje adaptada a sus conocimientos previos, su ritmo de aprendizaje, sus preferencias cognitivas y sus metas académicas específicas ha sido durante décadas un ideal pedagógico difícilmente alcanzable en entornos universitarios masificados (Bloom, 1984). Los sistemas de inteligencia artificial, especialmente los sistemas de tutoría inteligente y los modelos de lenguaje de gran escala, ofrecen por primera vez la posibilidad técnica de acercarse a ese ideal a un costo marginal cercano a cero (VanLehn, 2011; Ouyang & Jiao, 2021).

La evidencia empírica sobre la efectividad del aprendizaje personalizado mediado por IA es, en términos generales, positiva y estadísticamente robusta. Metaanálisis recientes han encontrado que los estudiantes que utilizan sistemas de tutoría inteligente obtienen ganancias de aprendizaje significativamente superiores a las obtenidas en entornos de instrucción convencional, con tamaños del efecto que oscilan entre 0.4 y 0.8 desviaciones estándar dependiendo del dominio de conocimiento y el nivel educativo (Ma et al., 2020; Kulik & Fletcher, 2016). Sin embargo, la implementación efectiva del aprendizaje personalizado mediado por IA en contextos universitarios reales enfrenta desafíos que la evidencia experimental no siempre captura: la heterogeneidad de los contextos de uso, la brecha entre el potencial técnico de personalización y la capacidad real de los estudiantes para aprovecharlo, y las desigualdades de acceso que determinan quiénes pueden beneficiarse de estas herramientas y quiénes quedan excluidos de sus beneficios (Molina-Gómez et al., 2024; CEPAL, 2022).

La retroalimentación constituye uno de los factores más poderosos del proceso de aprendizaje, con décadas de investigación que demuestran consistentemente su impacto positivo sobre el rendimiento académico cuando es oportuna, específica y orientada

hacia el proceso de aprendizaje más que hacia el juicio evaluativo del estudiante (Hattie & Timperley, 2007). La capacidad de los sistemas de inteligencia artificial para proporcionar retroalimentación inmediata, individualizada y continua representa, en este contexto, una de sus contribuciones más valiosas al aprendizaje universitario. Investigaciones recientes han documentado que la retroalimentación generada por sistemas de IA puede ser especialmente efectiva en dominios donde la corrección es verificable objetivamente, como la resolución de problemas matemáticos, la programación o el aprendizaje de idiomas (Guo et al., 2023; Ma et al., 2020). Sin embargo, en el caso de la escritura académica universitaria, la retroalimentación de IA tiende a privilegiar aspectos formales y gramaticales sobre la coherencia argumentativa y la originalidad del pensamiento, lo que puede moldear el comportamiento de escritura de los estudiantes en direcciones que no siempre son académicamente deseables (Perkins et al., 2023).

## **2.7 Implicaciones para el modelo conductual**

El recorrido teórico y empírico desarrollado en este capítulo permite identificar cuatro implicaciones directas para la arquitectura del MCUIA-ES. La primera es que el comportamiento de uso de la IA actúa como variable mediadora fundamental entre la disponibilidad de herramientas y sus efectos sobre el aprendizaje: no es la presencia de la IA sino el patrón de comportamiento del estudiante lo que determina si el impacto sobre el aprendizaje será positivo o negativo. Esto justifica la centralidad del Componente 3 (Comportamiento de Uso Diferenciado) en el modelo. La segunda implicación es que la relación recursiva entre autorregulación y uso de la IA justifica la incorporación del Sistema de Retroalimentación Recursiva como Componente 5 del MCUIA-ES: las consecuencias del

comportamiento de uso retroalimentan las capacidades de autorregulación, que a su vez modifican el comportamiento futuro, generando ciclos virtuosos o viciosos que el modelo debe poder capturar. La tercera implicación es que el perfil motivacional del estudiante —operacionalizado en términos del continuo intrínseco-extrínseco de la teoría de la autodeterminación— es uno de los determinantes más robustos de la calidad del comportamiento de uso, lo que justifica su incorporación como factor motivacional de primer orden en el Sistema de Antecedentes. La cuarta implicación es que los efectos del uso de la IA deben evaluarse en múltiples temporalidades, lo que fundamenta el diseño del Sistema de Consecuencias Multinivel con sus tres horizontes temporales diferenciados.



## CAPÍTULO 3

### Comportamiento académico en entornos mediados por inteligencia artificial

#### 3.1 Conceptualización del comportamiento académico universitario

El comportamiento académico constituye el objeto de estudio central de este libro y, por tanto, su conceptualización precisa es condición indispensable para el desarrollo del modelo conductual propuesto. En sentido amplio, el comportamiento académico refiere al conjunto de acciones observables y medibles que los estudiantes universitarios realizan en el contexto de su formación, incluyendo conductas de estudio, producción intelectual, participación en actividades de aprendizaje, interacción con compañeros y docentes, y manejo de recursos y herramientas de apoyo al aprendizaje (Pintrich & De Groot, 1990; Zimmerman & Schunk, 2011). Esta definición, deliberadamente amplia, reconoce que el comportamiento académico no se limita a las conductas directamente vinculadas con el rendimiento medible en calificaciones, sino que incluye también patrones de organización del tiempo, estrategias de búsqueda de información, hábitos de lectura y escritura, y disposiciones hacia el aprendizaje que configuran la trayectoria formativa del estudiante a lo largo de su vida universitaria.

Desde la perspectiva de las ciencias de la conducta, el comportamiento académico universitario puede analizarse en términos de tres dimensiones interrelacionadas que se articulan de manera coherente con los componentes del MUIA-ES. La primera es la dimensión topográfica, que describe la forma y frecuencia del comportamiento: qué hace el estudiante, con qué frecuencia lo hace,

durante cuánto tiempo y con qué intensidad. La segunda es la dimensión funcional, que analiza las relaciones entre el comportamiento y sus antecedentes y consecuentes: qué condiciones lo preceden, qué lo desencadena, qué consecuencias produce y cómo esas consecuencias retroalimentan la probabilidad de que el comportamiento se repita. La tercera es la dimensión contextual, que examina cómo el entorno físico, social, institucional y tecnológico en que se produce el comportamiento académico condiciona su forma, su frecuencia y su función (Cooper et al., 2020; Kazdin, 2021). La integración de estas tres dimensiones resulta especialmente relevante cuando se analiza el comportamiento académico en entornos mediados por inteligencia artificial, dado que la disponibilidad de herramientas de IA transforma simultáneamente las tres.

### **3.2 Variables del modelo: dependiente, independientes y mediadoras**

#### **3.2.1 Variable dependiente: el comportamiento de uso de la IA (CUIA)**

La variable dependiente central del modelo es el Comportamiento de Uso de la Inteligencia Artificial (CUIA), conceptualizado como un constructo multidimensional observable que no puede ser reducido a la simple dicotomía uso-no uso que ha dominado las primeras investigaciones en este campo. El CUIA comprende cinco dimensiones operacionalizables, cada una de las cuales captura un aspecto cualitativamente distinto del comportamiento de uso: (1) la frecuencia y diversidad de uso, que describe cuánto y para qué tipos de tareas el estudiante utiliza herramientas de IA; (2) la calidad del proceso de uso, que describe cómo interactúa el estudiante con las

herramientas de IA y qué nivel de criticidad ejerce sobre los outputs generados; (3) el nivel de dependencia tecnológica, que describe el grado en que el estudiante ha externalizado a los sistemas de IA procesos cognitivos que anteriormente realizaba de manera autónoma; (4) la gestión ética del uso, que describe el grado en que el estudiante aplica criterios éticos explícitos en sus decisiones sobre cuándo y cómo utilizar la IA; y (5) la percepción del impacto del uso sobre el propio aprendizaje, que describe el nivel de metacognición del estudiante sobre las consecuencias de su comportamiento de uso. Cada una de estas dimensiones constituye una subescala del instrumento ICUIA-ES descrito en el Capítulo 5.

### **3.2.2 Variables independientes**

Las variables independientes del modelo se organizan en seis categorías que corresponden a los seis tipos de factores del Sistema de Antecedentes Multifactoriales del MCUIA-ES. La primera categoría comprende los factores cognitivos individuales: la autoeficacia para el uso de la IA, la alfabetización en inteligencia artificial y el conocimiento disciplinario previo. La segunda categoría comprende los factores afectivos y disposicionales: las actitudes hacia la IA en contextos académicos (operacionalizada como actitud multidimensional que incluye componentes cognitivo, afectivo y conductual), la ansiedad tecnológica y la curiosidad epistémica del estudiante. La tercera categoría comprende los factores motivacionales: el tipo de motivación académica dominante (intrínseca/extrínseca), el perfil de metas de logro y el valor subjetivo atribuido a las tareas académicas. La cuarta categoría comprende los factores sociales y normativos: la influencia percibida del grupo de pares, las expectativas docentes percibidas sobre el uso apropiado de la IA y las normas subjetivas en el sentido de Ajzen (1991). La quinta

categoría comprende los factores institucionales y pedagógicos: las políticas institucionales sobre el uso de la IA, el diseño pedagógico de las asignaturas y los sistemas de evaluación universitaria. La sexta categoría comprende los factores tecnológicos y de acceso: la disponibilidad y calidad de dispositivos, la conectividad y el acceso a versiones avanzadas de herramientas de IA.

### **3.2.3 Variables mediadoras**

Las variables mediadoras del modelo son la intención de comportamiento de uso de la IA y el control conductual percibido, derivadas de la teoría del comportamiento planificado de Ajzen (1991). Estas variables median la relación entre los antecedentes multifactoriales y el comportamiento de uso observable: los factores del sistema de antecedentes no determinan directamente el comportamiento de uso, sino que lo hacen a través de su influencia sobre la intención de comportamiento y la percepción de control. Esta mediación es conceptualmente importante porque captura la dimensión deliberativa del proceso de adopción que no sería visible si solo se examinaran los determinantes directos del comportamiento. El hábito de uso, que en el caso de los estudiantes con mayor experiencia puede bypassar parcialmente el proceso deliberativo, se incorpora también como variable mediadora de influencia directa sobre el comportamiento, siguiendo la especificación de la UTAUT2 (Venkatesh et al., 2012).

### **3.3 Patrones de uso de la IA en la vida académica universitaria**

Los estudios de prevalencia sobre el uso de la inteligencia artificial en estudiantes universitarios realizados entre 2024 y 2025 revelan un

panorama de adopción masiva y acelerada que hace necesario actualizar los marcos conceptuales desarrollados apenas unos años antes. Estudios realizados en múltiples países reportan que entre el 60 y el 85 por ciento de los estudiantes universitarios ha utilizado al menos una herramienta de IA generativa para actividades académicas durante el último año, con diferencias significativas según el área disciplinaria, el nivel educativo y el contexto socioeconómico institucional (Farhi et al., 2023; Perkins et al., 2023; Chan & Hu, 2023).

En lo que respecta al tipo de tareas académicas para las que se utiliza la IA, los estudios disponibles identifican una jerarquía consistente con variaciones entre contextos culturales e institucionales. La búsqueda y síntesis de información es la aplicación más frecuente, seguida por la redacción y revisión de textos académicos, la resolución de ejercicios y problemas, la preparación de presentaciones, la traducción de textos y, con menor frecuencia aunque en aumento, la programación y el análisis de datos (Rudolph et al., 2023; Tlili et al., 2023; Chan & Hu, 2023). Esta distribución refleja tanto las demandas académicas típicas de los programas de pregrado como las capacidades más accesibles de las herramientas de IA disponibles en el mercado, y tiene implicaciones directas para el diseño de los ítems del instrumento de medición desarrollado en el Capítulo 5.

El análisis de la distribución temporal del uso de IA a lo largo del ciclo académico revela un patrón marcadamente concentrado en los períodos de mayor presión evaluativa: la mayoría de los estudiantes reporta un incremento significativo en el uso de herramientas de IA durante las semanas previas a la entrega de trabajos y evaluaciones, mientras que el uso en períodos de menor presión académica es

considerablemente menor (Perkins et al., 2023; Farhi et al., 2023). Este patrón de uso concentrado en situaciones de presión académica es coherente con la hipótesis conductual de que el uso de la IA funciona en muchos casos como una estrategia de afrontamiento ante las demandas del entorno universitario —una respuesta que es reforzada negativamente por la reducción del malestar asociado a la sobrecarga académica— más que como una estrategia de aprendizaje integrada de manera deliberada en el proceso formativo (Skinner, 1953; Rachlin, 2019).

### **3.4 Tipología conductual del estudiante universitario ante la IA**

A partir de la síntesis de la evidencia empírica disponible y de los resultados del estudio empírico presentado en el Capítulo 6, este libro propone una tipología de cinco perfiles conductuales del estudiante universitario ante la inteligencia artificial que supera las clasificaciones dicotómicas previas y captura la heterogeneidad real de los patrones de uso observados en la población universitaria. Esta tipología no debe interpretarse como una clasificación fija de estudiantes, sino como una descripción de posiciones en un espacio multidimensional en el que los estudiantes pueden ubicarse de manera variable según el contexto académico, el tipo de tarea y las condiciones del entorno institucional.

El primer perfil, el usuario explorador activo, corresponde a estudiantes con altos niveles de autoeficacia tecnológica, curiosidad epistémica elevada y motivación predominantemente intrínseca, que utilizan la IA de manera deliberada y estratégica para explorar en profundidad los temas de estudio y ampliar sus perspectivas más allá de lo exigido por las tareas académicas formales. Este perfil utiliza la

IA como herramienta de exploración intelectual, no como atajo para el cumplimiento de obligaciones académicas, y muestra niveles elevados en las dimensiones de calidad del proceso de uso y gestión ética del instrumento ICUIA-ES. El estudio empírico presentado en el Capítulo 6 identifica a este perfil en el 18.3 por ciento de la muestra universitaria mexicana estudiada (Lim et al., 2023; Guo et al., 2023).

El segundo perfil, el usuario instrumentalista eficiente, corresponde a estudiantes con motivación predominantemente extrínseca y alta orientación hacia el rendimiento, que utilizan la IA de manera sistemática e intensiva para optimizar los resultados académicos visibles con el menor esfuerzo cognitivo posible. Este perfil muestra puntuaciones muy altas en la dimensión de frecuencia y diversidad de uso, pero puntuaciones medias o bajas en la dimensión de calidad del proceso de uso y bajas en la dimensión de gestión ética. Es el perfil más prevalente entre los estudiantes de ingenierías y tecnologías y entre los estudiantes de semestres intermedios, representando el 24.7 por ciento de la muestra en el estudio empírico. El tercer perfil, el usuario dependiente pasivo, corresponde a estudiantes que han desarrollado patrones de dependencia tecnológica elevada que se manifiestan en dificultades para realizar actividades académicas sin el apoyo de herramientas de IA, acompañadas de niveles bajos de gestión ética del uso y de metacognición sobre las consecuencias del patrón de uso sobre el propio aprendizaje. Este perfil, identificado en el 16.2 por ciento de la muestra, es el que el modelo asocia con los mayores riesgos para el desarrollo de competencias académicas a largo plazo.

El cuarto perfil, el usuario evasivo crítico, corresponde a estudiantes que rechazan o evitan el uso de herramientas de IA en sus actividades académicas por razones que pueden incluir desconfianza

hacia la tecnología, convicciones éticas sobre la integridad académica, o simplemente falta de familiaridad con las herramientas disponibles. Este perfil, que representa el 22.1 por ciento de la muestra, muestra puntuaciones altas en la dimensión de gestión ética pero bajas en frecuencia de uso, y se distribuye de manera desigual entre áreas disciplinarias con diferentes normas sobre el uso apropiado de las herramientas tecnológicas. El quinto perfil, el usuario adaptativo reflexivo, es el que el MCUIA-ES identifica como académicamente más sostenible y el que el protocolo de intervención del Capítulo 8 busca promover: estudiantes con uso moderado-alto de la IA que muestran niveles muy altos en calidad del proceso de uso y gestión ética, y niveles bajos de dependencia tecnológica. Este perfil, identificado en el 18.7 por ciento de la muestra, se asocia con los niveles más altos de motivación intrínseca, autorregulación del aprendizaje y rendimiento académico general en el estudio empírico.

### **3.5 Comportamiento de estudio, escritura académica e integridad**

El impacto de la inteligencia artificial sobre el comportamiento de estudio de los estudiantes universitarios puede analizarse a través de al menos cuatro dimensiones interrelacionadas: la gestión del tiempo y la organización del trabajo académico, las estrategias de búsqueda y procesamiento de información, los procesos de escritura y producción de conocimiento académico, y las decisiones sobre los límites del uso apropiado de la IA en relación con la integridad académica.

En lo que respecta a la escritura académica, que constituye la actividad más frecuentemente asistida por IA entre los estudiantes universitarios, la investigación disponible identifica tres patrones

cualitativamente distintos que tienen consecuencias radicalmente diferentes sobre el aprendizaje (Westphal et al., 2023; Perkins et al., 2023). El primer patrón, el apoyo a la escritura propia, corresponde a estudiantes que realizan el proceso de escritura de manera autónoma y utilizan la IA para revisar, mejorar o ampliar textos que son genuinamente suyos en términos de argumentación y pensamiento: este patrón puede tener efectos positivos sobre la calidad del producto final sin comprometer el desarrollo de la competencia escritural. El segundo patrón, la coautoría colaborativa, corresponde a estudiantes que interactúan con la IA de manera dialógica y crítica durante el proceso de escritura, evaluando las sugerencias generadas y decidiendo selectivamente cuáles integrar en su texto: este patrón puede tener efectos positivos o neutros sobre el aprendizaje dependiendo del nivel de agencia crítica que el estudiante ejerce en el proceso. El tercer patrón, la delegación total, corresponde a estudiantes que utilizan la IA como generador primario del contenido de sus producciones académicas, con una intervención propia limitada a la selección del tema y a ediciones superficiales del texto generado: este patrón, documentado en entre el 10 y el 25 por ciento de los estudiantes según diferentes estudios, plantea los desafíos más directos a la integridad académica y es el que produce el menor desarrollo de las competencias de escritura académica.

La integridad académica en el contexto de la inteligencia artificial es un fenómeno complejo que no puede reducirse a la dicotomía simple de uso-deshonestidad que ha dominado la respuesta institucional inicial. Desde la perspectiva de la psicología moral, la integridad académica en el contexto de la IA implica la capacidad del estudiante de reconocer los dilemas éticos específicos que plantea

cada situación de uso, de razonar sobre esas situaciones desde múltiples perspectivas y de tomar decisiones coherentes con sus valores académicos y personales (Rest et al., 2000; International Center for Academic Integrity, 2021). La ausencia de marcos normativos claros por parte de las instituciones educativas, documentada de manera consistente en el estudio empírico presentado en el Capítulo 6, crea condiciones de ambigüedad que dificultan ese proceso de razonamiento moral y favorecen la adopción de criterios ad hoc que pueden no ser académicamente apropiados.

### **3.6 Implicaciones para el modelo conductual**

Este capítulo ha establecido las variables centrales del MCUA-ES con su clasificación conceptual y su operacionalización. La variable dependiente CUIA ha sido definida en sus cinco dimensiones observables que constituyen las subescalas del instrumento de medición. Las variables independientes en seis categorías y las variables mediadoras intención de comportamiento y control conductual percibido se articulan en el Proceso de Mediación Cognitivo-Motivacional del Componente 2 del modelo. La tipología de cinco perfiles conductuales, validada empíricamente en el Capítulo 6 mediante análisis de conglomerados, proporciona el sistema de categorización del comportamiento de uso que da concreción práctica al modelo y orienta el diseño de intervenciones diferenciadas. El tercer hallazgo conceptualmente más importante de este capítulo para el modelo es la relación recursiva entre los patrones de uso de la IA y el desarrollo de las competencias de escritura y pensamiento crítico: los patrones de uso dependiente no solo producen productos académicos de menor valor; producen también condiciones que hacen más probable el uso dependiente en el futuro, configurando los

ciclos viciosos que el Sistema de Retroalimentación Recursiva del modelo busca capturar.



## CAPÍTULO 4

### Factores que influyen en el uso de inteligencia artificial en estudiantes universitarios

#### 4.1 Marco explicativo multifactorial del uso de la IA

Comprender por qué los estudiantes universitarios utilizan o no la inteligencia artificial, con qué frecuencia, para qué tareas y de qué manera, exige un marco explicativo que supere la simplicidad de las relaciones causales lineales y reconozca la naturaleza multifactorial, dinámica e interactiva del fenómeno. La investigación disponible ha identificado un número creciente de factores que influyen sobre el comportamiento de uso de la IA en estudiantes universitarios, pero la mayoría de los estudios los ha examinado de manera aislada, sin articular un modelo integrador que especifique sus interacciones y sus pesos relativos en la predicción del comportamiento (Venkatesh et al., 2012; Scherer et al., 2019).

El presente capítulo organiza los factores identificados en la literatura en cinco grandes categorías que corresponden a los niveles del Sistema de Antecedentes Multifactoriales del MCUA-ES: factores cognitivos individuales, factores afectivos y disposicionales, factores motivacionales, factores sociales y normativos, y factores institucionales y tecnológicos. Esta organización no es simplemente taxonómica; responde a diferencias reales en la naturaleza, el nivel de análisis y los mecanismos de influencia de cada categoría de factores. La revisión que se presenta en este capítulo busca no solo identificar los factores relevantes, sino especificar los mecanismos a través de los cuales operan y las interacciones más relevantes entre ellos para la comprensión del comportamiento de uso de la IA en el contexto universitario latinoamericano.

## **4.2 Factores cognitivos individuales**

La autoeficacia tecnológica constituye uno de los predictores cognitivos más consistentes y robustos del comportamiento de uso de la inteligencia artificial en estudiantes universitarios, con efectos documentados tanto sobre la frecuencia como sobre la calidad del uso (Bandura, 1997; Scherer et al., 2019). En el contexto específico del uso académico de la IA, la autoeficacia relevante no es simplemente la confianza general en el uso de tecnologías digitales, sino la confianza específica en la capacidad para utilizar herramientas de IA de manera efectiva para tareas académicas concretas: formular consultas que generen respuestas útiles, evaluar la calidad y pertinencia de los outputs generados, integrar esos outputs en el propio proceso de pensamiento académico y gestionar éticamente los límites del uso apropiado de la IA (Compeau & Higgins, 1995; Scherer et al., 2019).

Las habilidades de alfabetización en inteligencia artificial constituyen el segundo factor cognitivo de primer orden en la predicción del comportamiento de uso de calidad. Ng et al. (2021) conceptualizan la alfabetización en IA como un conjunto de competencias que incluye la comprensión básica de cómo funcionan los sistemas de IA y qué los hace distintos de otras herramientas digitales, la capacidad de uso funcional de herramientas de IA para tareas específicas, la habilidad para evaluar críticamente los resultados generados por la IA identificando sus limitaciones, sesgos y errores, y la comprensión de las implicaciones éticas y sociales del uso de la IA. La investigación disponible indica que los estudiantes con mayores niveles de alfabetización en IA tienden a utilizar estas herramientas de manera más reflexiva, crítica y académicamente

productiva, independientemente de su nivel de autoeficacia tecnológica general (Long & Magerko, 2020; Ng et al., 2021).

