



Facultad de Ciencias Económicas y Empresariales

Comportamiento del Consumidor frente al uso de la inteligencia artificial para influir en la compra de los consumidores

Autor: Irene Yongling Barrena Lorente

Director: Eduardo Gismera Tierno

MADRID | Junio 2025-2026

Índice general

1. Objeto	1
1.1. Motivación	1
1.2. Objetivos	2
1.2.1. Objetivo General	2
1.2.2. Objetivos Específicos	2
1.3. Estructura del Documento	3
2. Metodología	4
2.0.1. Análisis documental	4
2.0.2. Estudio de campo: Focus Group	4
2.0.3. Estudio de campo: Encuesta	5
2.0.4. Análisis de datos obtenidos	5
2.1. Estudio de campo: Focus Group	5
2.2. Estudio de campo: Encuesta	8
2.3. Análisis de los datos recopilados	10
2.3.1. Análisis del Focus Group	10
2.3.2. Análisis de la Encuesta	12
3. Marco Teórico	14
4. Trabajo de Campo	19
4.1. Resultados Estudio Cualitativo	19
4.1.1. Nube de palabras y Análisis de frecuencias	19
4.1.2. Análisis temático manual	22
4.2. Resultados de la Encuesta	25
5. Conclusiones	36
A. Encuesta y datos de la investigación	42
Bibliografía	43

Índice de figuras

2.1. Flujo metodológico del estudio	7
4.1. <i>WordCloud</i>	20
4.2. Gráfico de Frecuencias	21
4.3. Distribución de menciones agrupadas por las seis dimensiones de interés definidas	22
4.4. Distribución de la muestra por edad	26
4.5. Distribución por género	27
4.6. Perfil sociodemográfico: situación laboral e ingresos	27
4.7. Perfil sociodemográfico: gasto online y familiaridad digital	28
4.8. Uso de inteligencia artificial en compras	28
4.9. Sector de compras y funcionalidades de IA	29
4.10. Influencia percibida y satisfacción general con IA en compras	32
4.11. Plataforma percibida como más innovadora en IA	33
4.12. Expectativas de uso futuro de IA en compras	33

Índice de tablas

2.1. Tests estadísticos descriptivos aplicados	12
3.1. Resumen de los estudios incluidos en la literatura del arte	17
4.1. Resumen del análisis temático: temas, códigos y participantes	23
4.2. Estadísticos descriptivos de los ítems Likert agrupados por dimensión . . .	30
4.3. Diferencial semántico: percepción de los sistemas de recomendación	32
4.4. Importancia de los factores en la decisión de compra con IA (Likert 1-5) . .	32
4.5. Tests estadísticos: Objetivo 1. Contextualización de la IA en el entorno digital	34
4.6. Tests estadísticos: Objetivo 2. Percepción real del consumidor	34
4.7. Tests estadísticos: Objetivo 3. Beneficios percibidos y preocupaciones . . .	35

Resumen

Este Trabajo de Fin de Grado analiza cómo la inteligencia artificial influye en el comportamiento de compra del consumidor en el entorno digital actual. Se optó por una metodología cualitativa que combina el análisis documental con trabajo de campo. Primero se hizo un *focus group* con cinco participantes, cuyo análisis —apoyado en procesamiento de lenguaje natural en Python y en el análisis temático de seis fases de Braun y Clarke (2006)— llevó a identificar siete temas: confianza condicionada, paradoja de la privacidad, personalización y encasillamiento algorítmico, transparencia y explicabilidad, autonomía frente a conveniencia, sesgo algorítmico y brecha generacional. Esos temas sirvieron de base para diseñar una encuesta que recogió 123 respuestas válidas, analizadas con estadísticos descriptivos y tests de asociación (Pearson, Spearman, t de Student y Chi-cuadrado).

Los datos muestran que el 81,3 % de los encuestados ya ha usado algún sistema de IA al comprar, y el 82,9 % espera usarla más. Quienes la usan con más frecuencia están más satisfechos ($r = 0,479$; $p < 0,001$), y quienes más confían en sus recomendaciones también ($\rho = 0,568$; $p < 0,001$). Pero lo más curioso no son esos números: es la contradicción con la que muchos consumidores conviven sin demasiado problema. Dicen que les preocupa la privacidad de sus datos y, al mismo tiempo, siguen en las mismas plataformas que los recopilan. No se plantean irse. Piden más claridad sobre cómo funcionan los algoritmos, pero la falta de claridad tampoco les hace cambiar de comportamiento. Esa tensión entre lo que la gente dice y lo que hace, entre la comodidad y el control, es básicamente el hilo que conecta todo el trabajo.

Palabras Clave: *inteligencia artificial, comportamiento del consumidor, comercio electrónico, confianza, privacidad, transparencia algorítmica, metodología cualitativa*

Abstract

This undergraduate thesis examines how artificial intelligence influences consumer purchasing behavior in today's digital environment. A qualitative methodology was used, combining documentary analysis with two field research techniques. A focus group with five participants was first conducted and analyzed using natural language processing in Python and the six-phase thematic analysis framework by Braun and Clarke (2006). Seven themes emerged: conditional trust, the privacy paradox, personalization and algorithmic pigeonholing, transparency and explainability, autonomy versus convenience, algorithmic bias, and the generational divide. These themes shaped the design of a structured survey yielding 123 valid responses, analyzed through descriptive statistics and association tests (Pearson and Spearman correlations, Student's t-test, and Chi-square).

Results show that 81.3% of respondents have used AI systems when shopping, and 82.9% expect to use them more. More frequent users report higher satisfaction ($r = 0.479$; $p < 0,001$), and the same holds for those who trust recommendations more ($\rho = 0.568$; $p < 0,001$). But arguably the most interesting finding is not in those correlations. It is the contradiction that many consumers seem perfectly comfortable living with: they say data privacy worries them, and yet they keep using the exact platforms that collect it. They do not seem to be planning to stop anytime soon. They ask for more transparency about how algorithms work, but a lack of it does not seem to change their behavior either. That gap — between what people say and what they actually do, between convenience and control — runs through the entire study and is arguably its most thought-provoking thread.

Keywords: *artificial intelligence, consumer behavior, e-commerce, trust, privacy, algorithmic transparency, qualitative methodology*

Acrónimos

IA	Inteligencia Artificial
EDA	Análisis Exploratorio de Datos (<i>Exploratory Data Analysis</i>)
PLS-SEM	Mínimos Cuadrados Parciales - Modelo de Ecuaciones Estructurales (<i>Partial Least Squares - Structural Equation Modeling</i>)
GDPR	Reglamento General de Protección de Datos (<i>General Data Protection Regulation</i>)
NLTK	Kit de Herramientas de Lenguaje Natural (<i>Natural Language Toolkit</i>)
NLP	Procesamiento de Lenguaje Natural (<i>Natural Language Processing</i>)
SD	Desviación Típica (<i>Standard Deviation</i>)
TFG	Trabajo de Fin de Grado

Capítulo 1

Objeto

1.1. Motivación

La inteligencia artificial (IA) lleva años dejando de ser una promesa para convertirse en algo cotidiano. Aparece cuando buscas un producto, cuando una plataforma te recomienda algo que no habías pedido, cuando un chatbot te atiende antes que cualquier persona. Ya no es tecnología del futuro: está aquí, metida en la experiencia de compra de millones de personas. Y la verdad es que cada vez cuesta más distinguir dónde termina tu decisión y dónde empieza la del algoritmo.

Eso es lo que motivó este trabajo. No tanto que la IA exista —eso ya lo sabemos todos— sino lo que hace con nosotros cuando compramos. Mogaji y Jain (Mogaji y Jain, 2024) lo explican bien: las herramientas de IA generativa no solo automatizan procesos, sino que están cambiando la naturaleza misma de la relación entre marcas y personas. El consumidor ya no busca y elige; en muchos casos, el sistema anticipa, filtra y presenta. La pregunta es qué pasa con él en ese proceso.

Desde la literatura académica, los últimos años han traído respuestas parciales. Hermann y Puntoni (Hermann y Puntoni, 2024) distinguen entre IA predictiva —que analiza datos pasados para anticipar lo que querrás— e IA generativa —que crea contenido nuevo a partir de esos datos. La distinción importa porque cada tipo actúa de forma distinta sobre el comportamiento del consumidor, y no tiene sentido estudiarlos como si fueran lo mismo.

El impacto económico también es claro. Gonzales (Gonzales, 2023) encontró, con datos de panel de casi cinco décadas, que la IA tiene un efecto positivo y significativo sobre el crecimiento económico a largo plazo. Y a escala más concreta, Tanlamai et al. (Tanlamai, Khern-Am-Nuai, y Adulyasak, 2024) demostraron que un modelo de IA fue capaz de identificar 293 oportunidades de arbitraje en un año, con una ganancia media de 7,06 dólares por oportunidad. Son números concretos, sí, pero dicen algo más grande: la IA no es neutral. Genera valor económico real, y ese valor acaba influyendo en cómo las empresas montan sus estrategias y en lo que termina viéndote tú cuando abres una app.

Pero no todo son ventajas. André et al. (André et al., 2018) señalan algo incómodo: la IA puede hacer que las decisiones sean más rápidas y eficientes, pero esa comodidad tiene un precio. La persona puede acabar dependiendo de sistemas que no entiende y confiando en recomendaciones que no sabe cómo se generan. La tecnología simplifica la elección, sí —pero también puede vaciarla de autonomía.

Y luego está lo que se llama la paradoja de la privacidad (Mantilla Gonzales de la Cotera, 2019). Que básicamente es esto: mucha gente dice que le preocupa cómo se usan sus datos. Pero no se va de las plataformas que los recopilan. Sigue ahí. No es que sean irracionales —es que la alternativa no existe o es demasiado incómoda.

Y hay un ángulo más, menos evidente. Reif et al. (Reif, Larrick, y Soll, 2025) documentaron, con más de 4.400 participantes, que usar herramientas de IA puede acarrear una penalización social: otros te perciben como menos competente o menos esforzado. La adopción tecnológica, por tanto, no depende solo de si algo funciona. Depende también de cómo te ve la gente cuando lo usas.

Todo esto, junto, justifica el trabajo. Desde el punto de vista académico, hay preguntas abiertas sobre cómo la IA moldea la toma de decisiones, la confianza y la relación de las personas con las marcas. Desde el punto de vista práctico, las empresas necesitan entender qué perciben realmente sus clientes cuando interactúan con estos sistemas —no lo que dicen en abstracto, sino lo que sienten y hacen. Y el campo avanza tan rápido que la investigación corre siempre algo por detrás. Ese desfase es, también, una razón para investigar.

1.2. Objetivos

1.2.1. Objetivo General

El objetivo principal de este Trabajo de Fin de Grado es analizar cómo la inteligencia artificial influye en el comportamiento de compra del consumidor en el entorno digital actual, combinando la revisión de la literatura académica con un estudio empírico que integra un focus group y una encuesta. Se busca entender cómo perciben los consumidores el uso de la IA, cómo afecta a sus decisiones de compra y qué nivel de confianza y aceptación genera hoy.

1.2.2. Objetivos Específicos

- Contextualizar el papel de la inteligencia artificial en el entorno digital y comercial actual, con especial atención a su influencia en la experiencia de compra, la personalización de servicios y la relación entre empresas y consumidores.
- Diseñar y aplicar un focus group y una encuesta para estudiar cómo perciben realmente

los consumidores la IA: qué saben de ella, con qué frecuencia la usan, cuánto confían en ella y si estarían dispuestos a integrarla más en su proceso de compra.

- Identificar y analizar los principales efectos del uso de la IA en el comportamiento del consumidor, tanto los aspectos positivos —personalización, comodidad, ahorro de tiempo— como las preocupaciones que genera, especialmente en torno a la privacidad, la seguridad de los datos y la posible pérdida de control sobre las propias decisiones.

El enfoque es exploratorio. No hay hipótesis previas, básicamente porque el tema cambia tan rápido que los modelos teóricos existentes no terminan de capturar todo lo que está pasando. Lo más honesto era arrancar con una mirada abierta y ver qué salía de los datos, sin forzar nada desde el principio.

1.3. Estructura del Documento

El trabajo se organiza en cinco capítulos.

