



Facultad de Ciencias Económicas y Empresariales
ICADE

El fenómeno de la Shadow AI. ¿Por qué ocultamos la IA en el trabajo?

Autor: Carlota Riesgo Yanes 202102052
Director: Carlos Martínez de Ibarreta Zorita

Junio 2026

Abstract

This study examines why university students use generative artificial intelligence tools in an unauthorized or undeclared way, a phenomenon known as Shadow AI. Drawing on technology adoption models and Behavioral Economics, a quantitative survey was administered to students from multiple Spanish and international universities, with a focus on Universidad Pontificia Comillas (ICADE) and Cardiff University. Results show that present bias is the strongest predictor of Shadow AI use, followed by perceived utility and perceived risk. A k-means segmentation identifies three user profiles, "Rule-benders", "In-betweeners" and "Cautious", with distinct attitudinal and sociodemographic patterns. These findings should be interpreted as exploratory tendencies rather than generalizable conclusions, given the convenience sampling method and moderate sample size.

Keywords

Shadow AI, generative artificial intelligence, Behavioral Economics, present bias, academic integrity, higher education, k-means clustering

Resumen

Este trabajo estudia por qué los estudiantes universitarios utilizan herramientas de inteligencia artificial generativa de forma no declarada o no autorizada, fenómeno conocido como Shadow AI. A partir de modelos de adopción tecnológica y la Economía del Comportamiento, se administró un cuestionario cuantitativo a estudiantes de diversas universidades españolas e internacionales, con especial atención a la Universidad Pontificia Comillas (ICADE) y Cardiff University. Los resultados apuntan a que el present bias es el factor con mayor asociación observada con el uso de Shadow AI, seguido de la utilidad percibida y el riesgo percibido. Una segmentación k-means identifica tres perfiles de usuario, "Tramposos", "Intermedios" y "Cautelosos", con patrones actitudinales y sociodemográficos diferenciados. Estos hallazgos deben interpretarse como tendencias exploratorias y no como conclusiones generalizables, dada la naturaleza no probabilística del muestreo y el tamaño moderado de la muestra.

Palabras clave

Shadow AI, inteligencia artificial generativa, Economía del Comportamiento, present bias, integridad académica, educación superior, clustering k-means

ÍNDICE

1. Introducción	5
1.1. Contexto y justificación del tema: el auge de la IA generativa en la educación superior	5
1.2. Problema y relevancia académica y social.....	6
1.3. Objetivos y preguntas de investigación	7
1.4. Estructura del trabajo	8
2. Marco Teórico	9
2.1. Inteligencia artificial generativa: concepto y aplicaciones en educación	9
2.2. Shadow AI: definición, antecedentes y alcance.....	10
2.3. Modelos clásicos de adopción tecnológica: TAM, UTAUT y TPB	13
2.4. Behavioral Economics y sesgos conductuales en el Shadow AI	14
3. Preguntas e Hipótesis de Investigación	18
3.1. Factores personales que predicen el uso de Shadow AI	18
3.2. Diferencias esperadas entre perfiles de estudiante.....	19
4. Metodología de Investigación	20
4.1. Diseño del estudio y muestra	20
4.2. Variables y escalas de medición	21
4.2.1. Variable dependiente: uso de Shadow AI	22
4.2.2. Variables independientes	22
4.2.3. Variables contextuales	22
4.3. Procedimiento, ética y plan de análisis	22
5. Resultados	23
5.1. Descripción de la muestra.....	23
5.2. Prevalencia y patrones de uso de Shadow AI	24
5.3. Fiabilidad de las escalas y estadísticos descriptivos	26
5.4. Contraste de hipótesis: factores asociados al uso de Shadow AI.....	26
5.4.1. Análisis correlacional	26
5.4.2. Contraste de hipótesis	27
5.4.3. Modelo de regresión lineal múltiple	28
5.5. Diferencias por género y tipo de universidad	29
5.6. Perfiles de usuario: Segmentación K-means	31
6. Discusión	35
6.1. Interpretación de los resultados y conexión con el marco teórico	35
6.2. Perfiles de usuario y su significado	36

6.3. Diferencias por tipo de universidad y grupo institucional.....	37
6.4. Implicaciones para políticas universitarias	38
6.5. Contribución del estudio	38
6.6. Limitaciones y futuras líneas de investigación	39
7. Conclusiones	39
7.1. Síntesis del fenómeno y hallazgos principales.....	39
7.2. Recomendaciones prácticas para las universidades	40
7.3. Reflexión final sobre IA, autonomía y educación responsable.....	41
Referencias	43
Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado.....	50

1. Introducción

1.1. Contexto y justificación del tema: el auge de la IA generativa en la educación superior

En las últimas décadas, la tecnología ha transformado de manera profunda la forma en que aprendemos, trabajamos y nos comunicamos. Dentro de este proceso de cambio acelerado, la inteligencia artificial generativa ha aparecido como uno de los avances más novedosos, al ser capaz de reproducir procesos cognitivos y creativos que hasta hace poco se consideraban exclusivamente humanos. Modelos como ChatGPT, Copilot o Gemini han pasado de ser innovaciones experimentales a convertirse en herramientas de uso cotidiano para millones de estudiantes y profesionales en todo el mundo, marcando un punto de inflexión en distintos ámbitos sociales, laborales y educativos.

Su expansión ha sido especialmente notable en la educación superior. Según el *Student Generative AI Survey 2026* elaborado por HEPI, el uso de la IA generativa entre los estudiantes universitarios ha alcanzado una adopción casi universal: el 95% de los estudiantes declara utilizarla de alguna forma y el 94% afirma usarla para la realización de trabajos evaluados.

Esta realidad plantea un reto institucional muy importante. La rapidez con la que la tecnología ha avanzado ha superado, en muchos casos, la capacidad de las universidades para adaptar sus marcos normativos y pedagógicos. El resultado es una brecha creciente entre los usos digitales de los estudiantes y las políticas académicas vigentes, que en la mayoría de los casos se limitan a prohibir o restringir el uso de IA sin ofrecer orientación clara sobre cómo integrarlo de manera ética y formativa. Es precisamente en esta brecha donde surge el fenómeno conocido como **Shadow AI**.

La Shadow AI hace referencia al “uso de herramientas de inteligencia artificial de manera no declarada o no autorizada en contextos donde su empleo está regulado o prohibido” (IBM, 2024). En el entorno universitario, se manifiesta cuando los estudiantes recurren a la IA para hacer trabajos, resolver ejercicios o incluso hacer exámenes sin informar de ello, desafiando así las normas de integridad académica. Este fenómeno proviene del estudio sobre el Shadow IT, el cual documentó hace más de una década cómo los usuarios adoptaban soluciones tecnológicas al margen de los canales institucionales cuando percibían que estas les ofrecían mayor eficiencia o flexibilidad (Zimmermann y Rentrop,

2014). La *Shadow AI* representa, en este sentido, la expresión más reciente y actualizada de ese mismo fenómeno.

Desde la perspectiva del Business Analytics, la *Shadow AI* es especialmente relevante ya que permite analizar el comportamiento de los usuarios ante la tecnología: qué factores predicen su adopción y comportamiento, cómo influyen los sesgos conductuales en la toma de decisiones y hasta qué punto las políticas institucionales logran regular o frenar estas prácticas. Entender estos mecanismos es el primer paso para diseñar respuestas más eficaces por parte de las universidades, que no se limiten a sancionar el uso oculto de la IA, sino que promuevan un uso responsable y crítico de estas herramientas en la formación universitaria.

1.2. Problema y relevancia académica y social

El fenómeno de la *Shadow AI* se está convirtiendo en un reto cada vez más visible en la educación superior. Por un lado, plantea dudas sobre si las universidades están siendo capaces de adaptarse al ritmo al que la IA está cambiando la forma de estudiar, enseñar y evaluar. Por otro, refleja un cambio en la forma de pensar de muchos estudiantes, que buscan soluciones rápidas, eficientes y personalizadas, incluso si eso implica usar herramientas como la IA al margen de las normas. Analizar este fenómeno es importante para entender cómo están cambiando las formas de aprendizaje y por qué algunos estudiantes terminan incumpliendo las reglas universitarias. No se trata solo de un problema ético puntual, sino que también está relacionado con factores más amplios, como la presión por obtener buenas calificaciones, la percepción de que los sistemas de evaluación no se han adaptado al avance tecnológico y la influencia del entorno, donde el uso de IA sin declararlo se está normalizando. En este sentido, la *Shadow AI* no es solo una decisión individual de los estudiantes, sino también una señal de que muchas instituciones todavía no se han ajustado completamente a esta nueva realidad digital.

La importancia de este tema no se limita solo al ámbito académico del que hablo en este trabajo. Los estudiantes que hoy usan estas herramientas en la universidad serán los profesionales que mañana tomarán decisiones en empresas y organizaciones. Las consecuencias en el mundo laboral son también de gran importancia, ya que el uso de *Shadow AI* en las empresas puede generar problemas parecidos a los que se ven en la universidad, como la filtración de datos sensibles, la pérdida de control sobre procesos

automatizados o las dificultades para cumplir con las normas y regulaciones (IBM, 2024; BBVA, 2024).

Desde la perspectiva del Business Analytics, este trabajo aporta valor al tratar el comportamiento ante la tecnología como un fenómeno cuantificable y analizable. A partir de datos empíricos recogidos mediante una encuesta a alumnos universitarios con políticas normativas distintas como son la Universidad Pontificia Comillas (ICADE), Cardiff University y otras universidades, se identifican los factores personales, conductuales y contextuales que se asocian con el uso de la Shadow AI entre estudiantes universitarios. Este diseño comparativo permite, además, evaluar en qué medida el marco institucional se relaciona con el comportamiento de los estudiantes, una pregunta con implicaciones directas para el diseño de políticas educativas más efectivas.

1.3. Objetivos y preguntas de investigación

El objetivo general de este trabajo es analizar los factores que predicen el uso de Shadow AI entre estudiantes universitarios, con especial atención al papel de las variables personales, conductuales y contextuales en esta decisión.

De manera más concreta, el trabajo persigue cuatro objetivos específicos. En primer lugar, identificar la prevalencia y los patrones de uso de Shadow AI en la muestra estudiada, determinando en qué medida y con qué finalidades los estudiantes emplean IA de forma no declarada. En segundo lugar, contrastar en qué medida variables como la utilidad percibida, las normas sociales, la presión académica y los sesgos conductuales, en particular el *present bias* y el *overconfidence* predicen el uso de Shadow AI. En tercer lugar, examinar si existen diferencias significativas en el uso de Shadow AI entre estudiantes de distintas universidades, con enfoques normativos distintos, en especial estudiantes de ICADE y de Cardiff University (al ser las dos universidades en las que yo he estudiado y cuyas políticas normativas de uso de la IA difieren) pero teniendo en cuenta también las respuestas de estudiantes de otras universidades. En cuarto lugar, identificar perfiles de usuario que permitan caracterizar al estudiantado en función de sus actitudes y comportamientos hacia estas herramientas.

A partir de estos objetivos, se plantean las siguientes preguntas de investigación:

- (i) ¿Qué factores personales y conductuales se asocian con el uso de IA de forma no declarada por parte de un estudiante universitario?

- (ii) ¿En qué medida influyen las normas sociales del entorno académico en esta decisión?
- (iii) ¿Existe una relación entre la presión académica y el uso de Shadow AI?
- (iv) ¿Difiere el comportamiento de los estudiantes en función del marco normativo de su universidad?

1.4. Estructura del trabajo

Este trabajo se organiza en siete bloques principales. Tras esta introducción, el segundo bloque desarrolla el marco teórico, que aborda los conceptos clave que sustentan la investigación: la inteligencia artificial generativa, el fenómeno de la Shadow AI y sus antecedentes en el estudio sobre el Shadow IT, los modelos clásicos de adopción tecnológica (TAM, UTAUT y TPB), los sesgos conductuales identificados desde la Economía del Comportamiento y el contexto normativo las universidades analizadas, especialmente de ICADE y Cardiff University.

El tercer bloque recoge las preguntas e hipótesis de investigación, formuladas a partir del marco teórico y organizadas en torno a dos ejes: los factores personales que se asocian al uso de Shadow AI y las diferencias esperadas entre distintos perfiles de estudiante en función de variables contextuales como el tipo de universidad o el género.

El cuarto bloque describe la metodología empleada, incluyendo el diseño del estudio, la muestra de 164 estudiantes universitarios de España, Italia y Reino Unido, las variables y escalas utilizadas, y el plan de análisis estadístico, que comprende desde la construcción de constructos hasta la segmentación mediante análisis k-means.

El quinto bloque presenta los resultados, comenzando por la descripción de la muestra y la fiabilidad de las escalas, y avanzando hacia el contraste de hipótesis, la identificación de tres perfiles de usuario mediante análisis k-means, denominados "Tramposos", "Intermedios" y "Cautelosos", y su caracterización sociodemográfica en función del género y el tipo de universidad de procedencia.

El sexto bloque interpreta los hallazgos a la luz del marco teórico, presta especial atención al *present bias* como predictor con mayor asociación con el uso de Shadow AI, analiza las diferencias observadas entre perfiles de estudiante según el tipo de institución y el género, y extrae implicaciones para el diseño de políticas universitarias más eficaces.

El trabajo concluye con un séptimo bloque de conclusiones, que sintetiza los hallazgos principales y ofrece recomendaciones prácticas, seguido de las referencias bibliográficas y los anexos.