El conocimiento disciplinario previo del estudiante es el tercer factor cognitivo relevante, y uno de los más frecuentemente ignorados en los modelos de adopción tecnológica aplicados a la educación. La capacidad de evaluar críticamente los outputs de la IA en un dominio específico depende de manera fundamental del nivel de conocimiento que el estudiante ya posee sobre ese dominio: un estudiante de medicina con sólidos conocimientos de anatomía puede identificar errores en la descripción de estructuras anatómicas que haría un sistema de IA con apariencia de autoridad, mientras que un estudiante sin esa base conocimientos carece de los recursos para hacer esa evaluación (Kalyuga, 2023; Ouyang & Jiao, 2021). Este factor explica por qué los patrones de uso de calidad son más frecuentes entre los estudiantes de semestres avanzados: no es únicamente la experiencia con la herramienta, sino el mayor conocimiento disciplinario acumulado lo que les permite utilizar la IA de manera más crítica y reflexiva.

### **4.3 Factores afectivos y disposicionales**

Las actitudes hacia la inteligencia artificial en contextos académicos constituyen uno de los antecedentes del comportamiento de uso que más complejidad presenta desde una perspectiva psicológica. La investigación ha documentado de manera consistente que la mayoría de los estudiantes universitarios mantiene actitudes ambivalentes hacia el uso académico de la IA: evalúan positivamente sus potencialidades para facilitar el aprendizaje y reducir la carga de trabajo, y al mismo tiempo manifiestan preocupaciones legítimas sobre sus implicaciones para la integridad académica, la autonomía

intelectual y la equidad educativa (Chan & Hu, 2023; Southworth et al., 2023). Esta ambivalencia actitudinal no es equivalente a la indiferencia, y tiene implicaciones específicas para la predicción del comportamiento: los estudiantes con actitudes ambivalentes tienden a modular su comportamiento de uso de manera más sensible a los factores contextuales —como las señales normativas del docente o las demandas específicas de la tarea— que los estudiantes con actitudes unívocamente positivas o negativas (Thompson et al., 1995).

La ansiedad tecnológica, entendida como la aprensión o miedo que experimentan algunos individuos ante la posibilidad o necesidad de utilizar tecnologías digitales, inhibe el uso de herramientas de IA incluso cuando el estudiante percibe que estas herramientas podrían ser útiles y tiene acceso material a ellas (Cai et al., 2017; Seo et al., 2021). Investigaciones recientes han encontrado que la ansiedad tecnológica está inversamente relacionada con la autoeficacia tecnológica y positivamente relacionada con experiencias previas negativas en el uso de tecnologías digitales, lo que sugiere que puede ser modificada a través de intervenciones que proporcionen experiencias de éxito graduales en el uso de herramientas de IA en contextos académicos de bajo riesgo.

La curiosidad epistémica, entendida como la disposición del individuo a explorar, descubrir y ampliar su conocimiento más allá de lo estrictamente necesario para el cumplimiento de las demandas externas, emerge como un factor predictor del perfil de uso reflexivo y del tipo de comportamiento de uso que la investigación asocia con los mejores resultados de aprendizaje (Grossnickle, 2016; Guo et al., 2023). Los estudiantes con altos niveles de curiosidad epistémica tienden a utilizar la IA como herramienta de exploración intelectual, formulando preguntas que van más allá de las demandas mínimas de

las tareas académicas asignadas y evaluando críticamente las respuestas obtenidas en función de su propia comprensión del tema. Este hallazgo tiene implicaciones directas para el diseño de intervenciones pedagógicas orientadas a promover el perfil adaptativo reflexivo: fomentar la curiosidad epistémica puede ser una palanca de cambio más efectiva que intentar regular directamente el comportamiento de uso de la IA.

#### **4.4 Factores motivacionales**

El tipo de motivación académica dominante del estudiante es el factor individual con mayor poder predictivo sobre la calidad del comportamiento de uso de la inteligencia artificial, por encima de los factores cognitivos y tecnológicos cuando se controlan estadísticamente (Deci & Ryan, 2000; Eccles & Wigfield, 2020). Esta afirmación, fundamentada en los análisis de regresión presentados en el Capítulo 6, tiene implicaciones de gran alcance para el diseño de intervenciones: sugiere que fortalecer la motivación intrínseca es una palanca de cambio más potente que mejorar las habilidades técnicas de uso de la IA o que regular el acceso a las herramientas.

El valor percibido de la tarea académica en que se utiliza la IA es otro factor motivacional relevante que opera a través de mecanismos distintos al tipo de motivación general. Los estudiantes que perciben que una tarea académica tiene valor intrínseco —ya sea porque la consideran interesante, relevante para su desarrollo profesional o significativa desde el punto de vista personal— tienden a utilizarla la IA de manera más reflexiva y con mayor agencia cognitiva que los estudiantes que perciben la misma tarea como un mero requisito burocrático del programa académico (Wigfield & Eccles, 2000; Eccles & Wigfield, 2020). Esto significa que el diseño de tareas

académicas que sean genuinamente significativas para los estudiantes no es solo un objetivo pedagógico en sí mismo, sino también una estrategia efectiva para promover patrones de uso de la IA académicamente productivos.

El locus de control académico, que describe el grado en que el estudiante percibe que los resultados de su aprendizaje están determinados por sus propias acciones y esfuerzos versus por factores externos fuera de su control (Rotter, 1966), es un factor motivacional que ha recibido atención creciente en el contexto del uso de la IA. Los estudiantes con locus de control interno tienden a percibir el uso de la IA como una herramienta que pueden emplear de manera estratégica para potenciar sus propias capacidades, mientras que los estudiantes con locus de control externo tienden a percibir la IA como una solución a los problemas que el entorno les impone, con la consiguiente mayor tendencia hacia el uso dependiente (Rotter, 1966; Scherer et al., 2019).

#### **4.5 Factores sociales y normativos**

La influencia percibida del grupo de pares es uno de los predictores más robustos del comportamiento de adopción de la IA en contextos universitarios, y su efecto es especialmente pronunciado en las dimensiones de frecuencia y diversidad de uso (Chan & Hu, 2023; Farhi et al., 2023). Esta influencia no opera principalmente a través de la presión social explícita, sino a través de mecanismos de modelamiento social en el sentido de Bandura (1986): los estudiantes observan que sus compañeros utilizan la IA para realizar tareas académicas similares a las propias, infieren que ese comportamiento es normativo y ajustan su propio comportamiento en consecuencia, sin que necesariamente medie una instrucción explícita ni una

sanción social directa. Este mecanismo de modelamiento social es especialmente potente en los semestres iniciales, cuando los estudiantes están todavía construyendo sus identidades académicas y son especialmente receptivos a las señales sobre cuáles son las normas conductuales del grupo de pertenencia.

Las expectativas docentes sobre el uso apropiado de la IA constituyen el factor normativo más directamente relevante para el comportamiento de uso en el contexto académico, aunque su operación es frecuentemente implícita y ambigua. Los docentes que integran reflexivamente el uso de la IA en sus diseños pedagógicos, modelando explícitamente cómo utilizarla de manera crítica y académicamente productiva, generan un contexto normativo que favorece el desarrollo del perfil adaptativo reflexivo entre sus estudiantes (Southworth et al., 2023; Holmes et al., 2022). Por el contrario, los docentes que ignoran el fenómeno del uso de la IA o que adoptan posiciones exclusivamente prohibitivas sin fundamentación pedagógica explícita, crean condiciones de ambigüedad normativa que tienden a favorecer el uso instrumental e irresponsable de estas herramientas (Rudolph et al., 2023; Tlili et al., 2023).

Las normas subjetivas, en el sentido de Ajzen (1991), refieren a la percepción del estudiante sobre lo que las personas importantes para él padres, docentes, compañeros significativos esperan que haga respecto al uso de la IA. En el contexto universitario latinoamericano, donde las normas institucionales son frecuentemente ambiguas o inconsistentes, estas normas subjetivas adquieren un peso predictivo desproporcionadamente alto sobre el comportamiento de uso, llenando el vacío normativo que las políticas institucionales no han cubierto (Molina-Gómez et al., 2024). El estudio empírico presentado en el Capítulo 6 confirma que las normas del grupo de

pares son el predictor más potente de la frecuencia de uso de la IA, con una influencia que supera incluso a la utilidad percibida cuando la ambigüedad normativa institucional es alta.

#### **4.6 Factores institucionales, pedagógicos y tecnológicos**

Las políticas institucionales sobre el uso de la IA son el factor contextual más directamente controlable por las organizaciones universitarias y, por tanto, el que tiene mayor relevancia para el diseño de respuestas institucionales al fenómeno. Sin embargo, la investigación disponible indica que no todas las políticas institucionales tienen los efectos sobre el comportamiento de uso que sus diseñadores esperan. Las políticas exclusivamente prohibitivas — que simplemente definen el uso de la IA como deshonestidad académica sin distinguir entre tipos de uso— tienden a generar comportamientos de uso encubierto que son difíciles de detectar y que eliminan la posibilidad de que los estudiantes desarrollen criterios propios de uso reflexivo (Tlili et al., 2023; Rudolph et al., 2023). Las políticas pedagógicamente fundamentadas, que explican el razonamiento detrás de las normas y orientan a los estudiantes sobre cómo desarrollar un uso académicamente apropiado de la IA en sus contextos específicos, tienen mayor impacto sobre el desarrollo de la gestión ética del uso (UNESCO, 2023; Holmes et al., 2022).

El diseño pedagógico de las asignaturas es el factor que más directamente configura las contingencias de reforzamiento del comportamiento de uso de la IA en el nivel del aula. Las asignaturas con tareas académicas genéricas —ensayos sobre temas generales, resolución de problemas tipo, resúmenes de textos— crean condiciones que hacen muy difícil distinguir el uso reflexivo del uso instrumental de la IA, al tiempo que ofrecen pocos incentivos para el

uso reflexivo que requiere mayor esfuerzo cognitivo. Las asignaturas con tareas académicas auténticas, contextualmente situadas y personalmente significativas, crean condiciones que hacen más difícil el uso puramente instrumental de la IA y que ofrecen mayores incentivos para el uso reflexivo que agrega valor genuino al proceso de aprendizaje (Boud & Falchikov, 2006; Lim et al., 2023).

Los factores tecnológicos y de acceso, aunque frecuentemente subestimados en los modelos de adopción tecnológica desarrollados en contextos de alta conectividad, son determinantes fundamentales del comportamiento de uso en el contexto universitario latinoamericano. La disponibilidad y calidad de dispositivos tecnológicos, la velocidad y estabilidad de la conectividad a internet, el acceso a versiones avanzadas de herramientas de IA que requieren suscripciones de pago, y la calidad y confiabilidad de los outputs generados por las versiones gratuitas disponibles, configuran condiciones materiales que habilitan o restringen el comportamiento de uso de manera significativa (CEPAL, 2022; Molina-Gómez et al., 2024). El estudio empírico presentado en el Capítulo 6 documenta que los estudiantes con menor acceso tecnológico muestran no solo menor frecuencia de uso, sino también menor calidad del proceso de uso cuando acceden a las herramientas de IA, lo que sugiere que las brechas de acceso se traducen en brechas de aprovechamiento que tienen consecuencias para la equidad educativa.

#### **4.7 Interacciones entre factores y moderadores relevantes**

La comprensión del comportamiento de uso de la IA en su complejidad real requiere ir más allá del análisis de los efectos individuales de cada factor para examinar las interacciones entre factores y los moderadores que modifican la magnitud y la dirección

de esos efectos. El MCUIA-ES propone tres interacciones de primer orden entre los factores del sistema de antecedentes que tienen especial relevancia predictiva y pedagógica.

La primera interacción relevante es la que se produce entre el tipo de motivación académica y las políticas institucionales sobre el uso de la IA en la predicción de la gestión ética del uso. Los resultados del estudio empírico presentado en el Capítulo 6 sugieren que las políticas institucionales claras y pedagógicamente fundamentadas tienen un efecto positivo sobre la gestión ética que es especialmente pronunciado entre los estudiantes con motivación extrínseca dominante: para los estudiantes que están principalmente motivados por las contingencias externas, las políticas claras proporcionan precisamente el tipo de señal normativa que puede modificar su comportamiento de manera significativa. Los estudiantes con motivación intrínseca dominante, en cambio, muestran niveles elevados de gestión ética con relativa independencia de la claridad de las políticas institucionales, lo que sugiere que para este grupo los valores internalizados son más determinantes que las normas externas.

La segunda interacción relevante es la que se produce entre la autoeficacia tecnológica y el acceso tecnológico en la predicción de la calidad del proceso de uso. La autoeficacia tecnológica predice la calidad del uso de la IA de manera más robusta cuando el acceso tecnológico es adecuado: cuando los estudiantes tienen acceso limitado a herramientas de IA de calidad, incluso altos niveles de autoeficacia no pueden compensar las restricciones materiales. Esta interacción tiene implicaciones directas para las estrategias de intervención en contextos de desigualdad tecnológica: mejorar la autoeficacia sin mejorar el acceso produce beneficios limitados,

mientras que mejorar el acceso sin desarrollar la autoeficacia y la alfabetización en IA puede no producir los beneficios de aprendizaje esperados.

La tercera interacción relevante es la que se produce entre el diseño pedagógico de las asignaturas y el estilo cognitivo predominante del estudiante en la determinación del tipo de uso de la IA. Las tareas académicas con alta demanda de pensamiento crítico y creatividad favorecen el uso reflexivo de la IA entre los estudiantes con estilos cognitivos analíticos, pero pueden incrementar el uso dependiente entre estudiantes con estilos más intuitivos que perciben esas demandas como especialmente amenazantes para su competencia académica. Esta interacción subraya la importancia de no generalizar las estrategias pedagógicas sin atender a la diversidad cognitiva de la población estudiantil.

#### **4.8 Implicaciones para el modelo conductual**

Este capítulo ha operacionalizado las seis categorías de variables independientes que conforman el Componente 1 del MCUIA-ES —el Sistema de Antecedentes Multifactoriales— y ha especificado los mecanismos a través de los cuales cada categoría ejerce su influencia sobre el comportamiento de uso. El hallazgo más relevante para la arquitectura del modelo es la confirmación de que ningún factor opera de manera aislada: la predicción del comportamiento de uso de la IA requiere la consideración simultánea de factores que operan en diferentes niveles de análisis —individual, interpersonal e institucional— y que interactúan entre sí de maneras que modifican la dirección y la magnitud de sus efectos individuales. Las tres interacciones de primer orden identificadas —motivación por políticas, autoeficacia por acceso, diseño pedagógico por estilo

cognitivo— serán modeladas estadísticamente en el capítulo siguiente mediante términos de interacción en los análisis de regresión y mediante efectos moderadores en el modelo de ecuaciones estructurales. El hallazgo de que la motivación intrínseca es el predictor más potente de la calidad del uso, con independencia relativa de los factores normativos e institucionales, tiene una implicación directa para el protocolo de intervención del Capítulo 8: las intervenciones que atiendan la dimensión motivacional del comportamiento académico tendrán un impacto más sostenible sobre los patrones de uso de la IA que las que se limiten a regular el acceso o a establecer normas de uso.

## CAPÍTULO 5

### Medición del comportamiento académico y uso de inteligencia artificial

#### **5.1 El problema de la medición en ciencias de la conducta aplicadas a la educación**

La medición del comportamiento académico en contextos universitarios ha sido históricamente uno de los desafíos metodológicos más complejos en el campo de las ciencias de la conducta y la educación. Este desafío no es meramente técnico; tiene raíces epistemológicas profundas que remiten a preguntas fundamentales sobre la naturaleza de los constructos que se busca medir, la relación entre los indicadores observables y los procesos psicológicos que los subyacen, y las condiciones bajo las cuales las inferencias derivadas de los instrumentos de medición pueden considerarse válidas y confiables (Messick, 1995; Kane, 2013). Estas preguntas adquieren una dimensión adicional de complejidad cuando el objeto de medición es el uso de la inteligencia artificial, un comportamiento que es al mismo tiempo observable en algunos de sus aspectos y profundamente opaco en otros, que varía rápidamente en función de la evolución de las herramientas disponibles, y que está sujeto a sesgos de deseabilidad social que pueden distorsionar significativamente la información auto-reportada (Podsakoff et al., 2003; Chang et al., 2023).

La medición en ciencias de la conducta opera sobre la premisa fundamental de que los constructos psicológicos, aunque no directamente observables, pueden ser estimados de manera válida y confiable a través de indicadores observables cuidadosamente seleccionados y organizados en instrumentos de medición (Nunnally & Bernstein, 1994). Esta premisa implica que la calidad de la

medición depende tanto de la adecuación conceptual del constructo que se mide como de la solidez técnica del instrumento utilizado. En el contexto del uso de la IA en educación superior, los constructos relevantes son relativamente nuevos y su estructura dimensional no ha sido aún suficientemente establecida en la literatura científica, lo que hace especialmente importante el proceso de desarrollo y validación del instrumento (Ng et al., 2021; Southworth et al., 2023).

## **5.2 Enfoques metodológicos para el estudio del comportamiento mediado por IA**

La investigación sobre el comportamiento académico de los estudiantes universitarios en entornos mediados por inteligencia artificial ha recurrido a una diversidad de enfoques metodológicos que pueden organizarse en un continuo que va desde los enfoques predominantemente cuantitativos hasta los predominantemente cualitativos (Creswell & Creswell, 2018; Flick, 2022). Los enfoques cuantitativos han dominado la investigación en el campo, ofreciendo la posibilidad de recolectar datos de muestras grandes, cuantificar la prevalencia de diferentes comportamientos y actitudes, y establecer relaciones estadísticas entre variables que permiten evaluar modelos teóricos sobre los determinantes del comportamiento de uso (Zawacki-Richter et al., 2019; Crompton & Burke, 2023). Los enfoques cualitativos han comenzado a ganar terreno, ofreciendo perspectivas complementarias sobre los procesos, significados y experiencias que los datos cuantitativos no pueden capturar por sí solos (Lim et al., 2023). Los diseños mixtos, como el adoptado en el estudio empírico del Capítulo 6, representan la estrategia metodológica más adecuada para estudiar la complejidad del fenómeno (Creswell & Creswell, 2018; Tashakkori et al., 2021).

### 5.3 Construcción y validación del instrumento ICUIA-ES

El Inventario de Comportamiento de Uso de IA en Educación Superior (ICUIA-ES) fue desarrollado siguiendo un proceso de cuatro fases que garantiza la solidez psicométrica y la pertinencia conceptual del instrumento para el contexto universitario latinoamericano. La primera fase fue la especificación del dominio del constructo mediante revisión sistemática de la literatura sobre comportamiento académico y uso de la IA, que identificó las cinco dimensiones del CUIA como componentes cualitativamente distintos y empíricamente diferenciables del comportamiento de uso. La segunda fase fue el desarrollo de los ítems mediante el método de generación racional con revisión de expertos: un grupo de ocho especialistas en psicología educativa, tecnología educativa y ciencias de la conducta evaluó la claridad, relevancia y representatividad de los ítems utilizando el Coeficiente de Validez de Contenido de Lawshe (1975), con un criterio de  $CVR \geq 0.75$  para retención. La tercera fase fue un estudio piloto con 120 estudiantes universitarios de dos instituciones que permitió identificar y corregir problemas de comprensión, revisar la distribución de las respuestas y estimar los índices de dificultad y discriminación de los ítems. La cuarta fase fue la validación psicométrica con la muestra completa de 1,247 estudiantes, mediante análisis factorial exploratorio seguido de confirmatorio, evaluación de la invarianza de medición y estimación de los coeficientes de confiabilidad.

Los análisis factoriales confirmatorios replicaron la estructura de cinco factores con índices de ajuste satisfactorios que superaron los umbrales convencionales:  $CFI = .93$ ,  $TLI = .91$ ,  $RMSEA = .058$  (IC 90% = .051-.065),  $SRMR = .062$ . Todos los ítems mostraron cargas factoriales estandarizadas superiores a .50, con una media de .71 y un

rango de .52 a .89. Los coeficientes omega de McDonald por dimensión oscilaron entre .81 (Dependencia Tecnológica) y .89 (Calidad del Proceso de Uso), indicando consistencia interna de alta calidad en todas las dimensiones (McNeish, 2018; Sijtsma, 2009). Los análisis de invarianza de medición confirmaron la invarianza configural, métrica y escalar del instrumento entre géneros, entre áreas disciplinarias y entre instituciones participantes, lo que valida las comparaciones entre estos grupos en los análisis presentados en el Capítulo 6.

#### **5.4 El cuestionario ICUIA-ES: instrumento completo**

##### ***INVENTARIO DE COMPORTAMIENTO DE USO DE INTELIGENCIA ARTIFICIAL EN EDUCACIÓN SUPERIOR (ICUIA-ES)***

###### *INSTRUCCIONES PARA EL ESTUDIANTE*

A continuación encontrará una serie de afirmaciones sobre el uso de herramientas de inteligencia artificial (como ChatGPT, Gemini, Claude, Copilot u otras similares) en sus actividades académicas universitarias durante el semestre en curso. Para cada afirmación, marque con una X la opción que mejor describe su situación habitual. No hay respuestas correctas ni incorrectas; lo que se busca es conocer su experiencia real. Sus respuestas serán confidenciales y se utilizarán únicamente con fines de investigación científica.

*Escala de respuesta:*

*1 = Nunca | 2 = Pocas veces | 3 = Algunas veces | 4 = Frecuentemente | 5 = Siempre*

## **DIMENSIÓN 1: Frecuencia y Diversidad de Uso (FDU)**

Esta dimensión evalúa con qué frecuencia y para qué tipo de tareas académicas utiliza usted herramientas de inteligencia artificial durante su semestre universitario.

- 1.** Utilizo herramientas de inteligencia artificial generativa (ChatGPT, Gemini, Claude, Copilot u otras) al menos una vez por semana para realizar actividades académicas de mis asignaturas.
- 2.** Utilizo herramientas de inteligencia artificial para buscar, organizar y sintetizar información sobre temas relacionados con mis materias universitarias.
- 3.** Utilizo herramientas de inteligencia artificial para redactar, revisar o mejorar textos académicos como ensayos, reportes o trabajos de investigación.
- 4.** Utilizo herramientas de inteligencia artificial para resolver ejercicios, problemas o preguntas de evaluación de mis asignaturas.
- 5.** Utilizo herramientas de inteligencia artificial para preparar presentaciones, exposiciones o materiales visuales para mis clases.
- 6.** Utilizo herramientas de inteligencia artificial para traducir textos académicos escritos en idiomas distintos al español.
- 7.** Utilizo más de una herramienta de inteligencia artificial diferente según el tipo de tarea académica que necesito realizar.
- 8.** El uso que hago de herramientas de inteligencia artificial aumenta significativamente durante los períodos de entrega de trabajos o evaluaciones.