El Capítulo 2 explica la metodología: el enfoque cualitativo adoptado, cómo se diseñaron el focus group y la encuesta, qué variables se analizaron y cómo se trató la información recogida. El Capítulo 3 revisa la literatura académica sobre inteligencia artificial y comportamiento del consumidor. Se abordan la evolución de la IA en el entorno digital, la distinción entre IA predictiva y generativa, los modelos de adopción tecnológica y las investigaciones más recientes sobre confianza, privacidad y autonomía en el proceso de compra. El Capítulo 4 presenta los resultados: qué saben los consumidores sobre la IA, cómo la usan, cuánto confían en ella y cómo la perciben, con los comportamientos detectados y su lectura a la luz del marco teórico. El Capítulo 5 recoge las conclusiones: qué aporta el estudio, qué limitaciones tiene y por dónde podría ir la investigación futura.

Capítulo 2

Metodología

Este capítulo explica la metodología usada para analizar el comportamiento del consumidor frente al uso de la inteligencia artificial en contextos de compra. El objetivo es entender qué percepciones y motivaciones hay detrás de sus decisiones, qué genera confianza y qué genera rechazo hacia estas tecnologías.

La metodología es de carácter cualitativo. Combina el análisis documental del marco teórico con dos técnicas de investigación de campo: un *focus group* y una encuesta estructurada. Merece la pena aclarar un punto que puede generar confusión: aunque la encuesta recoge datos numéricos y aplica algunos tests estadísticos descriptivos, no se usan análisis estadísticos avanzados, ni se construyen modelos matemáticos sobre algoritmos, ni se trabaja con técnicas de *machine learning*. Por eso el enfoque se considera cualitativo en su conjunto. El análisis documental del marco teórico es, por su propia naturaleza, también cualitativo. La Figura 2.1 presenta el flujo metodológico seguido.

2.0.1. Análisis documental

Revisión y análisis sistemático de la literatura académica sobre inteligencia artificial y comportamiento del consumidor. Este trabajo fundamenta teóricamente la investigación y es, por su propia naturaleza, cualitativo.

2.0.2. Estudio de campo: Focus Group

Un *focus group* con cinco participantes para explorar las percepciones, motivaciones y barreras de los consumidores frente al uso de la IA en compras. La sesión se estructuró en diez bloques temáticos y se analizó mediante técnicas de procesamiento de lenguaje natural en Python y el procedimiento de análisis temático de seis fases de Braun y Clarke (2006).

2.0.3. Estudio de campo: Encuesta

Una encuesta estructurada en cuatro bloques temáticos, distribuida a través de canales digitales durante tres semanas. Se obtuvieron 123 respuestas válidas tras aplicar los criterios de exclusión. El cuestionario incluye variables nominales, ordinales (Likert 1-5), escalas de diferencial semántico y escalas continuas (0-10). El análisis es descriptivo y no implica modelización estadística avanzada.

2.0.4. Análisis de datos obtenidos

Los datos del focus group se analizaron con un Análisis Exploratorio de Datos (EDA) y un análisis temático formal, identificando siete temas clave. Los datos de la encuesta se analizaron en tres fases: perfil sociodemográfico descriptivo, descripción de las variables de interés, y análisis de relaciones entre variables mediante tests estadísticos (Chi-cuadrado, Pearson, Spearman y t de Student).

2.1. Estudio de campo: Focus Group

La primera fase del trabajo de campo es exploratoria. Se realizó un focus group para acercarse a las percepciones, motivaciones y barreras que tienen los consumidores frente al uso de sistemas de IA en contextos de compra. La elección de esta técnica tiene una razón concreta: cuando hay un grupo debatiendo, salen cosas que en una entrevista individual no saldrían (Krueger y Casey, 2014). Los focus groups son especialmente útiles para explorar actitudes complejas y contradictorias, como la paradoja de privacidad o la tensión entre autonomía y conveniencia, que caracterizan la relación de los consumidores con la IA.

Se realizó 1 focus group con cinco participantes, con una duración de entre 60 y 90 minutos. Este tamaño responde a las recomendaciones para investigación cualitativa: grupos de entre seis y ocho personas permiten una participación equilibrada, sin que unos pocos monopolicen el debate ni que el grupo sea tan pequeño que no genere discusión (Morgan, 1997). La sesión fue por videollamada, lo que facilitó la participación de perfiles diversos sin límites geográficos. Se grabó en audio y video con autorización de todos los participantes.

Como el focus group trabaja con una muestra más reducida que la encuesta, se buscó un perfil específico que permitiera maximizar la profundidad y relevancia de los testimonios. El perfil objetivo era consumidores digitales activos, con edades entre 20 y 55 años, que comprasen online con frecuencia —al menos 3-4 veces al mes. Se priorizaron *early adopters* tecnológicos que usasen activamente sistemas de IA en sus compras habituales (chatbots, recomendadores personalizados, asistentes de voz, comparadores de precios) en plataformas como Instagram Shopping, TikTok Shop, Amazon, Shein o Zalando. Se buscó diversidad en la actitud hacia la IA (usuarios entusiastas, pragmáticos y críticos), en el tipo de com-

pra (impulsivos frente a planificados) y en sectores. En cuanto al género, se procuró una representación equilibrada.

Se priorizaron perfiles diferenciados según su experiencia con la IA en compras: usuarios entusiastas —que confían plenamente en las recomendaciones algorítmicas y las ven como una ventaja—, usuarios pragmáticos —que las usan de forma selectiva, valorando su utilidad pero con algo de escepticismo—, y usuarios críticos —que, a pesar de usar plataformas con IA, tienen preocupaciones sobre privacidad, sesgos o pérdida de autonomía. En cuanto al tipo de compra, se buscaron tanto consumidores impulsivos, que compran con frecuencia productos de bajo coste influenciados por publicidad personalizada, como compradores planificados, que dedican más tiempo a decidir y usan la IA como apoyo para comparar alternativas. Se intentó incluir diferentes sectores de compra. En cuanto al género, se procuró una distribución equilibrada, y se buscó diversidad en nivel educativo y sector profesional, con especial interés en perfiles de tecnología, marketing digital, comercio electrónico o análisis de datos, ya que suelen tener mayor conciencia sobre el funcionamiento de los algoritmos.

La sesión se dividió en 10 bloques para ir cubriendo, paso a paso, los aspectos más importantes del comportamiento del consumidor frente a la IA. El primer bloque fue la bienvenida y el consentimiento informado: se explicó el objetivo del estudio, se garantizó el anonimato mediante seudónimos, se pidió autorización para la grabación y se informó del derecho a retirarse en cualquier momento. El segundo bloque fue una ronda de presentaciones donde los participantes compartieron su nombre, ocupación y frecuencia aproximada de compras online, lo que permitió identificar de forma natural las plataformas que utilizan habitualmente. El tercer bloque exploró las experiencias con compras online y los primeros contactos con la IA: qué tipos de sistemas habían notado los participantes en las plataformas que usan (recomendaciones personalizadas, chatbots, asistentes virtuales). Se dejó que las plataformas y marcas surgieran de forma natural en la conversación, sin preguntarlo directamente. El cuarto bloque abordó la confianza y la transparencia: si confían en las recomendaciones que reciben, qué les preocupa y cómo gestionan el equilibrio entre conveniencia y privacidad de datos. El quinto bloque se centró en la influencia de la IA en las decisiones de compra: si sienten que realmente influye y si les ha llevado a comprar cosas que no habrían comprado de otra manera. El sexto bloque exploró la tensión entre autonomía y conveniencia: si al usar estos sistemas sienten que pierden autonomía o si, al contrario, les facilita la vida. El séptimo bloque profundizó en experiencias concretas con herramientas de IA —ChatGPT, Pinterest, aplicaciones de supermercados— incluyendo el uso de versiones gratuitas frente a versiones de pago. El octavo bloque abordó las barreras y los sesgos algorítmicos: si han notado recomendaciones sesgadas, si sienten que los sistemas les encasillan en un tipo de producto, y qué cambios les gustaría. El noveno bloque exploró los tipos de compra y la satisfacción: si son más impulsivos o planificados, cómo la IA influye en esos comportamientos y si están satisfechos con su experiencia. El décimo bloque abordó las expectativas de futuro: cómo ven la evolución de la IA en compras, si prevén usarla más o menos, qué mejoras les gusta-

rían y qué límites éticos consideraran necesarios. La sesión cerró con un espacio abierto para que los participantes añadieran reflexiones, anécdotas o ideas que no hubieran tenido cabida en el guion.




Figura 2.1: Flujo metodológico del estudio

Las preguntas del focus group fueron abiertas y no directivas, pensadas para fomentar el debate y dejar que emergieran perspectivas diversas sin que el moderador condicionara las respuestas. Se evitaron preguntas cerradas o que sugirieran respuestas concretas, optando por formulaciones amplias que invitaran a la reflexión y al intercambio. El moderador guio la conversación a través de los bloques temáticos, asegurándose de que todos pudieran expresarse, pero sin dirigir el contenido de las respuestas ni cortar el flujo del debate. Se fomentó

la interacción directa entre participantes, ya que el contraste de opiniones y experiencias es precisamente uno de los valores que tiene esta técnica frente a las entrevistas individuales.

Todos los participantes firmaron un consentimiento informado antes del inicio, donde se les explicó el carácter académico del estudio, el tratamiento anónimo y confidencial de sus respuestas mediante seudónimos, el uso exclusivamente académico de las grabaciones, y su derecho a abandonar la sesión o pedir la eliminación de sus datos en cualquier momento, garantizando el cumplimiento de los principios éticos de la investigación y de la normativa de protección de datos (European Parliament and Council, 2016). Las grabaciones se guardaron de forma segura, accesibles solo para el equipo de investigación, y fueron eliminadas tras el análisis y la defensa del trabajo. La transcripción completa del focus group, junto con los datos anonimizados de la encuesta y los scripts de análisis, se incluye en el Anexo A para que cualquiera pueda verificar los resultados y replicar el análisis si lo necesita.

2.2. Estudio de campo: Encuesta

Una vez hecho el focus group, hacía falta algo que complementara esos resultados con una muestra más grande. Para eso se diseñó una encuesta estructurada dirigida a consumidores que cumplieran un perfil similar. La idea era poder ver si lo que salió del grupo de discusión se repetía a mayor escala, medir con más detalle la intensidad de las percepciones y buscar relaciones entre variables (Malhotra, 2008). Un matiz importante: aunque la encuesta recoge datos numéricos y aplica tests estadísticos, el enfoque sigue siendo cualitativo, ya que no se usan análisis estadísticos avanzados (regresiones multivariantes, modelos predictivos, *machine learning*), sino análisis descriptivos y de asociación básicos. El estudio combina así la riqueza interpretativa del análisis documental y del focus group con el apoyo descriptivo de la encuesta.

El cuestionario se diseñó a partir de los temas que emergieron en el focus group, que permitieron identificar los aspectos clave a medir y los factores más relevantes en la toma de decisiones de compra asistida por IA. Las preguntas se formularon traduciendo los conceptos del marco teórico en ítems concretos, de forma que cada uno respondiera a una categoría teórica precisa y contribuyera a los objetivos de investigación. Se usó Google Forms por su accesibilidad, facilidad de distribución y compatibilidad con software estadístico. Antes de lanzar la encuesta, se revisó con un grupo reducido de participantes para detectar posibles ambigüedades y verificar el correcto funcionamiento técnico de la plataforma.

La encuesta se estructuró en cuatro bloques temáticos. El primero abordó el uso actual y las preferencias respecto a sistemas de IA en procesos de compra: frecuencia de uso, tipos de sistemas más utilizados y funcionalidades más valoradas. El segundo bloque se centró en los factores que influyen en la decisión de compra cuando interviene la IA: confianza en el sistema, transparencia algorítmica, precio, marca, privacidad de datos y autonomía percibida.

El tercer bloque exploró la percepción del mercado y el comportamiento de las empresas que usan IA: qué marcas se perciben como líderes en innovación y cómo influye esa percepción en las decisiones de compra. El cuarto bloque recogió datos sociodemográficos para permitir análisis cruzados y detectar diferencias según el perfil del consumidor. Estos bloques se plantearon a partir del marco teórico, y su contenido específico se ajustó en función de lo que reveló el focus group.