2. Marco Teórico

2.1. Inteligencia artificial generativa: concepto y aplicaciones en educación

La inteligencia artificial generativa (en adelante, IA generativa) se basa en modelos computacionales capaces de aprender patrones complejos a partir de grandes volúmenes de datos y generar nuevo contenido de manera autónoma. A diferencia de los sistemas de inteligencia artificial tradicionales, la IA generativa puede producir desde cero textos, imágenes, código o audio que imitan la creatividad humana con un nivel de precisión creciente. Esta capacidad se sustenta en arquitecturas de aprendizaje profundo, especialmente los modelos de lenguaje de gran escala (*large language models*, LLM), que procesan y generan lenguaje natural a partir del entrenamiento con corpus de datos masivos (Bommasani et al., 2021).

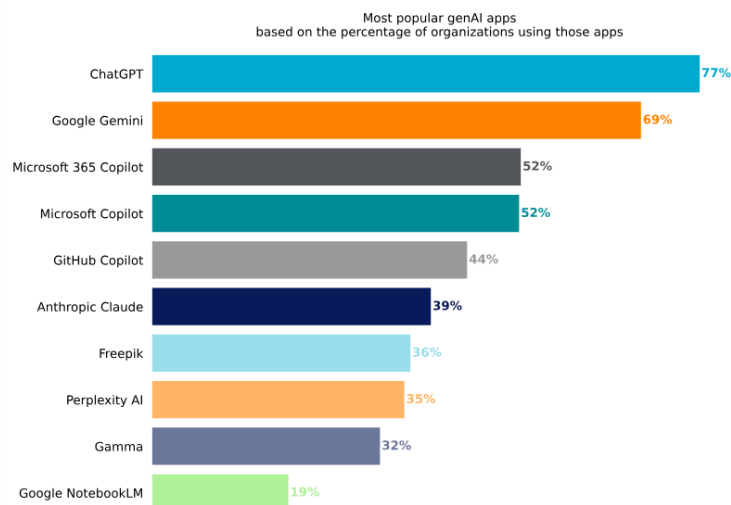
El Stanford Center for Research on Foundation Models acuñó el concepto de *foundation models* para referirse a esta nueva categoría de sistemas, entrenados con múltiples fuentes de datos y capaces de transferir lo aprendido a contextos y tareas muy diversas (Bommasani et al., 2021). Lo que distingue a estos modelos de generaciones anteriores de IA es precisamente su versatilidad: no están diseñados para resolver un problema concreto, sino para adaptarse a múltiples escenarios, desde la redacción de trabajos hasta la generación de código o el análisis de documentos complejos. Entre los modelos más extendidos se encuentran ChatGPT, desarrollado por OpenAI, así como Google Gemini, Claude o Microsoft Copilot, que han integrado capacidades generativas en herramientas de productividad de uso masivo.

La UNESCO advirtió en 2023 que la irrupción de la IA generativa en la educación superior constituye tanto una oportunidad como un desafío de primera magnitud, al alterar los procesos de aprendizaje, evaluación y producción del conocimiento (Giannini, 2023). En la práctica, estas herramientas permiten generar materiales didácticos personalizados, proporcionar retroalimentación inmediata, simular tutores virtuales o adaptar los contenidos al ritmo y estilo de cada estudiante. Sin embargo, esta misma accesibilidad plantea interrogantes fundamentales sobre la autenticidad del aprendizaje y la validez de las formas tradicionales de evaluación académica.

Los datos confirman que la adopción de estas herramientas entre el estudiantado universitario español es ya un fenómeno consolidado. Según el informe *Uso y percepción de la IA en el entorno universitario* (Fundación CYD, 2025), las principales finalidades para las que se utiliza la IA son: resolver dudas específicas (66%), investigar o recopilar información (48%) y redactar trabajos (45%). Estos datos son consistentes con los obtenidos en el presente estudio, que analizaremos más adelante.

Este panorama pone de manifiesto que la IA generativa ha dejado de ser una tecnología emergente para convertirse en un elemento esencial del ecosistema universitario. La cuestión relevante ya no es si los estudiantes la usan, ya que se da por hecho que sí, sino cómo, con qué finalidad y bajo qué condiciones normativas lo hacen. Responder a esa pregunta exige comprender primero el fenómeno de la Shadow AI, que se aborda en el subapartado siguiente.

Figura 2: Aplicaciones de IA generativa más utilizadas en organizaciones según el porcentaje de empresas que las emplean



Fuente: Netskope (2026)

2.2. Shadow AI: definición, antecedentes y alcance

El término Shadow AI hace referencia al uso de herramientas de inteligencia artificial (especialmente de IA generativa) por parte de empleados o estudiantes sin autorización formal ni supervisión por parte de la institución u organización a la que pertenecen. IBM define este fenómeno como el “uso no autorizado de aplicaciones de IA generativa (IA

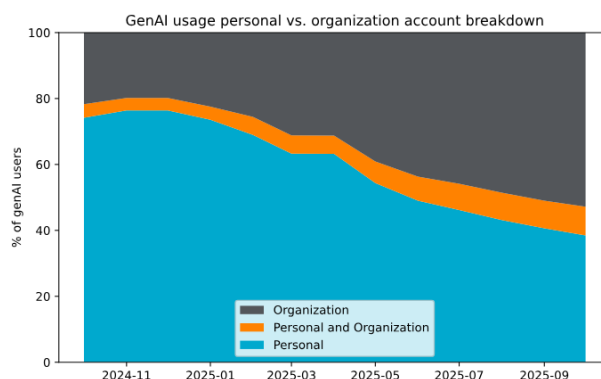
Gen), como Chat GPT de OpenAI, para automatizar tareas como la edición del texto y el análisis de datos” (IBM, 2024).

Como he mencionado anteriormente, para entender bien el término de Shadow AI, hay que remontarse a su antecedente más directo: la Shadow IT. Zimmermann y Rentrop (2014) la definieron como el uso de tecnología y aplicaciones SaaS (Software as a Service) sin el conocimiento ni la autorización del departamento de Tecnologías de la Información (IT). Según datos de Gartner recogidos por BBVA (2024), el 41% de los empleados de empresas adquirieron, modificaron o crearon tecnología fuera de la visibilidad de los equipos de IT en 2022, porcentaje que podría ascender al 75% en 2027 (Gartner, 2023). Las razones que sostienen este comportamiento son consistentes con las de la Shadow AI: los usuarios recurren a soluciones no permitidas cuando las herramientas institucionales resultan lentas, insuficientes o desconocidas, y cuando perciben que las alternativas externas les ofrecen mayor rapidez, eficiencia o flexibilidad (Zimmermann y Rentrop, 2014). La Shadow AI reproduce esta misma lógica pero la amplifica, dado que las herramientas de IA generativa son gratuitas, intuitivas y extraordinariamente capaces.

Magnitud y alcance del fenómeno

Los datos disponibles revelan una expansión acelerada. Según el *Cloud and Threat Report 2026* de Netskope, el número de usuarios de herramientas de IA generativa en entornos empresariales se ha triplicado en el último año, y el volumen de prompts enviados a estas aplicaciones se ha multiplicado por seis, pasando de una media de 3.000 a 18.000 mensajes mensuales por organización. En cuanto al uso a través de cuentas personales, fuera del control de los departamentos de IT, la cifra ha descendido del 78% al 47%, lo que refleja por un lado, una cierta mejora en la gobernanza corporativa, y por otro, que cada vez más se está integrando la IA en las propias plataformas y dispositivos de las empresas, lo cual disminuye la necesidad de usar las cuentas personales. En paralelo, las violaciones de políticas de datos relacionadas con el uso de IA se han duplicado, con una media de 223 incidentes mensuales por organización, siendo el código fuente, los datos regulados y la propiedad intelectual los tipos de información más frecuentemente comprometidos.

Figura 2. Porcentaje del uso de IA generativa en organizaciones realizado mediante cuentas personales (Shadow AI).



Fuente: Netskope (2026)

El dato más llamativo en el contexto educativo proviene del propio estudio realizado para este trabajo: el 77% de los participantes declara haber modificado el texto generado por IA para evitar detectores automáticos, el 59% ha entregado trabajos redactados parcialmente con IA sin declararlo, y el 51% reconoce haber usado IA en tareas donde su uso estaba expresamente prohibido. Estas cifras, obtenidas sobre una muestra de 164 estudiantes universitarios de España, Italia y Reino Unido, sitúan la Shadow AI como una práctica extendida y normalizada entre el estudiantado universitario.

Riesgos específicos de la Shadow AI

Los riesgos asociados a la Shadow AI van más allá de los ya documentados en el estudio sobre Shadow IT. En primer lugar, existe un riesgo de seguridad y fuga de datos mencionado anteriormente, en segundo lugar, la Shadow AI plantea riesgos de cumplimiento normativo, especialmente relevantes en Europa tras la aprobación del Reglamento General de Protección de Datos (RGPD)¹ y el AI Act². En tercer lugar, y de especial relevancia para el ámbito educativo, existe un riesgo cognitivo: el uso no reflexivo de estas herramientas puede generar dependencia tecnológica y reducir el desarrollo del pensamiento crítico y la capacidad de producción autónoma del estudiante

¹ El RGPD (Reglamento 2016/679) regula el tratamiento de datos personales en la UE y resulta especialmente relevante ya que el uso de herramientas no supervisadas puede implicar la transferencia de datos personales a servidores externos sin el consentimiento informado de los afectados.

² El AI Act (Reglamento 2024/1689) regula el uso de sistemas de inteligencia artificial en la UE y es especialmente relevante ya que el uso de herramientas de IA no declaradas puede implicar el incumplimiento de las obligaciones de transparencia y trazabilidad que la norma impone a los usuarios de estos sistemas.

(De Frutos Sastre, 2025). Hoy en día cuando nos planteamos algo o nos surgen dudas, la gran mayoría de jóvenes acudimos a la IA como primera fuente, en lugar de preguntar a alguien, consultar documentos oficiales o libros en papel, como se hacía antes del auge de la IA.

En definitiva, la Shadow AI no es un fenómeno pasajero ni reducible a un problema de cumplimiento normativo puntual. **Es la expresión más reciente de una tensión estructural entre la velocidad de adopción tecnológica por parte de los usuarios y la capacidad de las instituciones para gestionar, regular e integrar esas herramientas de manera ética y responsable.** Comprender por qué ocurre exige analizar los modelos que describen la adopción tecnológica, que se abordan en el subapartado siguiente.

2.3. Modelos clásicos de adopción tecnológica: TAM, UTAUT y TPB

Para entender por qué los estudiantes utilizan herramientas de IA generativa y a veces sin declararlo, es útil recurrir a algunos modelos teóricos que describen cómo las personas adoptan nuevas tecnologías y qué factores se asocian con dicha adopción. Entre los más utilizados en la literatura destacan el *Technology Acceptance Model* (TAM), la *Unified Theory of Acceptance and Use of Technology* (UTAUT) y la *Theory of Planned Behavior* (TPB). Cada uno ofrece una perspectiva diferente que ayuda a comprender mejor el fenómeno de la *Shadow AI*.

El Technology Acceptance Model (TAM)

El TAM fue propuesto por Davis (1989) para explicar por qué las personas deciden utilizar una tecnología. El modelo señala que esta decisión depende principalmente de dos factores: la utilidad percibida, es decir, hasta qué punto el usuario cree que la tecnología le ayudará a mejorar su rendimiento, y la facilidad de uso percibida, que se refiere a lo sencillo que resulta utilizarla.

En el caso de la Shadow AI, este modelo resulta especialmente relevante. La utilidad percibida de herramientas como ChatGPT o Copilot es previsiblemente alta entre los estudiantes universitarios, dado que estas herramientas permiten generar texto, resolver dudas o mejorar trabajos de forma rápida e intuitiva. A esto se suma que son gratuitas y accesibles desde cualquier dispositivo, lo que reduce prácticamente a cero las barreras tecnológicas para adoptarlas, incluso en contextos donde su uso no está autorizado.

La Unified Theory of Acceptance and Use of Technology (UTAUT)

El modelo UTAUT, desarrollado por Venkatesh et al. (2003), amplía esta explicación incorporando el papel del entorno social. Según este modelo, las personas también adoptan una tecnología en función de lo que perciben que hacen o esperan los demás a su alrededor.

En el contexto universitario, esto se refleja en la influencia de los compañeros. Si un estudiante percibe que otros utilizan herramientas de IA sin consecuencias visibles, es más probable que considere esta práctica como algo normal y decida hacer lo mismo. Este mecanismo de normalización social es especialmente relevante en entornos universitarios, donde los grupos de iguales tienen una influencia intensa sobre las actitudes y comportamientos individuales.

La Theory of Planned Behavior (TPB)

La TPB, desarrollada por Ajzen (1991), describe los comportamientos a partir de tres elementos: la actitud hacia el comportamiento, las normas sociales y el control conductual percibido. Este último se refiere a la percepción que tiene una persona sobre su capacidad para realizar una acción y sobre la existencia de posibles obstáculos.

En el caso de la Shadow AI, esto incluye la percepción de que el uso de IA puede pasar desapercibido o que los sistemas de detección son limitados. Este aspecto está relacionado con el sesgo de *overconfidence*, es decir, la tendencia a pensar que es poco probable ser descubierto. En entornos donde los mecanismos de detección son percibidos como limitados o ineficaces, este sesgo puede reducir el riesgo subjetivo asociado al uso no declarado de IA y facilitar su adopción.

Integración de los modelos

Estos tres modelos no se excluyen entre sí, sino que se complementan. El TAM ayuda a explicar el papel de la utilidad y la facilidad de uso de la tecnología. El UTAUT incorpora la influencia del entorno social. Por último, la TPB añade factores relacionados con las actitudes, las normas y la percepción de control sobre el comportamiento. En conjunto, estos enfoques permiten entender la *Shadow AI* no simplemente como un acto impulsivo, sino como una decisión que muchos estudiantes perciben como lógica, útil y con bajo riesgo.