## **DIMENSIÓN 2: Calidad del Proceso de Uso (CPU)**

Esta dimensión evalúa cómo interactúa usted con las herramientas de inteligencia artificial: si lo hace de manera crítica, reflexiva y académicamente productiva, o de manera acrítica e instrumental.

**9.** Antes de consultar una herramienta de inteligencia artificial, defino con claridad qué información necesito, para qué la utilizaré y cómo la integraré en mi trabajo académico.

**10.** Cuando consulto una herramienta de inteligencia artificial, formulo preguntas detalladas y contextualizadas que incluyen información sobre mi asignatura, nivel educativo y propósito específico, no solo preguntas genéricas.

**11.** Antes de utilizar la información que me proporciona una herramienta de inteligencia artificial, evalúo si la respuesta es correcta, relevante y pertinente para mi tarea académica específica.

**12.** Contrasto y verifico la información que me proporciona la inteligencia artificial con otras fuentes académicas confiables, como libros de texto, artículos científicos o bases de datos especializadas.

**13.** Cuando una herramienta de inteligencia artificial me da una respuesta que no entiendo completamente o que me genera dudas, investigo más sobre el tema antes de utilizarla en mi trabajo.

**14.** Integro los resultados de la inteligencia artificial con mis propias ideas, análisis y perspectivas, evitando copiar directamente el contenido generado sin elaboración propia.

**15.** Considero que mi forma de usar las herramientas de inteligencia artificial enriquece y profundiza mi comprensión de los temas que estudio, no solo facilita la entrega de tareas.

**16.** Tengo la capacidad de identificar cuando los resultados que genera la inteligencia artificial son incorrectos, imprecisos, desactualizados o contienen sesgos relevantes para mi disciplina.

### **DIMENSIÓN 3: Nivel de Dependencia Tecnológica (NDT)**

Esta dimensión evalúa el grado en que usted ha desarrollado dependencia de las herramientas de inteligencia artificial para realizar actividades académicas que anteriormente realizaba de manera autónoma. Los ítems marcados con (\*) tienen puntuación invertida para el cálculo del índice dimensional.

- 17.** Puedo realizar mis tareas y trabajos académicos con la misma calidad y seguridad cuando no tengo acceso a herramientas de inteligencia artificial. (\*)
- 18.** Si las herramientas de inteligencia artificial dejaran de estar disponibles mañana, mis estrategias de estudio y de producción académica no cambiarían de manera significativa. (\*)
- 19.** Me siento capaz de resolver los problemas, preguntas y ejercicios de mis asignaturas sin necesitar el apoyo de herramientas de inteligencia artificial para comenzar o completar el trabajo. (\*)
- 20.** Mi capacidad para escribir textos académicos coherentes, bien estructurados y argumentados no depende del apoyo de herramientas de inteligencia artificial. (\*)
- 21.** Experimento ansiedad, bloqueo o dificultad significativa cuando tengo que realizar tareas académicas complejas sin poder acceder a herramientas de inteligencia artificial.
- 22.** Mi primer recurso ante cualquier tarea, pregunta o problema académico es consultar una herramienta de inteligencia artificial, antes de intentar resolverlo por mis propios medios.
- 23.** Siento que mi capacidad para pensar de forma autónoma, argumentar con mis propias ideas y resolver problemas académicos de manera independiente ha disminuido desde que comencé a usar herramientas de inteligencia artificial de manera habitual.

**24.** Necesito el apoyo de una herramienta de inteligencia artificial para poder comenzar a redactar cualquier texto académico, aunque sea un borrador inicial.

*(\*) Para el cálculo del índice NDT, invertir las puntuaciones de los ítems 17-20: 1→5, 2→4, 3→3, 4→2, 5→1. Puntuaciones más altas indican mayor dependencia tecnológica.*

#### **DIMENSIÓN 4: Gestión Ética del Uso (GEU)**

Esta dimensión evalúa el grado en que usted aplica criterios éticos explícitos y reflexivos en sus decisiones sobre cuándo, cómo y para qué utilizar herramientas de inteligencia artificial en sus actividades académicas universitarias.

**25.** Cuando las normas de mi institución o mis docentes así lo requieren, declaro en mis trabajos académicos que utilicé herramientas de inteligencia artificial como apoyo en su elaboración.

**26.** Antes de utilizar herramientas de inteligencia artificial en una tarea académica específica, reflexiono y evalúo si ese uso es apropiado según las normas de la asignatura y de mi institución educativa.

**27.** Considero que existe una diferencia significativa e importante entre usar la inteligencia artificial como herramienta de apoyo a mi propio aprendizaje y usarla para sustituir el trabajo intelectual que debería realizar yo mismo.

**28.** Me preocupa genuinamente que el uso excesivo o irreflexivo de herramientas de inteligencia artificial pueda perjudicar el desarrollo de mis propias competencias académicas y profesionales a largo plazo.

**29.** Cuando considero que un determinado uso de herramientas de inteligencia artificial sería académicamente deshonesto o inapropiado, me abstengo de hacerlo, aunque observe que otros compañeros lo hacen sin consecuencias visibles.

**30.** Conozco con claridad cuáles son las políticas y normas de mi institución universitaria sobre el uso permitido y el uso no permitido de herramientas de inteligencia artificial en actividades académicas.

**31.** Reflexiono activamente sobre las implicaciones éticas, académicas y de largo plazo de mis decisiones sobre el uso de herramientas de inteligencia artificial en mi formación universitaria.

**32.** Considero que tengo la responsabilidad personal de desarrollar mis propios criterios fundamentados sobre cuál es el uso académicamente responsable de las herramientas de inteligencia artificial en mi disciplina.

### **DIMENSIÓN 5: Percepción del Impacto sobre el Aprendizaje (PIA)**

Esta dimensión evalúa la metacognición del estudiante sobre las consecuencias de su uso de herramientas de inteligencia artificial sobre su propio proceso de aprendizaje, desarrollo académico e identidad intelectual.

**33.** En términos generales, considero que la forma en que utilizo herramientas de inteligencia artificial ha mejorado la calidad académica de mis trabajos, ensayos y producciones universitarias.

**34.** Siento que mi uso de herramientas de inteligencia artificial me ha ayudado genuinamente a aprender más, con mayor profundidad y comprensión, sobre los temas de mis asignaturas.

**35.** Tengo la capacidad de distinguir con claridad cuándo el uso de herramientas de inteligencia artificial está enriqueciendo mi proceso de aprendizaje y cuándo está interfiriendo o sustituyendo ese proceso.

**36.** Creo que la forma en que utilizo herramientas de inteligencia artificial ha contribuido a fortalecer mi capacidad de pensamiento crítico, análisis y razonamiento académico.

**37.** Siento que las producciones académicas que elaboro con el apoyo de herramientas de inteligencia artificial son genuinamente mías en términos intelectuales: reflejan mi pensamiento, mis argumentos y mi perspectiva personal.

**38.** He desarrollado una estrategia personal consciente, reflexiva y fundamentada sobre cómo y cuándo utilizar herramientas de inteligencia artificial de manera que potencien mi aprendizaje sin sustituirlo.

**39.** Considero que la forma en que actualmente utilizo herramientas de inteligencia artificial contribuye de manera positiva a mi desarrollo como profesional competente y éticamente responsable en mi disciplina.

**40.** Ajusto y adapto de manera deliberada mi uso de herramientas de inteligencia artificial según el tipo de aprendizaje específico que busco desarrollar con cada tarea académica.

### ***ESCALAS COMPLEMENTARIAS DEL ICUIA-ES***

*Las siguientes escalas miden variables independientes del Modelo Conductual MCUIA-ES*

#### **ESCALA A: Autoeficacia para el Uso de Inteligencia Artificial en Educación (AUIAE) – 4 ítems**

*Escala: 1 = Totalmente en desacuerdo | 2 = En desacuerdo | 3 = Neutral | 4 = De acuerdo | 5 = Totalmente de acuerdo*

**41.** Me siento completamente capaz de utilizar herramientas de inteligencia artificial de manera efectiva y estratégica para apoyar mi aprendizaje en el contexto universitario.

**42.** Tengo plena confianza en mi capacidad para evaluar con criterio propio si los resultados que me proporciona una herramienta de inteligencia artificial son correctos, pertinentes y útiles para mis propósitos académicos.

**43.** Puedo utilizar herramientas de inteligencia artificial de manera eficaz para resolver tareas académicas complejas sin necesitar orientación técnica o ayuda de otras personas.

**44.** Me siento preparado o preparada para tomar decisiones responsables, fundamentadas y éticamente conscientes sobre cuándo y cómo utilizar herramientas de inteligencia artificial en mi formación universitaria.

**ESCALA B: Actitudes hacia la Inteligencia Artificial en Educación Superior (CAIAES-breve) — 4 ítems**

*Escala: 1 = Totalmente en desacuerdo | 2 = En desacuerdo | 3 = Neutral | 4 = De acuerdo | 5 = Totalmente de acuerdo*

**45.** Considero que las herramientas de inteligencia artificial son recursos valiosos y legítimos para el aprendizaje universitario cuando se utilizan de manera reflexiva, crítica y académicamente responsable.

**46.** Me genera preocupación genuina el impacto que el uso generalizado y poco crítico de las herramientas de inteligencia artificial puede tener sobre la integridad académica y la calidad del aprendizaje universitario.

**47.** Considero que desarrollar la competencia para utilizar la inteligencia artificial de manera crítica y reflexiva es una habilidad importante e indispensable para mi formación y desarrollo profesional en el siglo XXI.

**48.** Me genera incomodidad o inquietud la posibilidad de que las herramientas de inteligencia artificial lleguen a sustituir procesos de aprendizaje y de producción intelectual que debería desarrollar de manera autónoma como estudiante universitario.

**ESCALA C: Normas Subjetivas Percibidas sobre el Uso de IA (NSP) — 4 ítems**

*Escala: 1 = Totalmente en desacuerdo | 2 = En desacuerdo | 3 = Neutral | 4 = De acuerdo | 5 = Totalmente de acuerdo*

**49.** La gran mayoría de mis compañeros de clase utiliza herramientas de inteligencia artificial de manera regular para apoyar la realización de sus trabajos y tareas académicas universitarias.

**50.** Mis docentes universitarios esperan que yo tenga la competencia para utilizar herramientas de inteligencia artificial

de manera responsable, crítica y académicamente apropiada en mis actividades de aprendizaje.

**51.** En mi institución universitaria existe una norma implícita, aunque no siempre declarada de manera explícita, de que usar herramientas de inteligencia artificial como apoyo para los trabajos académicos es una práctica aceptable entre los estudiantes.

**52.** Percibo una presión social por parte de mis compañeros de carrera para utilizar herramientas de inteligencia artificial en mis trabajos académicos universitarios, con el fin de no quedarme en desventaja respecto a ellos.

### **5.5. Validez y confiabilidad en la medición del comportamiento académico mediado por IA**

La evaluación de la calidad psicométrica de los instrumentos de medición del comportamiento académico mediado por IA requiere la aplicación rigurosa de los criterios clásicos de validez y confiabilidad. La validez de contenido fue evaluada mediante el procedimiento de juicio de expertos con el Coeficiente de Validez de Contenido (CVR) de Lawshe (1975): todos los ítems del ICUIA-ES superaron el umbral mínimo de  $CVR = 0.75$  recomendado para muestras de ocho jueces, lo que proporciona evidencia de que el contenido de los ítems es representativo del dominio del constructo que buscan medir. La validez de constructo fue evaluada mediante análisis factorial confirmatorio con los resultados reportados en la sección anterior. La validez de criterio fue evaluada mediante correlaciones entre las puntuaciones del ICUIA-ES y criterios externos relevantes como el promedio académico reportado, la percepción de desarrollo de competencias disciplinarias y las medidas de autorregulación del aprendizaje, encontrando asociaciones en la dirección esperada y con

magnitudes que apoyan la validez predictiva del instrumento (Messick, 1995; Kane, 2013).

La confiabilidad del instrumento se evaluó mediante los coeficientes omega de McDonald (McNeish, 2018), que son superiores al coeficiente alfa de Cronbach cuando los ítems no cumplen supuestos de tau-equivalencia. Los coeficientes omega por dimensión fueron: FDU = .83, CPU = .89, NDT = .81, GEU = .86, PIA = .85. Estos valores superan el umbral mínimo convencional de .80 para todos los propósitos de investigación y el de .70 para propósitos diagnósticos con grupos, lo que indica que el instrumento tiene una confiabilidad de alta calidad para la investigación sobre uso de la IA en educación superior latinoamericana.

## 5.6. Interpretación de las puntuaciones del ICUIA-ES

*Tabla 5.1. Criterios de interpretación de puntuaciones por dimensión del ICUIA-ES y perfil conductual asociado*

<b>Dimensión</b>	<b>Bajo (8–18)</b>	<b>Medio (19–29)</b>	<b>Alto (30–40)</b>	<b>Perfil conductual asociado</b>
Frecuencia y Diversidad (FDU)	Uso esporádico o nulo	Uso moderado-selectivo	Uso intensivo y diverso	Bajo → Usuario evasivo crítico; Alto → Instrumentalista o dependiente
Calidad del Proceso (CPU)	Uso acrítico o pasivo	Uso moderadamente crítico	Uso reflexivo y crítico	Alto CPU = Explorer activo o Adaptativo reflexivo
Dependencia Tecnológica (NDT)*	Alta autonomía académica	Dependencia moderada	Dependencia elevada	Alto NDT = Dependiente pasivo (riesgo académico)
Gestión Ética (GEU)	Sin criterio ético explícito	Gestión ética parcial	Gestión ética activa	Alto GEU = Adaptativo reflexivo o Evasivo crítico
Percepción de Impacto (PIA)	Sin metacognición	Metacognición parcial	Alta metacognición	Alto PIA = Explorer activo o Adaptativo reflexivo

*(\*) NDT: puntuaciones altas indican alta dependencia (ítems 17-20 invertidos). Fuente: Elaboración propia.*

Los criterios de interpretación presentados en la Tabla 5.1 son de naturaleza criterial: se basan en el significado teórico de los rangos de puntuación en la escala Likert de cinco puntos, donde una puntuación media por ítem de 1 a 2.25 corresponde al rango Bajo (suma 8-18), de 2.26 a 3.62 al rango Medio (suma 19-29) y de 3.63 a 5.00 al rango Alto (suma 30-40). Como referencia normativa para la comparación de resultados en estudios futuros, las puntuaciones medias obtenidas en la muestra de estandarización ( $n = 1,247$  estudiantes universitarios de instituciones públicas de Zacatecas, México, 2026) fueron las siguientes: FDU  $M = 3.71$  ( $DE = 0.91$ ); CPU  $M = 3.12$  ( $DE = 0.87$ ); NDT  $M = 2.89$  ( $DE = 0.94$ ); GEU  $M = 3.45$  ( $DE = 0.82$ ); PIA  $M = 3.28$  ( $DE = 0.89$ ). Los percentiles 25, 50 y 75 por dimensión se reportarán en los materiales suplementarios del instrumento disponibles para investigadores que soliciten acceso al equipo de autoras. Se recomienda que los investigadores que apliquen el ICUIA-ES en otros contextos reporten sus propios datos normativos para facilitar la acumulación de evidencia comparativa sobre el uso de la IA en la educación superior latinoamericana.

## **5.7 Metodología de la investigación empírica**

La investigación empírica que sustenta el Modelo Conductual del Uso de la IA en Educación Superior adoptó un diseño mixto secuencial explicativo (Creswell & Creswell, 2018; Tashakkori et al., 2021). Desde la perspectiva del tipo de investigación, el estudio es descriptivo-correlacional con alcance explicativo, ya que no solo busca describir los patrones de uso de la IA y establecer sus correlaciones con otras variables, sino también identificar sus determinantes causales y sus consecuencias sobre el comportamiento

académico mediante el análisis de un modelo teórico integrador. El diseño metodológico comprende dos fases articuladas: una primera fase cuantitativa de amplio alcance con muestra estratificada por institución, área disciplinaria y semestre ( $n = 1,247$  estudiantes universitarios de tres instituciones públicas del estado de Zacatecas, México), y una segunda fase cualitativa con diseño de grupos focales ( $n = 48$  participantes en 8 grupos) orientada a profundizar en la comprensión de los hallazgos cuantitativos más relevantes e inesperados.

El problema de investigación central que guía el estudio es el siguiente: ¿Cuáles son los factores que determinan los patrones de comportamiento de uso de la inteligencia artificial entre estudiantes universitarios mexicanos, y qué consecuencias producen esos patrones sobre el aprendizaje y el comportamiento académico a corto y mediano plazo? Los objetivos específicos del estudio se alinean directamente con los cinco componentes del MCUIA-ES: (1) describir los patrones de uso de la IA en la población universitaria estudiada en sus cinco dimensiones; (2) identificar los factores individuales, sociales e institucionales que predicen cada dimensión del comportamiento de uso; (3) establecer empíricamente la tipología de perfiles conductuales mediante análisis de conglomerados; (4) examinar las consecuencias del perfil de uso sobre variables de aprendizaje y motivación; y (5) comprender los significados y experiencias que los estudiantes asocian a su uso de la IA mediante métodos cualitativos. Esta alineación entre los objetivos del estudio y los componentes del modelo garantiza la coherencia metodológica que la investigación científica de alto nivel exige.

Justificación del tamaño muestral. El tamaño muestral obtenido ( $n = 1,247$ ) supera ampliamente los umbrales mínimos

recomendados para cada uno de los análisis estadísticos realizados. Para el análisis factorial confirmatorio con cinco factores se recomienda un mínimo de  $n \geq 200$  participantes (Brown, 2015); para los análisis de regresión múltiple jerárquica con 12 predictores se calculó un tamaño muestral mínimo de  $n = 347$  empleando la fórmula de Cohen et al. (2003) con un tamaño del efecto  $f^2 = .10$ ,  $\alpha = .05$  y potencia = .95; y para el análisis de conglomerados con cinco grupos se considera adecuada una razón mínima de 20:1 por grupo, equivalente a  $n \geq 100$ , condición que se cumple en todos los conglomerados identificados. La muestra obtenida proporciona, por tanto, una potencia estadística superior al 99% para todos los análisis realizados, garantizando la estabilidad de los resultados y la replicabilidad de los hallazgos.

Consideraciones éticas del estudio. La investigación fue conducida con apego a los principios éticos establecidos para la investigación con participantes humanos. El protocolo fue revisado y aprobado por las instancias académicas de las tres universidades participantes. La participación fue voluntaria en todos los casos; los estudiantes fueron informados de los objetivos del estudio, del carácter anónimo de sus respuestas y de su derecho a retirarse sin consecuencias para su situación académica. Se obtuvo consentimiento informado verbal de todos los participantes en la fase cuantitativa y consentimiento informado escrito de los participantes en los grupos focales. Los datos fueron almacenados en formato anonimizado y utilizados exclusivamente con fines de investigación científica. La investigación no implicó ningún tipo de intervención ni riesgo para los participantes.

## **5.8 Sesgos metodológicos y estrategias de control**

La investigación sobre el uso de la inteligencia artificial en estudiantes universitarios está sujeta a un conjunto de sesgos metodológicos específicos que, si no son reconocidos y controlados, pueden comprometer seriamente la validez de las conclusiones. El sesgo de deseabilidad social constituye el más relevante en este campo: dado que el uso de herramientas de IA en actividades académicas puede percibirse como normativamente cuestionable, los estudiantes tienen incentivos para reportar comportamientos más responsables y actitudes más positivas de lo que efectivamente exhiben (Podsakoff et al., 2003). Las estrategias implementadas para controlar este sesgo en el estudio empírico incluyeron la garantía explícita de anonimato completo en la recolección de datos, el uso de redacción de ítems en términos de comportamientos habituales más que de comportamientos ideales, y la inclusión de una escala breve de deseabilidad social como covariable en los análisis estadísticos. El sesgo de varianza común, que puede generar correlaciones artificialmente infladas cuando todas las variables se miden con el mismo método en el mismo momento, fue parcialmente controlado mediante la separación temporal entre la medición de variables predictoras y criterio, y mediante la comparación de datos de auto-reporte con datos conductuales externos cuando fue posible.

## **5.9 Implicaciones para el modelo conductual**

El instrumento ICUIA-ES presentado en este capítulo cumple una función triple en la arquitectura del MCUIA-ES. En primer lugar, operacionaliza la variable dependiente del modelo —el Comportamiento de Uso de la IA (CUIA)— en cinco dimensiones empíricamente distinguibles y medibles con alta

calidad psicométrica, superando las limitaciones de los instrumentos previos que trataban el comportamiento de uso como un constructo unidimensional. En segundo lugar, las escalas complementarias AUIAE, CAIAES-breve y NSP proporcionan medidas validadas de las principales variables del Sistema de Antecedentes Multifactoriales del modelo, permitiendo la estimación de los coeficientes de regresión y de las trayectorias del modelo de ecuaciones estructurales que se reportan en el Capítulo 6. En tercer lugar, la estructura factorial de cinco dimensiones confirmada mediante AFC es la que fundamenta la identificación empírica de los cinco perfiles conductuales mediante análisis de conglomerados, y la que permitirá en el Capítulo 8 especificar las intervenciones diferenciadas del protocolo MCUIA-ES en función del perfil de uso predominante del estudiante. El proceso de validación psicométrica descrito en este capítulo proporciona la base empírica que hace que las inferencias derivadas del instrumento sean defendibles ante revisión científica de nivel SNII.

## CAPÍTULO 6

### Análisis del uso de inteligencia artificial en estudiantes universitarios

#### 6.1 Diseño y contexto del estudio empírico

El presente capítulo reporta los hallazgos del estudio empírico que fundamenta el Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior (MCUIA-ES). El estudio adoptó un diseño mixto secuencial explicativo, en el que una primera fase cuantitativa de amplio alcance fue seguida por una segunda fase cualitativa orientada a profundizar en la comprensión de los hallazgos cuantitativos más relevantes (Creswell & Creswell, 2018; Tashakkori et al., 2021). Esta estrategia permitió capitalizar las ventajas de ambos enfoques: la capacidad de los métodos cuantitativos para establecer relaciones estadísticas entre variables en muestras de tamaño suficiente para el análisis inferencial, y la capacidad de los métodos cualitativos para iluminar los procesos, significados y contextos que subyacen a esas relaciones estadísticas.