El cuestionario incluyó variables de distinta naturaleza, sin preguntas abiertas o de respuesta libre. Se usaron variables nominales dicotómicas —uso o no uso de sistemas de IA en compras, codificadas como 0 y 1— y variables nominales politómicas —tipo de sistema más utilizado o sector de compra preferente, codificadas numéricamente. Las variables ordinales se midieron con escalas Likert de cinco puntos, donde 1 representa el menor grado de acuerdo o importancia y 5 el mayor (Likert, 1932). También se incluyeron escalas de diferencial semántico para evaluar percepciones bipolares, como la percepción de un sistema de IA entre “poco confiable” y “muy confiable” (Osgood, Suci, y Tannenbaum, 1957), y variables continuas en escalas de 0 a 10 para aspectos como la influencia de la IA en las decisiones, la satisfacción o la percepción de innovación de las marcas. La edad se recogió como valor entero y los ingresos mensuales se categorizaron en rangos ordinales para facilitar la participación y reducir la sensibilidad de la pregunta. Se usaron preguntas de selección única y escalas numéricas deslizantes para las variables continuas.

Para garantizar la calidad de las respuestas y detectar participantes que no prestaran atención al cuestionario, se incluyó una pregunta de control o *attention check* en el segundo bloque. Esta pregunta pedía explícitamente al encuestado seleccionar una opción concreta: “Si está leyendo atentamente esta pregunta, por favor seleccione el número 4 en la escala siguiente”. Las respuestas que no superaran este filtro quedarían excluidas del análisis (Oppenheimer, Meyvis, y Davidenko, 2009).

El perfil objetivo eran consumidores digitales activos, preferentemente entre 18 y 55 años —aunque sin excluir a mayores que cumplieran los demás criterios, ya que su inclusión permite capturar la diversidad generacional del fenómeno—, que comprasen online al menos una vez al mes y hubieran tenido algún tipo de contacto con sistemas de IA en contextos de compra. Se buscó diversidad en género, nivel educativo, sector profesional y nivel de ingresos, con especial interés en perfiles con un gasto online superior a 50 euros mensuales, ya que este segmento interactúa más con sistemas de recomendación basados en IA. Se priorizaron usuarios habituales de plataformas como Instagram, TikTok, Amazon, Shein o Zalando. Se esperaba que al menos el 60 % de los encuestados tuviera un nivel medio o alto de familiaridad digital, aunque también se incluyeron usuarios con menos experiencia para capturar la diversidad de percepciones.

La encuesta se distribuyó principalmente a través de redes sociales como Instagram y TikTok, grupos especializados en tecnología, consumo digital y comercio electrónico, y correo electrónico directo a contactos que cumplieran el perfil. El objetivo era entre 100 y 150

respuestas válidas. El periodo de recogida duró aproximadamente tres semanas.

Al cerrar la recogida, se aplicaron criterios de exclusión: respuestas que no superaran la pregunta de control, cuestionarios incompletos con más del 20 % de preguntas sin responder, patrones de respuesta sospechosos —como seleccionar siempre el mismo valor en todas las escalas Likert— y tiempos de cumplimentación inferiores a 4 minutos o superiores a 30. Se esperaba una tasa de respuestas válidas superior al 85 %.

Los participantes fueron informados al inicio del carácter académico del estudio, del tratamiento anónimo y confidencial de sus respuestas, y de su derecho a abandonar el cuestionario en cualquier momento, garantizando el cumplimiento de los principios éticos de la investigación y de la normativa de protección de datos (European Parliament and Council, 2016). La duración estimada fue de entre 8 y 12 minutos. El análisis se realizó con software estadístico especializado, con un nivel de significancia de $p < 0,05$.

Aunque la muestra es representativa del perfil de consumidores digitales activos, hay limitaciones que conviene tener en cuenta. El sesgo de autoselección derivado de la participación voluntaria puede sobrerrepresentar a personas con mayor interés en tecnología. Pueden aparecer también sesgos de deseabilidad social en respuestas sobre privacidad y confianza. El momento de recogida de datos, en un contexto de rápida evolución tecnológica, limita la generalización temporal de los resultados. Y la limitación geográfica a consumidores españoles puede condicionar percepciones culturales que no se extrapolan a otros contextos. Estas limitaciones se tienen en cuenta en la interpretación de los resultados y en las conclusiones finales.

2.3. Análisis de los datos recopilados

Una vez cerrada la fase de recogida de datos, se analizó de forma sistemática la información obtenida para extraer conclusiones que respondieran a las preguntas de investigación. El capítulo se divide en dos partes: el análisis de los datos del focus group mediante técnicas de análisis de contenido y visualización, y el análisis de la encuesta con técnicas estadísticas descriptivas para identificar tendencias y relaciones entre variables. Ambas perspectivas se complementan.

2.3.1. Análisis del Focus Group

El análisis de los datos cualitativos del focus group se hizo combinando técnicas de análisis textual en Python con un análisis temático formal basado en el procedimiento de seis fases de Braun y Clarke (2006). Esta combinación permitió identificar temas recurrentes, visualizar conceptos frecuentes y sistematizar los resultados.

Primero se usó una plataforma de transcripción automática para convertir la grabación de audio en texto, preservando la fidelidad de los testimonios mediante seudónimos para

proteger el anonimato de los participantes. Aunque existen varias opciones disponibles como *Otter.ai*, la herramienta concreta se eligió en función de criterios de precisión, compatibilidad con el español y disponibilidad institucional.

Una vez obtenida la transcripción, se hizo un Análisis Exploratorio de Datos (EDA) para tener una visión general del contenido y facilitar la identificación preliminar de conceptos clave. Esta fase requirió un preprocesamiento previo: limpieza del texto, eliminación de palabras vacías en español y normalización de términos. Fue especialmente importante aplicar técnicas de lematización para agrupar variaciones morfológicas de un mismo concepto, de modo que términos como “comprar”, “compra” y “comprado” se contabilizaran como una única unidad semántica.

Para complementar este preprocesamiento, se usaron varias herramientas de Python. El procesamiento lingüístico se hizo con la librería *spaCy* (Honnibal y Montani, 2017) y el modelo *es_core_news_sm*, que lematiza con precisión en castellano. La lista de palabras vacías base vino de la librería *NLTK* (Bird, Klein, y Loper, 2009) y se completó con un listado personalizado adaptado al contexto del estudio. La eliminación de palabras vacías se aplicó en dos fases: una primera pasada previa a la lematización, para eliminar términos genéricos en su forma original, y una segunda pasada posterior, para filtrar las formas base que *spaCy* genera a partir de verbos auxiliares, adverbios y otras palabras genéricas que podrían distorsionar los resultados. Este doble filtrado permitió obtener un corpus más representativo del contenido sustantivo del discurso. El análisis de frecuencias se hizo con la clase *Counter* de Python, cuantificando la aparición de conceptos relacionados con los seis temas de interés definidos a partir del marco teórico: confianza, privacidad, personalización, transparencia, autonomía y recomendación. Para la visualización, se usó la librería *WordCloud* (Mueller, 2012) para generar una nube de palabras con los términos más frecuentes, y *matplotlib* (Hunter, 2007) para elaborar gráficos de barras que facilitaran la comparación visual de las palabras más frecuentes y la relevancia relativa de cada tema.

El núcleo del análisis cualitativo siguió el procedimiento de análisis temático de Braun y Clarke (2006), con seis fases sistemáticas para identificar, organizar e interpretar temas. El enfoque fue mixto deductivo-inductivo: por un lado, se partió de categorías del marco teórico (confianza, privacidad, personalización, transparencia y autonomía) como estructura inicial; por otro, se dejó espacio para que emergieran categorías nuevas a partir de los propios datos.

El proceso empezó con una lectura iterativa de las transcripciones para familiarizarse con el contenido (fase 1). Luego se identificaron unidades de significado relevantes y se asignaron códigos descriptivos (fase 2). Estos códigos se agruparon en temas más amplios, combinando las categorías teóricas con las que emergieron de los datos (fase 3). Después se revisó la coherencia interna de los temas (fase 4), se definieron y nombraron con precisión (fase 5) y se redactaron los resultados con citas textuales representativas (fase 6). Este procedimiento no solo capturó la frecuencia de los conceptos, sino también su significado cualitativo dentro del discurso de los participantes, garantizando que la estructura analítica respondiera tanto

al marco teórico como a los resultados empíricos.

Todo lo que salió del focus group sirvió para diseñar la encuesta que se llevó a cabo en la segunda parte del estudio de campo.

Es verdad que hacer un solo focus group con cinco personas tiene sus limitaciones evidentes. Pero el objetivo de esta fase nunca fue generalizar nada: era explorar, entender qué preocupa a la gente y usar eso para diseñar bien la encuesta posterior. Y para eso, cumplió.

2.3.2. Análisis de la Encuesta

El análisis de los datos de la encuesta se hizo aplicando técnicas estadísticas descriptivas apropiadas a la naturaleza de las variables y a los objetivos de investigación. El análisis se estructuró en tres fases: análisis descriptivo del perfil sociodemográfico, análisis descriptivo de las variables de interés, y análisis de relaciones entre variables mediante tests estadísticos para identificar asociaciones significativas y ampliar lo que reveló el focus group.

La primera fase fue el análisis descriptivo del perfil sociodemográfico, presentando la distribución de variables como edad, género, nivel educativo, sector profesional, frecuencia de compra online y nivel de ingresos mediante gráficos que facilitan la visualización de la composición de la muestra. Este análisis inicial permitió verificar que la muestra fuera representativa del perfil objetivo definido en la metodología. La segunda fase fue el análisis descriptivo de cada variable de interés, presentando distribuciones de frecuencia, medidas de tendencia central (como la media) y medidas de dispersión según la naturaleza de cada variable. Esto proporcionó una primera aproximación a los comportamientos y percepciones de los encuestados.

La tercera fase aplicó tests estadísticos para identificar relaciones significativas entre variables. La elección del test dependió de la naturaleza de las variables. La Tabla 2.1 resume los principales tests aplicados.

Para analizar si existe asociación entre dos variables categóricas —como el uso o no uso de sistemas de IA y el sector profesional del encuestado— se usó el test Chi-cuadrado de independencia (Field, 2013). Este test determina si la distribución de una variable categórica depende de los valores de otra, considerándose significativo cuando el valor p es inferior a 0,05.

Para medir la intensidad de la relación entre dos variables continuas —como el nivel de confianza en sistemas de IA y la frecuencia de uso, ambas en escala 0-10— se calculó el coeficiente de correlación de Pearson (Field, 2013). Toma valores entre -1 y +1: cercano a +1 indica relación positiva fuerte, cercano a -1 relación negativa fuerte, y cercano a 0 ausencia de relación lineal.

Para variables ordinales medidas con escalas Likert —como el grado de acuerdo con afirmaciones sobre transparencia algorítmica y el nivel de satisfacción con sistemas de IA— se calculó el coeficiente de correlación de Spearman (Field, 2013). Es el más apropiado para

Tabla 2.1: Tests estadísticos descriptivos aplicados

Test Estadístico	Qué Mide	Cómo se Mide
Chi-cuadrado	Asociación entre dos variables categóricas	Compara frecuencias observadas con frecuencias esperadas bajo independencia. Significativo si $p < 0.05$
Correlación de Pearson	Relación lineal entre dos variables continuas	Coeficiente entre -1 y +1 que indica intensidad y dirección de la relación. Significativo si $p < 0.05$
Correlación de Spearman	Relación monótona entre variables ordinales	Coeficiente entre -1 y +1 aplicado a rangos de las variables. Apropiado para escalas Likert. Significativo si $p < 0.05$
Test t de Student	Diferencia de medias entre dos grupos independientes	Compara medias de una variable continua entre dos grupos. Significativo si $p < 0.05$

variables ordinales y mide relaciones monótonas sin asumir linealidad.

Para comparar las medias de una variable continua entre dos grupos independientes — como el nivel de confianza entre usuarios frecuentes y esporádicos— se aplicó el test t de Student para muestras independientes (Field, 2013). Permite determinar si la diferencia entre las medias de ambos grupos es estadísticamente significativa o puede atribuirse al azar.

Todos los análisis se hicieron con un nivel de significancia de $p < 0,05$. Los resultados se presentan en tablas con los valores estadísticos relevantes y las medidas descriptivas necesarias, y su interpretación en relación con los temas teóricos del estudio se desarrolla en el capítulo de conclusiones.