2.4. Behavioral Economics y sesgos conductuales en el Shadow AI

Los modelos de adopción tecnológica describen el uso de la IA suponiendo que los usuarios toman decisiones de forma racional, evaluando costes y beneficios. Sin embargo, la Economía del Comportamiento ha demostrado que muchas decisiones están influenciadas por sesgos cognitivos que afectan a la forma en que las personas evalúan esas opciones. Estos sesgos ayudan a entender por qué algunos estudiantes utilizan *Shadow AI* incluso cuando saben que su uso no está permitido.

Present bias: preferencia por beneficios inmediatos

Uno de los sesgos más relevantes para comprender la *Shadow AI* es el *present bias* o sesgo de presente. Este concepto, desarrollado por Laibson (1997), describe la tendencia de las personas a priorizar beneficios inmediatos frente a posibles consecuencias futuras. En el ámbito universitario, esto puede ocurrir cuando un estudiante decide usar IA para terminar un trabajo más rápido o reducir el estrés, aunque sepa que no debería hacerlo. El beneficio inmediato pesa más que el riesgo futuro de ser detectado. Desde esta perspectiva, el *present bias* constituye un mecanismo especialmente relevante para comprender por qué algunos estudiantes recurren a la IA de forma no declarada incluso cuando son conscientes de que su uso no está permitido.

Overconfidence: exceso de confianza

Otro sesgo relevante es el *overconfidence* o exceso de confianza. Este sesgo hace que las personas tiendan a sobreestimar sus propias capacidades o a subestimar los riesgos. En el caso de la *Shadow AI*, puede aparecer cuando los estudiantes creen que pueden usar IA sin ser detectados o que podrán justificar su uso si surge algún problema. En entornos donde los mecanismos de detección son percibidos como poco fiables, este sesgo puede reducir considerablemente el riesgo subjetivo asociado al uso no declarado de IA.

Influencia del grupo y reactancia

Además de estos sesgos, también influyen factores sociales. Uno de ellos es el *herding*, que se refiere a la tendencia de las personas a imitar el comportamiento de los demás. En el entorno universitario, si un estudiante percibe que sus compañeros usan IA sin consecuencias, es más probable que considere esa práctica como algo normal. Este mecanismo de normalización puede actuar como catalizador del uso no declarado de IA,

al reducir la sensación de riesgo moral y desplazar la norma implícita del grupo hacia la aceptación de estas prácticas.

Otro mecanismo relevante es la reactancia psicológica, que aparece cuando las personas reaccionan negativamente ante restricciones que consideran excesivas. Si las universidades prohíben el uso de IA de forma estricta sin dar a conocer de manera clara las razones o sin ofrecer alternativas, algunos estudiantes pueden responder utilizando estas herramientas igualmente, como una forma de recuperar su autonomía.

Aplicación al fenómeno de la Shadow AI

En conjunto, estos factores muestran que la *Shadow AI* no suele ser simplemente una decisión deliberada de incumplir las normas. Más bien es el resultado de varios elementos que actúan al mismo tiempo: la presión por cumplir plazos, la percepción de bajo riesgo, la influencia de los compañeros y, en algunos casos, la reacción frente a normas consideradas demasiado restrictivas. Por ello, para abordar este fenómeno no basta con prohibiciones o sanciones. También es necesario diseñar políticas universitarias que tengan en cuenta cómo toman realmente las decisiones los estudiantes y que faciliten un uso más transparente y responsable de la IA.

2.5. Contexto universitario y normativo: ICADE, Cardiff University y otras instituciones

El análisis de la *Shadow AI* también debe tener en cuenta el contexto institucional en el que ocurre. Las políticas universitarias sobre el uso de la inteligencia artificial influyen en cómo los estudiantes perciben y utilizan estas herramientas. En este apartado pretendo describir las políticas de las universidades analizadas en el estudio, especialmente la Universidad Pontificia Comillas (ICADE) y Cardiff University, que representan dos enfoques diferentes. La muestra incluye también estudiantes de otras universidades españolas e internacionales, cuyas políticas sobre IA no se incluyen en este estudio.

La política de ICADE: un enfoque formativo

En la Universidad Pontificia Comillas, la regulación del uso de IA se basa principalmente en dos documentos: la *Guía práctica de aplicación de la IA* elaborada por la Oficina de Apoyo a la Innovación Docente (OAID) en 2024, y la *Declaración de uso de*

herramientas de IA que los estudiantes deben incluir en su Trabajo de Fin de Grado (Universidad Pontificia Comillas, OAID, 2024).

La guía adopta un enfoque abierto pero responsable. Reconoce que la IA puede ser útil para tareas como investigar, escribir o desarrollar ideas, siempre que su uso sea declarado y citado correctamente. En lugar de prohibirla, la universidad busca fomentar un uso crítico y ético de estas herramientas. No obstante, utilizar IA para generar trabajos completos o partes importantes sin citarlo se considera plagio según el Reglamento General de la universidad.

La declaración de uso en el TFG refuerza esta idea de transparencia: el estudiante debe indicar qué herramientas de IA ha utilizado y con qué finalidad. Este sistema busca integrar la IA en el proceso de aprendizaje sin sustituir el trabajo propio del estudiante.

La política de Cardiff University: un enfoque más restrictivo

Cardiff University adopta un enfoque más centrado en la integridad académica y la prevención del fraude. Según el *Academic Regulations and Policies Handbook 2025–26* (Cardiff University, 2025), el uso de IA generativa en trabajos o evaluaciones que deben reflejar el esfuerzo personal del estudiante está sujeto a restricciones estrictas. Si un contenido generado por IA no se declara, puede considerarse plagio o mala conducta académica, con posibles sanciones.

Aun así, la universidad no rechaza completamente el uso de la IA. La *Learning and Teaching Academy* ha desarrollado recursos para ayudar a integrar estas herramientas en la docencia (Cardiff University Learning and Teaching Academy, 2025). En algunos casos se permite su uso, pero normalmente el estudiante debe comunicarlo previamente al profesor o supervisor. En general, Cardiff mantiene una postura más prudente, priorizando el control y la integridad académica.

Otras universidades de la muestra

Además de ICADE y Cardiff, la muestra incluye estudiantes de 88 universidades españolas e internacionales, como la Universidad Politécnica de Madrid, la Universidad Carlos III, la Universidad Autónoma de Madrid, CUNEF, la Universidad de Villanueva, el Politecnico di Milano o la Université de Genève. En muchos de estos casos, los estudiantes indicaron que no existía una política clara sobre el uso de IA o que no la

conocían. Esto muestra que el marco normativo sobre IA en las universidades todavía está en desarrollo y es bastante heterogéneo.

Implicaciones para el estudio de la Shadow AI

Las diferencias entre estos enfoques institucionales pueden influir en cómo los estudiantes utilizan la IA. En el caso de ICADE, la existencia de una guía clara y de un sistema de declaración podría reducir el uso oculto, ya que los estudiantes tienen un marco que permite utilizar estas herramientas de forma transparente. Esto puede favorecer una relación más abierta y responsable con la tecnología.

En cambio, en entornos más restrictivos como Cardiff, donde el enfoque se centra más en la prohibición y las sanciones, algunos estudiantes podrían optar por utilizar la IA de forma más discreta. Este comportamiento puede relacionarse con la *reactancia psicológica* mencionada anteriormente y con la hipótesis H5 de este estudio, que veremos más adelante, la cual plantea posibles diferencias entre instituciones.

Sin embargo, los resultados del estudio muestran un dato interesante: los estudiantes de ICADE presentan una media de uso de Shadow AI ligeramente superior ($M = 3.54$) a la de los estudiantes de Cardiff ($M = 2.96$), y esta diferencia es estadísticamente significativa. Este resultado se analizará con más detalle en el capítulo de discusión, donde se explorarán posibles explicaciones relacionadas con el perfil de la muestra, la cultura académica o el efecto de normalización que puede generar un marco normativo más permisivo.

3. Preguntas e Hipótesis de Investigación

3.1. Factores personales que predicen el uso de Shadow AI

El uso de inteligencia artificial de manera no declarada no puede explicarse únicamente por la disponibilidad tecnológica ni por un acto de rebeldía individual. Como se ha argumentado a lo largo del marco teórico, se trata del resultado de la interacción entre percepciones cognitivas, influencias sociales y sesgos conductuales que actúan simultáneamente sobre la decisión del estudiante. A partir de este marco, se formulan las siguientes hipótesis sobre los factores personales que se asocian al uso de Shadow AI.

Desde la perspectiva del TAM (Davis, 1989), la utilidad percibida es el predictor más robusto de la adopción tecnológica. En el contexto de la IA generativa, los estudiantes que perciben estas herramientas como un medio eficaz para mejorar su rendimiento, ahorrar tiempo o producir trabajos de mayor calidad muestran una mayor tendencia a utilizarlas, incluso en contextos donde su uso no está autorizado. Esta lógica lleva a plantear la primera hipótesis:

H1. La utilidad percibida de la inteligencia artificial generativa se asocia positivamente con el uso de Shadow AI.

El modelo UTAUT (Venkatesh et al., 2003) añade la dimensión social a esta explicación. Las normas subjetivas, es decir, la percepción de que el entorno académico inmediato utiliza IA sin consecuencias visibles, pueden actuar como impulso del comportamiento no declarado, al reducir la sensación de riesgo moral y normalizar la práctica. No obstante, la medición de este constructo presenta limitaciones de fiabilidad interna ($\alpha = .441$) que obligan a interpretar sus resultados con cautela:

H2. La influencia de las normas sociales percibidas se asocia positivamente con el uso no declarado de IA.

Desde la Economía del Comportamiento (Kahneman, 2011; Thaler y Sunstein, 2008), los sesgos conductuales ofrecen una explicación complementaria. El *present bias*, la tendencia a priorizar recompensas inmediatas frente a consecuencias futuras, lleva a los estudiantes a optar por la entrega rápida que facilita la IA. El *overconfidence* hace que subestimen la probabilidad de ser detectados:

H3. Los sesgos conductuales, en particular el *present bias* y el *overconfidence*, se asocian positivamente con el uso de Shadow AI.

La presión académica actúa como un factor contextual que amplifica los mecanismos anteriores. En periodos de alta carga de trabajo y plazos ajustados, los estudiantes pueden considerar la IA como un recurso necesario incluso si ello implica no declarar su uso:

H4. La presión académica percibida se asocia positivamente con el uso de Shadow AI.

3.2. Diferencias esperadas entre perfiles de estudiante

Aunque el foco principal de este estudio son los factores individuales, el contexto institucional y las características sociodemográficas pueden influir en cómo se manifiestan. A diferencia de estudios previos centrados exclusivamente en la

comparación entre dos instituciones, este trabajo amplía el análisis a los 164 participantes de la muestra, incorporando el tipo de universidad (pública o privada) y el género (hombre o mujer) como variables contextuales de interés.

Los estudiantes de universidades privadas pueden estar expuestos a mayores exigencias académicas y a una cultura de rendimiento más intensa, lo que podría asociarse con mayor uso de Shadow AI. Del mismo modo, diferencias en la experiencia con la tecnología o en la presión percibida por el entorno podrían traducirse en patrones distintos según el género:

H5. Existen diferencias en el uso de Shadow AI en función del tipo de universidad (pública vs. privada).

H6. Existen diferencias en el uso de Shadow AI en función del género (hombre vs. mujer).

H7. Se pueden identificar distintos perfiles de estudiantes según su actitud y comportamiento ante el uso no declarado de IA, a partir de variables actitudinales y sociodemográficas.

Es importante señalar que estas hipótesis se plantean en términos de relación entre variables y no de causa-efecto, ya que el estudio tiene un diseño transversal.

Los resultados empíricos del estudio, analizados en el Capítulo 5, permitirán contrastar en qué medida estas predicciones se sostienen y qué matices emergen de los datos.

4. Metodología de Investigación

4.1. Diseño del estudio y muestra

El presente trabajo adopta un diseño cuantitativo, transversal y descriptivo-correlacional, basado en la aplicación de un cuestionario estructurado en formato digital a través de *Google Forms*. El objetivo es analizar los factores personales, conductuales y contextuales que se asocian al uso de Shadow AI entre estudiantes universitarios, así como identificar perfiles tipológicos de usuario mediante análisis de segmentación.

La población objetivo está compuesta por alumnado universitario de grado y máster, con especial representación de la Universidad Pontificia Comillas (ICADE), donde estudié mi doble grado de Derecho y Business Analytics y de Cardiff University, mi destino de ERASMUS durante el primer cuatrimestre del curso 2025-2026, aunque la muestra se

amplía a estudiantes de otras universidades españolas e internacionales. Se empleó un muestreo no probabilístico por conveniencia.

El cuestionario permaneció abierto durante octubre y noviembre de 2025 y fue distribuido a través de WhatsApp, grupos de estudiantes, correo electrónico y redes sociales. Tras aplicar los filtros de calidad descritos en el apartado 4.3, la muestra final válida quedó compuesta por 164 participantes, cantidad adecuada para análisis descriptivos, correlacionales y de regresión múltiple (Hair et al., 2014; Krejcie y Morgan, 1970).

Los criterios de inclusión fueron: ser estudiante universitario de grado o máster, haber utilizado alguna herramienta de IA generativa (ChatGPT, Copilot, Gemini o DeepSeek), y participar de forma voluntaria y anónima. Todos los participantes aceptaron el consentimiento informado antes de comenzar.