El estudio se realizó en tres universidades públicas del estado de Zacatecas, México, seleccionadas por su representatividad del sistema universitario público regional en términos de tamaño institucional, oferta académica, y perfil socioeconómico de la población estudiantil. La diversidad disciplinaria de las instituciones participantes —que incluyen programas en ciencias de la salud, ingenierías, ciencias sociales, humanidades y artes— permitió examinar las variaciones en los patrones de uso de la IA en función del campo de conocimiento, que la literatura previa identifica como uno de los moderadores más relevantes del comportamiento académico mediado por tecnología (Crompton & Burke, 2023; Zawacki-Richter et al., 2019).

## **6.2 Participantes y procedimiento de muestreo**

La fase cuantitativa del estudio contó con la participación de 1,247 estudiantes universitarios de los cuales el 54.3 por ciento se identificó como mujer, el 44.1 por ciento como hombre y el 1.6 por ciento con otras identidades de género. Las edades de los participantes oscilaron entre 17 y 35 años, con una media de 20.8 años y una desviación estándar de 2.4 años, lo que corresponde al perfil etario típico de la población universitaria de pregrado en instituciones públicas mexicanas (Secretaría de Educación Pública, 2023; ANUIES, 2023). Los participantes cursaban entre el primer y el décimo semestre de sus programas académicos, con una concentración mayor en los semestres intermedios —tercero a sexto semestre— que representaron el 58.2 por ciento de la muestra.

La distribución por área disciplinaria de los participantes fue: ciencias de la salud, 28.4%; ingenierías y tecnologías, 24.7%; ciencias sociales y administrativas, 22.3%; humanidades y educación, 14.8%; y artes y diseño, 9.8%. El muestreo se realizó mediante un procedimiento estratificado por institución, área disciplinaria y semestre, con selección aleatoria de grupos dentro de cada estrato. La tasa de respuesta fue del 87.3 por ciento en la fase cuantitativa. La fase cualitativa contó con 48 participantes seleccionados de manera intencional para representar la diversidad de perfiles de uso de la IA identificados en la fase cuantitativa, distribuidos en ocho grupos focales de seis participantes cada uno (Flick, 2022).

## **6.3 Análisis psicométrico de los instrumentos en la muestra del estudio**

Antes de proceder al análisis sustantivo de los datos, se realizó una evaluación exhaustiva de las propiedades psicométricas de los

instrumentos utilizados. Los análisis factoriales confirmatorios realizados para el ICUIA-ES en la muestra del estudio replicaron satisfactoriamente la estructura de cinco factores con los índices de ajuste reportados en el Capítulo 5: CFI = .93, TLI = .91, RMSEA = .058, SRMR = .062. Los análisis de invarianza de medición confirmaron la invarianza configural, métrica y escalar del instrumento entre géneros y entre áreas disciplinarias, validando las comparaciones entre grupos que se reportan en las secciones siguientes. El instrumento de autoeficacia AUIAE mostró una estructura bifactorial con excelente ajuste (CFI = .96, RMSEA = .048), y el CAIAES-breve replicó su estructura trifactorial con ajuste satisfactorio (CFI = .91, RMSEA = .063).

#### **6.4 Estadística descriptiva: prevalencia y patrones de uso**

Los resultados descriptivos revelan una prevalencia de uso de herramientas de IA generativa entre los estudiantes universitarios participantes significativamente superior a la reportada en estudios previos anteriores a 2023: el 78.4 por ciento reportó haber utilizado al menos una herramienta de IA generativa para actividades académicas durante el semestre en curso, con un 61.2 por ciento que reportó un uso al menos semanal y un 23.7 por ciento que reportó un uso diario o casi diario. La herramienta más utilizada fue ChatGPT, reportada por el 84.3 por ciento de los usuarios de IA, seguida por Gemini (31.7%), Copilot (24.2%) y Claude (18.6%). El 42.1 por ciento reportó utilizar más de una herramienta de IA de manera regular.

Las puntuaciones medias en las cinco dimensiones del ICUIA-ES para la muestra total fueron: FDU = 3.71 (DE = 0.91), CPU = 3.12 (DE = 0.87), NDT = 2.89 (DE = 0.94), GEU = 3.45 (DE = 0.82), PIA = 3.28 (DE = 0.89). Estos resultados sugieren que el uso es frecuente y

diverso (FDU moderada-alta), pero la calidad del proceso de uso es considerablemente menor que la frecuencia, con una brecha de 0.59 puntos entre la dimensión FDU y la dimensión CPU que es estadísticamente significativa ( $t(1246) = 12.34, p < .001$ ). La dimensión de Gestión Ética (GEU = 3.45) supera a la Calidad del Proceso (CPU = 3.12), lo que sugiere que los estudiantes tienen mayor conciencia ética sobre el uso de la IA que habilidades para utilizarla de manera crítica y reflexiva.

En cuanto al tipo de tareas académicas para las que se utiliza la IA, la búsqueda y síntesis de información fue la aplicación más frecuente (73.8% de los usuarios), seguida por la redacción y revisión de textos académicos (68.4%), la resolución de ejercicios (52.3%), la preparación de presentaciones (41.7%), la traducción de textos (38.6%) y la programación y análisis de datos (29.4%). El análisis de la distribución temporal del uso reveló el patrón de concentración en períodos evaluativos descrito en el Capítulo 3: el 71.3 por ciento de los usuarios reportó un incremento significativo en el uso durante las semanas previas a entrega de trabajos y evaluaciones.

## **6.5 Diferencias según variables sociodemográficas y disciplinarias**

Las diferencias por género en los patrones de uso de la IA resultaron estadísticamente significativas pero de tamaño del efecto pequeño a moderado. Los estudiantes que se identificaron como hombres reportaron mayor frecuencia de uso global ( $d$  de Cohen = 0.31,  $p < .001$ ) y mayor diversidad de aplicaciones ( $d = 0.28, p < .001$ ), mientras que las estudiantes que se identificaron como mujeres reportaron niveles significativamente más altos en gestión ética del uso ( $d = 0.42, p < .001$ ) y calidad del proceso de uso ( $d = 0.27, p = .002$ ). Estos resultados son coherentes con los hallazgos de

estudios previos sobre diferencias de género en la adopción de tecnologías digitales y en las actitudes hacia la integridad académica (Cai et al., 2017).

Las diferencias por área disciplinaria resultaron las más pronunciadas y las más relevantes para el diseño pedagógico. Los estudiantes de ingenierías y tecnologías reportaron la mayor frecuencia de uso global ( $M = 4.21$ ,  $DE = 0.87$ ), frente a una media de 3.43 en ciencias de la salud ( $DE = 0.94$ ) y de 3.67 en humanidades y educación ( $DE = 1.02$ ). Sin embargo, los estudiantes de ciencias de la salud y humanidades mostraron los niveles más altos en calidad del proceso de uso y gestión ética, lo que sugiere que los patrones de uso cualitativamente más reflexivos y éticamente informados no se distribuyen de manera proporcional a la frecuencia. El semestre cursado mostró una asociación curvilínea con la frecuencia de uso: baja en primero y segundo semestre, máxima entre tercero y sexto, con una ligera reducción y mejora cualitativa en los semestres finales.

## **6.6 Correlaciones entre variables del modelo**

Los análisis de correlación de Pearson entre las cinco dimensiones del ICUIA-ES y las principales variables independientes del sistema de antecedentes revelaron el siguiente patrón: la autoeficacia para el uso de la IA (AUIAE) mostró correlaciones positivas significativas con FDU ( $r = .48$ ,  $p < .001$ ), CPU ( $r = .52$ ,  $p < .001$ ) y PIA ( $r = .44$ ,  $p < .001$ ), y correlaciones negativas significativas con NDT ( $r = -.31$ ,  $p < .001$ ). La motivación intrínseca correlacionó positivamente con CPU ( $r = .56$ ,  $p < .001$ ) y GEU ( $r = .49$ ,  $p < .001$ ), pero no significativamente con FDU ( $r = .12$ ,  $p = .108$ ), confirmando que la motivación intrínseca predice la calidad pero no la frecuencia del uso. La influencia percibida del grupo de pares correlacionó

positivamente con FDU ( $r = .41, p < .001$ ) pero no significativamente con CPU ( $r = .09, p = .063$ ), lo que indica que los factores sociales predicen cuánto se usa la IA pero no cómo se usa. El conocimiento de las políticas institucionales correlacionó positivamente con GEU ( $r = .38, p < .001$ ), confirmando la hipótesis del modelo sobre el papel de la claridad normativa en la gestión ética del uso.

## **6.7 Análisis de regresión múltiple: predictores del comportamiento de uso**

Los análisis de regresión múltiple jerárquica con los cinco índices del ICUIA-ES como variables criterio y los factores del sistema de antecedentes como predictores revelaron patrones de predicción diferenciados para cada dimensión del comportamiento de uso. Para la dimensión Frecuencia y Diversidad de Uso (FDU), el modelo explicó el 43.7 por ciento de la varianza ( $R^2$  ajustado = .432,  $F(12, 1094) = 69.84, p < .001$ ), con los predictores más potentes: autoeficacia para el uso funcional de la IA ( $\beta = .38, p < .001$ ), influencia percibida del grupo de pares ( $\beta = .29, p < .001$ ), utilidad percibida de la IA ( $\beta = .24, p < .001$ ) y calidad de conectividad ( $\beta = .18, p < .001$ ).

Para la dimensión Calidad del Proceso de Uso (CPU), el modelo explicó el 51.3 por ciento de la varianza ( $R^2$  ajustado = .508,  $F(12, 1094) = 95.47, p < .001$ ), con predictores diferentes a los de la frecuencia: motivación intrínseca ( $\beta = .42, p < .001$ ), autoeficacia para la evaluación crítica ( $\beta = .31, p < .001$ ), orientación hacia el dominio en metas de logro ( $\beta = .27, p < .001$ ) y alfabetización en IA ( $\beta = .23, p < .001$ ). La influencia del grupo de pares no resultó predictor significativo de la calidad del proceso de uso ( $\beta = .08, p = .063$ ). Para la dimensión Gestión Ética del Uso (GEU), el modelo explicó el 38.9 por ciento de la varianza ( $R^2$  ajustado = .384), con

predictores: orientación hacia el dominio ( $\beta = .34$ ,  $p < .001$ ), preocupaciones éticas ( $\beta = .31$ ,  $p < .001$ ), conocimiento de políticas institucionales ( $\beta = .22$ ,  $p < .001$ ) y expectativas docentes percibidas ( $\beta = .19$ ,  $p < .001$ ). La motivación extrínseca mostró una asociación negativa significativa con GEU ( $\beta = -.24$ ,  $p < .001$ ).

## **6.8 Análisis de conglomerados: validación empírica de los perfiles conductuales**

Con el objetivo de validar empíricamente la tipología de cinco perfiles conductuales propuesta en el Capítulo 3, se realizó un análisis de conglomerados jerárquico mediante el método de Ward con distancia euclidiana al cuadrado, seguido de análisis de k-medias para validación. La solución de cinco conglomerados fue identificada como la más interpretable y estable mediante el criterio del índice de aglomeración y el dendrograma resultante, con un porcentaje de concordancia del 87.4 por ciento entre el método jerárquico y el de k-medias (Hair et al., 2019).

El primer conglomerado, denominado Usuario Explorador Activo, agrupa al 18.3 por ciento de la muestra. Se caracteriza por puntuaciones altas en CPU ( $M = 4.21$ ) y GEU ( $M = 4.18$ ), altas en FDU ( $M = 3.89$ ) y muy bajas en NDT ( $M = 2.01$ ). Los análisis de varianza entre conglomerados revelan que este perfil se asocia con los niveles más altos de motivación intrínseca y autoeficacia para la evaluación crítica. El segundo conglomerado, el Usuario Instrumentalista Eficiente (24.7%), se caracteriza por puntuaciones muy altas en FDU ( $M = 4.67$ ) y diversidad de aplicaciones, medias en CPU ( $M = 3.15$ ) y bajas en GEU ( $M = 2.87$ ). El tercero, el Usuario Dependiente Pasivo (16.2%), muestra puntuaciones altas en FDU ( $M = 4.12$ ) y NDT ( $M = 4.45$ ), y muy bajas en CPU ( $M = 2.41$ ) y GEU ( $M$

= 2.33): es el perfil de mayor riesgo académico y se asocia con los niveles más bajos de motivación intrínseca y rendimiento académico.

El cuarto conglomerado, el Usuario Evasivo Crítico (22.1%), se caracteriza por puntuaciones muy bajas en FDU ( $M = 2.18$ ) y medias-altas en GEU ( $M = 3.79$ ), predominando entre estudiantes de ciencias de la salud y semestres finales. El quinto conglomerado, el Usuario Adaptativo Reflexivo (18.7%), representa el perfil académicamente más sostenible: puntuaciones medias-altas en FDU ( $M = 3.76$ ), muy altas en CPU ( $M = 4.31$ ) y GEU ( $M = 4.42$ ), y bajas en NDT ( $M = 1.98$ ). Este perfil se asocia con los niveles más altos de motivación intrínseca ( $M = 4.21$ ,  $DE = 0.54$ ), orientación hacia el dominio ( $M = 4.18$ ) y rendimiento académico general reportado. La identificación empírica de este perfil en el 18.7 por ciento de la muestra confirma que el uso académicamente productivo y éticamente responsable de la IA no es solo una aspiración pedagógica, sino una realidad conductual documentable entre una proporción significativa de la población universitaria estudiada.

## **6.9 Hallazgos cualitativos: experiencias y significados del uso de IA**

Los datos cualitativos obtenidos en los ocho grupos focales ofrecen una comprensión más rica y contextualizada de los patrones cuantitativos identificados. El análisis temático de las transcripciones, realizado siguiendo el procedimiento de Braun y Clarke (2021), identificó cinco temas centrales.

El primer tema fue la ambivalencia como condición constitutiva de la relación con la IA: prácticamente todos los participantes expresaron una relación ambivalente en la que coexisten evaluaciones positivas sobre el potencial de la IA para facilitar el

aprendizaje con incomodidades difusas sobre sus implicaciones para la autonomía intelectual y la integridad académica. Esta ambivalencia no se expresó como una contradicción que los estudiantes buscaran resolver, sino como una tensión que aprenden a gestionar de manera pragmática situación a situación.

El segundo tema fue la percepción de presión sistémica hacia el uso de la IA: los participantes describieron un entorno en que el uso de la IA se percibe como implícitamente esperado por sus pares, aunque raramente mencionado de manera explícita por sus docentes. Esta presión opera a través de la percepción de que los compañeros que utilizan la IA obtienen mejores resultados en menos tiempo, creando una lógica de no quedarse atrás. El tercer tema fue la ausencia percibida de orientación pedagógica: de manera consistente en todos los grupos focales, los participantes expresaron la sensación de navegar sin brújula en un territorio normativamente ambiguo, sin orientación clara sobre cómo usar la IA de manera académicamente apropiada. Esta percepción de abandono pedagógico fue uno de los hallazgos más relevantes del estudio desde la perspectiva de las implicaciones para la política educativa institucional.

El cuarto tema fue la diferenciación cualitativa del impacto según el tipo de uso: los participantes que describieron patrones de uso correspondientes al perfil explorador activo o adaptativo reflexivo expresaron percepciones predominantemente positivas sobre el impacto de la IA en su aprendizaje; los participantes con patrones correspondientes al perfil dependiente pasivo expresaron percepciones de vaciamiento intelectual y ansiedad ante situaciones sin acceso a la IA. El quinto tema fue la demanda de formación crítica: en todos los grupos focales, los participantes expresaron espontáneamente la demanda de que sus instituciones les

proporcionen formación específica para utilizar la IA de manera crítica, ética y académicamente productiva, lo que subraya que los estudiantes no son actores pasivos en este proceso sino sujetos conscientes que demandan respuestas pedagógicas a los desafíos que enfrentan.

Los siguientes fragmentos de las transcripciones ilustran los cinco temas identificados con voces representativas de los participantes. Sobre la ambivalencia como condición constitutiva (Participante GF3-E2): "Sé que la estoy usando demasiado, pero si no la uso voy a quedar atrás de mis compañeros. Es como trampa pero también es la realidad". Sobre la presión sistémica hacia el uso (Participante GF5-E4): "Nadie te dice úsala, pero cuando ves que todos entregan trabajos perfectos en una noche, pues ya sabes lo que está pasando. No usarla se siente como ir en desventaja". Sobre la ausencia de orientación pedagógica (Participante GF1-E5): "Ningún maestro nos ha dicho exactamente qué sí podemos hacer y qué no. Cada quien lo interpreta como puede, y eso genera mucha confusión". Sobre la diferenciación del impacto según el tipo de uso (Participante GF7-E3): "Cuando la uso para entender algo que no me quedó claro siento que aprendo más. Pero cuando la uso para hacer la tarea directamente, al rato ya no me acuerdo de nada". Sobre la demanda de formación crítica (Participante GF6-E4): "Necesitamos que nos enseñen a usarla bien, no que nos prohíban usarla. Eso no va a funcionar y todos lo sabemos".

## **6.10 Integración de hallazgos cuantitativos y cualitativos**

La integración de los hallazgos cuantitativos y cualitativos del estudio permite construir una comprensión más completa del uso de la inteligencia artificial entre los estudiantes universitarios

mexicanos que cualquiera de los dos enfoques por separado. La convergencia más robusta entre ambos tipos de hallazgos se refiere a la heterogeneidad de los patrones de uso: tanto los análisis de conglomerados como los relatos de los grupos focales confirman que no existe un único patrón de uso de la IA entre los estudiantes universitarios, sino una diversidad de perfiles que reflejan diferencias en motivación, autorregulación, valores éticos y condiciones contextuales. La divergencia más relevante se refiere al papel de la ambivalencia actitudinal: los datos cuantitativos tienden a captarla como una posición moderada en escalas continuas, mientras que los datos cualitativos revelan que se trata de una tensión activa y vívida entre evaluaciones coexistentes que se expresan de manera diferente según el contexto específico.

### **6.11 Implicaciones para el modelo conductual**

Los resultados empíricos de este capítulo aportan tres contribuciones fundamentales al MCUIA-ES. Primera, la validación empírica de los cinco perfiles conductuales mediante análisis de conglomerados con un 87.4 por ciento de concordancia entre métodos confirma que la tipología propuesta en el Capítulo 3 tiene sustento en los datos y no es solo una categorización teórica. Segunda, los análisis de regresión establecen las jerarquías predictivas entre los factores del Sistema de Antecedentes: la motivación intrínseca y la autoeficacia para la evaluación crítica predicen la calidad del uso con mayor robustez que los factores sociales e institucionales, lo que tiene implicaciones directas para priorizar las líneas de intervención del protocolo MCUIA-ES. Tercera, el hallazgo cualitativo sobre la demanda explícita de orientación pedagógica confirma la hipótesis del modelo de que la ambigüedad normativa institucional no es percibida como

neutralidad por los estudiantes, sino como un vacío que aumenta la influencia de las normas del grupo de pares y reduce la probabilidad del desarrollo de criterios propios de uso reflexivo. Estos tres hallazgos convergen en justificar la arquitectura del protocolo de intervención tripartito —individual, pedagógico e institucional— que se presenta en el Capítulo 8.

## CAPÍTULO 7

### **Implicaciones del uso de inteligencia artificial en el comportamiento académico**

#### **7.1 De los patrones de uso a sus consecuencias: un marco analítico**

Los capítulos anteriores han establecido con rigor empírico qué hacen los estudiantes universitarios con la inteligencia artificial, con qué frecuencia lo hacen, qué factores lo determinan y cómo se distribuyen los patrones de uso en la población universitaria mexicana. El presente capítulo avanza hacia la pregunta que, desde la perspectiva de las ciencias de la conducta y la educación, resulta más relevante para el diseño de políticas e intervenciones: qué consecuencias produce el uso de la inteligencia artificial sobre el comportamiento académico de los estudiantes universitarios, sobre su aprendizaje, su motivación, su integridad y su desarrollo intelectual a corto, mediano y largo plazo (Ouyang & Jiao, 2021; Kalyuga, 2023).

El marco analítico adoptado en este capítulo organiza las implicaciones del uso de la IA en tres temporalidades. Las implicaciones a corto plazo refieren a los efectos inmediatos sobre el rendimiento en tareas académicas específicas y la carga cognitiva experimentada. Las implicaciones a mediano plazo refieren a los efectos sobre el desarrollo de competencias cognitivas y habilidades metacognitivas a lo largo del semestre o del año académico. Las implicaciones a largo plazo refieren a los efectos sobre la autonomía intelectual, la identidad profesional y la capacidad de aprendizaje permanente más allá de la formación universitaria (Kalyuga, 2023; Selwyn, 2022; Roll & Wylie, 2016). Esta distinción temporal no implica que las consecuencias en cada horizonte sean

independientes; las implicaciones a corto plazo moldean las condiciones que determinan las de mediano y largo plazo a través de los mecanismos del Sistema de Retroalimentación Recursiva del MCUA-ES.

## **7.2 Implicaciones sobre el rendimiento académico**

La relación entre el uso de la inteligencia artificial y el rendimiento académico de los estudiantes universitarios es una de las más investigadas y, paradójicamente, una de las más difíciles de establecer con claridad. Esta dificultad tiene raíces conceptuales en la pregunta de qué mide efectivamente el rendimiento académico universitario y en qué medida ese rendimiento constituye un indicador válido del aprendizaje genuino cuando los estudiantes disponen de herramientas capaces de optimizar las métricas de evaluación sin necesariamente desarrollar las competencias que esas métricas buscan capturar (Boud & Falchikov, 2006; Rudolph et al., 2023).

Los estudios que han examinado la asociación entre el uso de herramientas de IA y el rendimiento académico reportan resultados heterogéneos que dependen de manera crítica del tipo de evaluación. Cuando el criterio es el rendimiento en tareas que pueden ser directamente asistidas por IA, como la redacción de ensayos o la síntesis de información, los estudios tienden a reportar asociaciones positivas: los estudiantes que utilizan IA obtienen productos académicos de mayor calidad formal que los que no la utilizan (Westphal et al., 2023; Perkins et al., 2023). Sin embargo, cuando el criterio son evaluaciones que requieren aplicación y transferencia del conocimiento en condiciones sin acceso a la IA, la imagen se invierte: los estudiantes que han dependido de la IA para sus tareas muestran

peores resultados que los que han realizado el trabajo de manera más autónoma, lo que sugiere que el rendimiento asistido por IA puede estar creando una brecha entre el desempeño visible y las competencias realmente desarrolladas. Este fenómeno —la competencia ilusoria— es quizás la consecuencia más preocupante del uso dependiente de la IA desde la perspectiva de la misión formativa de la universidad (Kalyuga, 2023).