Esta metodología permite estudiar el comportamiento del consumidor frente a la IA de forma completa. El análisis documental da la base teórica; el focus group aporta profundidad y permite explorar cosas que una encuesta no recoge; y la encuesta contrasta esos resultados con una muestra más amplia. Cada técnica tapa los huecos que las otras dejan.

Capítulo 3

Marco Teórico

La inteligencia artificial lleva ya un tiempo dejando su huella en cómo compramos. Lo que antes era anecdótico —una recomendación por aquí, un chatbot por allá— se ha acabado convirtiendo en algo bastante sistemático: hoy, casi cualquier interacción con una plataforma de comercio electrónico pasa por algún tipo de sistema inteligente. La literatura académica reciente lo confirma: entre 2022 y 2026, los estudios empíricos han documentado cambios importantes en cómo se usa y acepta esta tecnología, en la confianza que genera y en el propio proceso de decisión del consumidor (Mogaji y Jain, 2024).

Bunea et al. (Bunea, Corboș, Mișu, Triculescu, y Trifu, 2024), en el *Journal of Theoretical and Applied Electronic Commerce Research*, analizaron una muestra de 1.128 jóvenes de la Generación Z usando modelos PLS-SEM. El resultado viene a decir que cuanto más expuesto estás a la IA, más útil te parece, y cuanto más útil te parece, más probable es que termines comprando online. La familiaridad reduce la fricción, básicamente. Cuanto más familiarizado está el consumidor con la IA, mayor es su disposición a usarla para comprar.

Pero esa familiaridad no se distribuye igual. Guerra-Tamez et al. (Guerra-Tamez, Kraul Flores, Serna-Mendiburu, Chavelas Robles, y Ibarra Cortés, 2024), en *Frontiers in Artificial Intelligence*, estudiaron cómo la Generación Z interactúa con sistemas de recomendación y vieron que estas herramientas influyen en la confianza hacia las marcas y en cómo se toman las decisiones de compra. En el otro extremo del espectro generacional, Zhang, Zhu, y Wang (2023) revisó 83 estudios sobre la adopción de tecnología en personas mayores y concluyó que factores personales, tecnológicos y sociales inciden de forma importante en la aceptación. Lo que se saca de aquí es bastante intuitivo pero importante: aunque el uso de la IA se ha extendido mucho, no todo el mundo llega a ella del mismo modo ni con las mismas expectativas.

Uno de los temas más trabajados en la literatura es la confianza. Chen et al. (Chen, Prentice, Weaven, y Hisao, 2022), en *Frontiers in Psychology*, demostraron mediante ecuaciones estructurales que confiar en un sistema de IA se traduce en mayor compromiso y lealtad del cliente. La interactividad y la sensación de humanidad en los sistemas conversacionales son

claves para que esa confianza se desarrolle. Sin eso, da igual que el chatbot sea eficiente: puede acabar generando rechazo igualmente.

En cuanto al proceso de compra en sí, la IA ha ganado terreno sobre todo en las fases de búsqueda y comparación. Más del 80 % de los consumidores la encuentran especialmente útil para descubrir y evaluar alternativas. Y lo que se ha observado es un efecto acumulativo: cuanto más la usan, más confían en ella, y más predisposición muestran hacia la compra online (Chen et al., 2022).

Más allá de quién usa la IA y con qué frecuencia, la investigación ha empezado a preguntarse por qué la gente confía en ella y cómo termina influyendo en lo que compra. Un marco útil distingue entre consumidores con motivaciones utilitarias —que buscan funcionalidad— y motivaciones hedónicas —que buscan placer o experiencia. Los primeros tienden a confiar más en las recomendaciones de IA cuando evalúan atributos objetivos; los segundos prefieren el criterio humano cuando la decisión tiene una carga emocional. Esto ayuda a entender por qué la misma tecnología genera respuestas tan distintas según el tipo de compra o de consumidor (Dhar y Wertenbroch, 2000).

La precisión de la información también tiene su papel. Cuando un sistema ofrece datos numéricos detallados, el consumidor percibe más sofisticación y, con ello, más confianza. Cuando hay riesgo percibido elevado —una compra cara, un producto de salud— esa confianza se vuelve el factor más determinante para aceptar o rechazar la recomendación (Glikson y Woolley, 2020).

Otro aspecto que aparece con frecuencia en la investigación es la autonomía algorítmica: cuánto decide el sistema y cuánto decide la persona. Los estudios basados en la teoría de la autodeterminación indican que la relación no es lineal. Niveles moderados de autonomía del sistema favorecen la aceptación; si el sistema decide demasiado, el consumidor siente que pierde el control y se echa atrás (Fan y Liu, 2022). Hay un punto de equilibrio, y cuando el sistema se pasa de ese punto, el efecto se da la vuelta.

También se ha visto cómo cambia el camino que sigue el consumidor antes de comprar. Los modelos clásicos —detectar una necesidad, buscar información, comparar, decidir— están siendo reemplazados por algo más fluido y menos lineal. Los sistemas de IA anticipan necesidades, filtran información y comparan opciones antes de que el propio consumidor lo pida. Varios autores hablan de una “compresión del recorrido de compra”: etapas que antes llevaban días se concentran en una sola interacción mediada por un algoritmo (Fan y Liu, 2022).

Hermann y Puntoni (Hermann y Puntoni, 2024) contribuyeron de forma importante a este debate al distinguir entre IA predictiva —que anticipa lo que harás— e IA generativa —que crea propuestas nuevas a partir de lo que ya sabes. Ambas afectan al consumidor, pero de maneras distintas. Entender esa diferencia es clave para estudiar sus efectos. En paralelo, Mogaji y Jain (Mogaji y Jain, 2024) señalan que la IA generativa está cambiando la forma en que la gente busca recomendaciones e información sobre productos, algo que hace solo

unos años era impensable.

El contexto también importa. Dias et al. (Dias, Gonçalves, da Costa, Pereira, y Dias, 2023) documentaron que la pandemia de COVID-19 aceleró la adopción de la IA en entornos comerciales y disparó el interés académico por entender sus efectos. Desde entonces, la investigación en este campo no ha parado de crecer, con aportaciones desde el marketing, la psicología, la economía y la informática.

Hay, sin embargo, aspectos que la literatura todavía trata con menos profundidad. Rohden et al. (Rohden y Zeferino, 2023) muestran que la mayoría de los consumidores no entiende cómo funcionan los sistemas de recomendación que usan. Eso genera inseguridad. Y esa inseguridad frena la adopción más que la tecnología en sí. Se puede reducir con transparencia y con experiencias positivas, pero no desaparece sola.

El sesgo algorítmico es otra preocupación real. Belenguer (Belenguer, 2022) señala que abordarlo exige un enfoque interdisciplinar, porque la investigación actual está bastante dividida entre quienes lo analizan desde la filosofía o la sociología y quienes se centran en el código. Lo que ha surgido con fuerza en los últimos años es el concepto de “sesgo ensamblado” (Waller y Waller, 2022): un tipo de sesgo que no está en los datos originales, sino que el propio sistema genera durante su funcionamiento. El resultado puede ser discriminación hacia grupos ya vulnerables, sin que nadie lo haya programado explícitamente. Y lo peor es que es difícil de detectar y muy fácil de perpetuar.

En el plano económico, Gonzales (Gonzales, 2023) encontró un impacto positivo y significativo de la IA en el crecimiento económico a largo plazo, y Wagner (Wagner, 2020) la conceptualiza como un nuevo factor de producción que está redefiniendo las relaciones económicas tradicionales.

En conjunto, la literatura es bastante clara: la IA ya no es solo una herramienta de apoyo, sino que juega un papel activo en cómo la gente decide qué comprar. Cuanto más la usan, más confían en ella, y los sistemas son cada vez más autónomos. Todo eso ha cambiado de forma notable la manera en que los consumidores descubren, comparan y compran productos. Y el hecho de que la investigación sobre este tema no pare de crecer confirma que todavía queda mucho por explorar.

Como se observa en la Tabla 3.1, la literatura ha apostado principalmente por metodologías cuantitativas (modelos PLS-SEM, ecuaciones estructurales, experimentos). Este estudio incorpora también el focus group porque en un campo tan nuevo hacen falta enfoques que combinen distintas perspectivas, especialmente cuando se trata de capturar las contradicciones y matices que una encuesta sola no recoge.

Tabla 3.1: Resumen de los estudios incluidos en la literatura del arte

Referencia	Descripción del estudio	Conclusiones principales
(Mogaji y Jain, 2024)	Análisis conceptual sobre cómo la IA generativa está transformando el comportamiento del consumidor y sus implicaciones para la investigación, la práctica empresarial y las políticas públicas.	La IA generativa modifica la forma en que los consumidores buscan información, interactúan con marcas y toman decisiones de compra.
(Bunea et al., 2024)	Estudio empírico con 1.128 participantes de la Generación Z usando modelos PLS-SEM para analizar la percepción y uso de la IA en el comercio electrónico.	La exposición y el uso de herramientas de IA aumentan la utilidad percibida y la facilidad de uso, lo que incrementa las intenciones de compra online.
(Guerra-Tamez et al., 2024)	Investigación sobre la influencia de la IA en la confianza hacia la marca y el comportamiento de compra en consumidores de la Generación Z.	Las recomendaciones impulsadas por IA influyen en la confianza en la marca y en las decisiones de compra.
(Chen et al., 2022)	Estudio basado en modelos de ecuaciones estructurales en el sector de economía colaborativa para analizar la relación entre IA, confianza del consumidor, engagement y lealtad.	Confiar en sistemas impulsados por IA se traduce en mayor compromiso y lealtad del cliente.
(Dhar y Wertenbroch, 2000)	Investigación sobre la toma de decisiones del consumidor entre productos utilitarios y hedónicos.	Las motivaciones utilitarias y hedónicas explican diferencias en cómo se evalúan las decisiones de consumo, influyendo en la aceptación de herramientas tecnológicas según el tipo de producto.
(Glikson y Woolley, 2020)	Revisión de estudios empíricos sobre la confianza humana en sistemas de inteligencia artificial.	La percepción de precisión, competencia y fiabilidad del sistema aumenta la confianza del usuario e influye directamente en su intención de uso.
(Fan y Liu, 2022)	Estudio sobre el impacto de la autonomía algorítmica en la toma de decisiones del consumidor basado en la teoría de la autodeterminación.	Hay una relación en forma de U invertida: niveles moderados de autonomía aumentan la aceptación, pero si la autonomía es excesiva el consumidor siente que pierde el control y la rechaza.
(Hermann y Puntoni, 2024)	Desarrollo de un marco conceptual que distingue entre IA predictiva y generativa en contextos de consumo.	Cada tipo de IA influye de manera distinta en el comportamiento del consumidor y en el proceso de decisión.
(Dias et al., 2023)	Estudio sobre el impacto de la pandemia de COVID-19 en la adopción de IA y en los cambios en la actividad empresarial.	La pandemia aceleró la digitalización y el uso de la IA, impulsando cambios en el comportamiento del consumidor y en las estrategias empresariales.
(Rohden y Zeferino, 2023)	Análisis de la percepción del riesgo del consumidor frente a los agentes de recomendación basados en IA.	No entender cómo funciona la IA genera inseguridad y aumenta el riesgo percibido, lo que frena su adopción.
(Belenguer, 2022)	Estudio sobre el sesgo algorítmico y sus implicaciones éticas en los modelos de toma de decisiones automatizadas.	Abordar la discriminación algorítmica requiere enfoques interdisciplinarios y un diseño más responsable de los sistemas de IA.
(Waller y Waller, 2022)	Investigación sobre el concepto de “sesgo ensamblado” en sistemas de aprendizaje automático generativos.	Los sistemas de IA pueden generar nuevas formas de discriminación durante su propio funcionamiento, aunque los datos originales no presenten sesgos explícitos.
(André et al., 2018)	Análisis conceptual sobre la autonomía del consumidor en la era del big data y la inteligencia artificial.	La IA puede hacer las decisiones más rápidas y eficientes, pero también puede reducir el sentido de control y autonomía del consumidor.