En cuanto a la distribución de la muestra, 44 participantes pertenecen a ICADE, 27 a Cardiff University y 93 a otras universidades españolas e internacionales (entre otras la Universidad Politécnica de Madrid, la Universidad Carlos III, la Universidad Autónoma de Madrid, CUNEF, la Universidad de Villanueva, el Politecnico di Milano o la Université de Genève). Por género, el 66,5% son mujeres y el 33,5% hombres. La edad media es de 21,6 años (DT = 1,4)

4.2. Variables y escalas de medición

El cuestionario fue diseñado a partir de instrumentos teóricos y empíricos validados en investigaciones previas sobre adopción tecnológica, comportamiento ético y uso de IA en educación. Se apoya en tres marcos de referencia: los modelos TAM (Davis, 1989) y UTAUT (Venkatesh et al., 2003), de los que se adaptan las dimensiones de utilidad percibida, normas sociales y riesgo percibido; los trabajos de Kahneman (2011) y Laibson (1997) sobre sesgos conductuales; y el informe de la Fundación CYD (2025) sobre uso de IA en el entorno universitario español.

El cuestionario consta de 50 ítems estructurados en bloques temáticos. Los constructos medidos en escala Likert 1–5 son Shadow AI, utilidad percibida, normas sociales y riesgo percibido. Los bloques de presión académica, *present bias* y *overconfidence* emplean una escala 1–7, opción justificada por la mayor sensibilidad que esta escala proporciona para captar variabilidad en constructos psicológicos continuos (Kahneman, 2011; Laibson, 1997). Se fijó un objetivo de α de Cronbach $\geq 0,70$ para cada constructo.

4.2.1. Variable dependiente: uso de Shadow AI

La variable dependiente mide el grado de uso no declarado o no autorizado de herramientas de IA en contextos académicos donde su utilización está restringida o prohibida. Se establece mediante cinco ítems que evalúan: la frecuencia de uso de IA en tareas prohibidas, la entrega de trabajos con IA sin declararlo, la percepción de indetectabilidad, la influencia de normas sociales implícitas y la modificación del texto generado para evitar detectores automáticos. La puntuación es la media de los cinco ítems (escala 1–5). La fiabilidad interna arroja $\alpha = 0,714$, aceptable para un constructo exploratorio de cinco ítems.

4.2.2. Variables independientes

- **Utilidad percibida** (TAM; Davis, 1989): tres ítems, $\alpha = 0,810$.
- **Normas sociales** (UTAUT; Venkatesh et al., 2003): tres ítems, $\alpha = 0,441$ (por debajo del umbral recomendado; interpretar con precaución).
- **Riesgo percibido**: tres ítems, $\alpha = 0,649$.
- **Presión académica**: cuatro ítems en escala 1–7, $\alpha = 0,788$.
- **Present bias** (Laibson, 1997): tres ítems en escala 1–7, $\alpha = 0,781$.
- **Overconfidence** (Kahneman, 2011): tres ítems en escala 1–7, $\alpha = 0,806$.

4.2.3. Variables contextuales

Se incorporan dos variables contextuales derivadas de los datos sociodemográficos:

- **Tipo de universidad**: variable dicotómica (pública / privada), codificada a partir de la universidad declarada por cada participante.
- **Género**: variable categórica (hombre / mujer), utilizada tanto en las comparaciones bivariadas como en la caracterización de los perfiles k-means.

Estas variables permiten analizar si el tipo de institución y el género se asocian con distintos niveles de Shadow AI y con distintos perfiles de usuario, enriqueciendo el análisis más allá de la comparación entre instituciones concretas.

4.3. Procedimiento, ética y plan de análisis

El cuestionario fue administrado en línea mediante *Google Forms*, garantizando el anonimato y el cumplimiento del RGPD (Reglamento 2016/679) y de los principios éticos

de la Declaración de Helsinki (2013)³. Todos los participantes aceptaron un consentimiento informado previo. Se realizó una prueba piloto con un grupo reducido de estudiantes ($n \approx 12$) para verificar la claridad y comprensión de todas las preguntas del cuestionario o si había necesidad de cambiar alguna.

Antes del análisis, se aplicaron dos filtros de calidad: eliminación de las respuestas que no superaron la pregunta de control de atención (marcar el número 3 en una escala) y eliminación de respuestas duplicadas. Tras esta depuración, la muestra quedó compuesta por los 164 casos válidos.

El procesamiento de los datos se realizó con Python. El plan de análisis comprende las siguientes etapas:

1. **Análisis descriptivo:** frecuencias, medias y desviaciones típicas para cada constructo e ítem.
2. **Fiabilidad interna:** coeficiente α de Cronbach para cada escala.
3. **Correlaciones bivariadas** (Pearson) entre la variable dependiente y cada predictor.
4. **Regresión lineal múltiple:** modelo OLS con los seis constructos como predictores de Shadow AI.
5. **Comparaciones por subgrupos:** prueba U de Mann-Whitney para género y tipo de universidad; Kruskal-Wallis para grupo de institución (ICADE / Cardiff / Otras).
6. **Segmentación k-means:** análisis de conglomerados sobre los siete constructos estandarizados (Z-scores), con selección de k óptimo mediante coeficiente de silueta. Los perfiles resultantes se caracterizan mediante variables actitudinales y sociodemográficas (género, tipo de universidad, grupo institucional, curso y GPA).

5. Resultados

5.1. Descripción de la muestra

³ Declaración de Helsinki (Asociación Médica Mundial, 2013): conjunto de principios éticos internacionales para la investigación con seres humanos, que establece criterios como la participación voluntaria, el consentimiento informado previo, la confidencialidad de los datos y la protección de los participantes frente a posibles daños.

La muestra final válida está compuesta por 164 estudiantes universitarios. El 66,5% son mujeres y el 33,5% hombres. La edad media es de 21,6 años (DT = 1,4), con un rango de 18 a 26 años. El 27,4% cursa 5.º curso y el 26,2% está en 4.º, representando conjuntamente más de la mitad de la muestra. El 11,6% son estudiantes de máster. La nota media autodeclarada es de 7,44 sobre 10 (DT = 1,05).

En cuanto a la distribución institucional, 44 participantes (26,8%) pertenecen a ICADE, 27 (16,5%) a Cardiff University y 93 (56,7%) a otras universidades. Por tipo de institución, 121 pertenecen a universidades privadas (73,8%) y 43 a públicas (26,2%). La totalidad de los participantes declaró haber utilizado alguna vez herramientas de IA generativa, requisito de inclusión explícito del cuestionario.

Tabla 1. Descripción de la muestra (N = 164)

Variable	Categoría	n	%
Género	Mujer	109	66,5%
	Hombre	55	33,5%
Tipo universidad	Privada	121	73,8%
	Pública	43	26,2%
Institución	ICADE	44	26,8%
	Cardiff	27	16,5%
	Otras	93	56,7%
Edad media	21,6 años	DT = 1,4	
Nota media (GPA)	7,44 / 10	DT = 1,05	

Fuente: Elaboración propia.

5.2. Prevalencia y patrones de uso de Shadow AI

Los resultados revelan una prevalencia elevada y generalizada del uso de Shadow AI entre los estudiantes universitarios de la muestra. La media global del índice es de 3,41 sobre 5 (DT = 0,90), lo que sitúa el uso no declarado de IA claramente por encima del punto medio de la escala.

El comportamiento más extendido es la modificación del texto generado por IA para evitar detectores automáticos, con una media de 4,20 sobre 5 y un 77% de participantes que puntúa 4 o 5. Este dato refleja no solo el uso no declarado de la IA, sino una conducta activamente estratégica orientada a evitar los mecanismos de control institucional. En

segundo lugar, el 59% declara haber entregado trabajos redactados parcialmente con IA sin informar de ello, y el 51% reconoce haber usado IA en tareas expresamente prohibidas. Los comportamientos menos frecuentes son la justificación social del uso no declarado (34%) y la percepción de indetectabilidad (40%).

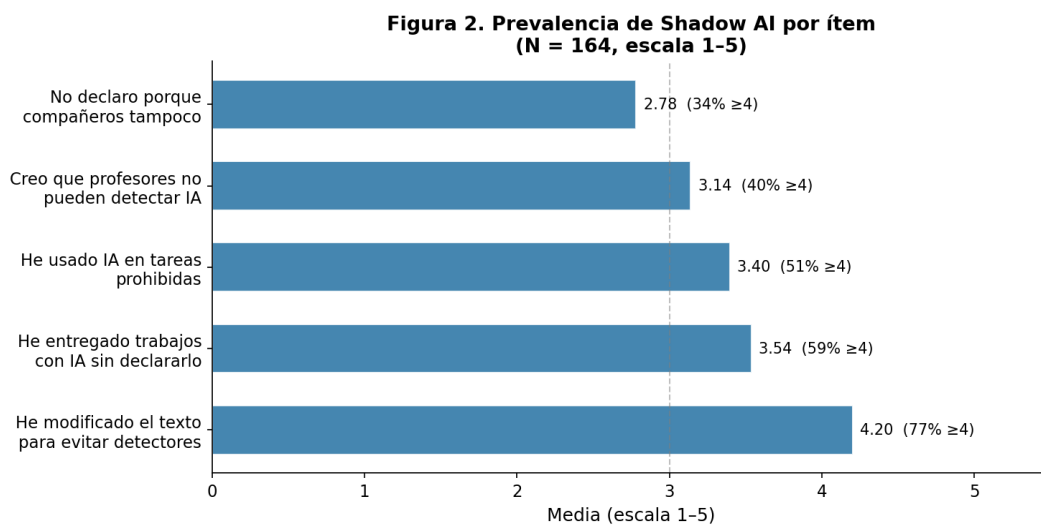
En cuanto a las finalidades de uso, la generación de ideas o esquemas es la función más utilizada (73%), seguida de la redacción de textos académicos (69%) y la mejora gramatical o de estilo (65%). La preparación de exámenes (60%), la traducción (48%), la programación o análisis de datos (43%) y la creación de presentaciones e imágenes (40%) completan el panorama.

Tabla 2. Prevalencia de Shadow AI por ítem (N = 164, escala 1-5)

Ítem	Media	≥ 4 (%)	Posición
He modificado el texto para evitar detectores	4,20	77%	1. ^a
He entregado trabajos con IA sin declararlo	3,54	59%	2. ^a
He usado IA en tareas donde estaba prohibido	3,40	51%	3. ^a
Creo que los profesores no pueden detectar el uso de IA	3,14	40%	4. ^a
No declaro el uso porque mis compañeros tampoco lo hacen	2,78	34%	5. ^a

Fuente: Elaboración propia.

Figura 2. Prevalencia de Shadow AI por ítem (N = 164)



Fuente: Elaboración propia.

5.3. Fiabilidad de las escalas y estadísticos descriptivos

La mayoría de las escalas superan el umbral de $\alpha \geq 0,70$. Los constructos de utilidad percibida ($\alpha = 0,810$), *overconfidence* ($\alpha = 0,806$), presión académica ($\alpha = 0,788$) y *present bias* ($\alpha = 0,781$) presentan buena fiabilidad. La variable dependiente Shadow AI obtiene $\alpha = 0,714$, aceptable para un constructo exploratorio. El riesgo percibido ($\alpha = 0,649$) se sitúa en el límite inferior del rango aceptable. Las normas sociales ($\alpha = 0,441$) están por debajo del umbral recomendado, lo que obliga a interpretar sus resultados con precaución.

En cuanto a los estadísticos descriptivos, destaca la elevada media de utilidad percibida ($M = 4,21$ sobre 5), lo que confirma que prácticamente la totalidad de los participantes valora positivamente la IA como herramienta académica. La presión académica obtiene la media relativa más alta ($M = 5,29$ sobre 7). El *overconfidence* ($M = 4,46$) y el *present bias* ($M = 4,21$), ambos sobre 7, se sitúan por encima del punto medio de sus escalas.

Tabla 3. Fiabilidad y estadísticos descriptivos (N = 164)

Constructo	Ítems	Escala	α	M	DT	Rango
Shadow AI (VD)	5	1–5	.714	3,41	0,90	1,0–5,0
Utilidad percibida	3	1–5	.810	4,21	0,81	1,0–5,0
Normas sociales	3	1–5	.441	3,37	0,79	1,3–5,0
Riesgo percibido	3	1–5	.649	3,39	0,97	1,0–5,0
Presión académica	4	1–7	.788	5,29	1,24	1,2–7,0
<i>Present bias</i>	3	1–7	.781	4,21	1,40	1,0–7,0
<i>Overconfidence</i>	3	1–7	.806	4,46	1,40	1,0–7,0

Fuente: Elaboración propia.

5.4. Contraste de hipótesis: factores asociados al uso de Shadow AI

5.4.1. Análisis correlacional

El análisis de correlaciones bivariadas muestra que todos los predictores presentan correlaciones positivas y estadísticamente significativas con Shadow AI. El predictor con mayor correlación es el *present bias* ($r = +0,476$, $p < 0,001$), seguido de la utilidad percibida ($r = +0,286$, $p < 0,001$) y la presión académica ($r = +0,266$, $p < 0,001$). El *overconfidence* ($r = +0,250$, $p = 0,001$) y el riesgo percibido ($r = +0,203$, $p = 0,009$)

muestran correlaciones significativas de menor intensidad. Las normas sociales presentan la correlación más débil ($r = +0,170$, $p = 0,029$), aunque su baja fiabilidad interna obliga a interpretar este resultado con precaución.