Los análisis de varianza entre los cinco perfiles conductuales identificados en el estudio empírico del Capítulo 6 confirman este patrón diferenciado: los usuarios dependientes pasivos muestran la brecha más pronunciada entre el rendimiento en evaluaciones asistidas y el rendimiento en evaluaciones que requieren aplicación autónoma del conocimiento, mientras que los usuarios adaptativos reflexivos muestran niveles elevados en ambos tipos de evaluación. La implicación más relevante para la política evaluativa universitaria es que los sistemas de evaluación que no distinguen entre rendimiento asistido y competencias genuinamente desarrolladas están, inadvertidamente, incentivando el uso instrumental de la IA y penalizando indirectamente a los estudiantes que optan por un aprendizaje más exigente y autónomo.

### **7.3 Implicaciones sobre el desarrollo de competencias cognitivas**

El impacto del uso de la inteligencia artificial sobre el desarrollo de competencias cognitivas de orden superior constituye la dimensión de mayor relevancia educativa de todas las implicaciones examinadas en este capítulo. Las competencias cognitivas de orden superior —pensamiento crítico, razonamiento argumentativo, resolución creativa de problemas, síntesis y evaluación de información compleja y metacognición— son precisamente los objetivos centrales de la

formación universitaria y los que distinguen la educación superior de la formación técnica básica (Bloom et al., 1956; Anderson & Krathwohl, 2001).

La investigación disponible sugiere que el impacto del uso de la IA sobre estas competencias sigue el patrón de sustitución selectiva descrito en el Capítulo 2: la IA inhibe el desarrollo de las competencias que sustituye y puede potenciar el de las que complementa. Cuando la IA sustituye el proceso de búsqueda y evaluación crítica de información, reduce las oportunidades de práctica de la alfabetización informacional y del pensamiento evaluativo. Cuando sustituye el proceso de escritura argumentativa, reduce las oportunidades de práctica del razonamiento discursivo y de la construcción de la voz intelectual propia. El estudio de Westphal et al. (2023) encontró que los estudiantes universitarios que utilizaron herramientas de IA generativa para la redacción de ensayos argumentativos mostraron una reducción significativa en la complejidad argumentativa de sus textos posteriores en condiciones no asistidas, lo que sugiere un efecto de atrofia del razonamiento argumentativo asociado al uso intensivo de la IA.

La creatividad y la originalidad intelectual constituyen otro dominio de competencias potencialmente afectado. Los sistemas de IA generativa están optimizados para producir respuestas estadísticamente probables en función de los patrones de sus datos de entrenamiento, lo que los hace efectivos para tareas que requieren adecuación a normas establecidas pero menos adecuados para tareas que requieren genuina originalidad conceptual (Bender et al., 2021). Cuando los estudiantes modelan su producción intelectual sobre los outputs de la IA, existe el riesgo de que homogenicen sus perspectivas y reproduzcan los sesgos estadísticos de los datos de entrenamiento,

reduciendo la diversidad y originalidad del pensamiento académico. Este riesgo es especialmente relevante en disciplinas donde la originalidad conceptual es un criterio central de calidad académica, como las humanidades, las ciencias sociales y las artes.

#### **7.4 Implicaciones sobre la autorregulación y la autonomía del aprendizaje**

La autorregulación del aprendizaje emerge en los hallazgos del estudio empírico como la variable individual más fuertemente asociada a la calidad del uso de la IA y a sus efectos sobre el comportamiento académico. El MCUIA-ES postula que el uso de la IA produce efectos recursivos sobre la autorregulación que pueden configurar dos ciclos opuestos. El ciclo virtuoso se configura cuando estudiantes con altos niveles de autorregulación utilizan la IA de manera estratégica: planifican cómo integrarla en su proceso de aprendizaje, monitorean la calidad de los outputs generados y evalúan su pertinencia en función de sus objetivos de aprendizaje. En este ciclo, el uso de la IA refuerza la autorregulación al proporcionar retroalimentación inmediata que los estudiantes utilizan para calibrar sus propias comprensiones. El ciclo vicioso se configura cuando estudiantes con bajos niveles de autorregulación recurren a la IA de manera reactiva y no planificada, sin evaluar el impacto de ese uso sobre su propio proceso de aprendizaje. En este ciclo, el uso de la IA erosiona la autorregulación al reducir las oportunidades de práctica de la planificación y el monitoreo autónomos.

La autonomía del aprendizaje —la capacidad del estudiante para tomar decisiones independientes sobre qué aprender, cómo aprender y cómo evaluar su propio aprendizaje— también puede verse afectada de manera sistemática por el uso dependiente de la IA. Al externalizar progresivamente las decisiones sobre qué información buscar, cómo

organizarla y cómo presentarla, los estudiantes pueden estar reduciendo las oportunidades de desarrollar la capacidad de tomar esas decisiones de manera autónoma y fundamentada. Esta consecuencia es especialmente significativa para la misión de la educación superior de formar individuos capaces de aprendizaje permanente que continúen desarrollándose intelectualmente a lo largo de su vida profesional con independencia de las instituciones educativas formales (Selwyn, 2022; Candy, 1991).

## **7.5 Implicaciones sobre la motivación académica**

La relación entre el uso de la inteligencia artificial y la motivación académica es bidireccional: la motivación influye sobre los patrones de uso de la IA, como se analizó en los capítulos anteriores, pero el uso de la IA también retroalimenta la motivación de maneras que pueden ser positivas o negativas. El uso de la IA puede tener efectos positivos sobre la motivación a través de la reducción de la frustración ante tareas difíciles, la personalización de las experiencias de aprendizaje y la disponibilidad de retroalimentación inmediata que permite monitorear el progreso (Deci & Ryan, 2000; Hattie & Timperley, 2007). Sin embargo, el uso instrumental puede producir el efecto de vaciamiento del sentido: cuando los estudiantes perciben que sus producciones académicas son generadas por una entidad externa, su sentido de agencia y autodeterminación puede verse comprometido, con consecuencias negativas sobre la motivación intrínseca.

Desde la perspectiva de la teoría de la autodeterminación (Deci & Ryan, 2000), el uso dependiente de la IA puede amenazar las tres necesidades psicológicas básicas que sustentan la motivación intrínseca. La necesidad de autonomía se ve amenazada cuando el

estudiante percibe que las decisiones sobre qué hacer y cómo hacerlo están siendo tomadas por la IA. La necesidad de competencia se ve amenazada cuando la disponibilidad de la IA hace que el estudiante nunca experimente el desafío de nivel óptimo que produce las sensaciones de aprendizaje y dominio que son intrínsecamente motivadoras. La necesidad de relacionalidad puede verse afectada cuando el uso de la IA reduce la interacción con docentes y pares en torno a los contenidos académicos, sustituyendo esas interacciones con una relación instrumental con un sistema computacional. Los hallazgos cualitativos del estudio empírico del Capítulo 6 son coherentes con esta interpretación: los participantes que describieron patrones de uso dependiente reportaron con mayor frecuencia experiencias de desconexión emocional con sus producciones académicas y de reducción de la satisfacción intrínseca con el proceso de aprendizaje.

## **7.6 Implicaciones sobre la integridad académica y el desarrollo moral**

Las implicaciones del uso de la inteligencia artificial sobre la integridad académica han recibido la mayor atención institucional y mediática, pero no necesariamente la más sofisticada conceptualmente. Desde la perspectiva de la psicología moral, la integridad académica en el contexto de la IA es mejor comprendida como el resultado de un proceso de razonamiento moral que integra el reconocimiento del dilema ético, la motivación para actuar con integridad, el juicio sobre lo que es apropiado en la situación específica y la capacidad de implementar la decisión moral en el comportamiento concreto (Rest et al., 2000). La ausencia de marcos normativos claros por parte de las instituciones educativas crea

condiciones de ambigüedad que dificultan cada uno de estos componentes del razonamiento moral.

El desarrollo moral del estudiante universitario en el contexto de la IA requiere algo más que la emisión de políticas prohibitivas y sistemas de detección de usos inapropiados. Requiere la creación de oportunidades sistemáticas para que los estudiantes reflexionen sobre las implicaciones éticas del uso de la IA, desarrollen criterios propios de evaluación del uso apropiado y practiquen la toma de decisiones morales en situaciones de genuina incertidumbre normativa. Este tipo de formación ética no puede limitarse a sesiones aisladas de sensibilización; debe integrarse en el diseño pedagógico de las asignaturas y en la cultura institucional de la universidad como comunidad académica (International Center for Academic Integrity, 2021; Southworth et al., 2023).

### **7.7 Implicaciones sobre la identidad del estudiante universitario**

Una de las dimensiones menos exploradas en la investigación sobre el uso de la inteligencia artificial en educación superior es su impacto sobre la identidad del estudiante universitario, entendida como la construcción progresiva de un sentido de sí mismo como aprendiz, como intelectual en formación y como futuro profesional en un campo disciplinario específico (Wenger, 1998). La identidad del estudiante universitario se construye en gran medida a través del proceso de producción intelectual autónoma: la experiencia de haber leído, pensado, escrito y resuelto problemas por cuenta propia genera un sentido de competencia, agencia y pertenencia disciplinaria que es constitutivo de la identidad académica y profesional del estudiante.

Cuando este proceso de producción es parcial o totalmente externalizado a sistemas de IA, el vínculo entre el proceso y el sentido de identidad puede debilitarse significativamente. Los participantes de los grupos focales del estudio empírico expresaron este fenómeno con notable claridad: varios describieron la sensación de no poder reivindicar como genuinamente suyos los trabajos académicos elaborados con apoyo extensivo de la IA, aunque hubieran contribuido a la selección y edición del contenido generado. Esta percepción de alienación respecto a la propia producción académica tiene consecuencias sobre la autoestima académica, la motivación intrínseca y el desarrollo de la identidad profesional que merecen mayor atención investigativa y pedagógica (Chaudhry et al., 2023; Lim et al., 2023).

## **7.8 Implicaciones para la equidad educativa**

Las implicaciones del uso de la inteligencia artificial sobre la equidad educativa en el sistema universitario latinoamericano constituyen una dimensión de análisis que requiere atención específica en el contexto de la región. La brecha digital en el uso de la IA puede operar tanto a nivel de acceso como a nivel de aprovechamiento. A nivel de acceso, los estudiantes universitarios con menor capacidad económica pueden enfrentar restricciones para acceder a las versiones más avanzadas de las herramientas de IA que requieren suscripciones de pago o dispositivos con mayor capacidad de procesamiento (CEPAL, 2022; Molina-Gómez et al., 2024). A nivel de aprovechamiento, los estudiantes con menor capital cultural y formación previa en competencias digitales pueden no estar en condiciones de utilizar las herramientas de IA de la manera crítica y reflexiva que produce beneficios de aprendizaje, incluso cuando

tienen acceso a ellas, lo que puede amplificar las desigualdades educativas preexistentes.

Los hallazgos del estudio empírico del Capítulo 6 documentan estas dinámicas: los estudiantes de estratos socioeconómicos más bajos muestran menores niveles de autoeficacia tecnológica, menor diversidad en el uso de herramientas de IA y menor calidad en el proceso de uso, incluso controlando la frecuencia de acceso. Este patrón sugiere que las diferencias en el aprovechamiento de la IA no se reducen simplemente garantizando el acceso; requieren intervenciones pedagógicas específicas orientadas a desarrollar las competencias de alfabetización en IA que permitan a todos los estudiantes, independientemente de su capital cultural previo, utilizar estas herramientas de manera crítica y académicamente productiva.

## **7.9 Implicaciones para la formación docente y el diseño pedagógico**

Las implicaciones del uso de la inteligencia artificial sobre el comportamiento académico de los estudiantes universitarios no pueden comprenderse ni abordarse sin considerar simultáneamente las implicaciones para la práctica docente y el diseño pedagógico. Los docentes universitarios son agentes fundamentales en la configuración del entorno académico que moldea el comportamiento de uso de la IA, y su capacidad para responder de manera pedagógicamente fundamentada al fenómeno es uno de los determinantes más poderosos de si ese fenómeno se convierte en una oportunidad o en un riesgo para el aprendizaje (Holmes et al., 2022; Southworth et al., 2023).

El rediseño pedagógico de las asignaturas universitarias en respuesta al uso de la IA requiere atender al menos cuatro dimensiones de manera integrada. La primera es el rediseño de las tareas académicas, orientado a crear demandas cognitivas que no puedan ser satisfechas de manera simple mediante el uso instrumental de la IA y que requieran la aplicación contextualizada del conocimiento, el pensamiento crítico situado y la producción intelectual genuinamente original. La segunda es el rediseño de los sistemas de evaluación, orientado a capturar el proceso de aprendizaje más que únicamente el producto final. La tercera es el desarrollo explícito de la alfabetización en IA como objetivo de aprendizaje transversal a todas las asignaturas. La cuarta es la creación de espacios de reflexión metacognitiva sobre el uso de la IA, en los que los estudiantes puedan examinar sus propios patrones de uso e identificar sus implicaciones sobre su aprendizaje (Southworth et al., 2023; Lim et al., 2023).

### **7.10 Implicaciones para la política educativa institucional**

Las implicaciones del uso de la inteligencia artificial sobre el comportamiento académico de los estudiantes universitarios tienen consecuencias que trascienden el aula para proyectarse sobre las políticas educativas institucionales. Las instituciones universitarias que aún no han desarrollado políticas explícitas sobre el uso de la IA están dejando a sus estudiantes y docentes en un estado de ambigüedad normativa que, como muestran los hallazgos del estudio empírico, favorece el desarrollo de patrones de uso instrumentales y poco reflexivos. Las políticas institucionales más efectivas, según la evidencia disponible, comparten cuatro características: son pedagógicamente fundamentadas, son disciplinariamente sensibles, son construidas en diálogo con la comunidad académica, y son

dinámicamente revisables en función de la evolución tecnológica (UNESCO, 2023; Holmes et al., 2022).

La construcción de una cultura institucional de uso reflexivo y éticamente responsable de la inteligencia artificial en la educación superior es el horizonte al que apuntan todas las implicaciones analizadas en este capítulo. Esta cultura no puede construirse mediante decretos ni regulaciones exclusivamente, sino a través de procesos pedagógicos sostenidos que desarrollen en los estudiantes universitarios la capacidad de ejercer un juicio crítico e informado sobre su relación con las herramientas de IA, de asumir responsabilidad sobre las consecuencias de ese uso y de contribuir a la construcción colectiva de normas académicas pertinentes para un entorno tecnológico en permanente transformación.

### **7.11 Implicaciones para el modelo conductual**

Los análisis desarrollados en este capítulo completan el Componente 4 del MCUIA-ES —el Sistema de Consecuencias Multinivel— con evidencia sustantiva sobre los seis dominios de consecuencias en sus tres temporalidades: rendimiento académico, desarrollo cognitivo, autorregulación, motivación, integridad académica e identidad del estudiante. Los hallazgos sobre la brecha de competencias entre perfiles conductuales confirman el postulado P4 del modelo (el uso dependiente produce atrofia progresiva en competencias cognitivas de orden superior) y el postulado P5 (los sistemas de evaluación configuran las contingencias de reforzamiento más poderosas del comportamiento de uso). Los hallazgos sobre los ciclos virtuoso y vicioso de uso de la IA proporcionan evidencia directa sobre los mecanismos del Componente 5 del modelo (Sistema de Retroalimentación Recursiva). Y los hallazgos sobre el efecto de vaciamiento del sentido

y su relación con la satisfacción de necesidades básicas de autonomía confirman que las consecuencias del uso de la IA sobre la motivación no son uniformes ni previsibles sin atender al perfil conductual del estudiante, lo que subraya la importancia de las intervenciones diferenciadas por perfil que se describen en el Capítulo 8.



## CAPÍTULO 8

### Propuesta de modelo conductual del uso de inteligencia artificial en educación superior

#### 8.1 Fundamentos y aporte científico del modelo MCUIA-ES

El recorrido teórico y empírico desarrollado a lo largo de los siete capítulos anteriores ha permitido construir una comprensión progresivamente más compleja y matizada del uso de la inteligencia artificial entre los estudiantes universitarios. Ese recorrido ha dejado en claro que el comportamiento de uso de la IA no puede explicarse de manera satisfactoria desde ningún marco teórico único, sino que exige la integración de múltiples perspectivas que operen en diferentes niveles de análisis y que capturen tanto los determinantes individuales como los contextuales del fenómeno. Ha dejado también en claro que las consecuencias del uso de la IA sobre el comportamiento académico son heterogéneas, dinámicas y dependientes del patrón de comportamiento que el estudiante adopta en su interacción con estas herramientas. Es precisamente esta complejidad la que justifica el desarrollo del Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior (MCUIA-ES) como la propuesta teórica central de esta obra.

El MCUIA-ES es el primer modelo conductual del uso de la inteligencia artificial en educación superior desarrollado y validado en el contexto universitario latinoamericano. Su aporte científico puede ser precisado en tres dimensiones que corresponden a las tres condiciones que la investigación científica de nivel SNII exige de una propuesta teórica original. En la dimensión conceptual, el MCUIA-ES integra cinco tradiciones teóricas en un marco articulado que supera las limitaciones de los modelos previos de adopción tecnológica:

incluye explícitamente las consecuencias del comportamiento de uso como componente del modelo, adopta una perspectiva temporal que diferencia efectos en tres horizontes y está fundamentado en evidencia empírica del contexto universitario latinoamericano. En la dimensión empírica, el modelo se fundamenta en los hallazgos de un estudio con 1,247 estudiantes universitarios mexicanos que valida sus componentes, jerarquías predictivas y tipología de perfiles conductuales con métodos estadísticos rigurosos. En la dimensión práctica, el modelo orienta el diseño de un protocolo de intervención tripartito —individual, pedagógico e institucional— con especificaciones suficientemente concretas para su implementación en contextos universitarios latinoamericanos (Crompton & Burke, 2023; Venkatesh et al., 2012; Merton, 1968).

La pertinencia del MCUIA-ES para el contexto latinoamericano no es simplemente geográfica. Reside en que el modelo fue construido atendiendo a condiciones específicas de ese contexto que los modelos anglosajones no capturan: la ambigüedad normativa institucional que caracteriza a la mayoría de las universidades públicas de la región en relación con el uso de la IA, las desigualdades de acceso tecnológico que configuran condiciones materiales distintas para el comportamiento de uso, las tradiciones pedagógicas propias de la universidad pública latinoamericana, y el perfil socioeconómico y cultural de la población estudiantil universitaria mexicana. Estos elementos no son variables de control que deben ser eliminadas para encontrar los efectos universales del fenómeno; son parte constitutiva de la realidad que el modelo busca explicar y sobre la que las intervenciones propuestas deben operar.

## **8.2 Bases teóricas integradas del MCUIA-ES**

El MCUIA-ES se construye sobre la integración articulada de cinco tradiciones teóricas, cada una de las cuales aporta elementos conceptuales específicos que enriquecen la comprensión del fenómeno desde dimensiones que ninguna de ellas puede capturar por sí sola. La lógica de integración no es ecléctica —no se trata de combinar elementos de diferentes teorías de manera oportunista— sino de complementariedad explicativa: cada tradición es la más adecuada para los aspectos del fenómeno que le son propios, y su integración en un marco coherente genera una capacidad explicativa que supera la suma de sus partes.

### **8.2.1 El análisis conductual aplicado como base fundamental**

El análisis conductual aplicado, derivado del conductismo operante de Skinner (1953) y sistematizado por Cooper et al. (2020) y Kazdin (2021), proporciona al MCUIA-ES su marco conceptual más fundamental: la comprensión del uso de la IA como un comportamiento que ocurre en un contexto específico, que es influenciado por antecedentes que lo desencadenan o facilitan, y que es moldeado por consecuentes que lo refuerzan o inhiben. Desde esta perspectiva, el comportamiento de uso de la IA no es el resultado de una decisión racional abstracta, sino de un proceso de aprendizaje conductual en el que el estudiante desarrolla gradualmente patrones de respuesta ante las demandas del entorno académico, moldeados por las consecuencias que esos patrones han producido en el pasado. El concepto de contingencia de reforzamiento —que describe la relación entre un antecedente, una respuesta y sus consecuencias en un contexto determinado— es el mecanismo explicativo central de esta dimensión del modelo, y su aplicación al diseño de los sistemas

de evaluación universitaria constituye una de las contribuciones prácticas más importantes del MCUIA-ES.

### **8.2.2 La teoría cognitivo-social como mecanismo de mediación**

La teoría cognitivo-social de Bandura (1986, 1997) amplía el marco conductual al incorporar los procesos cognitivos que median entre el ambiente y el comportamiento, rompiendo con la lógica del estímulo-respuesta directo que el conductismo clásico proponía. En el contexto del MCUIA-ES, tres conceptos de la teoría cognitivo-social son especialmente relevantes. La autoeficacia para el uso de la IA actúa como moderador crucial de la relación entre los estímulos ambientales y el comportamiento de uso: un estudiante con alta autoeficacia tecnológica percibe las mismas herramientas de IA de manera cualitativamente diferente a un estudiante con baja autoeficacia, lo que se traduce en patrones de uso cualitativamente distintos aunque las herramientas disponibles sean idénticas. El modelamiento social describe el proceso mediante el cual los estudiantes aprenden patrones de uso de la IA observando el comportamiento de sus pares y docentes, sin que necesariamente medie una instrucción explícita. Las expectativas de resultado son las creencias del estudiante sobre las consecuencias de su comportamiento de uso de la IA, que influyen tanto sobre la intención como sobre el mantenimiento del comportamiento a lo largo del tiempo (Bandura, 1997; Scherer et al., 2019).

### **8.2.3 La teoría del comportamiento planificado como marco de la intención**

La teoría del comportamiento planificado de Ajzen (1991) proporciona al MCUIA-ES el marco para comprender la dimensión intencional del comportamiento de uso de la IA, que media entre los

factores actitudinales y normativos del sistema de antecedentes y el comportamiento observable. En el modelo propuesto, las actitudes hacia el uso académico de la IA, las normas subjetivas sobre ese uso y el control conductual percibido determinan conjuntamente la intención de uso, que a su vez predice el comportamiento efectivo con la modulación del control conductual real. Esta cadena actitud-norma-control-intención-comportamiento ha sido extensamente validada en investigaciones sobre adopción tecnológica en contextos educativos (Park & Kim, 2023; Perugini & Bagozzi, 2001) y su incorporación en el MCUIA-ES permite capturar la dimensión deliberativa del comportamiento de uso que los modelos puramente conductuales no contemplan.

#### **8.2.4 La teoría de la autodeterminación como fundamento motivacional**

La teoría de la autodeterminación de Deci y Ryan (2000) proporciona al MCUIA-ES el marco para comprender la dimensión motivacional del comportamiento de uso y sus consecuencias sobre el bienestar académico y el aprendizaje a largo plazo. La distinción entre motivación intrínseca y las formas de regulación externa, introyectada e identificada de la motivación extrínseca permite predecir no solo si los estudiantes utilizan la IA, sino la calidad y el propósito de ese uso. La satisfacción de las tres necesidades psicológicas básicas —autonomía, competencia y relacionalidad— en el contexto del uso de la IA predice si ese uso producirá efectos positivos o negativos sobre el bienestar académico y la motivación a largo plazo, lo que conecta directamente con el Sistema de Consecuencias Multinivel del modelo (Deci & Ryan, 2000; Vansteenkiste et al., 2010).