Referencia	Descripción del estudio	Conclusiones principales
(Gonzales, 2023)	Estudio econométrico basado en datos de panel internacionales sobre el impacto de la innovación en IA en el crecimiento económico.	La inteligencia artificial tiene un impacto positivo y significativo en el crecimiento económico a largo plazo.
(Wagner, 2020)	Marco teórico que conceptualiza la IA como un nuevo factor de producción en la economía.	La IA transforma las estructuras económicas tradicionales y redefine las relaciones entre empresas, mercados y consumidores.
(Tanlamai et al., 2024)	Experimento aplicado al sector retail para identificar oportunidades de arbitraje mediante IA.	Los modelos de IA pueden detectar oportunidades económicas con alta precisión y generar beneficios financieros medibles.
(Reif et al., 2025)	Estudio experimental sobre la percepción social del uso de herramientas de IA.	Usar IA puede generar penalizaciones sociales: otros te perciben como menos competente o menos esforzado.
(Mantilla Gonzales de la Coterá, 2019)	Análisis teórico sobre la paradoja de la privacidad en el entorno digital.	Los consumidores dicen preocuparse por la privacidad, pero siguen compartiendo datos personales en servicios digitales.

Capítulo 4

Trabajo de Campo

Este capítulo recoge los resultados de la metodología cualitativa descrita en el Capítulo 2. Primero se exponen los resultados del análisis del *focus group*: los del Análisis Exploratorio de Datos (EDA) hecho en Python y los del análisis temático formal basado en el procedimiento de seis fases de (Braun y Clarke, 2006). Después se presentan los resultados de la encuesta estructurada: el perfil sociodemográfico de la muestra, la descripción de las variables de interés y el análisis de relaciones entre variables mediante los *tests* estadísticos definidos en la metodología. Combinar ambas perspectivas da una imagen más completa de cómo se comportan los consumidores cuando la inteligencia artificial entra en juego en sus compras.

4.1. Resultados Estudio Cualitativo

Antes de entrar en los resultados, hay que tener claro una cosa: todo esto sale de un único *focus group* con cinco personas. Las frecuencias que se muestran no son representativas ni pretenden serlo. Su valor es otro: sirven para hacerse una idea inicial de por dónde van las cosas, detectar temas que merecen atención y, como se verá después, la encuesta confirma bastantes de las intuiciones que salieron aquí.

4.1.1. Nube de palabras y Análisis de frecuencias

La Figura 4.1 presenta la nube de palabras generada a partir del corpus final, y la Figura 4.2 muestra el gráfico de barras con las veinte palabras más frecuentes tras el doble filtrado y la lematización. Ambas visualizaciones reflejan los mismos datos.

El término más frecuente fue *caballo* con 20 apariciones, lo que se explica por el perfil específico de P1, cuyas intervenciones giraron en gran medida en torno a la compra de productos especializados para equitación. Esto evidencia una limitación inherente al tamaño reducido de la muestra: un único participante con un contexto de consumo muy particular




Figura 4.2: Gráfico de Frecuencias

(7). Esto encaja bien con el contenido del *focus group*, donde los sistemas de recomendación de *Amazon*, *Pinterest* y aplicaciones de supermercados fueron lo más comentado por todos los participantes.

Personalización y Autonomía obtuvieron el mismo número de menciones (49 cada una), lo que es especialmente revelador. En Personalización, los términos dominantes fueron *recomendación* (14), *recomendar* (13) y *algoritmo* (7), lo que refleja que los participantes perciben la personalización fundamentalmente a través de los sistemas de recomendación algorítmica. La presencia de *encasillado* (2) apunta a una percepción negativa de la personalización excesiva, donde los algoritmos limitan la variedad de opciones. En Autonomía, el término más frecuente fue *control* (12), seguido de *decidir* (8) y *decisión* (7), lo que refleja la preocupación recurrente de los participantes por mantener su propia capacidad de decisión. La presencia de *manipulación* (3), *influir* (5) e *influencia* (3) evidencia que una parte de los participantes percibe estos sistemas como potencialmente manipuladores.

Privacidad registró 28 menciones, con *dato* (6) como término principal, seguido de *privacidad* (4), *rastrear* (3), *escuchar* (3) y *compartir* (3). Aunque no fue el tema más mencionado, generó las intervenciones más cargadas emocionalmente de toda la sesión, especialmente por parte de P5, quien mostró un rechazo firme hacia cualquier forma de rastreo digital.

Transparencia acumuló 26 menciones, con *entender* (8) como término más frecuente, seguido de *transparencia* (6) y *transparente* (6). Es significativo que el verbo *entender* lidere este bloque: lo que piden los consumidores no es que las empresas publiquen información sobre sus algoritmos, sino que esa información sea comprensible y accesible. La mención de *caja* (2) en referencia a la expresión *caja negra* que usó P4 refuerza esta interpretación.

Confianza fue el tema con menos menciones (15), con *confiar* (3) y *confianza* (2) como términos principales. Pero este dato no significa que la confianza no sea relevante: más bien al contrario, apareció de forma implícita a lo largo de toda la sesión a través de otros temas —la fiabilidad de los precios (Recomendación), la preocupación por los datos personales




Figura 4.3: Distribución de menciones agrupadas por las seis dimensiones de interés definidas

(Privacidad) o la demanda de explicabilidad algorítmica (Transparencia). La confianza actuó como un concepto de fondo que impregnó el discurso sin ser nombrado explícitamente con la misma frecuencia.

4.1.2. Análisis temático manual

Siguiendo el procedimiento de (Braun y Clarke, 2006), se identificaron 34 códigos descriptivos extraídos de las intervenciones de los cinco participantes. Estos códigos se agruparon progresivamente en categorías más amplias hasta definir siete temas principales. Cinco corresponden a las categorías deductivas del marco teórico —confianza, privacidad, personalización, transparencia y autonomía—, y dos emergieron de forma inductiva a partir de los propios datos: el sesgo algorítmico y la brecha generacional en la adopción tecnológica. Por ejemplo, códigos como *verificar con veterinario*, *contrastar con manuales oficiales* y *leer reseñas negativas* se agruparon bajo el tema de confianza condicionada, al compartir un mismo comportamiento de validación externa de la información de la IA. Del mismo modo, *encasillamiento en un estilo*, *solo productos de caballos* y *solo marca blanca* convergieron en el tema de personalización y encasillamiento algorítmico.

Vale la pena señalar que el tema de Recomendación, que registró la mayor frecuencia en el análisis exploratorio (59 menciones), no se convirtió en un tema independiente en el análisis temático, ya que su contenido se distribuyó entre varios temas, especialmente Personalización y Autonomía. Los sistemas de recomendación fueron el vehículo a través del cual los participantes experimentaron tanto la personalización como la influencia algorítmica en sus decisiones, por lo que tratarlos como tema aparte habría generado redundancia. La Tabla X presenta un resumen de los siete temas, sus códigos representativos y los participantes que

contribuyeron a cada uno.

Tabla 4.1: Resumen del análisis temático: temas, códigos y participantes

Tema	Códigos representativos	Participantes	Origen
Confianza condicionada	Confío pero verifico, contraste con experto, porcentaje de acierto, riesgo de error	P1, P3, P4, P5	Deductivo
Paradoja de la privacidad	Saben todo pero sigo usando, intercambio privacidad-conveniencia, rastreo, sin alternativas	P1, P2, P3, P5	Deductivo
Personalización y encasillamiento	Encasillado en un estilo, solo caballos, solo marca blanca, burbuja de recomendación	P1, P2, P3	Deductivo
Transparencia y explicabilidad	Caja negra, no sé por qué me recomienda esto, quiero entender, botón de sorpréndeme	P1, P3, P4	Deductivo
Autonomía frente a conveniencia	Pérdida de control, manipulación, libertad de elección, calculadora avanzada, actitud crítica	P1, P2, P3, P4, P5	Deductivo
Sesgo algorítmico	Anuncios por género, estereotipos, discriminación, auditoría de algoritmos	P2, P4, P5	Inductivo
Brecha generacional	Crecí con internet, me costó adaptarme, confianza intuitiva vs. analítica	P1, P2, P3	Inductivo

A continuación se presentan los resultados por temas, con citas textuales representativas.

Confianza Condicionada. La confianza de los participantes en los sistemas de IA no es absoluta ni binaria: es gradual y condicionada. El comportamiento dominante fue lo que P4 resumió como *“confío pero verifico”*. P1 lo ilustró al hablar de su uso de *ChatGPT* para consultar productos veterinarios: *“No sustituye al veterinario, pero me prepara para la consulta”*. P3 cuantificó su confianza estimando que la IA acierta *“un 70-80% de las veces con los precios”*, una confianza basada en la experiencia pero sujeta a verificación. Un dato relevante es que esa confianza está directamente ligada al riesgo percibido del error: P1 señaló que *“no es lo mismo equivocarte comprando una camiseta que equivocarte con una medicina para un animal”*, lo que sugiere que a mayor riesgo, mayor es la necesidad de contrastar con fuentes expertas. Esto encaja con el análisis de frecuencias por temas, donde Confianza registró el menor número de menciones explícitas (15) precisamente porque apareció de forma implícita a través de otros temas.

Paradoja de la Privacidad. La privacidad generó las intervenciones más cargadas emocionalmente de toda la sesión. P1 articuló la contradicción central: *“Sabes que te están vigilando pero sigues ahí porque te resulta cómodo y porque no hay muchas alternativas”*. P3 lo definió como *“un intercambio: tu privacidad por conveniencia”*. En el extremo opuesto, P5 mantuvo un rechazo firme al rastreo en contextos de consumo, aunque reconoció usar IA para estudiar, lo que sugiere que la resistencia se concentra específicamente en el ámbito comercial. P2 fue la más pragmática: *“ya nos están rastreando de todas formas [...] al menos que sea útil”*, reflejando una aceptación resignada del intercambio entre datos personales y

funcionalidad. Este comportamiento conecta directamente con la paradoja de la privacidad de Mantilla Gonzales de la Cotera (2019).

Personalización y encasillamiento algorítmico. Los participantes valoraron positivamente la personalización cuando la percibían como relevante, pero expresaron frustración cuando derivaba en encasillamiento. P2 describió cómo *Pinterest* la había limitado a un estilo concreto: *“como si pensara que solo me gusta un estilo cuando en realidad depende del momento”*. P1 experimentó algo similar con *Amazon*: *“busqué un regalo para mi hija y me seguían saliendo recomendaciones de mantas para caballos”*. P3 reconoció que el sistema *“siempre me recomienda marcas blancas y nunca marcas premium”*. Este comportamiento sugiere que los algoritmos tienden a crear burbujas de consumo que reducen progresivamente la exposición del usuario a alternativas distintas, lo que amplía los 49 registros del tema de Personalización, donde el término *encasillado* ya anticipaba esta percepción negativa.

Transparencia y explicabilidad. Esta dimensión emergió como consenso unánime al cierre de la sesión. P4 ofreció la metáfora más usada: *“Es una caja negra total [...] no sabes qué ha pasado en medio”*. P3 concretó la demanda: *“Si me dijeran ‘te recomendamos este producto porque has comprado estos otros tres’, pues vale, lo entiendo”*. Los consumidores no piden entender el algoritmo, sino recibir explicaciones comprensibles sobre por qué se les recomienda algo. P1 propuso poder decirle al sistema *“no me recomiendes más cosas de este tipo”*, mientras que P3 sugirió un *“botón de ‘sorpréndeme’”*. Ambas propuestas reflejan una demanda no solo de transparencia pasiva, sino de interactividad con los sistemas de recomendación.

Autonomía frente a conveniencia. Este tema generó el debate más polarizado de la sesión. P5 percibe la influencia de la IA como pérdida de autonomía: *“es como perder el control sobre tu propia vida [...] y lo peor es que mucha gente ni se da cuenta”*. P2 fue al contrario: *“al final yo decido si compro o no, nadie me obliga a darle al botón”*. P4 ofreció una síntesis que P1 y P3 respaldaron: *“si la usas como herramienta de apoyo, como una calculadora avanzada, mantienes el control”*. Lo más interesante de este debate es que la percepción de autonomía no depende tanto de la tecnología en sí como de la actitud del consumidor: quienes adoptaban una postura activa y crítica (contrastar, verificar, ignorar recomendaciones) percibían mayor control, mientras que quienes se dejaban guiar sin cuestionarlas reconocían mayor influencia algorítmica. Este resultado conecta con la relación en forma de U invertida entre autonomía algorítmica y decisión de compra descrita por (Fan y Liu, 2022).