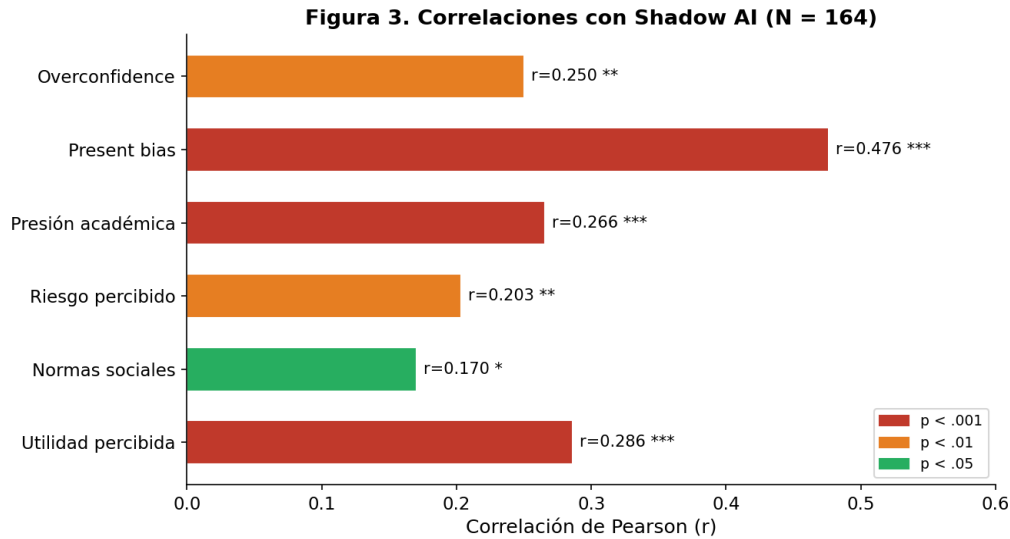
Tabla 4. Correlaciones de Pearson con Shadow AI (N = 164)

Variable	r	p	Sig.
<i>Present bias</i>	+0.476	< .001	***
Utilidad percibida	+0.286	< .001	***
Presión académica	+0.266	< .001	***
<i>Overconfidence</i>	+0.250	.001	**
Riesgo percibido	+0.203	.009	**
Normas sociales	+0.170	.029	*

*** $p < .001$; ** $p < .01$; * $p < .05$.

Fuente: Elaboración propia.

Figura 3. Correlaciones de Pearson con Shadow AI (N = 164)



Fuente: Elaboración propia.

5.4.2. Contraste de hipótesis

H2 recibe apoyo preliminar ($r = +0,170$, $p = 0,029$), aunque la baja fiabilidad del constructo de normas sociales ($\alpha = 0,441$) limita la robustez de esta evidencia. H3 se confirma para ambos sesgos: *present bias* ($r = +0,476$, $p < 0,001$) y *overconfidence* ($r = +0,250$, $p = 0,001$). H4 también se confirma ($r = +0,266$, $p < 0,001$). Todos estos

resultados son correlacionales: el diseño transversal no permite establecer relaciones causales.

5.4.3. Modelo de regresión lineal múltiple

Para evaluar la contribución independiente de cada predictor una vez controlado el efecto del resto, se estimó un modelo de regresión lineal múltiple mediante OLS. El modelo explica el 29,1% de la varianza en Shadow AI ($R^2 = 0,291$, $R^2_{adj} = 0,259$, $N = 164$). El predictor con mayor peso es el *present bias* ($\beta = 0,242$, $p < 0,001$), seguido de la utilidad percibida ($\beta = 0,178$, $p = 0,037$) y el riesgo percibido ($\beta = 0,155$, $p = 0,016$). Normas sociales, presión académica y *overconfidence* pierden peso explicativo al controlar el efecto del resto, lo que sugiere que su relación con Shadow AI está parcialmente mediada por otros constructos.

Cabe insistir en que los coeficientes β reflejan asociaciones parciales, no efectos causales. El presente bias puede estar correlacionado con otras variables no medidas que expliquen parte de la varianza compartida.

Tabla 5. Modelo de regresión múltiple (N = 164)


Variable	β	SE	t	p	Sig.
Intercepto	0,670	0,458	1,464	.145	n.s.
Utilidad percibida	0,178	0,085	2,101	.037	*
Normas sociales	0,041	0,082	0,501	.617	n.s.
Riesgo percibido	0,155	0,064	2,437	.016	*
Presión académica	0,016	0,055	0,282	.779	n.s.
<i>Present bias</i>	0,242	0,049	4,898	< .001	***
<i>Overconfidence</i>	0,050	0,048	1,056	.293	n.s.

$R^2 = 0,291$; $R^2_{adj} = 0,259$. *** $p < .001$; * $p < .05$; n.s. = no significativo.

Fuente: Elaboración propia.

Figura 4. Coeficientes de regresión múltiple sobre Shadow AI

Figura 4. Regresión múltiple sobre Shadow AI
($R^2 = 0.291$, $R^2_{adj} = 0.259$, $N = 164$)



Las barras de error representan IC al 95%.

Fuente: Elaboración propia.

5.5. Diferencias por género y tipo de universidad

Para contrastar H5 y H6, se compararon los niveles de Shadow AI en función del tipo de universidad y del género mediante la prueba U de Mann-Whitney ($N = 164$).

En cuanto al tipo de universidad, los estudiantes de universidades privadas presentan una media de Shadow AI ligeramente superior a la de los de universidades públicas ($M = 3,53$ vs. $M = 3,28$), si bien la diferencia no alcanza significatividad estadística convencional ($p = 0,058$). Este resultado no permite confirmar H5.

En cuanto al género, no se observan diferencias estadísticamente significativas entre hombres ($M = 3,27$) y mujeres ($M = 3,48$) en el uso de Shadow AI ($p = 0,120$), por lo que H6 no se confirma. Sin embargo, como se verá en el apartado de perfiles, el género sí aparece como variable diferenciadora dentro de los clústeres, lo que sugiere que su influencia opera de forma indirecta, mediada por otros factores actitudinales.

Respecto al grupo institucional, la comparación entre ICADE ($M = 3,41$), Cardiff ($M = 2,96$) y otras universidades ($M = 3,54$) arroja diferencias estadísticamente significativas (Kruskal-Wallis $H = 9,18$, $p = 0,010$). Destaca que el grupo "Otras universidades", compuesto mayoritariamente por instituciones españolas de diversa naturaleza, presenta el mayor nivel de Shadow AI, lo que amplía el foco de análisis más allá del contraste ICADE-Cardiff.

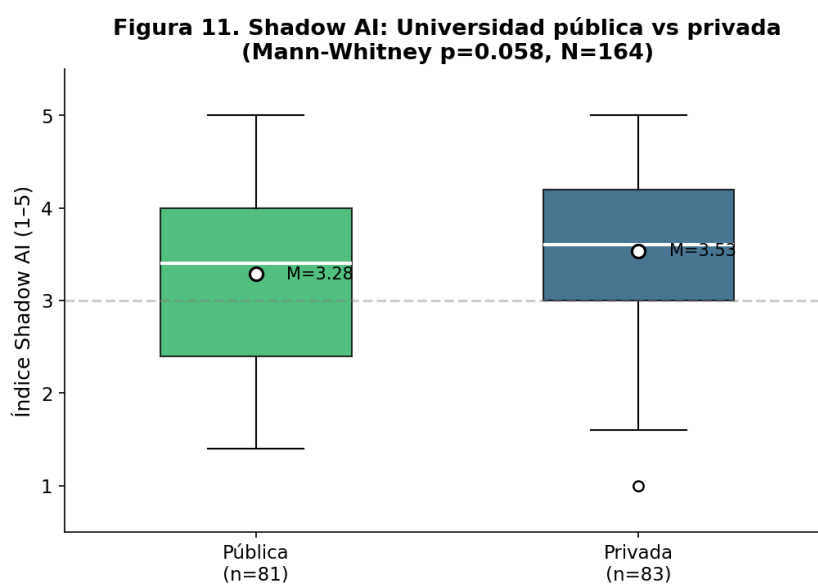
Tabla 6. Comparaciones de Shadow AI por subgrupos (N = 164)

Variable	Grupo	M	DT	n	p
Tipo universidad	Privada	3,53	0,85	121	0,058†
	Pública	3,28	0,93	43	
Género	Mujer	3,48	0,89	109	0,120 n.s.
	Hombre	3,27	0,90	55	
Institución	Otras	3,54	0,87	93	0,010 ** (KW)
	ICADE	3,41	0,91	44	
	Cardiff	2,96	0,85	27	

† Tendencia marginal ($p = .058$). ** $p < .01$ (Kruskal-Wallis para grupo institución).

Fuente: Elaboración propia.

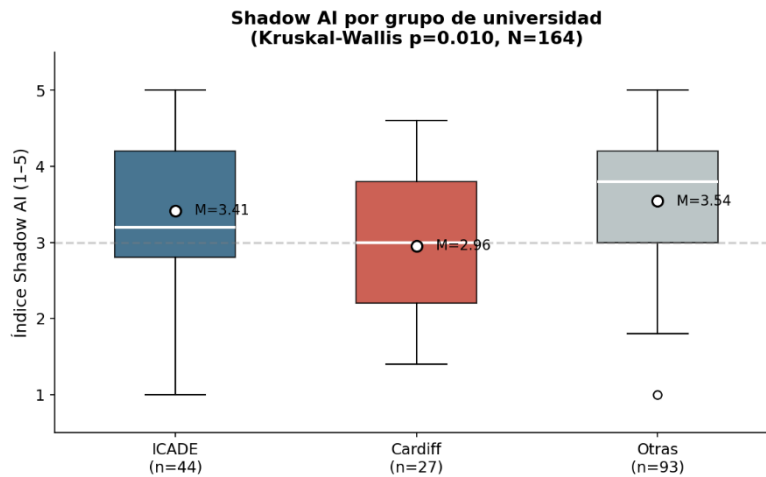
Figura 5. Shadow AI: universidad pública vs. privada (N = 164)



Puntos blancos = media. Mann-Whitney $p = 0,255$.

Fuente: Elaboración propia.

Figura 6. Shadow AI: ICADE vs. Cardiff vs. Otras



Fuente: Elaboración propia.

5.6. Perfiles de usuario: Segmentación K-means

Con el objetivo de identificar tipologías de estudiantes en función de sus actitudes y comportamientos ante la Shadow AI, se realizó un análisis de segmentación k-means sobre los siete constructos del estudio (*shadow_ai*, utilidad percibida, normas sociales, riesgo percibido, presión académica, *present bias* y *overconfidence*). Las variables fueron estandarizadas previamente (Z-scores) para eliminar el efecto de las diferencias de escala. La selección del número óptimo de clústeres se realizó mediante el coeficiente de silueta, que resultó máximo para $k = 2$ (silueta = 0,198). Sin embargo, se optó por $k = 3$ por su mayor riqueza tipológica: permite identificar un perfil intermedio con características actitudinales propias que $k = 2$ no distingue, y que resulta especialmente relevante para el análisis sociodemográfico. Es importante señalar que los coeficientes de silueta son moderados en todos los valores de k , lo que es esperable en datos de encuesta con constructos correlacionados: los perfiles deben interpretarse como tendencias descriptivas, no como categorías mutuamente excluyentes.

Los tres perfiles identificados son los siguientes:

Perfil 1: "Tramposos" (n = 72, 43,9%). Es el grupo con mayor uso de Shadow AI ($M = 4,10$ sobre 5). Sus rasgos actitudinales más definatorios son el *present bias* muy elevado ($M = 5,27$ sobre 7), la alta utilidad percibida ($M = 4,60$ sobre 5) y el alto *overconfidence* ($M = 5,12$ sobre 7). También registran la mayor presión académica ($M = 5,86$ sobre 7). En comportamientos concretos, presentan medias de 4,26 en uso de IA en tareas prohibidas, 4,38 en entregar trabajos sin declararlo y 4,74 en modificar el texto generado para evitar detectores. Desde el punto de vista sociodemográfico, este perfil está

compuesto en un 72,2% por mujeres, el 58,3% procede de universidades privadas y el 27,8% pertenece a ICADE. El curso medio es el 4.º y el GPA medio es de 7,41.

Perfil 2: "Intermedios" (n = 57, 34,8%). Presenta un nivel de Shadow AI bajo (M = 2,91), similar al de los Cautelosos, pero con una diferencia actitudinal clave: su *overconfidence* es llamativamente alto (M = 4,39 sobre 7) pese a un *present bias* muy bajo (M = 3,32). Esto sugiere que estos estudiantes perciben que podrían usar la IA sin ser detectados, pero no sienten el impulso inmediato de hacerlo. Su utilidad percibida es alta (M = 4,39), comparable a la de los Tramposos. Es el perfil más masculino de los tres: el 52,6% son hombres, frente al 27,8% en los Tramposos y el 14,3% en los Cautelosos. El 56,1% procede de universidades públicas y el 19,3% pertenece a Cardiff, la mayor proporción institucional de este grupo.

Perfil 3: "Cautelosos" (n = 35, 21,3%). Es el grupo con el Shadow AI más bajo (M = 2,82), y se caracteriza por puntuaciones bajas en todos los constructos: baja utilidad percibida (M = 3,10), bajo *present bias* (M = 3,48), bajo *overconfidence* (M = 3,23) y la mayor preocupación por el riesgo percibido (M = 3,67), la más alta de los tres perfiles. Es el perfil con mayor proporción de mujeres (85,7%) y con mayor representación de Cardiff (28,6%), lo que es coherente con el entorno normativo más restrictivo de esa institución. El 54,3% procede de universidades públicas.