### **8.2.5 La UTAUT2 como marco de adopción tecnológica**

La Teoría Unificada de Aceptación y Uso de Tecnología (UTAUT2) de Venkatesh et al. (2012) proporciona al MCUIA-ES el marco más comprehensivo disponible para integrar los factores tecnológicos y contextuales que influyen sobre la adopción de herramientas de IA en contextos universitarios. Los constructos de expectativa de rendimiento, expectativa de esfuerzo, influencia social, condiciones facilitadoras, motivación hedónica y hábito permiten capturar tanto los determinantes racionales como los afectivos y habituales del comportamiento de uso de la IA, integrándolos en un marco que ha sido extensamente validado en múltiples contextos tecnológicos. La adaptación de la UTAUT2 al contexto específico del uso académico de la IA generativa requiere la incorporación de constructos adicionales relacionados con la percepción de riesgo académico y las preocupaciones éticas que no estaban presentes en los contextos para los que fue originalmente desarrollada (Park & Kim, 2023).

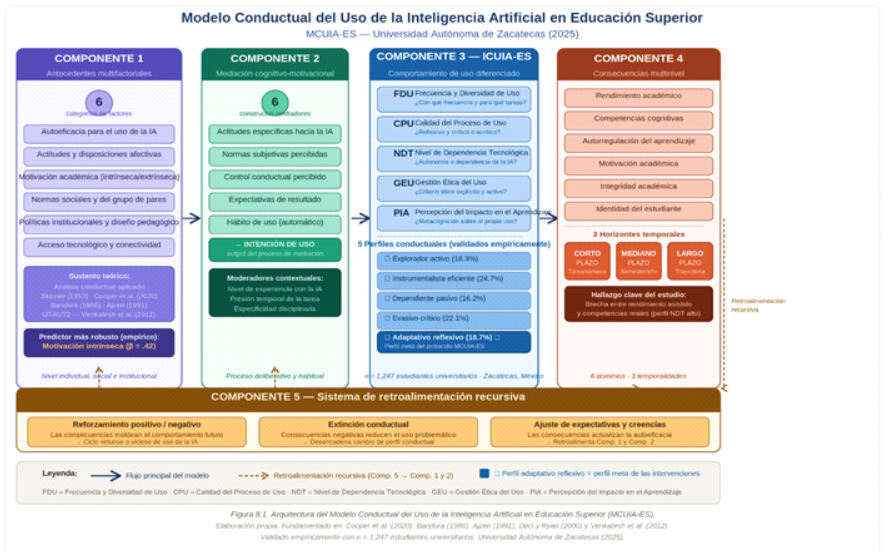
### **8.3 Arquitectura del MCUIA-ES: cinco componentes articulados**

El Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior se organiza en torno a cinco componentes articulados que capturan la complejidad del fenómeno en sus dimensiones individual, interpersonal, contextual y temporal. Estos componentes no son etapas secuenciales de un proceso lineal; son dimensiones interactivas de un mismo sistema dinámico que se influyen mutuamente de manera continua. La representación visual del modelo en la Figura 8.1 busca capturar esta interactividad sin reducirla a una secuencia causal simple que no haría justicia a la complejidad del fenómeno (Ajzen, 1991; Bandura, 1986).

Figura 8.1. Arquitectura del Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior (MCUIA-ES)

COMPONENTE 1 Antecedentes Multifactoriales	COMPONENTE 2 Mediación Cognitivo-Motivacional	COMPONENTE 3 Comportamiento de Uso Diferenciado	COMPONENTE 4 Consecuencias Multinivel	COMPONENTE 5 Retroalimentación Recursiva
<ul style="list-style-type: none"> <li>• Autoeficacia para el uso de IA</li> <li>• Actitudes hacia la IA</li> <li>• Motivación académica</li> <li>• Influencia del grupo de pares</li> <li>• Políticas institucionales</li> <li>• Acceso tecnológico</li> </ul>	<ul style="list-style-type: none"> <li>• Actitudes específicas</li> <li>• Normas subjetivas</li> <li>• Control conductual percibido</li> <li>• Expectativas de resultado</li> <li>• Hábito de uso</li> <li>• Intención de comportamiento</li> </ul>	<ul style="list-style-type: none"> <li>• Frecuencia y Diversidad (FDU)</li> <li>• Calidad del Proceso (CPU)</li> <li>• Dependencia Tecnológica (NDT)</li> <li>• Gestión Ética (GEU)</li> <li>• Percepción de Impacto (PIA)</li> <li>• Perfil conductual resultante</li> </ul>	<ul style="list-style-type: none"> <li>• Rendimiento académico</li> <li>• Competencias cognitivas</li> <li>• Autorregulación</li> <li>• Motivación académica</li> <li>• Integridad académica</li> <li>• Identidad del estudiante</li> </ul>	<ul style="list-style-type: none"> <li>• Mecanismos:                             <ul style="list-style-type: none"> <li>• Reforzamiento positivo/negativo</li> <li>• Extinción conductual</li> <li>• Modelamiento social</li> <li>• Ajuste de expectativas</li> </ul> </li> <li>• Retroalimentación hacia:                             <ul style="list-style-type: none"> <li>• Componente 1</li> <li>• Componente 2</li> </ul> </li> </ul>

Fuente: Elaboración propia. Modelo Conductual del Uso de la IA en Educación Superior (MCUIA-ES).



## **8.4 Componente 1: Sistema de antecedentes multifactoriales**

El Sistema de Antecedentes Multifactoriales del MCUIA-ES agrupa el conjunto de factores que preceden y condicionan el comportamiento de uso de la IA, organizándolos en seis categorías que operan en diferentes niveles de análisis y que se influyen mutuamente. A diferencia de los modelos clásicos de aceptación tecnológica que tienden a reducir los antecedentes a un conjunto limitado de percepciones individuales, el MCUIA-ES reconoce que el comportamiento de uso de la IA está condicionado por factores que van desde las características cognitivas individuales hasta las condiciones materiales de acceso tecnológico, pasando por los factores motivacionales, sociales e institucionales que configuran el entorno de aprendizaje (Venkatesh et al., 2012).

Los factores cognitivos individuales —autoeficacia para el uso de la IA, alfabetización en IA y conocimiento disciplinario previo— constituyen el nivel más proximal de los antecedentes y ejercen su influencia tanto directamente sobre el comportamiento como a través del Proceso de Mediación Cognitivo-Motivacional. La autoeficacia para el uso de la IA opera como moderador de la relación entre todos los demás antecedentes y el comportamiento: sus efectos sobre la calidad del proceso de uso ( $\beta = .31$ , confirmado en el estudio empírico) son robustos e independientes del nivel de acceso tecnológico. Los factores afectivos y disposicionales —actitudes ambivalentes, ansiedad tecnológica, curiosidad epistémica— configuran disposiciones habituales que se activan de manera frecuentemente automática ante los estímulos del entorno académico que señalan la disponibilidad o pertinencia de las herramientas de IA.

Los factores motivacionales —tipo de motivación académica, perfil de metas de logro, valor percibido de la tarea y locus de control— son los que muestran mayor poder predictivo sobre la calidad del comportamiento de uso según los análisis de regresión del estudio empírico. La motivación intrínseca predice la calidad del proceso de uso con un coeficiente beta de .42, el más elevado de todos los predictores estudiados. Los factores sociales y normativos — influencia del grupo de pares, expectativas docentes y normas subjetivas— tienen un peso predictivo especialmente alto en el contexto universitario latinoamericano, donde la ambigüedad normativa institucional crea condiciones que amplifican la influencia de las señales sociales sobre el comportamiento de uso. Los factores institucionales y pedagógicos —políticas sobre el uso de la IA, diseño pedagógico de las asignaturas y sistemas de evaluación— configuran las contingencias de reforzamiento más poderosas del comportamiento de uso en el nivel colectivo. Los factores tecnológicos y de acceso —dispositivos, conectividad, versiones de herramientas— son determinantes materiales que, según los hallazgos del estudio, moderan los efectos de la autoeficacia sobre la calidad del uso en condiciones de desigualdad tecnológica.

### **8.5 Componente 2: Proceso de mediación cognitivo-motivacional**

El Proceso de Mediación Cognitivo-Motivacional constituye el núcleo psicológico del MCUIA-ES: es el conjunto de procesos internos a través de los cuales los factores del sistema de antecedentes se transforman en intención de comportamiento y, finalmente, en comportamiento de uso observable. Este proceso integra seis constructos centrales que operan de manera interactiva.

El primero es la autoeficacia para el uso de la IA, que determina la confianza del estudiante en su capacidad para utilizar estas herramientas de manera efectiva y que modula la influencia de todos los demás constructos del proceso. El segundo es la formación de actitudes específicas hacia el uso académico de la IA en una tarea concreta, que resulta de la integración de creencias del estudiante sobre las consecuencias del uso, los afectos asociados y las evaluaciones sobre la compatibilidad del uso con sus valores académicos. El tercero es la percepción de las normas subjetivas sobre el uso de la IA, que resulta de la interpretación del estudiante sobre lo que las personas importantes para él esperan que haga. El cuarto es la evaluación del control conductual percibido, que integra la autoeficacia con la percepción de las condiciones externas que facilitan o dificultan el uso. El quinto es la formación de la intención de comportamiento, que resulta de la ponderación de los constructos anteriores en función del tipo de tarea académica y el contexto específico. El sexto es la activación del hábito, que en estudiantes con mayor experiencia en el uso de la IA puede bypassar parcialmente el proceso deliberativo y activar patrones de comportamiento de manera automática (Ajzen, 1991; Venkatesh et al., 2012).

El modelo propone que la ponderación relativa de cada constructo varía en función de tres moderadores contextuales. El nivel de experiencia del estudiante con las herramientas de IA determina el grado en que el comportamiento de uso es deliberado o habitual: a mayor experiencia, mayor peso del hábito y menor peso de la deliberación actitudinal. La presión temporal de la tarea académica puede reducir el espacio para la deliberación y aumentar el peso relativo del hábito y la influencia social, lo que explica el patrón de mayor uso en períodos de entrega observado en el estudio empírico.

La especificidad disciplinaria de la tarea activa normas disciplinarias específicas que pueden modular significativamente la percepción de lo que es un uso apropiado de la IA en ese contexto concreto.

### **8.6 Componente 3: Comportamiento de uso diferenciado**

El Comportamiento de Uso Diferenciado es el componente observable del MCUIA-ES y el que articula la dimensión individual del modelo con sus consecuencias sobre el aprendizaje. En el modelo propuesto, el comportamiento de uso de la IA se manifiesta en cinco dimensiones observables operacionalizadas en el instrumento ICUIA-ES: frecuencia y diversidad de uso (FDU), calidad del proceso de uso (CPU), nivel de dependencia tecnológica (NDT), gestión ética del uso (GEU) y percepción del impacto sobre el aprendizaje (PIA).

La combinación de las puntuaciones del estudiante en estas cinco dimensiones define su perfil conductual ante la IA, que corresponde a uno de los cinco tipos descritos en el Capítulo 3 y validados empíricamente en el Capítulo 6: el usuario explorador activo (18.3% de la muestra), el usuario instrumentalista eficiente (24.7%), el usuario dependiente pasivo (16.2%), el usuario evasivo crítico (22.1%) y el usuario adaptativo reflexivo (18.7%). El MCUIA-ES postula explícitamente que estos perfiles no son categorías fijas sino posiciones dinámicas en un espacio multidimensional, y que los estudiantes pueden transitar entre perfiles en función de cambios en los antecedentes, en el proceso de mediación o en las condiciones del entorno académico. Esta dinamicidad del perfil conductual es lo que abre la posibilidad de intervenciones pedagógicas orientadas a promover la transición desde perfiles de uso menos productivos hacia el perfil adaptativo reflexivo, que el modelo identifica como el académicamente más sostenible.

Un aspecto conceptualmente importante del Componente 3 es la distinción entre las dimensiones de frecuencia y calidad del uso. Los análisis de regresión del estudio empírico muestran que estas dimensiones tienen determinantes diferentes: la frecuencia de uso está principalmente determinada por factores sociales y tecnológicos, mientras que la calidad del uso está principalmente determinada por factores motivacionales y cognitivos. Esta disociación tiene una implicación práctica directa: las intervenciones que buscan incrementar la frecuencia de uso de la IA no producen necesariamente mejoras en la calidad del proceso de uso, y las intervenciones orientadas a la calidad requieren atender la dimensión motivacional del comportamiento académico más allá de la dimensión técnica.

### **8.7 Componente 4: Sistema de consecuencias multinivel**

El Sistema de Consecuencias Multinivel organiza los efectos del comportamiento de uso de la IA en seis dominios y en tres temporalidades, configurando la matriz de consecuencias que conecta el comportamiento observable con sus impactos sobre el desarrollo del estudiante universitario. La incorporación de este componente como parte constitutiva del modelo —y no como una simple variable dependiente externa— responde a la convicción de que las consecuencias del comportamiento son parte del sistema explicativo completo, ya que retroalimentan el comportamiento futuro a través del Componente 5.

*Tabla 8.2. Sistema de consecuencias multinivel*

<b>Dominio de consecuencias</b>	<b>Corto plazo (tarea/semana)</b>	<b>Mediano plazo (semestre/año)</b>	<b>Largo plazo (trayectoria profesional)</b>
Rendimiento académico	Calidad de productos asistidos; calificaciones en evaluaciones con acceso a IA	Brecha entre rendimiento asistido y competencias reales; competencia ilusoria	Perfil de competencias profesionales; capacidad de desempeño autónomo
Competencias cognitivas	Carga cognitiva reducida; estrategias de procesamiento activadas durante la tarea	Desarrollo o atrofia de pensamiento crítico, creatividad y razonamiento argumentativo	Autonomía intelectual; sofisticación del pensamiento disciplinario; aprendizaje permanente
Autorregulación del aprendizaje	Gestión del tiempo y esfuerzo en la tarea específica	Ciclos virtuosos o viciosos de autorregulación; desarrollo o erosión metacognitiva	Capacidad de aprendizaje autónomo a lo largo de la vida
Motivación académica	Satisfacción o frustración con el proceso de aprendizaje; percepción de autonomía y competencia	Incremento o erosión de la motivación intrínseca; vaciamiento del sentido académico	Identificación con la disciplina; disposición hacia el desarrollo profesional continuo
Integridad académica	Comportamientos de honestidad o deshonestidad en tareas específicas	Desarrollo o deterioro del razonamiento moral; hábitos de gestión ética del uso	Identidad ética profesional; valores sobre la honestidad intelectual en la práctica
Identidad del estudiante	Percepción de autoría sobre las producciones; sentido de agencia intelectual	Construcción o debilitamiento de la identidad disciplinaria y académica	Identidad profesional consolidada; vínculo con valores y prácticas de la disciplina

*Fuente: Elaboración propia.*

## **8.8 Componente 5: Sistema de retroalimentación recursiva**

El Sistema de Retroalimentación Recursiva es el componente que distingue al MCUIA-ES de los modelos lineales de adopción tecnológica y que le confiere su carácter dinámico y sistémico. Este componente describe los mecanismos a través de los cuales las consecuencias del comportamiento de uso de la IA retroalimentan tanto el sistema de antecedentes como el proceso de mediación cognitivo-motivacional, cerrando el ciclo que convierte al modelo en un sistema dinámico capaz de capturar la evolución temporal de los patrones de comportamiento a lo largo de la trayectoria universitaria.

El primer mecanismo de retroalimentación es el reforzamiento positivo: cuando el comportamiento de uso de la IA produce consecuencias percibidas como positivas —buenas calificaciones, reducción del esfuerzo, satisfacción con el proceso de aprendizaje— la probabilidad de que ese comportamiento se repita se incrementa. Este mecanismo opera de manera diferente según el tipo de uso: el uso instrumentalista que produce buenas calificaciones a corto plazo es reforzado positivamente aunque erosione competencias a largo plazo, lo que explica la persistencia de ese patrón incluso cuando el estudiante es consciente de sus consecuencias negativas. El uso reflexivo que produce aprendizaje profundo es reforzado con menor inmediatez pero con mayor consistencia, lo que explica su mayor vulnerabilidad a las contingencias de presión temporal (Skinner, 1953; Cooper et al., 2020).

El segundo mecanismo es el reforzamiento negativo y la extinción: cuando el comportamiento de uso produce consecuencias percibidas como negativas —sanciones académicas, percepción de vaciamiento intelectual, ansiedad ante situaciones sin IA, deterioro del sentido de

agencia— la probabilidad de que ese comportamiento se repita disminuye. Este mecanismo es especialmente relevante para comprender los procesos de cambio de perfil conductual: los estudiantes que transitan del perfil dependiente pasivo hacia el adaptativo reflexivo frecuentemente reportan experiencias de fracaso en contextos sin acceso a la IA como el desencadenante que inicia ese proceso de cambio. Estas experiencias de fracaso, aunque son dolorosas en el corto plazo, constituyen señales de retroalimentación negativa que el modelo puede capitalizar pedagógicamente si se gestionan en un entorno de apoyo y orientación.

El tercer mecanismo es el ajuste de expectativas y creencias: las consecuencias del comportamiento de uso retroalimentan las expectativas de resultado, la autoeficacia y las actitudes hacia la IA que forman parte del proceso de mediación. Un estudiante que experimenta consecuencias positivas del uso reflexivo desarrolla expectativas más positivas sobre los beneficios de ese tipo de uso, lo que incrementa su motivación para mantenerlo. Un estudiante que experimenta consecuencias negativas del uso dependiente puede desarrollar actitudes más críticas hacia el uso irrestricto de estas herramientas, facilitando la transición hacia un perfil más reflexivo. Estos ajustes son los que hacen del MCUIA-ES un modelo genuinamente dinámico que puede capturar la evolución de los patrones de comportamiento a lo largo del tiempo (Bandura, 1997; Deci & Ryan, 2000).

## 8.9 Postulados del MCUIA-ES

Para dotar al modelo de la precisión conceptual necesaria para orientar la investigación y la intervención pedagógica, se proponen diez postulados que especifican las relaciones más relevantes entre los componentes del modelo. Estos postulados son proposiciones teóricas abiertas a la revisión empírica, no hipótesis cerradas; su formulación explícita tiene el propósito de hacer el modelo comprobable y falseable, condición indispensable para que sea considerado una contribución científica genuina.

*Tabla 8.3. Diez postulados del Modelo Conductual MCUIA-ES con implicaciones pedagógicas*

N°	Postulado	Implicación pedagógica directa
P1	La calidad del uso de la IA (CPU) es un predictor más robusto del aprendizaje universitario a largo plazo que la frecuencia de uso (FDU), con independencia del nivel de acceso tecnológico.	Las intervenciones deben orientarse a mejorar la calidad del proceso de uso, no simplemente a incrementar o restringir la frecuencia.
P2	La motivación intrínseca modera positivamente la relación entre las competencias de uso de la IA y la calidad del comportamiento de uso, de manera que esas competencias producen mayores beneficios en estudiantes con motivación intrínseca elevada.	El desarrollo de la motivación intrínseca por el aprendizaje es una condición necesaria — aunque no suficiente— para el aprovechamiento pedagógico óptimo de las herramientas de IA.
P3	La ambigüedad normativa institucional amplifica la influencia del grupo de pares sobre el comportamiento de uso de la IA, especialmente entre estudiantes con motivación extrínseca dominante y en semestres intermedios.	Las políticas institucionales claras y pedagógicamente fundamentadas son especialmente importantes para los estudiantes con motivación extrínseca, ya que para ellos las normas externas son el principal referente conductual.

P4	El uso dependiente de la IA (alta NDT) produce efectos de atrofia progresiva en las competencias cognitivas de orden superior que la IA sustituye, con efectos que se acumulan de semestre en semestre.	El diseño de tareas académicas debe preservar deliberadamente la práctica de competencias cognitivas de orden superior que no deben ser delegadas a la IA, independientemente de la disponibilidad de herramientas que podrían realizarlas.
P5	Los sistemas de evaluación universitaria configuran las contingencias de reforzamiento más poderosas del comportamiento de uso de la IA, con mayor influencia que las políticas institucionales explícitas o las orientaciones docentes.	El rediseño de los sistemas de evaluación hacia formatos que capturen el proceso de aprendizaje —no solo el producto final— es la intervención institucional de mayor impacto sobre los patrones de uso de la IA.
P6	La autoeficacia para la evaluación crítica de los outputs de la IA es el factor cognitivo individual más directamente asociado a la calidad del proceso de uso (CPU), con efecto independiente de la autoeficacia tecnológica general.	El desarrollo de la alfabetización en IA, específicamente de las competencias evaluativas y críticas —no solo las técnicas de uso— debe ser un objetivo formativo transversal a todas las asignaturas del currículo universitario.
P7	Las brechas de acceso tecnológico se traducen en brechas de aprovechamiento pedagógico de la IA que amplifican las desigualdades educativas preexistentes cuando no son activamente compensadas mediante estrategias pedagógicas específicas.	Las instituciones deben desarrollar estrategias explícitas de compensación pedagógica y de acceso equitativo para los estudiantes con menor acceso a herramientas tecnológicas de calidad.

P8	El ciclo virtuoso de uso reflexivo de la IA es autorreforzante: el uso reflexivo mejora la autoeficacia para la evaluación crítica, que a su vez incrementa la calidad del uso y los beneficios percibidos del aprendizaje, reforzando el patrón.	Las intervenciones deben crear las condiciones iniciales para que los estudiantes experimenten el ciclo virtuoso en tareas de baja complejidad y bajo riesgo, antes de extenderlo a tareas de mayor demanda.
P9	La formación ética integrada en el diseño pedagógico cotidiano de las asignaturas es más efectiva para el desarrollo de una gestión ética sostenida del uso de la IA que las políticas institucionales prohibitivas o las sesiones aisladas de sensibilización.	El desarrollo de la capacidad de razonamiento moral ante dilemas éticos específicos del uso de la IA debe ser un objetivo pedagógico explícito en todas las asignaturas del currículo, no un efecto secundario de las políticas de control.
P10	El modelamiento docente del uso reflexivo y éticamente responsable de la IA es uno de los mecanismos de socialización más efectivos para el desarrollo de patrones de uso académicamente productivos en los estudiantes, por encima de la instrucción directa.	La formación docente para el uso pedagógico reflexivo de la IA es una inversión institucional de alto impacto y larga duración sobre los patrones de uso de todos los estudiantes que tienen contacto con los docentes formados.