Sesgo algorítmico. Esta dimensión emergió de forma inductiva, sin que la moderadora la planteara. P4 abrió el tema al mencionar sesgos de género: *“a las mujeres les muestran más anuncios de productos de limpieza y a los hombres más de tecnología”*. P2 lo confirmó con su propia experiencia: *“me salen muchos anuncios de maquillaje que nunca he buscado [...] supongo que es porque soy mujer joven”*. P5 fue directa: *“refuerza estereotipos y discriminación”*. P4 propuso que las empresas *“deberían auditar sus algoritmos regular-*

mente”, aunque reconoció que *“no lo implementan porque les cuesta dinero”*. Este tema conecta con la literatura sobre sesgo ensamblado (Belenguer, 2022; Waller y Waller, 2022) y resulta especialmente llamativo precisamente porque surgió de forma espontánea.

Brecha generacional. La segunda categoría inductiva fue la existencia de diferencias generacionales. P3 lo planteó abiertamente: *“vosotros los jóvenes habéis crecido con esto y lo veis más normal. Para los de mi edad es algo relativamente nuevo y nos cuesta más confiar”*. P1 coincidió: *“hace cinco años no compraba nada online y ahora compro bastante, pero siempre con cierta desconfianza”*. P2, en cambio, dijo que comprar online es *“incluso más normal”* que ir a una tienda. Más allá de la frecuencia de uso, el análisis reveló que la brecha se manifiesta en la naturaleza de la confianza: los participantes más jóvenes (P2, P4) mostraron una confianza más intuitiva basada en el uso continuado, mientras que los de mayor edad (P1, P3) desarrollaron una confianza más analítica, apoyada en la verificación sistemática.

En general, los siete temas vienen a confirmar lo que el análisis exploratorio ya apuntaba. Los que más menciones tenían en el EDA (Recomendación, Personalización y Autonomía) fueron también los que dieron más juego en el análisis temático. Y que Confianza saliera poco en el recuento de frecuencias tiene bastante lógica: estaba en todo el discurso, pero de forma implícita, sin que la gente dijera la palabra “confianza” tal cual. Con todo esto sobre la mesa, se pasó a diseñar la encuesta que se presenta a continuación.

4.2. Resultados de la Encuesta

Con los temas y códigos del focus group ya identificados, el siguiente paso fue diseñar la encuesta. Básicamente, se trataba de coger esos siete temas y convertirlos en preguntas concretas que permitieran ver si las percepciones que habían salido del grupo pequeño se repetían también cuando se preguntaba a más gente. Por ejemplo, la tensión entre autonomía y conveniencia, que generó el debate más polarizado, se tradujo en ítems que miden el grado de acuerdo con afirmaciones sobre la influencia de la IA en las decisiones de compra. La paradoja de la privacidad se convirtió en preguntas que evalúan a la vez la preocupación declarada por los datos personales y el comportamiento real de uso de plataformas que dependen de esos datos. Los temas inductivos de sesgo algorítmico y brecha generacional se incorporaron como variables adicionales que el *focus group* reveló como relevantes.

La encuesta se distribuyó a través de redes sociales, grupos especializados en tecnología y consumo digital, y correo electrónico directo a contactos que cumplieran el perfil objetivo. La recogida duró tres semanas y se obtuvieron 128 respuestas brutas.

Antes de analizar los datos, se aplicaron los criterios de exclusión definidos en la metodología para garantizar la fiabilidad de los resultados (Oppenheimer et al., 2009). Se aplicaron cuatro filtros de forma secuencial. Primero, se verificó el consentimiento informado:

1 respuesta fue excluida por no haberlo aceptado (European Parliament and Council, 2016). Segundo, se aplicó la pregunta de control o *attention check* (pregunta 11): de las 128 respuestas, 3 no la superaron —2 seleccionaron el valor 5 y 1 el valor 3—. Este tipo de preguntas detecta participantes que no leen las preguntas con atención y que podrían introducir ruido en los datos (Oppenheimer et al., 2009). Tercero, se revisaron los cuestionarios en busca de más del 20 % de preguntas sin responder; no se detectó ningún caso. Cuarto, se identificaron respuestas con el mismo valor en los 28 ítems Likert, lo que la literatura denomina *straight-lining* (Field, 2013): se detectó 1 caso. En cuanto al filtro de tiempos de cumplimentación previsto en la metodología, no fue posible aplicarlo porque Google Forms no registra de forma accesible el tiempo individual de respuesta de cada participante. Tras estos filtros, la muestra final fue de 123 respuestas válidas, una tasa de validez del 96,1 % sobre el total, que supera el umbral del 85 % establecido en la metodología. Con 123 observaciones se pueden aplicar los tests estadísticos previstos (Chi-cuadrado, correlaciones de Spearman y Pearson, y test t de Student) con un nivel de significancia de $p < 0,05$, ya que la literatura metodológica establece que muestras superiores a 100 observaciones son generalmente adecuadas para estos análisis (Field, 2013). El conjunto de datos anonimizado y los scripts de análisis están en el Anexo A.

La descripción del perfil sociodemográfico de los 123 encuestados válidos permite contextualizar los resultados posteriores. La edad media fue de 37,1 años, con un rango entre 18 y 83 años. El grupo más numeroso fue el de 18 a 24 años (36,4 %), seguido del de 45 a 55 años (24,0 %), 35 a 44 años (14,9 %), 25 a 34 años (13,2 %) y mayores de 55 años (11,6 %).




Figura 4.4: Distribución de la muestra por edad

La muestra está compuesta por 66 mujeres (53,7 %), 53 hombres (43,1 %), 3 participantes que prefirieron no indicar su género (2,4 %) y 1 respuesta sin dato (0,8 %).




Figura 4.5: Distribución por género

El 54,5 % posee un grado universitario o equivalente, el 21,1 % un máster o posgrado, el 20,3 % bachillerato o formación profesional, el 2,4% un doctorado y el 0,8% educación secundaria o inferior. En cuanto a la situación laboral: el 30,1 % son estudiantes, el 23,6 % empleados por cuenta ajena, otro 23,6 % autónomos o empresarios, el 12,2 % empleados en otra modalidad, el 6,5 % jubilados y el 1,6 % desempleados. La distribución por sector profesional abarca tecnología e informática (17,9 %), finanzas y banca (13,8 %), sanidad (10,6 %), marketing, publicidad y comunicación (8,9 %), administración pública (8,1 %), comercio y ventas (8,1 %), educación (6,5 %), ciencias jurídicas (4,1 %) y otros sectores (17,9 %).

El 22,8% declaró no tener ingresos propios, el 18,7% se sitúa entre 1.501 y 2.500 euros, el 17,9% entre 2.501 y 3.500 euros, el 18,7 % supera los 3.500 euros, el 6,5 % percibe menos de 1.000 euros y el 4,9% entre 1.000 y 1.500 euros; un 10,6% prefirió no revelar esta información. El gasto medio mensual en compras online se distribuye entre 51 y 100 euros (24,4 %), más de 200 euros (21,1 %), entre 25 y 50 euros (20,3 %), menos de 25 euros (17,1 %) y entre 101 y 200 euros (16,3 %).






Figura 4.6: Perfil sociodemográfico: situación laboral e ingresos



(a) Gasto mensual en compras online




(b) Nivel de familiaridad digital


Figura 4.7: Perfil sociodemográfico: gasto online y familiaridad digital

El 93,5 % de la muestra tiene un nivel de familiaridad digital medio o superior, cumpliendo el criterio metodológico de que al menos el 60 % de los encuestados tuviera un nivel medio o alto.

El 35,0 % compra online 1-2 veces al mes, el 18,7 % lo hace 3-4 veces, otro 18,7 % realiza 5 o más compras mensuales, el 23,6 % compra menos de una vez al mes y el 4,1 % no compra nunca online. El 81,3 % afirma haber interactuado con algún sistema de IA en un contexto de compra, frente al 18,7 % que declara no haberlo hecho. La frecuencia de uso de IA en compras (escala 0-10) tiene una media de 4,80 ($SD = 3,04$). El sistema más utilizado son las recomendaciones personalizadas de productos (22,8 %), seguidas de herramientas conversacionales como ChatGPT (22,0 %), feeds personalizados en redes sociales (15,4 %), comparadores inteligentes de precios (11,4 %), asistentes de voz (8,9 %) y chatbots de atención al cliente (6,5 %); un 12,2 % declaró no utilizar ninguno.




(a) Frecuencia de uso de IA (0-10)




(b) Sistema de IA más utilizado

Figura 4.8: Uso de inteligencia artificial en compras

El sector de compras predominante es moda y accesorios (35,8 %), seguido de ocio y entretenimiento (15,4 %), tecnología y electrónica (13,8 %) y alimentación y supermercado (11,4 %). La funcionalidad de IA más valorada son las recomendaciones personalizadas de productos (28,5 %), seguidas de la búsqueda y filtrado inteligente (23,6 %) y la comparación automática de precios (17,1 %). El 31,7 % paga actualmente por alguna herramienta de IA, frente al 67,5 % que no lo hace.



(a) Sector de compras



(b) Funcionalidad de IA más valorada

Figura 4.9: Sector de compras y funcionalidades de IA

El núcleo del análisis descriptivo son los factores determinantes en la decisión de compra con IA, que traducen los siete temas del *focus group* en escalas Likert de 1 a 5. La Tabla 4.2 presenta las medias y desviaciones típicas de todos los ítems agrupados por tema.

Tabla 4.2: Estadísticos descriptivos de los ítems Likert agrupados por dimensión

Dimensión	Ítem	$\bar{x}$	SD
Confianza	a) Confío en las recomendaciones de la IA	3,06	1,11
	b) Contrasto con otras fuentes antes de comprar	3,39	1,36
	c) Confío más en compras de bajo coste	3,26	1,28
	d) Información incorrecta reduce mi confianza	3,50	1,27
	e) Me preocupa la precisión de los precios	3,57	1,24
Privacidad	a) Me preocupa la cantidad de datos que recopilan	3,52	1,33
	b) Sigo usando plataformas pese a mi preocupación	3,45	1,29
	c) Siento que saben demasiado sobre mis hábitos	3,82	1,28
Personalización	a) Las recomendaciones suelen ser relevantes	3,24	1,13
	b) Los algoritmos me encasillan en un tipo de producto	3,19	1,09
	c) Me gustaría ver productos diferentes	3,36	1,18
	d) He descubierto productos nuevos gracias a la personalización	3,48	1,25
Transparencia	a) Entiendo por qué me recomiendan determinados productos	3,43	1,14
	b) Me gustaría que me explicaran por qué me recomiendan cada producto	3,49	1,28
	c) Los algoritmos funcionan como una “caja negra”	3,43	1,21
	d) Confiaría más si supiera qué datos se han utilizado	3,71	1,21
Autonomía y conveniencia	a) La IA influye en mis decisiones más de lo que me gustaría	2,85	1,20
	b) He comprado productos que no tenía previsto adquirir	2,63	1,35
	c) Mantengo el control total sobre mis decisiones	3,69	1,10
	d) Los sistemas están diseñados para manipular al consumidor	3,39	1,18
	e) La IA me facilita el proceso de compra y me ahorra tiempo	3,45	1,34
	f) La IA refuerza mis hábitos de compra	3,26	1,40
Sesgos algorítmicos	a) Las recomendaciones están sesgadas por género, edad u otras características	3,37	1,26
	b) Los algoritmos refuerzan estereotipos	3,33	1,28
	c) Las empresas deberían auditar regularmente sus algoritmos	3,92	1,09
Diferencias generacionales	a) Las personas más jóvenes confían más en la IA para comprar	4,13	1,00
	b) La edad influye en la disposición a adoptar IA en compras	4,22	0,90

En confianza, la confianza directa en las recomendaciones de IA registra la media más baja del bloque ($\bar{x} = 3,06$; $SD = 1,11$), mientras que la preocupación por la precisión de los precios alcanza la más alta ($\bar{x} = 3,57$; $SD = 1,24$). El hábito de contrastar con otras fuentes presenta una media de 3,39 ($SD = 1,36$), la confianza condicionada al riesgo de la compra una media de 3,26 ($SD = 1,28$), y la reducción de confianza tras información incorrecta una media de 3,50 ($SD = 1,27$).