Un resultado especialmente relevante es que el GPA medio es prácticamente idéntico en los tres perfiles (7,41 en Tramposos, 7,50 en Intermedios, 7,41 en Cautelosos), lo que confirma que el uso de Shadow AI no se traduce en mejores notas. Este hallazgo matiza la hipótesis implícita de que los estudiantes recurren a la IA principalmente para mejorar sus calificaciones, apuntando más bien a motivaciones de reducción del esfuerzo y gestión del tiempo, coherentes con el *present bias* como variable más asociada.

Las diferencias entre los tres perfiles son estadísticamente significativas en todos los constructos (Kruskal-Wallis, todos $p < 0,001$), lo que respalda la validez de la segmentación.

Tabla 7. Medias de constructos y perfil sociodemográfico por clúster (N = 164)

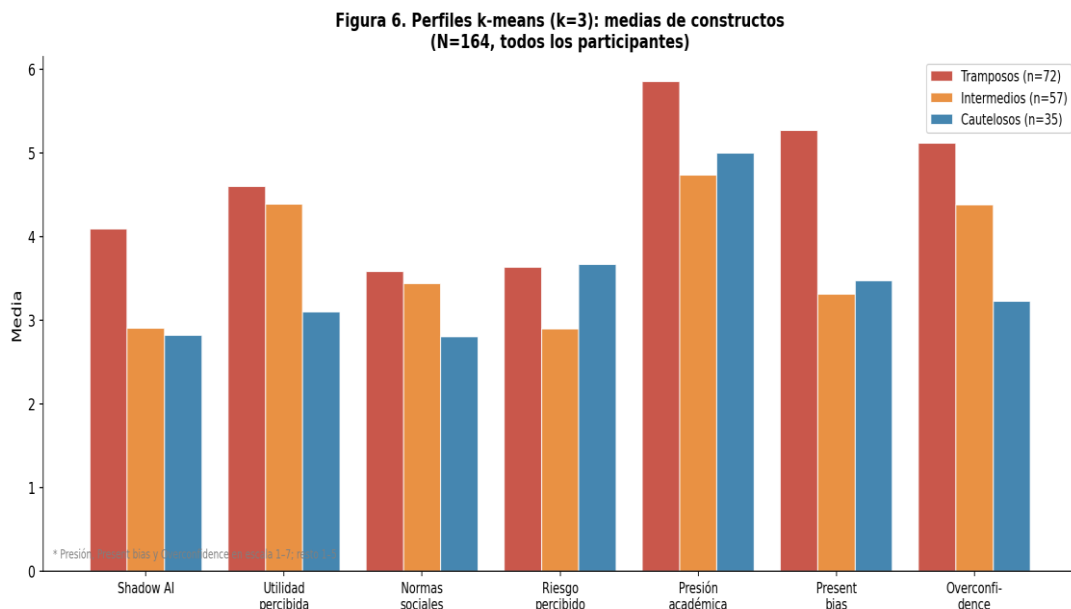
	Tramposos (n=72)	Intermedios (n=57)	Cautelosos (n=35)
Shadow AI	4,10	2,91	2,82
Utilidad percibida	4,60	4,39	3,10
Normas sociales	3,59	3,44	2,81

Riesgo percibido	3,63	2,90	3,67
Presión académica	5,86	4,74	5,00
<i>Present bias</i>	5,27	3,32	3,48
<i>Overconfidence</i>	5,12	4,39	3,23
% Mujeres	72,2%	47,4%	85,7%
% Hombres	27,8%	52,6%	14,3%
% Privada	58,3%	43,9%	45,7%
% Pública	41,7%	56,1%	54,3%
% Cardiff	8,3%	19,3%	28,6%
% ICADE	27,8%	22,8%	31,4%
GPA medio	7,41	7,50	7,41
Curso medio	4,2	4,4	4,0

Kruskal-Wallis significativo ($p < .001$) para todos los constructos.

Fuente: Elaboración propia.

Figura 6. Perfiles k-means (k=3): medias de constructos por perfil

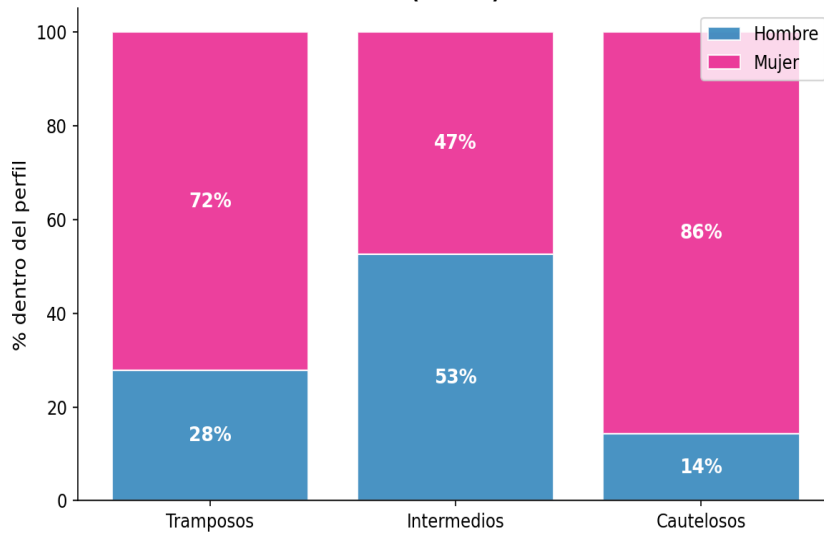


** Presión académica, Present bias y Overconfidence en escala 1-7; resto 1-5.*

Fuente: Elaboración propia.

Figura 7. Composición por género en cada perfil

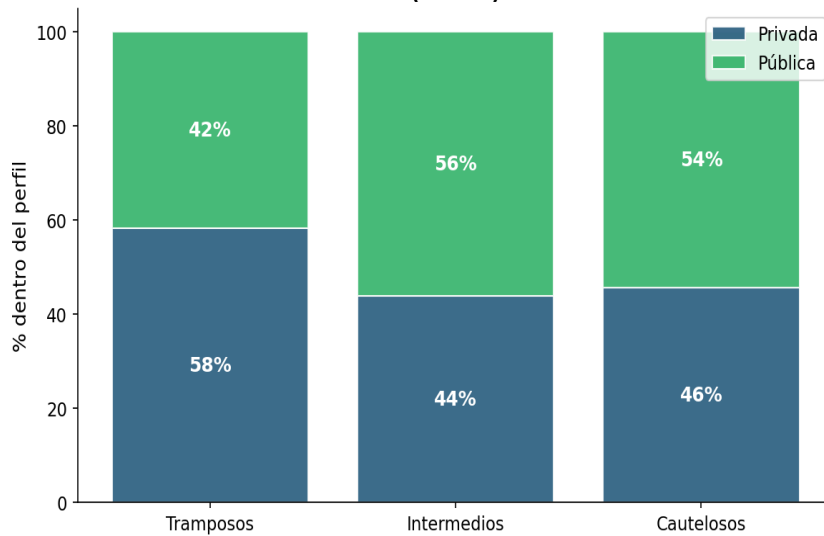
Figura 7. Composición por género en cada perfil (N=164)



Fuente: Elaboración propia.

Figura 8. Tipo de universidad en cada perfil


Figura 8. Tipo de universidad en cada perfil (N=164)



Fuente: Elaboración propia.

Figura 9. Comportamientos de Shadow AI por perfil

Figura 9. Comportamientos de Shadow AI por perfil (N=164)



Fuente: Elaboración propia.

6. Discusión

6.1. Interpretación de los resultados y conexión con el marco teórico

Los resultados ofrecen una imagen estadísticamente consistente del fenómeno de la Shadow AI en el contexto universitario. La media global de 3,41 sobre 5, junto con el hecho de que el 77% de los participantes haya modificado texto generado por IA para evitar detectores y el 59% haya entregado trabajos sin declarar el uso de estas herramientas, confirman que nos encontramos ante una práctica extendida y normalizada, y no ante un comportamiento marginal. Estos datos son coherentes con la literatura sobre Shadow IT en entornos empresariales (IBM, 2024) y sugieren que la dinámica que se produce en las organizaciones se replica con similar intensidad en el ámbito educativo.

El hallazgo más robusto del estudio es la elevada correlación del *present bias* con Shadow AI ($r = +0,476$, $p < 0,001$), que se mantiene como el predictor de mayor peso en el modelo de regresión ($\beta = 0,242$, $p < 0,001$). Esto es coherente con el marco de la Economía del Comportamiento (Kahneman, 2011; Thaler y Sunstein, 2008): los datos sugieren que los estudiantes tienden a priorizar el beneficio inmediato, ahorro de tiempo, reducción del estrés, entrega a tiempo, frente a consecuencias futuras percibidas como remotas. No obstante, dado que los datos se recogieron en un único momento temporal, no es posible establecer la dirección de esta relación: aunque lo más intuitivo es pensar que el *present*

bias se asocia con el uso de Shadow AI, también podría ocurrir que los estudiantes que más la usan desarrollen con el tiempo una mayor preferencia por los resultados inmediatos. La utilidad percibida también se asocia positivamente con Shadow AI ($r = +0,286$, $p < 0,001$), en línea con el TAM (Davis, 1989). Que prácticamente todos los participantes perciban la IA como muy útil ($M = 4,21$) y que esta percepción se asocie con mayor uso, incluso no autorizado, sugiere que la percepción de utilidad se asocia con un mayor uso de la IA incluso cuando su empleo no está autorizado, con independencia de las restricciones institucionales vigentes. Es posible, no obstante, que la causalidad sea inversa: los estudiantes que más usan la IA, incluidos usos no declarados, tiendan a valorarla más por su mayor experiencia con ella.

El *overconfidence* pierde relevancia en la regresión múltiple ($\beta = 0,050$, n.s.) a pesar de correlacionar significativamente a nivel bivariado ($r = +0,250$). Esto sugiere que su efecto puede estar parcialmente absorbido por el *present bias* y la utilidad percibida. La presión académica, por su parte, confirma H4 a nivel bivariado ($r = +0,266$) pero pierde peso en el modelo múltiple ($\beta = 0,016$), lo que apunta a que su influencia opera de forma indirecta, a través de su interacción con el *present bias*.

6.2. Perfiles de usuario y su significado

La segmentación k-means aporta una perspectiva complementaria y especialmente valiosa para la interpretación. Los tres perfiles identificados, "Tramposos", "Intermedios" y "Cautelosos", no son solo grupos con distinto nivel de Shadow AI, sino que revelan combinaciones actitudinales y sociodemográficas con coherencia interna.

El perfil "Tramposos" es el más numeroso (43,9%) y el que concentra las puntuaciones más altas en *present bias*, *overconfidence* y utilidad percibida simultáneamente. Es también el que mayor presión académica declara, lo que es coherente con la hipótesis de que los periodos de alta exigencia constituyen el contexto más propicio para el uso no declarado. Resulta llamativo que este perfil esté compuesto mayoritariamente por mujeres (72,2%) y tenga una concentración importante en universidades privadas (58,3%). Este resultado contraintuitivo, dado que la diferencia global en Shadow AI entre géneros no es significativa ($p = 0,120$), sugiere que el género actúa como variable moderadora dentro de ciertos perfiles actitudinales, y no como predictor directo.

El perfil "Intermedios" es el más masculino (52,6% hombres) y el más concentrado en universidades públicas (56,1%). Su rasgo más singular es la combinación de

overconfidence alto con *present bias* bajo: saben que podrían usar la IA sin ser detectados, pero no sienten la urgencia inmediata de hacerlo. Esto podría interpretarse, con la cautela que impone el diseño correlacional, como una actitud de "poder pero no querer": tienen la percepción de control pero no el impulso situacional. También tienen el GPA más alto de los tres perfiles (7,50), aunque la diferencia es mínima.

El perfil "Cautelosos" es el más femenino (85,7%), el que mayor riesgo percibido declara ($M = 3,67$) y el que mayor proporción de estudiantes de Cardiff concentra (28,6%). Este último dato es coherente con el entorno normativo más restrictivo de Cardiff, donde las políticas enfatizan las consecuencias del uso no declarado, lo que puede traducirse en una mayor sensibilización ante el riesgo.

Cabe señalar que, dado que la muestra presenta una proporción mayor de mujeres (66,5%), la sobrerrepresentación femenina en el perfil Tramposos debe interpretarse con cautela. Más relevante resulta, en cambio, la concentración masculina en el perfil Intermedios (52,6%), que supera notablemente el peso de los hombres en la muestra total.

6.3. Diferencias por tipo de universidad y grupo institucional

Los resultados por tipo de universidad no respaldan la dirección esperada: los estudiantes de universidades privadas presentan un uso de Shadow AI ligeramente mayor ($M = 3,53$) que los de públicas ($M = 3,28$), si bien la diferencia no alcanza significatividad estadística convencional ($p = 0,058$). Este resultado no permite atribuir el uso de Shadow AI a la mayor presión por el rendimiento de ciertos entornos privados, y el tamaño de la muestra limita la potencia estadística para detectar diferencias entre grupos.

La comparación entre grupos institucionales arroja un resultado que amplía el análisis más allá del contraste ICADE-Cardiff: las "Otras universidades", mayoritariamente españolas, públicas y privadas, presentan el mayor nivel de Shadow AI ($M = 3,54$), por encima de ICADE ($M = 3,41$) y de Cardiff ($M = 2,96$). Esto sugiere que el fenómeno no es exclusivo de ninguna institución concreta y que las diferencias observadas entre ICADE y Cardiff en estudios anteriores pueden estar influidas por el perfil de los estudiantes y el contexto cultural, más que por el marco normativo institucional en sí mismo.