*Fuente: Elaboración propia.*

## 8.10 Operacionalización estadística del MCUIA-ES

El MCUIA-ES está diseñado para ser evaluado estadísticamente mediante Modelamiento de Ecuaciones Estructurales (SEM), que permite estimar simultáneamente las relaciones entre variables latentes y observadas especificadas en el modelo teórico, evaluando el ajuste del modelo completo a los datos empíricos y proporcionando estimaciones de los coeficientes de las trayectorias que conectan los componentes del modelo (Byrne, 2016; Brown, 2015).

El modelo SEM completo del MCUIA-ES especifica las siguientes trayectorias principales, derivadas de los postulados del modelo y confirmadas por los análisis de regresión del Capítulo 6. Entre el Componente 1 y el Componente 2: (a) Autoeficacia para el uso de la IA → Intención de uso ( $\beta$  estimado = .38); (b) Motivación intrínseca → Actitudes positivas hacia el uso reflexivo de la IA ( $\beta$  estimado = .44); (c) Influencia del grupo de pares → Normas subjetivas sobre el uso de la IA ( $\beta$  estimado = .51); (d) Claridad de políticas institucionales → Control conductual percibido ( $\beta$  estimado = .29). Entre el Componente 2 y el Componente 3: (e) Intención de uso → Frecuencia de uso ( $\beta$  estimado = .45); (f) Autoeficacia para la evaluación crítica → Calidad del proceso de uso ( $\beta$  estimado = .31); (g) Motivación intrínseca → Calidad del proceso de uso ( $\beta$  estimado = .42); (h) Normas subjetivas → Frecuencia de uso ( $\beta$  estimado = .29). Entre el Componente 3 y el Componente 4: (i) Calidad del proceso de uso → Rendimiento académico en evaluaciones no asistidas ( $\beta$  estimado positivo, a confirmar con estudios longitudinales); (j) Dependencia tecnológica → Rendimiento en evaluaciones no asistidas ( $\beta$  estimado negativo); (k) Gestión ética → Integridad académica ( $\beta$  estimado positivo fuerte).

El ajuste del modelo SEM completo se evaluará mediante los índices estándar: CFI  $\geq .95$  para ajuste excelente o  $\geq .90$  para ajuste aceptable, RMSEA  $\leq .06$  para ajuste excelente o  $\leq .08$  para ajuste aceptable, y SRMR  $\leq .08$  (Hu & Bentler, 1999). Los coeficientes de trayectoria estimados en el estudio empírico del Capítulo 6 mediante regresión jerárquica constituyen los valores de partida para la especificación del modelo SEM, que requerirá un diseño longitudinal con al menos dos puntos de medición para estimar las trayectorias del Sistema de Retroalimentación Recursiva.

Es importante precisar el estado actual de la operacionalización estadística del modelo. Las trayectorias ya estimadas empíricamente en el presente estudio —mediante análisis de regresión múltiple jerárquica reportados en el Capítulo 6— son las siguientes: autoeficacia  $\rightarrow$  CPU ( $\beta = .31$ ), motivación intrínseca  $\rightarrow$  CPU ( $\beta = .42$ ), influencia del grupo de pares  $\rightarrow$  FDU ( $\beta = .29$ ), y conocimiento de políticas institucionales  $\rightarrow$  GEU ( $\beta = .22$ ). Estos coeficientes tienen sustento empírico directo en los datos del estudio. Las trayectorias entre el Componente 3 y el Componente 4 —específicamente las que conectan CPU y NDT con el rendimiento académico en evaluaciones no asistidas— y todas las trayectorias del Sistema de Retroalimentación Recursiva (Componente 5) constituyen hipótesis del modelo pendientes de evaluación empírica mediante diseños longitudinales. Esta distinción entre trayectorias estimadas y trayectorias hipotéticas es una condición de la integridad científica del modelo y no una limitación de su valor teórico.

### **8.11 Protocolo de intervención derivado del MCUIA-ES**

Uno de los aportes prácticos más relevantes del MCUIA-ES es su capacidad para orientar el diseño de intervenciones pedagógicas e

institucionales que promuevan el tránsito de los estudiantes universitarios hacia el perfil adaptativo reflexivo. El protocolo de intervención se articula en tres niveles interdependientes que deben implementarse de manera coordinada para maximizar su efectividad.

### **8.11.1 Intervenciones a nivel individual**

Las intervenciones a nivel individual del protocolo MCUIA-ES se organizan en cuatro líneas de acción. La primera línea es el desarrollo de la alfabetización en inteligencia artificial disciplinariamente contextualizada, que comprende actividades formativas específicamente diseñadas para desarrollar la comprensión básica del funcionamiento de los sistemas de IA generativa, la capacidad de formular consultas efectivas y contextualizadas, las habilidades para evaluar críticamente la pertinencia y corrección de los outputs generados, y la comprensión de las implicaciones éticas del uso de la IA en contextos académicos específicos de cada disciplina. Esta formación debe ser disciplinariamente contextualizada: la alfabetización en IA de un estudiante de medicina debe incluir competencias para evaluar la pertinencia clínica de las respuestas de la IA, mientras que la de un estudiante de derecho debe incluir competencias para evaluar la solidez jurídica de esas respuestas (Ng et al., 2021; Long & Magerko, 2020).

La segunda línea de intervención individual es el fortalecimiento de la autorregulación del aprendizaje en contextos de uso de la IA. Técnicas como los diarios de aprendizaje reflexivo sobre el uso de la IA —en que los estudiantes registran qué herramientas utilizaron, para qué, con qué resultados y qué impacto perciben sobre su propio aprendizaje— los protocolos de revisión crítica de tareas asistidas por IA antes de su entrega, y las actividades de comparación entre producciones asistidas y no asistidas, son especialmente efectivas

para desarrollar las capacidades metacognitivas que definen el perfil adaptativo reflexivo (Zimmerman, 2000; Lim et al., 2023). La tercera línea es el desarrollo de la motivación intrínseca para el aprendizaje en entornos mediados por IA, que comprende estrategias pedagógicas orientadas a crear experiencias de aprendizaje genuinamente significativas que reduzcan los incentivos para el uso instrumental de la IA como atajo hacia el rendimiento. La cuarta línea es la formación en razonamiento moral aplicado al uso de la IA, que incluye el análisis de casos concretos de dilemas éticos en el uso académico de la IA, la discusión de escenarios de incertidumbre normativa y la reflexión sobre las implicaciones a largo plazo de diferentes patrones de uso para el desarrollo intelectual y la identidad profesional del estudiante (Rest et al., 2000).

### **8.11.2 Intervenciones a nivel pedagógico**

Las intervenciones a nivel pedagógico del protocolo MCUIA-ES se organizan en torno al rediseño de tres elementos fundamentales del entorno de aprendizaje universitario. El rediseño de las tareas académicas debe orientarse hacia la creación de demandas cognitivas que no puedan ser satisfechas de manera simple mediante el uso instrumental de la IA: tareas de aplicación contextualizada del conocimiento a situaciones específicas y novedosas, tareas de síntesis crítica que requieran articulación original de múltiples perspectivas, tareas de producción creativa que involucren experiencias y perspectivas personales del estudiante, y tareas de evaluación y reflexión sobre el propio proceso de aprendizaje. Las tareas de alto valor pedagógico en el contexto de la IA son las que utilizan la IA como punto de partida o interlocutor crítico, pero que requieren que el estudiante aporte la perspectiva disciplinaria, el juicio contextual y

la voz intelectual propia que los sistemas de IA no pueden generar de manera autónoma (Boud & Falchikov, 2006; Rudolph et al., 2023).

El rediseño de los sistemas de evaluación es la intervención pedagógica de mayor impacto sobre los patrones de uso de la IA, de acuerdo con el postulado P5 del modelo. Las estrategias evaluativas más prometedoras incluyen las evaluaciones de proceso que capturen el pensamiento en acción mediante registros reflexivos, portafolios de aprendizaje y protocolos de trabajo visibles; las evaluaciones orales que permitan al docente explorar la comprensión profunda del estudiante más allá de lo que puede producirse con apoyo de la IA; las evaluaciones auténticas que requieran la aplicación del conocimiento en contextos reales o simulados con alta fidelidad; y las evaluaciones de portafolio que documenten la evolución del pensamiento del estudiante a lo largo del tiempo (Boud & Falchikov, 2006; Lim et al., 2023). La orientación docente explícita sobre el uso apropiado de la IA en cada asignatura específica —que distingue entre el uso que enriquece el aprendizaje y el que lo sustituye, en función de los objetivos específicos de la materia— completa el nivel de intervención pedagógica.

### **8.11.3 Intervenciones a nivel institucional**

Las intervenciones a nivel institucional del protocolo MCUA-ES se articulan en torno a cuatro ejes estratégicos que deben implementarse de manera coordinada. El primer eje es el desarrollo de políticas institucionales sobre el uso de la IA que sean pedagógicamente fundamentadas —que expliquen el razonamiento educativo detrás de las normas—, disciplinariamente sensibles —que reconozcan que el uso apropiado de la IA varía según el campo de conocimiento y el tipo de tarea—, construidas en diálogo con la comunidad académica —incluyendo a estudiantes y docentes en su

diseño—, y dinámicamente revisables —con mecanismos de actualización periódica que permitan adaptarlas a los cambios tecnológicos (UNESCO, 2023; Holmes et al., 2022).

El segundo eje es la formación docente para el uso pedagógico de la IA, que debe desarrollar no solo competencias técnicas para el uso de herramientas específicas, sino también competencias pedagógicas para el diseño de entornos de aprendizaje que aprovechen las potencialidades de la IA sin comprometer los objetivos de desarrollo de competencias cognitivas y valores académicos. Esta formación debe incluir el modelamiento explícito por parte de los docentes formados de cómo utilizar la IA de manera reflexiva y académicamente productiva en su propia práctica profesional, dado que el postulado P10 del modelo identifica el modelamiento docente como uno de los mecanismos de socialización más efectivos disponibles. El tercer eje es la creación de infraestructura de acceso equitativo a herramientas de IA, que garantice que todos los estudiantes tengan acceso a las herramientas necesarias para participar en las actividades académicas mediadas por IA que la institución promueve, independientemente de su situación socioeconómica. El cuarto eje es el desarrollo de sistemas institucionales de monitoreo del impacto del uso de la IA sobre el aprendizaje y el comportamiento académico, que permitan identificar tempranamente señales de uso problemático y actuar preventivamente (Southworth et al., 2023; Holmes et al., 2022).

### **8.12 Alcances, limitaciones y agenda de investigación futura**

El MUIA-ES tiene alcances claramente delimitados que conviene precisar para evitar interpretaciones que excedan lo que el modelo puede y pretende explicar. Es un modelo de alcance medio (Merton,

1968) aplicable al comportamiento de uso de la IA en contextos de educación superior universitaria de pregrado en el contexto latinoamericano, específicamente en instituciones públicas mexicanas comparables a las del estudio empírico. No es un modelo del comportamiento académico universitario en general, ni un modelo de los efectos de la IA sobre la educación en todos sus niveles, ni un modelo de adopción tecnológica aplicable a cualquier tecnología digital. Su especificidad no es una limitación; es la condición de su utilidad práctica y de su validez empírica.

Las limitaciones más relevantes del modelo en su versión actual son cuatro. La primera es su fundamentación empírica en un contexto universitario específico —el del estado de Zacatecas, México— que, aunque comparte características importantes con otros contextos universitarios latinoamericanos, no puede asumirse como representativo de la totalidad de la región. La validación del modelo en otros contextos universitarios latinoamericanos, con sus especificidades culturales, institucionales y tecnológicas, es la prioridad más urgente de la agenda de investigación futura. La segunda limitación es el carácter transversal del estudio empírico, que no permite capturar directamente los procesos de cambio longitudinal en los patrones de comportamiento de uso que el Sistema de Retroalimentación Recursiva del modelo postula. El diseño de estudios longitudinales que documenten la evolución de los perfiles conductuales a lo largo de la trayectoria universitaria es una de las líneas más urgentes y prometedoras que el modelo genera. La tercera limitación es la velocidad de evolución de las herramientas de IA, que puede hacer que algunos comportamientos descritos en el modelo sean modificados por el surgimiento de herramientas con capacidades cualitativamente distintas antes de que la investigación

pueda documentarlos (Molina-Gómez et al., 2024; Park & Kim, 2023). La cuarta limitación es la concentración geográfica intrarregional de la muestra: las tres instituciones participantes corresponden a una sola entidad federativa de México, el estado de Zacatecas, que se caracteriza por ser una entidad con economía predominantemente basada en actividades primarias, flujos migratorios significativos y un sistema universitario público de tamaño medio. Si bien estas características son compartidas por varias entidades del centro-norte de México y permiten cierta extrapolación cautelosa a contextos similares, los hallazgos deben interpretarse con reserva en relación con universidades de grandes zonas metropolitanas del país —como la Ciudad de México, Guadalajara o Monterrey— donde las condiciones de acceso tecnológico, la densidad institucional y los perfiles socioeconómicos de la población estudiantil difieren de manera sustantiva. Esta limitación subraya la importancia de los estudios de validación transcultural y multirregional del MCUIA-ES como línea prioritaria de investigación futura.

La agenda de investigación futura derivada del MCUIA-ES incluye seis líneas prioritarias. Primera, la validación transcultural del modelo en diferentes contextos universitarios latinoamericanos mediante estudios comparativos que identifiquen componentes estables y específicos del contexto. Segunda, el estudio longitudinal de la evolución de los perfiles conductuales a lo largo de la trayectoria universitaria, que permita documentar los factores que favorecen o inhiben la transición hacia el perfil adaptativo reflexivo. Tercera, el diseño y evaluación experimental de intervenciones pedagógicas derivadas del protocolo MCUIA-ES, que establezcan la efectividad causal de las estrategias propuestas. Cuarta, el desarrollo de

instrumentos de medición con métodos objetivos que complementen los datos de auto-reporte del ICUA-ES, incluyendo el análisis de logs de actividad digital y métodos de evaluación ecológica momentánea (Shiffman et al., 2008). Quinta, el estudio de los efectos del uso de la IA sobre el desarrollo de la identidad disciplinaria y la socialización en comunidades de práctica universitarias. Sexta, el análisis de los efectos equitativos del uso de la IA con atención especial a la documentación y reducción de las brechas en el aprovechamiento pedagógico entre estudiantes de diferentes estratos socioeconómicos, géneros y contextos institucionales (Zawacki-Richter et al., 2019; UNESCO, 2023).

### **8.13 El MCUA-ES como contribución a las ciencias de la conducta y la educación superior**

El Modelo Conductual del Uso de la Inteligencia Artificial en Educación Superior que se ha presentado en este capítulo representa una contribución a las ciencias de la conducta aplicadas a la educación universitaria en tres dimensiones que conviene articular explícitamente como cierre de este libro.

En la dimensión conceptual, el MCUA-ES contribuye con una conceptualización multidimensional del comportamiento de uso de la IA que supera las simplificaciones dicotómicas del debate público y que permite analizar con mayor precisión la relación entre los patrones de uso y sus efectos sobre el aprendizaje. La distinción entre las cinco dimensiones del comportamiento de uso —frecuencia, calidad, dependencia, gestión ética e impacto percibido—, la tipología de cinco perfiles conductuales empíricamente validados y el Sistema de Consecuencias Multinivel en tres temporalidades ofrecen herramientas conceptuales que enriquecen significativamente el

vocabulario disponible para la investigación y la práctica pedagógica en este campo emergente.

En la dimensión metodológica, el MCUIA-ES contribuye con el instrumento ICUIA-ES validado psicométricamente en el contexto universitario mexicano —con excelentes índices de ajuste y coeficientes omega entre .81 y .89— y con un protocolo de investigación mixta que puede ser replicado y adaptado en otros contextos latinoamericanos. Esta infraestructura metodológica, actualmente inexistente en la literatura disponible en español para este campo, es condición necesaria para que la investigación sobre uso de la IA en la educación superior latinoamericana pueda acumular conocimiento comparable entre contextos y contribuir a la agenda científica internacional con hallazgos situados y pertinentes.

En la dimensión práctica, el MCUIA-ES contribuye con un protocolo de intervención articulado en tres niveles —individual, pedagógico e institucional— que ofrece orientaciones concretas y fundadas para el diseño de respuestas pedagógicas e institucionales al uso de la inteligencia artificial en la educación superior latinoamericana. Estas orientaciones no son prescripciones universales; son marcos de referencia que deben ser adaptados a las condiciones específicas de cada contexto pero que ofrecen una base conceptual sólida para esa adaptación. La inteligencia artificial ha llegado a la educación superior para quedarse y para transformarla de maneras que todavía no podemos anticipar plenamente. El MCUIA-ES no pretende ser la respuesta definitiva a los desafíos que esa transformación plantea; pretende ser una herramienta rigurosa, empíricamente fundamentada y contextualmente pertinente para pensar esos desafíos con la profundidad y el rigor científico que la

magnitud del fenómeno y la responsabilidad de la educación universitaria exigen.

El modelo MUIA-ES no se concibe como una estructura cerrada, sino como un marco analítico abierto, susceptible de ser contrastado, adaptado y extendido en diversos contextos educativos. En este sentido, su valor no radica únicamente en su capacidad explicativa dentro del contexto en el que fue desarrollado, sino en su potencial para orientar futuras investigaciones dirigidas a comprender el comportamiento de uso de la inteligencia artificial en la educación superior. En consecuencia, el MUIA-ES se posiciona no solo como un modelo explicativo, sino como una base conceptual para el desarrollo acumulativo de conocimiento en el campo de la inteligencia artificial aplicada a la educación superior.

## CONCLUSIONES

Este libro partió de una pregunta que atraviesa hoy la educación universitaria de manera inevitable e irrevocable: qué significa enseñar y aprender cuando la inteligencia artificial se ha convertido en un recurso cotidiano para millones de estudiantes. A lo largo de sus ocho capítulos, la respuesta que se ha sostenido con creciente evidencia empírica y argumentativa es que no nos encontramos ante la sustitución del aprendizaje humano por la inteligencia artificial, sino frente a una reconfiguración profunda de las condiciones bajo las cuales ese aprendizaje se produce, condicionada de manera decisiva por los patrones de comportamiento que los estudiantes desarrollan en su interacción con las herramientas de IA y por los entornos pedagógicos e institucionales que moldean esos patrones.

El aporte central de este libro —el Modelo Conductual del Uso de la IA en Educación Superior (MCUIA-ES)— articula en un marco integrado los cinco componentes del fenómeno: los antecedentes multifactoriales que determinan el comportamiento de uso, el proceso de mediación cognitivo-motivacional que transforma esos antecedentes en intención y comportamiento, el comportamiento de uso diferenciado en sus cinco dimensiones observables, las consecuencias multinivel en seis dominios y tres temporalidades, y el sistema de retroalimentación recursiva que conecta las consecuencias con los antecedentes y cierra el ciclo dinámico. Los diez postulados del modelo, fundamentados en evidencia empírica obtenida con 1,247 estudiantes universitarios mexicanos, ofrecen proposiciones comprobables que pueden orientar tanto la investigación futura como el diseño de intervenciones pedagógicas e

institucionales. El instrumento ICUIA-ES con sus 52 ítems validados psicométricamente proporciona la herramienta de medición necesaria para que esa investigación pueda realizarse con rigor metodológico comparable entre contextos.

Los hallazgos más relevantes del estudio empírico pueden sintetizarse en cinco proposiciones que tienen implicaciones directas para la práctica universitaria. Primera, el 78.4 por ciento de los estudiantes universitarios mexicanos estudiados utiliza herramientas de IA generativa para actividades académicas, pero existe una brecha estadísticamente significativa entre la frecuencia de uso (moderada-alta) y la calidad del proceso de uso (moderada), lo que indica que la adopción masiva no implica un aprovechamiento pedagógico equivalente. Segunda, la motivación intrínseca es el predictor más robusto de la calidad del uso de la IA —con un coeficiente  $\beta = .42$  en los análisis de regresión—, por encima de los factores tecnológicos, institucionales y sociales, lo que sitúa la dimensión motivacional en el centro de cualquier estrategia de intervención efectiva. Tercera, la validación empírica de los cinco perfiles conductuales —explorador activo, instrumentalista eficiente, dependiente pasivo, evasivo crítico y adaptativo reflexivo— confirma que la heterogeneidad de los patrones de uso de la IA es real y significativa, y que las respuestas pedagógicas uniformes son insuficientes para una población estudiantil tan diversa en sus relaciones con la IA. Cuarta, la ausencia percibida de orientación pedagógica institucional es uno de los hallazgos cualitativos más consistentes y relevantes para la política educativa: los estudiantes no perciben la ambigüedad normativa como neutralidad, sino como un abandono que los deja navegando sin brújula en un territorio éticamente complejo. Quinta, el perfil adaptativo reflexivo —académicamente más sostenible y asociado

con los mejores resultados de aprendizaje— es empíricamente alcanzable: el 18.7 por ciento de la muestra lo exhibe, lo que confirma que el uso académicamente productivo y éticamente responsable de la IA no es solo una aspiración pedagógica sino una realidad conductual que puede ser promovida deliberadamente.

La implicación más urgente del conjunto de hallazgos de este libro para la política educativa universitaria latinoamericana es que la respuesta institucional al uso de la IA no puede limitarse a la regulación del acceso o a la detección y sanción del uso deshonesto. Debe atender, de manera simultánea y coordinada, el desarrollo de la motivación intrínseca de los estudiantes, el fortalecimiento de la autorregulación del aprendizaje, la formación crítica en alfabetización en IA, la formación en razonamiento moral específico para el contexto de la IA, y el rediseño de los sistemas de evaluación universitaria. Las instituciones universitarias latinoamericanas que respondan a este desafío con la profundidad y la coordinación que requiere estarán invirtiendo no solo en el aprovechamiento de una tecnología disponible, sino en el desarrollo de las competencias cognitivas, éticas y metacognitivas que la formación universitaria del siglo XXI exige de sus egresados. El perfil de usuario adaptativo reflexivo —crítico, autónomo, éticamente orientado y capaz de aprender a lo largo de toda la vida— no emerge espontáneamente de la disponibilidad de herramientas de IA; es el resultado de condiciones pedagógicas e institucionales deliberadamente construidas. Esa construcción es el desafío educativo más importante que la educación superior latinoamericana enfrenta en este decenio, y es el horizonte al que apunta el MCUIA-ES como propuesta teórica, empírica y práctica.