En privacidad, el ítem *“siento que las plataformas saben demasiado sobre mis hábitos de consumo”* registra una media de 3,82 ($SD = 1,28$), con un 41,5 % de los encuestados marcando la puntuación máxima de 5. La preocupación por los datos personales alcanza una media de 3,52 ($SD = 1,33$). Al mismo tiempo, el ítem *“a pesar de mis preocupaciones sobre privacidad, sigo utilizando plataformas que recopilan mis datos porque me resultan convenientes”* presenta una media de 3,45 ($SD = 1,29$), con un 53,7 % en las puntuaciones 4 y 5.

En personalización, el descubrimiento de productos nuevos registra una media de 3,48 ($SD = 1,25$), con un 52,8 % en puntuaciones 4-5. La percepción de encasillamiento algorítmico presenta una media de 3,19 ($SD = 1,09$), con un 41,5 % en puntuaciones 4-5. El deseo de ver productos diferentes alcanza una media de 3,36 ($SD = 1,18$) y la relevancia percibida de las recomendaciones una media de 3,24 ($SD = 1,13$).

En transparencia, el ítem *“confiaría más en las recomendaciones si supiera exactamente qué datos se han utilizado para generarlas”* registra la media más alta del bloque ($\bar{x} = 3,71$; $SD = 1,21$), con un 61,0 % en puntuaciones 4 y 5. La percepción de los algoritmos como *“caja negra”* alcanza una media de 3,43 ($SD = 1,21$), la demanda de explicaciones claras una media de 3,49 ($SD = 1,28$), y la comprensión del funcionamiento de las recomendaciones una media de 3,43 ($SD = 1,14$).

En autonomía y conveniencia, el control percibido sobre las decisiones de compra registra una media de 3,69 ($SD = 1,10$), con un 57,7 % en puntuaciones 4 y 5. Las compras no previstas inducidas por la IA presentan una media de 2,63 ($SD = 1,35$), la percepción de manipulación una media de 3,39 ($SD = 1,18$), la valoración de la IA como facilitadora una media de 3,45 ($SD = 1,34$), y el refuerzo de hábitos de compra una media de 3,26 con la mayor dispersión del bloque ($SD = 1,40$). La influencia no deseada de la IA registra una media de 2,85 ($SD = 1,20$).

En sesgos algorítmicos, la demanda de auditorías algorítmicas registra una media de 3,92 ($SD = 1,09$), con un 40,7 % marcando la puntuación máxima. La percepción de sesgos por género o edad alcanza una media de 3,37 ($SD = 1,26$) y la creencia de que los algoritmos refuerzan estereotipos una media de 3,33 ($SD = 1,28$).

En diferencias generacionales, el ítem *“la edad influye en la disposición a adoptar nuevas tecnologías de IA en contextos de compra”* registra la media más alta de todos los ítems Likert de la encuesta ($\bar{x} = 4,22$; $SD = 0,90$), con un 81,3 % en puntuaciones 4 y 5. El ítem sobre la mayor confianza de los jóvenes alcanza una media de 4,13 ($SD = 1,00$), con un 77,2 %

en las puntuaciones superiores.

La influencia percibida de la IA en las decisiones de compra (escala 0-10) tiene una media de 5,46 ($SD = 2,45$), con el valor más frecuente en 6 (19,5%). La satisfacción general con la experiencia de uso de IA en compras alcanza una media de 6,24 ($SD = 2,47$) sobre 10, con el valor más frecuente en 8 (22,1%).




Figura 4.10: Influencia percibida y satisfacción general con IA en compras

El diferencial semántico sobre la percepción de los sistemas de recomendación se presenta en la Tabla 4.3. La importancia de los distintos factores en la decisión de compra con IA aparece en la Tabla 4.4, ordenada de mayor a menor media.

Tabla 4.3: Diferencial semántico: percepción de los sistemas de recomendación

Par de conceptos	$\bar{x}$	SD
Manipulador (1) — Útil (5)	3,26	1,14
Opaco (1) — Transparente (5)	2,87	1,01
Limitante (1) — Liberador (5)	3,12	1,09

Tabla 4.4: Importancia de los factores en la decisión de compra con IA (Likert 1-5)

Factor	$\bar{x}$	SD
Precio del producto	3,97	1,09
Protección de datos personales	3,93	1,17
Sensación de mantener el control sobre la decisión	3,89	1,04
Opiniones y reseñas de otros usuarios	3,62	1,22
Transparencia sobre por qué se recomienda el producto	3,51	1,13
Confianza en la recomendación del sistema	3,40	1,00

La plataforma percibida como más innovadora en el uso de IA es ChatGPT y otras herramientas de IA conversacional (24,4%), seguida de Amazon (21,1%), ninguna en particular (17,1%), Zara/Mango e Instagram/TikTok (11,4% cada una), Mercadona y otros supermercados online (8,9%) y Pinterest (1,6%). La influencia de la percepción de innovación tecnológica en la decisión de compra tiene una media de 5,93 ($SD = 2,87$) sobre 10, con un 48,8% en valores de 7 o superiores.




Figura 4.11: Plataforma percibida como más innovadora en IA

En cuanto a las expectativas de uso futuro, el 45,5% anticipa usar la IA “*un poco más que ahora*” y el 37,4% “*mucho más que ahora*”, lo que suma un 82,9% que prevé un incremento; el 10,6% prevé mantener el nivel actual, el 2,4% anticipa una reducción y el 4,1% se muestra indeciso.




Figura 4.12: Expectativas de uso futuro de IA en compras

Con todo esto ya descrito, la siguiente pregunta es si hay relaciones entre estas variables o si cada dato va por su lado.

Se aplican los tests estadísticos definidos en el capítulo de Metodología: correlación de Pearson para variables continuas, correlación de Spearman para variables ordinales, test t de Student para comparación de medias entre grupos independientes, y Chi-cuadrado para asociación entre variables categóricas (Field, 2013). Todos los análisis se hicieron con un nivel de significancia de $p < 0,05$. Los scripts están disponibles en el Anexo A. Los tests se organizan por los tres objetivos específicos del estudio, y sus resultados se resumen en las Tablas 4.5, 4.6 y 4.7.

Para el primer objetivo —contextualizar la importancia de la IA en el entorno digital y comercial actual— se analizaron tres relaciones. La Tabla 4.5 presenta los resultados.

Tabla 4.5: Tests estadísticos: Objetivo 1. Contextualización de la IA en el entorno digital

Variables cruzadas	Test	Estadístico	p-valor	Significativo
Frecuencia uso IA (P3) × Satisfacción general (P21)	Pearson	$r = 0,479$	$< 0,001$	Sí
Usuarios IA (P2=Sí) vs No usuarios → Influencia percibida (P16)	t de Student	$t = 3,370$	0,001	Sí
Interacción con IA (P2) × Paga por IA (P7)	Chi-cuadrado	$\chi^2 = 2,997$	0,083	No

La correlación de Pearson entre la frecuencia de uso de IA en compras y la satisfacción general arroja $r = 0,479$ ($p < 0,001$): una correlación positiva moderada y estadísticamente significativa. El test t de Student revela una diferencia significativa en la influencia percibida de la IA entre quienes han interactuado con estos sistemas ($\bar{x} = 5,80$; $SD = 2,27$) y quienes no lo han hecho ($\bar{x} = 3,96$; $SD = 2,74$), con $t = 3,370$ ($p = 0,001$). El test Chi-cuadrado entre la interacción previa con IA y el pago por herramientas de IA no alcanza significación ($\chi^2 = 2,997$; $p = 0,083$): no hay asociación estadísticamente significativa entre haber usado IA en compras y estar dispuesto a pagar por estas herramientas.

Para el segundo objetivo —evaluar la percepción real de los consumidores en términos de conocimiento, confianza y uso— se analizaron cuatro relaciones. La Tabla 4.6 presenta los resultados.

Tabla 4.6: Tests estadísticos: Objetivo 2. Percepción real del consumidor

Variables cruzadas	Test	Estadístico	p-valor	Significativo
Confianza en recomendaciones (P8a) × Satisfacción general (P21)	Spearman	$\rho = 0,568$	$< 0,001$	Sí
Preocupación privacidad (P9a) × Sigo usando plataformas (P9b)	Spearman	$\rho = 0,089$	0,340	No
Demanda transparencia (P12d) × Confianza en recomendaciones (P8a)	Spearman	$\rho = -0,020$	0,827	No
Percepción caja negra (P12c) × Diferencial Opaco-Transparente (P17b)	Spearman	$\rho = 0,104$	0,262	No

La correlación de Spearman entre la confianza en las recomendaciones de IA y la satisfacción general da $\rho = 0,568$ ($p < 0,001$): una correlación positiva moderada-alta y estadísticamente significativa. La correlación entre la preocupación por la privacidad y el uso continuado de plataformas pese a esa preocupación arroja $\rho = 0,089$ ($p = 0,340$): no es

significativa, lo que indica que la preocupación declarada y el comportamiento real de uso coexisten sin que una prediga a la otra. La correlación entre la demanda de transparencia y la confianza en las recomendaciones es prácticamente nula ($\rho = -0,020$; $p = 0,827$), no significativa. La correlación entre la percepción de los algoritmos como caja negra y el diferencial semántico Opaco-Transparente registra $\rho = 0,104$ ($p = 0,262$): tampoco significativa.

Para el tercer objetivo —identificar los beneficios percibidos y las preocupaciones asociadas al uso de la IA— se analizaron cinco relaciones. La Tabla 4.7 presenta los resultados.

Tabla 4.7: Tests estadísticos: Objetivo 3. Beneficios percibidos y preocupaciones

Variables cruzadas	Test	Estadístico	p-valor	Significativo
Percepción manipulación (P13d) $\times$ Control percibido (P13c)	Spearman	$\rho = 0,142$	0,120	No
IA facilita compra (P13e) $\times$ Satisfacción general (P21)	Spearman	$\rho = 0,528$	$< 0,001$	Sí
Jóvenes (18-34) vs Mayores (35+) $\rightarrow$ Confianza (P8a)	t de Student	$t = 1,950$	0,054	No
Jóvenes (18-34) vs Mayores (35+) $\rightarrow$ Frecuencia uso IA (P3)	t de Student	$t = -0,357$	0,721	No
Sistema IA más usado (P4) $\times$ Sector de compras (P5)	Chi-cuadrado	$\chi^2 = 57,928$	0,052	No

La correlación entre la percepción de que los sistemas de IA están diseñados para manipular y el control percibido sobre las decisiones registra $\rho = 0,142$ ($p = 0,120$): no significativa. La correlación entre la percepción de la IA como facilitadora del proceso de compra y la satisfacción general arroja $\rho = 0,528$ ($p < 0,001$): correlación positiva moderada y estadísticamente significativa. El test t de Student comparando la confianza en recomendaciones entre jóvenes ($\bar{x} = 3,25$; $SD = 1,05$; $N = 60$) y mayores ($\bar{x} = 2,86$; $SD = 1,11$; $N = 59$) da $t = 1,950$ con $p = 0,054$: no alcanza el umbral de significación. La comparación de la frecuencia de uso de IA entre ambos grupos tampoco muestra diferencias significativas ($t = -0,357$; $p = 0,721$), con medias de 4,72 para jóvenes y 4,92 para mayores. El test Chi-cuadrado entre el sistema de IA más utilizado y el sector de compras da $\chi^2 = 57,928$ ($p = 0,052$; 42 grados de libertad): tampoco alcanza significación estadística.

En conjunto, de los 12 tests ejecutados, 4 arrojan resultados estadísticamente significativos al nivel de $p < 0,05$: la correlación entre frecuencia de uso y satisfacción ($r = 0,479$), la diferencia de influencia percibida entre usuarios y no usuarios de IA ($t = 3,370$), la correlación entre confianza en recomendaciones y satisfacción ($\rho = 0,568$), y la correlación entre percepción de la IA como facilitadora y satisfacción ($\rho = 0,528$). Los 8 tests restantes no alcanzan significación estadística. Estos resultados, junto con todo lo visto en las secciones anteriores, se recogen en el Capítulo 5 para responder a los objetivos de investigación.