En todo caso, la relación entre tipo de institución y Shadow AI no es lineal ni concluyente con esta muestra, y futuras investigaciones con diseños más equilibrados permitirán dilucidar con mayor precisión los mecanismos subyacentes.

6.4. Implicaciones para políticas universitarias

Los resultados tienen implicaciones prácticas para diseñar políticas universitarias. Sin embargo, como el estudio es correlacional, deben interpretarse como orientaciones iniciales y no como conclusiones definitivas.

La primera implicación es que las estrategias basadas solo en prohibiciones o en amenazas de sanción probablemente no son suficientes. Si el *present bias* está relacionado con el uso de Shadow AI, las normas formales por sí solas no cambian esa decisión. Diseñar sistemas de evaluación con entregas parciales y plazos repartidos podría ayudar a reducir la presión en los momentos de mayor carga académica.

La segunda es la necesidad de invertir en formación ética y práctica sobre el uso de la IA. Actualmente, solo el 34% del estudiantado universitario español ha recibido formación en este ámbito (Fundación CYD, 2025). Esta falta de formación puede aumentar el riesgo de un uso inadecuado.

La tercera es crear normas claras, realistas y coherentes con los objetivos educativos. Cuando las reglas no están bien definidas, los estudiantes pueden sentirse confundidos o reaccionar negativamente. Las políticas que combinan guías prácticas con declaraciones de uso, como la de ICADE, van en la dirección adecuada, aunque también es importante promover una cultura académica que valore la transparencia.

La cuarta es aprovechar la influencia de las normas sociales de forma positiva. Mostrar que los estudiantes que declaran el uso de IA también obtienen buenos resultados puede ayudar a normalizar la transparencia. El hecho de que el GPA sea similar en los tres perfiles apoya esta idea.

6.5. Contribución del estudio

Este trabajo realiza varias aportaciones al debate académico. En primer lugar, analiza la Shadow AI específicamente en el contexto universitario con una muestra amplia y diversa (N = 164, múltiples universidades españolas e internacionales). En segundo lugar, integra modelos de adopción tecnológica con sesgos conductuales de la Economía del Comportamiento, identificando el *present bias* como el constructo con mayor asociación observada. En tercer lugar, introduce el análisis k-means para construir tipologías de estudiantes, "Tramosos", "Intermedios" y "Cautelosos", caracterizadas tanto actitudinalmente como sociodemográficamente, lo que supera el enfoque de comparación

entre dos instituciones y permite una lectura más profunda del fenómeno. Finalmente, la inclusión de variables como el tipo de universidad (pública/privada) y el género como ejes de análisis amplía el alcance explicativo del estudio.

6.6. Limitaciones y futuras líneas de investigación

Este estudio presenta varias limitaciones que deben tenerse en cuenta al interpretar sus resultados. En primer lugar, al tratarse de un muestreo no probabilístico por conveniencia, la muestra no es representativa del conjunto del estudiantado universitario: está sesgada hacia perfiles de últimos cursos de grado, con predominio de universidades privadas y de entornos cercanos. En segundo lugar, el diseño transversal impide establecer relaciones causales entre los predictores y el uso de Shadow AI. En tercer lugar, el autoinforme está sujeto a sesgo de deseabilidad social: los participantes pueden haber subestimado su uso real de IA no declarada. En cuarto lugar, la baja fiabilidad del constructo de normas sociales ($\alpha = 0,441$) limita las conclusiones sobre el papel de la influencia social. Por último, la distribución desigual entre subgrupos (44 de ICADE, 27 de Cardiff, 93 de otras) reduce la potencia estadística de las comparaciones institucionales.

Como líneas futuras, sería valioso replicar el estudio con muestras más amplias y representativas, incorporar métodos cualitativos como entrevistas o grupos focales, y diseñar estudios longitudinales que permitan observar cómo evoluciona el fenómeno a lo largo del tiempo.

7. Conclusiones

7.1. Síntesis del fenómeno y hallazgos principales

Este trabajo ha explorado el fenómeno de la Shadow AI en el contexto universitario a partir de una encuesta a 164 estudiantes de España y Reino Unido. Los resultados deben leerse como tendencias exploratorias, no como conclusiones generalizables, dado el tamaño y la naturaleza no probabilística de la muestra.

Los datos apuntan a que el uso no declarado de IA es una práctica extendida: media de Shadow AI de 3,41 sobre 5, con un 77% que ha modificado texto generado por IA para evitar detectores y un 59% que ha entregado trabajos sin declararlo.

El factor más asociado al uso de Shadow AI es el *present bias* ($r=+0,476$, $\beta=0,242$, $p<0,001$): los estudiantes que priorizan el beneficio inmediato tienden a usar más la IA de forma no declarada. La utilidad percibida y la presión académica también se asocian positivamente, aunque esta última pierde peso cuando se controlan los demás factores.

La segmentación k-means identifica tres perfiles. Los Tramposos (44%) son mayoritariamente mujeres de universidades privadas con alto *present bias* y alta presión académica. Los Intermedios (35%) son el perfil más masculino y público, con *overconfidence* alto pero sin el impulso inmediato de actuar. Los Cautelosos (21%) son el perfil más femenino, más sensible al riesgo y con mayor presencia de Cardiff. El GPA es prácticamente idéntico en los tres perfiles (7,41–7,50), lo que sugiere que en esta muestra no se observan diferencias apreciables de GPA entre perfiles.

Las diferencias por tipo de universidad son sugerentes pero no concluyentes: privadas $M=3,53$ vs públicas $M=3,28$ ($p=0,058$). Las diferencias por género tampoco son significativas a nivel global ($p=0,120$), aunque el género sí diferencia los perfiles internamente.

7.2. Recomendaciones prácticas para las universidades

A partir de las tendencias observadas en esta muestra, y con la advertencia explícita de que no se trata de recomendaciones con base causal probada sino de orientaciones exploratorias inspiradas en los datos y en el marco teórico revisado, me permito sugerir las siguientes líneas de actuación para las instituciones universitarias.

Primera sugerencia: repensar los sistemas de evaluación para reducir la presión situacional. Si la asociación entre *present bias* y Shadow AI observada en estos datos tiene alguna implicación práctica, sería que las políticas que actúan exclusivamente sobre las consecuencias (prohibiciones, sanciones) pueden ser insuficientes, porque no modifican el contexto situacional en el que se toma la decisión. Distribuir las entregas a lo largo del curso, introducir rúbricas de proceso o reducir el peso de entregas puntuales de alta exigencia son medidas que, desde la lógica de la arquitectura de decisiones (Thaler y Sunstein, 2008), podrían reducir el contexto en el que el *present bias* se activa con más fuerza. No obstante, esta sugerencia se basa en razonamiento teórico más que en evidencia causal directa de este estudio.

Segunda sugerencia: cerrar la brecha formativa sobre el uso de IA. Solo el 34% del estudiantado universitario español ha recibido formación sobre IA por parte de su institución (Fundación CYD, 2025), a pesar de que el 89% la utiliza. Esta desproporción es en sí misma un dato relevante: parece razonable pensar que cuando los estudiantes no disponen de criterios claros para usar la IA de forma ética, es más probable que la usen de cualquier manera disponible, incluida la no declarada. Incorporar contenidos sobre uso responsable de IA en los planes de estudio parece una medida con bajo coste y potencial impacto, aunque su eficacia real requeriría evaluación empírica.

Tercera sugerencia: apostar por marcos normativos claros y pedagógicamente coherentes. Los datos no permiten concluir qué tipo de política, más permisiva o más restrictiva, produce menos Shadow AI. Lo que sí parece razonable, apoyándome en el marco teórico, es que la ambigüedad normativa y la falta de coherencia entre lo que se prohíbe y lo que se practica generan confusión y pueden alimentar la reactancia (Thaler y Sunstein, 2008). Las políticas que combinan orientación práctica con declaración explícita de uso, como la de ICADE, parecen un punto de partida sensato, aunque este estudio no permite evaluar su eficacia real.

Cuarta sugerencia: aprovechar la norma social en sentido positivo. Si el herding contribuye a normalizar el uso no declarado cuando la norma implícita apunta en esa dirección, tiene sentido intentar desplazar esa norma haciendo visibles los casos de uso transparente. El hecho de que el GPA sea similar en los tres perfiles puede ser un argumento útil en ese sentido: declarar el uso de IA no parece penalizar el rendimiento académico, al menos en esta muestra.

Quinta sugerencia: considerar la heterogeneidad del estudiantado. Los perfiles k-means, con todas sus limitaciones, apuntan a que no todos los estudiantes se relacionan con la Shadow AI por las mismas razones ni con la misma intensidad. Una política universitaria uniforme puede ser eficaz para algunos perfiles e ineficaz o incluso contraproducente para otros. En la medida en que sea posible, diseñar intervenciones diferenciadas, por ejemplo, para estudiantes con alta presión académica frente a los que ya muestran comportamientos cautelosos, podría ser más eficiente que una respuesta institucional única.

7.3. Reflexión final sobre IA, autonomía y educación responsable

La Shadow AI no es un problema tecnológico. Es un problema humano, institucional y cultural que refleja la tensión entre la velocidad con la que la inteligencia artificial se integra en la vida cotidiana de los estudiantes y la lentitud con la que las universidades adaptan sus marcos normativos y pedagógicos a esa nueva realidad. Los datos de este estudio con todas sus limitaciones apuntan a que los estudiantes no ocultan el uso de IA porque sean deshonestos por naturaleza, sino porque el entorno en el que se forman todavía no les ha ofrecido un marco claro, formativo y realista para hacerlo de otra manera.

Los comentarios cualitativos recogidos en la encuesta son elocuentes en este sentido. Numerosos participantes señalan que lo que mejorarían de sus universidades es la integración de la IA como herramienta de aprendizaje, no su prohibición: "en vez de prohibirlo, enseñar a usarlo bien"; "que entiendan que la IA la usamos todos y es poco eficiente prohibir su uso"; "enseñar a usarla de forma ética y de la mano del juicio propio". Estas frases de los estudiantes apuntan hacia una demanda que, independientemente del tamaño de la muestra, me parece significativa: no piden que la IA sea tolerada sin convicción, sino integrada con criterio, rigor y propósito pedagógico.

Desde mi perspectiva como estudiante que ha vivido este fenómeno desde dentro, tanto en ICADE como durante mi experiencia en Cardiff University, creo que el debate no debería centrarse en si permitir o prohibir la IA, sino en cómo integrarla de forma que fortalezca, y no sustituya, las capacidades críticas, creativas y analíticas que justifican la educación superior.

Este trabajo es, en última instancia, una primera aproximación exploratoria a un fenómeno que merece estudios más amplios, más controlados y más matizados. Sus limitaciones son reales y relevantes. Lo que espero que aporte, modestamente, es un punto de partida empírico y un marco conceptual útil para que futuras investigaciones, con muestras más representativas, diseños longitudinales y métodos mixtos, puedan avanzar con mayor solidez en la comprensión de por qué los estudiantes ocultan el uso de la IA, y qué pueden hacer las universidades al respecto.

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)

BBVA. (2024, 10 de octubre). *Shadow IT: el peligro de que los empleados usen la tecnología por su cuenta*. BBVA Noticias.

<https://www.bbva.com/es/innovacion/shadow-it-el-peligro-de-que-los-empleados-usen-la-tecnologia-por-su-cuenta/>

Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., Bernstein, M. S., ...

Liang, P. (2021). *On the opportunities and risks of foundation models*. Stanford University, Center for Research on Foundation Models.

<https://arxiv.org/abs/2108.07258>

Cardiff University. (2025). *Academic regulations and policies handbook 2025–26*.

Cardiff University. <https://www.cardiff.ac.uk/students/academic-life/academic-regulations>

Cardiff University Learning and Teaching Academy. (2025). *AI in education at Cardiff University*. Cardiff University Blogs. <https://blogs.cardiff.ac.uk/LTAcademy/ai-in-education-at-cardiff-university/>

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>

De Frutos Sastre, A. (2025, 17 de julio). *La IA tiene muchas ventajas, pero también peligros: el auge del Shadow AI en las empresas*. Cinco Días / El País.

<https://cincodias.elpais.com/smartlife/pymes/2025-07-17/shadow-ai-y-otros-peligros-de-la-inteligencia-artificial-en-empresas.html>

Fundación CYD. (2025). *Uso y percepción de la IA en el entorno universitario*.

Fundación Conocimiento y Desarrollo. <https://www.fundacioncyd.org/publicaciones-cyd/uso-y-percepcion-de-la-ia-en-el-entorno-universitario/>

Gartner. (2023, 28 de marzo). *Gartner unveils top eight cybersecurity predictions for 2023-2024*. <https://www.gartner.com/en/newsroom/press-releases/2023-03-28-gartner-unveils-top-8-cybersecurity-predictions-for-2023-2024>

- Giannini, S. (2023). *La inteligencia artificial generativa y el futuro de la educación* [Documento de reflexión]. UNESCO. <https://www.unesco.org/es/articles/la-inteligencia-artificial-generativa-en-la-educacion-documento-de-reflexion-de-sra-stefania>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2014). *Multivariate data analysis* (7.^a ed.). Pearson.
- IBM. (2024, 28 de noviembre). *Predicciones de IBM para 2025: de la IA en la sombra a la automatización inteligente*. IBM Newsroom LATAM. <https://latam.newsroom.ibm.com/Los-expertos-de-IBM-comparten-las-predicciones-para-2025>
- Kahneman, D. (2011). *Thinking, fast and slow*. Farrar, Straus and Giroux.
- Krejcie, R. V., & Morgan, D. W. (1970). Determining sample size for research activities. *Educational and Psychological Measurement*, 30(3), 607–610. <https://doi.org/10.1177/001316447003000308>
- Laibson, D. (1997). Golden eggs and hyperbolic discounting. *The Quarterly Journal of Economics*, 112(2), 443–478. <https://doi.org/10.1162/003355397555253>
- Netskope. (2026). *Cloud and threat report 2026*. Netskope Threat Labs. <https://www.netskope.com/resources/cloud-and-threat-reports/cloud-and-threat-report-2026>
- Stephenson, R., & Armstrong, C. (2026). *Student generative AI survey 2026* (HEPI Report 199). Higher Education Policy Institute. <https://www.hepi.ac.uk/reports/student-generative-ai-survey-2026/>
- Thaler, R. H., & Sunstein, C. R. (2008). *Nudge: Improving decisions about health, wealth, and happiness*. Yale University Press.
- Universidad Pontificia Comillas. (2024). *Declaración de uso de herramientas de inteligencia artificial generativa en Trabajos Fin de Grado*. Universidad Pontificia Comillas.
- Universidad Pontificia Comillas, Oficina de Apoyo a la Innovación Docente (OAID). (2024). *Guía práctica de aplicación de la IA*. <https://doi.org/10.14422/OAID20241126>

Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425–478.