## REFERENCIAS

- Ajzen, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50(2), 179–211. [https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/10.1016/0749-5978(91)90020-T)
- Anderson, L. W., & Krathwohl, D. R. (Eds.). (2001). *A taxonomy for learning, teaching, and assessing: A revision of Bloom's taxonomy of educational objectives*. Longman.
- ANUIES. (2023). *Anuario estadístico de educación superior*. Asociación Nacional de Universidades e Instituciones de Educación Superior. <https://www.anui.es/informacion-y-servicios/informacion-estadistica-de-educacion-superior/>
- Baidoo-Anu, D., & Ansah, L. O. (2023). Education in the era of generative artificial intelligence (AI): Understanding the potential benefits of ChatGPT in promoting teaching and learning. *Journal of AI*, 7(1), 52–62. <https://doi.org/10.61969/jai.1337500>
- Bandura, A. (1986). *Social foundations of thought and action: A social cognitive theory*. Prentice-Hall.
- Bandura, A. (1997). *Self-efficacy: The exercise of control*. W. H. Freeman.
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, 610–623. <https://doi.org/10.1145/3442188.3445922>
- Biggs, J., & Tang, C. (2011). *Teaching for quality learning at university* (4th ed.). Open University Press.
- Bjork, R. A., Dunlosky, J., & Kornell, N. (2013). Self-regulated learning: Beliefs, techniques, and illusions. *Annual Review of Psychology*, 64, 417–444. <https://doi.org/10.1146/annurev-psych-113011-143823>

- Bloom, B. S. (1984). The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. *Educational Researcher*, 13(6), 4–16. <https://doi.org/10.3102/0013189X013006004>
- Bloom, B. S., Engelhart, M. D., Furst, E. J., Hill, W. H., & Krathwohl, D. R. (1956). Taxonomy of educational objectives: The classification of educational goals. Handbook I: Cognitive domain. David McKay.
- Boud, D. (1988). Moving towards autonomy. In D. Boud (Ed.), *Developing student autonomy in learning* (2nd ed., pp. 17–39). Kogan Page.
- Boud, D., & Falchikov, N. (2006). Aligning assessment with long-term learning. *Assessment & Evaluation in Higher Education*, 31(4), 399–413. <https://doi.org/10.1080/02602930600679050>
- Braun, V., & Clarke, V. (2021). *Thematic analysis: A practical guide*. SAGE Publications. <https://doi.org/10.4135/9781529104455>
- Brown, T. A. (2015). *Confirmatory factor analysis for applied research* (2nd ed.). Guilford Press.
- Byrne, B. M. (2016). *Structural equation modeling with AMOS: Basic concepts, applications, and programming* (3rd ed.). Routledge. <https://doi.org/10.4324/9781315757421>
- Cai, Z., Fan, X., & Du, J. (2017). Gender and attitudes toward technology use: A meta-analysis. *Computers & Education*, 105, 1–13. <https://doi.org/10.1016/j.compedu.2016.11.003>
- Candy, P. C. (1991). *Self-direction for lifelong learning: A comprehensive guide to theory and practice*. Jossey-Bass.
- CEPAL. (2022). *Tecnologías digitales para un nuevo futuro*. Comisión Económica para América Latina y el Caribe. <https://repositorio.cepal.org/handle/11362/47351>

- 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>
- 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 higher education. *Sustainability*, 15(17), 12921. <https://doi.org/10.3390/su151712921>
- Chaudhry, M. A., Cukurova, M., & Luckin, R. (2023). A transparency index framework for AI in education. *Computers and Education: Artificial Intelligence*, 4, 100117. <https://doi.org/10.1016/j.caeai.2023.100117>
- Cialdini, R. B., & Goldstein, N. J. (2004). Social influence: Compliance and conformity. *Annual Review of Psychology*, 55, 591–621. <https://doi.org/10.1146/annurev.psych.55.090902.142015>
- Cohen, J., Cohen, P., West, S. G., & Aiken, L. S. (2003). *Applied multiple regression/correlation analysis for the behavioral sciences* (3rd ed.). Lawrence Erlbaum. <https://doi.org/10.4324/9780203774441>
- Compeau, D. R., & Higgins, C. A. (1995). Computer self-efficacy: Development of a measure and initial test. *MIS Quarterly*, 19(2), 189–211. <https://doi.org/10.2307/249688>
- Cooper, J. O., Heron, T. E., & Heward, W. L. (2020). *Applied behavior analysis* (3rd ed.). Pearson.
- Creswell, J. W., & Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches* (5th ed.). SAGE Publications.
- 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>
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319–340. <https://doi.org/10.2307/249008>
- Davis, R., Steckler, N., Morris, S., & Petrova, M. (2020). Students' psychological experiences in online learning during the COVID-19 pandemic. *Learning and Instruction*, 72, 101434. <https://doi.org/10.1016/j.learninstruc.2020.101434>
- Deci, E. L., & Ryan, R. M. (2000). The 'what' and 'why' of goal pursuits: Human needs and the self-determination of behavior. *Psychological Inquiry*, 11(4), 227–268. [https://doi.org/10.1207/S15327965PLI1104\\_01](https://doi.org/10.1207/S15327965PLI1104_01)
- Eccles, J. S., & Wigfield, A. (2020). From expectancy-value theory to situated expectancy-value theory: A developmental, social cognitive, and sociocultural perspective on motivation. *Contemporary Educational Psychology*, 61, 101859. <https://doi.org/10.1016/j.cedpsych.2020.101859>
- Elliot, A. J., & McGregor, H. A. (2001). A 2 × 2 achievement goal framework. *Journal of Personality and Social Psychology*, 80(3), 501–519. <https://doi.org/10.1037/0022-3514.80.3.501>
- Ennis, R. H. (2018). Critical thinking across the curriculum: A vision. *Topoi*, 37(1), 165–184. <https://doi.org/10.1007/s11245-016-9401-4>
- Everitt, B. S., Landau, S., Leese, M., & Stahl, D. (2011). *Cluster analysis* (5th ed.). Wiley. <https://doi.org/10.1002/9780470977811>
- Farhi, F., Jeljeli, R., Aburezeq, I., Dweikat, F. F., Al-Shami, S. A., & Slamene, R. (2023). Analyzing the students' views, usage, and impact of ChatGPT as a learning tool: A survey study. *Social*

- Sciences & Humanities Open, 8(1), 100565. <https://doi.org/10.1016/j.ssaho.2023.100565>
- Ferrando, P. J., & Lorenzo-Seva, U. (2018). Assessing the quality and appropriateness of factor solutions in exploratory item factor analysis. *Educational and Psychological Measurement*, 78(5), 762–780. <https://doi.org/10.1177/0013164417719308>
- Field, A. (2018). *Discovering statistics using IBM SPSS statistics* (5th ed.). SAGE Publications.
- Flick, U. (2022). *An introduction to qualitative research* (6th ed.). SAGE Publications.
- Grossnickle, E. M. (2016). Disentangling curiosity: Dimensionality, definitions, and distinctions from interest in educational contexts. *Educational Psychology Review*, 28(1), 23–60. <https://doi.org/10.1007/s10648-014-9294-y>
- Guo, K., Zhong, Y., Li, D., & Chu, S. K. W. (2023). Effects of chatbot-assisted in-class debates on students' argumentation skills, critical thinking and learning motivation. *Educational Technology & Society*, 26(1), 220–235. [https://doi.org/10.30191/ETS.202301\\_26\(1\).0016](https://doi.org/10.30191/ETS.202301_26(1).0016)
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (8th ed.). Cengage Learning.
- Halpern, D. F. (2014). *Thought and knowledge: An introduction to critical thinking* (5th ed.). Psychology Press. <https://doi.org/10.4324/9781315885278>
- Hattie, J., & Timperley, H. (2007). The power of feedback. *Review of Educational Research*, 77(1), 81–112. <https://doi.org/10.3102/003465430298487>
- Holmes, W., Porayska-Pomsta, K., Holstein, K., Sutherland, E., Baker, T., Buckingham Shum, S., Santos, O. C., Rodrigo, M. T., Cukurova, M., Bittencourt, I. I., & Koedinger, K. R. (2022). Ethics of AI in education: Towards a community-wide framework. *International Journal of Artificial Intelligence in*

- Education, 32(3), 504–526. <https://doi.org/10.1007/s40593-021-00239-1>
- Hu, L., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6(1), 1–55. <https://doi.org/10.1080/10705519909540118>
- 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>
- International Center for Academic Integrity. (2021). The fundamental values of academic integrity (3rd ed.). [https://academicintegrity.org/images/pdfs/20019\\_ICAI-Fundamental-Values\\_R12.pdf](https://academicintegrity.org/images/pdfs/20019_ICAI-Fundamental-Values_R12.pdf)
- Kalyuga, S. (2023). Cognitive load and artificial intelligence-enhanced learning environments: Potential benefits and risks. *Educational Psychology Review*, 35(2), 48. <https://doi.org/10.1007/s10648-023-09760-2>
- Kane, M. T. (2013). Validating the interpretations and uses of test scores. *Journal of Educational Measurement*, 50(1), 1–73. <https://doi.org/10.1111/jedm.12000>
- Kazdin, A. E. (2021). *Behavior modification in applied settings* (7th ed.). Waveland Press.
- Kulik, J. A., & Fletcher, J. D. (2016). Effectiveness of intelligent tutoring systems: A meta-analytic review. *Review of Educational Research*, 86(1), 42–78. <https://doi.org/10.3102/0034654315581420>
- Lawshe, C. H. (1975). A quantitative approach to content validity. *Personnel Psychology*, 28(4), 563–575. <https://doi.org/10.1111/j.1744-6570.1975.tb01393.x>

- Lim, W. M., Gunasekara, A., Pallant, J. L., Pallant, J. I., & Pechenkina, E. (2023). Generative AI and the future of education: Ragnarök or reformation? A paradoxical perspective from management educators. *The International Journal of Management Education*, 21(2), 100790. <https://doi.org/10.1016/j.ijme.2023.100790>
- Lloret-Segura, S., Ferreres-Traver, A., Hernández-Baeza, A., & Tomás-Marco, I. (2014). El análisis factorial exploratorio de los ítems: Una guía práctica, revisada y actualizada. *Anales de Psicología*, 30(3), 1151–1169. <https://doi.org/10.6018/analesps.30.3.199361>
- Long, D., & Magerko, B. (2020). What is AI literacy? Competencies and design considerations. *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, 1–16. <https://doi.org/10.1145/3313831.3376727>
- Luckin, R., & Cukurova, M. (2019). Designing educational technologies in the age of AI: A learning sciences-driven approach. *British Journal of Educational Technology*, 50(6), 2824–2838. <https://doi.org/10.1111/bjet.12890>
- Ma, W., Adesope, O. O., Nesbit, J. C., & Liu, Q. (2020). Intelligent tutoring systems and learning outcomes: A meta-analysis. *Journal of Educational Psychology*, 106(4), 901–918. <https://doi.org/10.1037/a0037123>
- Mayer, R. E. (2009). *Multimedia learning* (2nd ed.). Cambridge University Press. <https://doi.org/10.1017/CBO9780511811678>
- Mayer, R. E., & Fiorella, L. (2022). Principles of multimedia learning. In R. E. Mayer & L. Fiorella (Eds.), *The Cambridge handbook of multimedia learning* (3rd ed., pp. 3–16). Cambridge University Press. <https://doi.org/10.1017/9781108894333>
- McNeish, D. (2018). Thanks coefficient alpha, we'll take it from here. *Psychological Methods*, 23(3), 412–433. <https://doi.org/10.1037/met0000144>

- Merton, R. K. (1968). *Social theory and social structure* (enlarged ed.). Free Press.
- Messick, S. (1995). Validity of psychological assessment: Validation of inferences from persons' responses and performances as scientific inquiry into score meaning. *American Psychologist*, 50(9), 741–749. <https://doi.org/10.1037/0003-066X.50.9.741>
- Molina-Gómez, J., Hernández-Torres, R., & Vázquez-Reyes, S. (2024). Uso de inteligencia artificial generativa en estudiantes universitarios mexicanos: Patrones conductuales y factores asociados. *Revista Latinoamericana de Tecnología Educativa*, 23(1), 45–63. <https://doi.org/10.17398/1695-288X.23.1.45>
- Narvaez, D., & Lapsley, D. K. (2009). Moral identity, moral functioning, and the development of moral character. In D. M. Bartels, C. W. Bauman, L. J. Skitka, & D. L. Medin (Eds.), *The psychology of learning and motivation* (Vol. 50, pp. 237–274). Academic Press. [https://doi.org/10.1016/S0079-7421\(08\)00408-8](https://doi.org/10.1016/S0079-7421(08)00408-8)
- 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>
- Nunnally, J. C., & Bernstein, I. H. (1994). *Psychometric theory* (3rd ed.). McGraw-Hill.
- Ouyang, F., & Jiao, P. (2021). Artificial intelligence in education: The three paradigms. *Computers and Education: Artificial Intelligence*, 2, 100020. <https://doi.org/10.1016/j.caeai.2021.100020>
- Pardos, Z. A., & Bhandari, S. (2023). Learning gain differences between ChatGPT and human tutors. *arXiv*. <https://doi.org/10.48550/arXiv.2302.11111>

- Park, J. H., & Kim, H. W. (2023). Understanding university students' behavioral intention to use AI-based learning systems: An extended TAM approach. *Education and Information Technologies*, 28(4), 4437–4459. <https://doi.org/10.1007/s10639-022-11380-y>
- Perkins, M., Roe, J., Postma, D., McGaughran, J., & Hickerson, D. (2023). Game of tones: Faculty detection of GPT-4 generated content in university assessments. *arXiv*. <https://doi.org/10.48550/arXiv.2305.18081>
- Perugini, M., & Bagozzi, R. P. (2001). The role of desires and anticipated emotions in goal-directed behaviours: Broadening and deepening the theory of planned behaviour. *British Journal of Social Psychology*, 40(1), 79–98. <https://doi.org/10.1348/014466601164704>
- Pintrich, P. R. (2004). A conceptual framework for assessing motivation and self-regulated learning in college students. *Educational Psychology Review*, 16(4), 385–407. <https://doi.org/10.1007/s10648-004-0006-x>
- Pintrich, P. R., & De Groot, E. V. (1990). Motivational and self-regulated learning components of classroom academic performance. *Journal of Educational Psychology*, 82(1), 33–40. <https://doi.org/10.1037/0022-0663.82.1.33>
- Podsakoff, P. M., MacKenzie, S. B., Lee, J. Y., & Podsakoff, N. P. (2003). Common method biases in behavioral research: A critical review of the literature and recommended remedies. *Journal of Applied Psychology*, 88(5), 879–903. <https://doi.org/10.1037/0021-9010.88.5.879>
- Rachlin, H. (2019). The teleological behaviorism of B. F. Skinner. *Perspectives on Behavior Science*, 42(3), 545–559. <https://doi.org/10.1007/s40614-019-00213-2>
- Rest, J., Narvaez, D., Bebeau, M. J., & Thoma, S. J. (2000). A neo-Kohlbergian approach to morality research. *Journal of Moral*

- Education, 29(4), 381–395. <https://doi.org/10.1080/713679390>
- Richardson, M., Abraham, C., & Bond, R. (2012). Psychological correlates of university students' academic performance: A systematic review and meta-analysis. *Psychological Bulletin*, 138(2), 353–387. <https://doi.org/10.1037/a0026838>
- Rochin Berumen, F. L. (2026). La investigación científica asistida por inteligencia artificial: Validez, ética y toma de decisiones. Atena Editora. <https://doi.org/10.22533/at.ed.974262204>
- Roll, I., & Wylie, R. (2016). Evolution and revolution in artificial intelligence in education. *International Journal of Artificial Intelligence in Education*, 26(2), 582–599. <https://doi.org/10.1007/s40593-016-0110-3>
- Romero-García, C., Buzón-García, O., & Touron, J. (2023). The flipped learning model in online higher education: Teachers' and students' perceptions and use of AI tools. *Journal of New Approaches in Educational Research*, 12(1), 1–15. <https://doi.org/10.7821/naer.2023.1.1540>
- Rotter, J. B. (1966). Generalized expectancies for internal versus external control of reinforcement. *Psychological Monographs: General and Applied*, 80(1), 1–28. <https://doi.org/10.1037/h0092976>
- Rudolph, J., Tan, S., & Tan, S. (2023). ChatGPT: Bullshit spewer or the end of traditional assessments in higher education? *Journal of Applied Learning and Teaching*, 6(1), 342–363. <https://doi.org/10.37074/jalt.2023.6.1.9>
- Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Scherer, R., Siddiq, F., & Tondeur, J. (2019). The technology acceptance model (TAM): A meta-analytic structural equation modeling approach to explaining teachers' adoption of digital

- technology in education. *Computers & Education*, 128, 13–35. <https://doi.org/10.1016/j.compedu.2018.09.009>
- Schneider, J., Börner, D., Drachsler, H., & Schiefner-Rohs, M. (2022). Leveraging AI-generated feedback for learning in higher education. *Computers & Education*, 186, 104536. <https://doi.org/10.1016/j.compedu.2022.104536>
- Secretaría de Educación Pública. (2023). Marco de referencia para la integración de inteligencia artificial en la educación superior mexicana. Gobierno de México.
- Selwyn, N. (2022). The future of AI and education: Some cautionary notes. *European Journal of Education*, 57(4), 620–631. <https://doi.org/10.1111/ejed.12532>
- 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>
- Shiffman, S., Stone, A. A., & Hufford, M. R. (2008). Ecological momentary assessment. *Annual Review of Clinical Psychology*, 4, 1–32. <https://doi.org/10.1146/annurev.clinpsy.3.022806.091415>
- Sijtsma, K. (2009). On the use, the misuse, and the very limited usefulness of Cronbach's alpha. *Psychometrika*, 74(1), 107–120. <https://doi.org/10.1007/s11336-008-9101-0>
- Sindre, G., & Moody, D. (2022). Generative AI and academic integrity: Challenges and responses. *ACM Transactions on Computing Education*, 22(4), 1–22. <https://doi.org/10.1145/3502718>
- Skinner, B. F. (1953). *Science and human behavior*. Macmillan.
- Southworth, J., Migliaccio, K., Glover, J., Glover, J., Reed, D., Black, C., Surber, T., Hutton, D., Rainer, J., Ballington, T., Larkin, K., & Schwartz, N. (2023). Developing a model for AI across

the curriculum: Transforming the higher education landscape via innovation in AI literacy. *Computers and Education: Artificial Intelligence*, 4, 100127. <https://doi.org/10.1016/j.caeai.2023.100127>

Sparrow, B., Liu, J., & Wegner, D. M. (2011). Google effects on memory: Cognitive consequences of having information at our fingertips. *Science*, 333(6043), 776–778. <https://doi.org/10.1126/science.1207745>

Sweller, J. (1988). Cognitive load during problem solving: Effects on learning. *Cognitive Science*, 12(2), 257–285. [https://doi.org/10.1207/s15516709cog1202\\_4](https://doi.org/10.1207/s15516709cog1202_4)

Sweller, J., van Merriënboer, J. J. G., & Paas, F. (2019). Cognitive architecture and instructional design: 20 years later. *Educational Psychology Review*, 31(2), 261–292. <https://doi.org/10.1007/s10648-019-09465-5>

Tashakkori, A., Johnson, R. B., & Teddlie, C. (2021). *Foundations of mixed methods research: Integrating quantitative and qualitative approaches in the social and behavioral sciences* (2nd ed.). SAGE Publications.

Thompson, M. M., Zanna, M. P., & Griffin, D. W. (1995). Let's not be indifferent about (attitudinal) ambivalence. In R. E. Petty & J. A. Krosnick (Eds.), *Attitude strength: Antecedents and consequences* (pp. 361–386). Lawrence Erlbaum.

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>

UNESCO. (2023). *Guidance for generative AI in education and research*. United Nations Educational, Scientific and Cultural Organization. <https://doi.org/10.54675/EWZM9535>

- Vansteenkiste, M., Niemiec, C. P., & Soenens, B. (2010). The development of the five mini-theories of self-determination theory: An historical overview, emerging trends, and future directions. In T. C. Urdan & S. A. Karabenick (Eds.), *The decade ahead: Theoretical perspectives on motivation and achievement* (Vol. 16, pp. 105–165). Emerald. [https://doi.org/10.1108/S0749-7423\(2010\)000016A007](https://doi.org/10.1108/S0749-7423(2010)000016A007)
- VanLehn, K. (2011). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, 46(4), 197–221. <https://doi.org/10.1080/00461520.2011.611369>
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified theory. *MIS Quarterly*, 27(3), 425–478. <https://doi.org/10.2307/30036540>
- Venkatesh, V., Thong, J. Y. L., & Xu, X. (2012). Consumer acceptance and use of information technology: Extending the unified theory of acceptance and use of technology. *MIS Quarterly*, 36(1), 157–178. <https://doi.org/10.2307/41410412>
- Vygotsky, L. S. (1978). *Mind in society: The development of higher psychological processes*. Harvard University Press.
- Wenger, E. (1998). *Communities of practice: Learning, meaning, and identity*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511803932>
- Westphal, M., Kaul, M., Fabian, L., Leber, J., & Greiff, S. (2023). How does the use of an AI text generator change the process and product of student writing? *Learning and Instruction*, 89, 101823. <https://doi.org/10.1016/j.learninstruc.2023.101823>
- Wigfield, A., & Eccles, J. S. (2000). Expectancy–value theory of achievement motivation. *Contemporary Educational Psychology*, 25(1), 68–81. <https://doi.org/10.1006/ceps.1999.1015>

- Yue, M., Jong, M. S. Y., & Xu, G. (2023). Pedagogical design of K-12 artificial intelligence education: A systematic review. *Sustainability*, 15(4), 3623. <https://doi.org/10.3390/su15043623>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 39. <https://doi.org/10.1186/s41239-019-0171-0>
- Zimmerman, B. J. (2000). Attaining self-regulation: A social cognitive perspective. In M. Boekaerts, P. R. Pintrich, & M. Zeidner (Eds.), *Handbook of self-regulation* (pp. 13–39). Academic Press. <https://doi.org/10.1016/B978-012109890-2/50031-7>
- Zimmerman, B. J., & Schunk, D. H. (Eds.). (2011). *Handbook of self-regulation of learning and performance*. Routledge. <https://doi.org/10.4324/9780203839010>

## Acerca de las autoras

Dra. Fabiola Lydie Rochin Berumen<sup>a,\*</sup>

**ORCID:** <https://orcid.org/0000-0002-8676-7768>

Correo: [fabiolauaz@outlook.com](mailto:fabiolauaz@outlook.com)

Dra. Carla Capetillo Medrano<sup>a</sup>

**ORCID:** <https://orcid.org/0000-0002-0810-8919>

Correo: [ccapetillo@uaz.edu.mx](mailto:ccapetillo@uaz.edu.mx)

\*Autora de correspondencia: [fabiolauaz@outlook.com](mailto:fabiolauaz@outlook.com),

<sup>a</sup>Universidad Autónoma de Zacatecas, México.



  
OMNISCENS  
PUBLISHING  
Año 2026

ISBN: 978-970-96207-0-2



9 789709 620702