<https://doi.org/10.2307/30036540>

World Medical Association. (2013). *Declaration of Helsinki: Ethical principles for medical research involving human subjects*. <https://www.wma.net/policies-post/wma-declaration-of-helsinki/>

Zimmermann, S., & Rentrop, C. (2014). *Managing shadow IT instances: A method to control autonomous IT solutions in the business departments*. Proceedings of the European Conference on Information Systems (ECIS).

<https://www.researchgate.net/publication/263056038>

9. Anexos

Anexo A. Cuestionario completo

A continuación se presenta la estructura completa del cuestionario administrado a los 164 participantes mediante Google Forms. El cuestionario fue diseñado en versión bilingüe (español/inglés) para facilitar la participación de estudiantes de Cardiff University. Las escalas de respuesta son tipo Likert de 1 a 5 (bloques 1–5) y de 1 a 7 (bloques 6–10), donde 1 = Totalmente en desacuerdo y 5/7 = Totalmente de acuerdo.

Bloque 0 — Filtros previos

- ¿Has utilizado alguna vez herramientas de IA generativa (ChatGPT, Copilot, Gemini, DeepSeek, etc.)?
- Confirmando que participo de forma voluntaria y anónima, y que mis respuestas se usarán solo con fines académicos.

Bloque 1 — Frecuencia de uso

Escala 1–5 (1 = Totalmente en desacuerdo / 5 = Totalmente de acuerdo)

- Utilizo herramientas de IA a diario o semanalmente para estudiar o preparar trabajos de la universidad.
- Empleo la IA para resolver dudas o problemas específicos.
- Utilizo la IA para buscar información y redactar trabajos académicos.
- La IA me ayuda a planificar tareas y gestionar mi tiempo.
- Me preocupa la privacidad o seguridad de mis datos al usar IA.

Bloque 2 — Shadow AI (variable dependiente)

Escala 1–5 (1 = Totalmente en desacuerdo / 5 = Totalmente de acuerdo)

- He usado IA en tareas donde su uso estaba prohibido.
- He entregado trabajos redactados parcialmente con IA sin declararlo.
- Creo que los profesores no pueden detectar fácilmente el uso de IA.
- No informo del uso de IA porque mis compañeros tampoco lo hacen.
- He modificado el texto generado por IA para evitar detectores automáticos.

Bloque 3 — Utilidad percibida (TAM)

Escala 1–5 (1 = Totalmente en desacuerdo / 5 = Totalmente de acuerdo)

- La IA mejora mi rendimiento académico.
- La IA me permite trabajar de manera más eficiente.
- La IA me ayuda a obtener mejores resultados.

Bloque 4 — Normas sociales (UTAUT)

Escala 1–5 (1 = Totalmente en desacuerdo / 5 = Totalmente de acuerdo)

- Mis compañeros valoran positivamente que use IA.
- En mi entorno se espera que utilice herramientas de IA.
- Siento cierta presión por usar IA porque otros también lo hacen.

Bloque 5 — Riesgo percibido

Escala 1–5 (1 = Totalmente en desacuerdo / 5 = Totalmente de acuerdo)

- Podría tener consecuencias si se descubre que uso IA indebidamente.
- Me preocupa incumplir las normas académicas al usar IA.
- Existe un riesgo real de sanción por usar IA donde no está permitida.

Bloque 6 — Presión académica

Escala 1–7 (1 = Totalmente en desacuerdo / 7 = Totalmente de acuerdo)

- La carga de trabajo académica en mi universidad es elevada.
- Siento mucha presión por las calificaciones y los plazos de entrega.
- El tiempo disponible suele ser insuficiente para completar todas las tareas.
- En periodos de alta carga, considero la IA un recurso necesario para cumplir con las exigencias.

Bloque 7 — Control de atención

- Para confirmar que estás leyendo con atención, marca el número 3 en esta escala.

Bloque 8 — Present bias

Escala 1–7 (1 = Totalmente en desacuerdo / 7 = Totalmente de acuerdo)

- Prefiero ahorrar tiempo ahora aunque aprenda menos.
- Utilizo IA para entregar antes, incluso aunque pudiese hacerlo sin ayuda.
- Valoro más los resultados rápidos que el aprendizaje profundo.

Bloque 9 — Overconfidence

Escala 1–7 (1 = Totalmente en desacuerdo / 7 = Totalmente de acuerdo)

- Estoy seguro/a de que puedo usar IA sin que nadie lo note.
- Sé disimular cuándo un texto ha sido generado con IA.
- Si uso IA, puedo evitar consecuencias con facilidad.

Bloque 10 — Contexto institucional

Escala 1–7 (1 = Totalmente en desacuerdo / 7 = Totalmente de acuerdo)

- Estoy satisfecho/a con la calidad de la enseñanza en mi universidad.
- Los métodos de evaluación son justos y coherentes.
- La universidad ofrece información clara sobre cómo usar IA.
- Las normas sobre IA son razonables y realistas.
- En mi universidad hay información o normas claras sobre los usos lícitos y no permitidos de la IA.
- Conozco las normas de mi universidad sobre el uso de la IA.
- Me siento acompañado/a para aprender a usar IA de forma ética.
- Las políticas sobre IA me parecen demasiado restrictivas.

Bloque 11 — Datos sociodemográficos

- Edad
- Género
- Nacionalidad
- Universidad
- Titulación o grado
- Curso académico
- Nota media actual o del último curso (0–10)
- Rendimiento académico percibido

Fuente: Elaboración propia. El cuestionario incluyó además una pregunta abierta opcional sobre mejoras en el uso o enseñanza de la IA en la universidad.

Anexo de código

```

— ALPHA DE CRONBACH —
Shadow AI (VD)      : α = 0.714
Utilidad percibida : α = 0.810
Normas sociales    : α = 0.441
Riesgo percibido  : α = 0.649
Presión académica  : α = 0.788
Present bias       : α = 0.781
Overconfidence     : α = 0.806

— DESCRIPTIVOS —
shadow_ai      : M=3.41, DT=0.90, min=1.0, max=5.0
utilidad      : M=4.21, DT=0.81, min=1.0, max=5.0
normas        : M=3.37, DT=0.79, min=1.3, max=5.0
riesgo        : M=3.39, DT=0.97, min=1.0, max=5.0
presion       : M=5.29, DT=1.24, min=1.2, max=7.0
present_bias  : M=4.21, DT=1.40, min=1.0, max=7.0
overconfidence : M=4.46, DT=1.40, min=1.0, max=7.0

— CORRELACIONES CON SHADOW AI —
utilidad      : r=+0.286, p=0.0002 ***
normas        : r=+0.170, p=0.0292 *
riesgo        : r=+0.203, p=0.0090 **
presion       : r=+0.266, p=0.0006 ***
present_bias  : r=+0.476, p=0.0000 ***
overconfidence : r=+0.250, p=0.0012 **

— REGRESIÓN MÚLTIPLE (VD: Shadow AI) —
R² = 0.291, R²adj = 0.259, N = 164
Variable      β      SE      t      p      Sig.
Intercepto   0.670  0.458  1.464  0.1451
utilidad     0.178  0.085  2.101  0.0372 *
normas       0.041  0.082  0.501  0.6171
riesgo       0.155  0.064  2.437  0.0159 *
presion      0.016  0.055  0.282  0.7786
present_bias 0.242  0.049  4.898  0.0000 ***
overconfidence 0.050  0.048  1.056  0.2927

```

```

— REGRESIÓN MÚLTIPLE (VD: Shadow AI) —
R² = 0.291, R²adj = 0.259, N = 164
Variable      β      SE      t      p      Sig.
Intercepto   0.670  0.458  1.464  0.1451
utilidad     0.178  0.085  2.101  0.0372 *
normas       0.041  0.082  0.501  0.6171
riesgo       0.155  0.064  2.437  0.0159 *
presion      0.016  0.055  0.282  0.7786
present_bias 0.242  0.049  4.898  0.0000 ***
overconfidence 0.050  0.048  1.056  0.2927

— SILHOUETTE SCORES —
k=2: silhouette = 0.198
k=3: silhouette = 0.163
k=4: silhouette = 0.147
k=5: silhouette = 0.134
k=6: silhouette = 0.128

```

```

— MEDIAS POR PERFIL —
shadow_ai  utilidad  normas  riesgo  presion  present_bias  overconfidence
perfil
Cautelosos  2.82    3.10    2.81    3.67    5.00    3.48    3.23
Intermedios 2.91    4.39    3.44    2.90    4.74    3.32    4.39
Tramosos    4.10    4.60    3.59    3.63    5.86    5.27    5.12

Tamaños: {'Tramosos': 72, 'Intermedios': 57, 'Cautelosos': 35}

— ÍTEMS SHADOW AI POR PERFIL —
                Uso prohibido  No declarar  Indetectable  Norma social  Modificar texto
perfil
Cautelosos      2.80      3.00      2.26      2.40      3.66
Intermedios     2.67      2.81      2.93      2.26      3.86
Tramosos        4.26      4.38      3.74      3.38      4.74

```

```

— PERFIL SOCIODEMográfico —

[Tramosos] n=72
% Hombre: 27.8%
% Mujer: 72.2%
% Privada: 58.3%
% Pública: 41.7%
% ICADE: 27.8%
% Cardiff: 8.3%
% Otras: 63.9%
Curso medio: 4.2
GPA medio: 7.41

[Intermedios] n=57
% Hombre: 52.6%
% Mujer: 47.4%
% Privada: 43.9%
% Pública: 56.1%
% ICADE: 22.8%
% Cardiff: 19.3%
% Otras: 57.9%
Curso medio: 4.4
GPA medio: 7.50

[Cautelosos] n=35
% Hombre: 14.3%
% Mujer: 85.7%
% Privada: 45.7%
% Pública: 54.3%
% ICADE: 31.4%
% Cardiff: 28.6%
% Otras: 40.0%
Curso medio: 4.0
GPA medio: 7.41

```

```

— KRUSKAL-WALLIS ENTRE 3 PERFILES —
shadow_ai      : H= 81.48, p=0.0000 ***
utilidad      : H= 71.90, p=0.0000 ***
normas        : H= 18.31, p=0.0001 ***
riesgo        : H= 23.37, p=0.0000 ***
presion       : H= 30.27, p=0.0000 ***
present_bias  : H= 77.96, p=0.0000 ***
overconfidence : H= 42.93, p=0.0000 ***
sai1_prohibido : H= 49.61, p=0.0000 ***
sai2_nodeclarar : H= 44.90, p=0.0000 ***
sai3_indetect : H= 39.60, p=0.0000 ***
sai4_normasoc : H= 25.68, p=0.0000 ***
sai5_modificar : H= 39.12, p=0.0000 ***

— SHADOW AI: HOMBRE vs MUJER —
Hombre: M=3.27, DT=0.90, n=55
Mujer: M=3.48, DT=0.89, n=109
Mann-Whitney p=0.1197

```

```

— SHADOW AI: ICADE vs CARDIFF vs OTRAS —
ICADE: M=3.41, DT=0.91, n=44
Cardiff: M=2.96, DT=0.85, n=27
Otras: M=3.54, DT=0.87, n=93
Kruskal-Wallis H=9.18, p=0.0101

— DISTRIBUCIÓN PERFILES x TIPO UNI —
uni_tipo  Privada  Pública
perfil
Cautelosos    16     19
Intermedios   25     32
Tramosos      42     30

```

```

% por fila:
uni_tipo  Privada  Pública
perfil
Cautelosos    45.7    54.3
Intermedios   43.9    56.1
Tramosos      58.3    41.7

— DISTRIBUCIÓN PERFILES x GÉNERO —
gender     Hombre  Mujer
perfil
Cautelosos    5      30
Intermedios   30     27
Tramosos      20     52

% por fila:
gender     Hombre  Mujer
perfil
Cautelosos    14.3   85.7
Intermedios   52.6   47.4
Tramosos      27.8   72.2

```

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Carlota Riesgo Yanes, estudiante de E3 Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado " El fenómeno de la Shadow AI. ¿Por qué ocultamos la IA en el trabajo?", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Crítico:** Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
5. **Interpretador de código:** Para realizar análisis de datos preliminares.
6. **Estudios multidisciplinares:** Para comprender perspectivas de otras comunidades sobre temas de naturaleza multidisciplinar.
7. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
8. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
9. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.

10. **Generador de problemas de ejemplo:** Para ilustrar conceptos y técnicas.
11. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
12. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 09 de junio de 2026

Firma: Carlota.