Capítulo 5

Conclusiones

Este capítulo cierra el trabajo juntando todo lo que ha ido saliendo del análisis documental, del focus group y de la encuesta. La idea es ver hasta qué punto se pueden responder los tres objetivos del Capítulo 1, y si los datos confirman lo que decía la literatura o más bien la matizan.

Primer objetivo: la IA en el entorno digital y comercial actual

El 81,3 % de los encuestados ya ha interactuado con algún sistema de IA al comprar. El 82,9% espera usarla más. Si había alguna duda sobre si la IA ha entrado de verdad en el consumo cotidiano, estos números la disipan. Y lo que resulta especialmente interesante es que quienes más la usan son también quienes más satisfechos están ($r = 0,479$; $p < 0,001$) —lo que cuadra con lo que encontraron Bunea et al. (2024): cuanto más familiar te resulta la IA, más útil te parece y más la usas. Además, quienes ya han tenido contacto con estos sistemas perciben una influencia mucho mayor en sus decisiones ($\bar{x} = 5,80$ frente a 3,96; $t = 3,370$; $p = 0,001$). No es solo que la usen más: es que reconocen que les afecta más.

En el focus group, los nombres que salieron de forma natural fueron *ChatGPT* y *Amazon* —los mismos que lideran el uso en la encuesta (22,0 % y 22,8 % respectivamente). Y hay un detalle que merece la pena destacar: P1 usaba la IA para encontrar productos especializados de equitación que no existían en tiendas físicas cercanas. No es un caso anecdótico; es un ejemplo de algo que Dias et al. (2023) vincularon con la digitalización acelerada tras la pandemia: la IA está ampliando el acceso a mercados que antes eran difíciles de alcanzar.

Segundo objetivo: percepción real del consumidor

El resultado más consistente de todo el estudio es la confianza condicionada. Aparece en el focus group —en el “confío pero verifico” de P4, en el “no sustituye al veterinario pero me prepara para la consulta” de P1— y en la encuesta, donde la confianza directa en las recomendaciones de IA tiene la media más baja de su bloque ($\bar{x} = 3,06$), pero el hábito de contrastar con otras fuentes llega a 3,39 y la preocupación por los precios a 3,57. Los consumidores no rechazan la IA, pero tampoco se entregan a ella. La usan, digamos, con cierta distancia. Glikson y Woolley (2020) ya explicaron que la confianza en sistemas de

IA se construye despacio y depende de la percepción de precisión y fiabilidad —y eso es exactamente lo que se ve aquí. La correlación entre confianza y satisfacción ($\rho = 0,568$; $p < 0,001$) lo confirma: cuando confías, disfrutas más. Cuando no confías del todo, te quedas en tierra de nadie.

Sobre la privacidad, la verdad es que hay poco que añadir a lo que los datos ya dicen por sí solos. El 41,5 % siente que las plataformas saben demasiado sobre ellos ($\bar{x} = 3,82$). El 53,7 % sigue usándolas igualmente. Y la correlación entre preocupación y uso continuado no es significativa ($\rho = 0,089$; $p = 0,340$). Dicho de otro modo: preocuparse no predice irse. Eso es la paradoja de la privacidad (Mantilla Gonzales de la Coteria, 2019), y P1 lo resumió mejor que cualquier escala: *“Sabes que te están vigilando pero sigues ahí porque te resulta cómodo y porque no hay muchas alternativas”*. Al final la comodidad gana. Casi siempre gana.

En cuanto a la transparencia, el ítem más valorado de todo el Bloque 2 fue “confiaría más si supiera qué datos se han utilizado” ($\bar{x} = 3,71$). Los consumidores no piden entender el código detrás del algoritmo —piden que alguien les diga, en lenguaje normal, por qué les aparece lo que les aparece. La “caja negra” que mencionó P4 no es una metáfora técnica: es la sensación real de no entender por qué el sistema hace lo que hace. Y esa sensación, según Rohden y Zeferino (2023), es uno de los principales frenos para la adopción.

Tercer objetivo: beneficios percibidos y preocupaciones

La IA tiene dos caras, y en este estudio se ven las dos con bastante claridad. Por un lado, el 52,8 % reconoce haber descubierto productos nuevos gracias a la personalización, y el 54,5 % valora que le facilita las compras y le ahorra tiempo. Los consumidores que perciben esa utilidad práctica están claramente más satisfechos ($\rho = 0,528$; $p < 0,001$). Por otro lado, el 41,5 % siente que los algoritmos le encasillan, el 47,2 % cree que los sistemas están diseñados para manipular, y la demanda de auditorías algorítmicas tiene una media de 3,92. Que el sesgo algorítmico apareciera en el focus group sin que la moderadora lo planteara —P4 habló de anuncios diferenciados por género, P5 lo llamó directamente discriminación— dice mucho. No es una preocupación académica abstracta: es algo que los consumidores detectan en su día a día (Belenguer, 2022; Waller y Waller, 2022).

La tensión entre autonomía y conveniencia fue el debate más vivo del focus group y también aparece con claridad en la encuesta. El 57,7 % dice mantener el control total sobre sus decisiones. Pero el 26,8 % reconoce haber comprado algo que no tenía pensado por influencia de la IA. Que ambas cosas sean ciertas al mismo tiempo no es incoherencia: es exactamente lo que Fan y Liu (2022) describieron. Y la clave, como apuntó P4 en el focus group, está en la actitud: quienes usan la IA como herramienta de apoyo —como una calculadora avanzada— mantienen el control. Quienes se dejan llevar por las recomendaciones sin cuestionarlas, no tanto.

Un último resultado merece atención especial. El ítem con mayor acuerdo de toda la encuesta fue que la edad influye en la disposición a usar IA ($\bar{x} = 4,22$): casi todo el mundo

cree que existe una brecha generacional. Pero cuando se comparan jóvenes (18-34 años) y mayores (35+) en confianza y frecuencia de uso, no hay diferencias estadísticamente significativas ($p = 0,054$ y $p = 0,721$). La brecha que todo el mundo percibe no aparece en los datos cuando la buscas. Eso no quiere decir que no exista —puede que se note más en el tipo de confianza que en la cantidad de uso— pero sí invita a ser algo más cauteloso con el discurso fácil de “los jóvenes y la tecnología”.

Contribuciones

Este estudio aporta tres cosas concretas. Primero, aplica en el contexto español una metodología que combina análisis documental, focus group y encuesta —un contexto poco representado en la investigación sobre IA y consumo. Segundo, identifica dos temas —sesgo algorítmico y brecha generacional— que los propios participantes introdujeron sin que se les preguntara, y que la literatura previa no había vinculado directamente al comportamiento de compra. Tercero, documenta la distancia entre la percepción de brecha generacional ($\bar{x} = 4,22$) y la ausencia de diferencias reales en el comportamiento ($p = 0,054$ y $p = 0,721$), lo que matiza algunas asunciones sobre cómo la edad afecta al uso de la tecnología.

Limitaciones

La muestra de 123 respuestas está dentro del rango previsto pero no llega a 150, en parte por el tiempo de recogida y en parte porque la difusión dependió de redes digitales, lo que probablemente sobrerrepresenta a personas con más interés en tecnología —el 93,5 % tiene un nivel de familiaridad digital medio o superior. El focus group fue uno solo, con cinco participantes: suficiente para la fase exploratoria, pero claramente insuficiente para hablar de generalización. El momento de recogida también importa: en un campo que cambia tan rápido, las percepciones de hoy pueden ser distintas en seis meses. Y la limitación geográfica a consumidores españoles hace difícil extrapolar los resultados a otros contextos culturales.

Líneas de investigación futura

Lo más inmediato sería ampliar la muestra y diversificarla geográficamente. Los estudios longitudinales también aportarían mucho en un campo que evoluciona tan deprisa. La brecha generacional percibida frente a la ausencia de diferencias estadísticas en el comportamiento real es, por sí sola, un filón: requeriría muestras segmentadas por edad mucho mayores y preguntas más finas sobre la naturaleza de la confianza, no solo su intensidad. Sería también valioso analizar si los consumidores reaccionan de forma diferente ante la IA predictiva y la generativa —la distinción de Hermann y Puntoni (2024) se quedó como marco teórico en este trabajo y merece tener su propio diseño empírico. Y hay una pregunta práctica que este estudio deja en el aire y que alguien debería abordar: ¿qué tipo de explicación sobre el algoritmo genera más confianza? ¿Un texto? ¿Un gráfico? ¿O simplemente dejar que la experiencia hable por sí sola?

En definitiva, lo que muestran los datos es un consumidor que usa la IA, que en general está satisfecho con ella, pero que no termina de fiarse del todo. Le preocupa lo que pasa con sus datos y no cambia su comportamiento por eso. Quiere entender cómo funciona el

sistema y acepta que no lo entiende. Cree que tiene el control y a veces compra cosas que no tenía pensadas. No es un consumidor irracional: es un consumidor humano, con todas las contradicciones que eso implica. Entender esas contradicciones —no solo medirlas— es lo que este trabajo ha intentado hacer.

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, Nombre del Estudiante, estudiante de Programa de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado “Nombre del TFG”, 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 multidisciplinarios: 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. Generador previo de diagramas de flujo y contenido: Para esbozar diagramas iniciales.

10. Sintetizador y divulgador de libros complicados: Para resumir y comprender literatura compleja.
11. Generador de datos sintéticos de prueba: Para la creación de conjuntos de datos ficticios.
12. Generador de problemas de ejemplo: Para ilustrar conceptos y técnicas.
13. Revisor: Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
14. Generador de encuestas: Para diseñar cuestionarios preliminares.
15. 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: Mes Año

Firma: Nombre del Estudiante

Apéndice A

Encuesta y datos de la investigación

La encuesta completa utilizada en este estudio, el conjunto de datos anonimizado con las respuestas de los 123 participantes válidos, la transcripción íntegra del *focus group*, y los scripts de Python empleados tanto para el análisis exploratorio de datos cualitativos como para la ejecución de los tests estadísticos, se encuentran disponibles en el siguiente repositorio digital para garantizar la transparencia metodológica y la replicabilidad del estudio:

<https://drive.google.com/drive/folders/1yPXfciWezh8V3y-zowjTcFeTDPHQ-XGk?usp=sharing>

El repositorio contiene los siguientes archivos:

- **Encuesta completa:** Cuestionario íntegro tal como fue distribuido a los participantes a través de Google Forms.
- **Datos de la encuesta:** Archivo CSV con las respuestas anonimizadas de los participantes.
- **Transcripción del focus group:** Transcripción completa de la sesión cualitativa con los seudónimos asignados a los participantes.
- **Script de análisis cualitativo:** Código Python utilizado para el preprocesamiento textual, la lematización, el análisis de frecuencias y la generación de la nube de palabras.
- **Script de tests estadísticos:** Código Python utilizado para la ejecución de los tests estadísticos (Chi-cuadrado, correlaciones de Pearson y Spearman, y test t de Student) presentados en el Capítulo 4.

Referencias

- André, Q., Carmon, Z., Wertenbroch, K., Crum, A., Frank, D., Goldstein, W., . . . Yang, H. (2018). Consumer choice and autonomy in the age of artificial intelligence and big data. *Customer needs and solutions*, 5(1), 28–37.
- Belenguer, L. (2022). Ai bias: exploring discriminatory algorithmic decision-making models and the application of possible machine-centric solutions adapted from the pharmaceutical industry. *AI and Ethics*, 2(4), 771–787.
- Bird, S., Klein, E., y Loper, E. (2009). *Natural language processing with Python*. Sebastopol, CA: O'Reilly Media.
- Braun, V., y Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3(2), 77–101.
- Bunea, O.-I., Corboş, R.-A., Mişu, S. I., Triculescu, M., y Trifu, A. (2024). The next-generation shopper: a study of generation-z perceptions of ai in online shopping. *Journal of Theoretical and Applied Electronic Commerce Research*, 19(4), 2605–2629.
- Chen, Y., Prentice, C., Weaven, S., y Hisao, A. (2022). The influence of customer trust and artificial intelligence on customer engagement and loyalty—the case of the home-sharing industry. *Frontiers in psychology*, 13, 912339.
- Dhar, R., y Wertenbroch, K. (2000). Consumer choice between hedonic and utilitarian goods. *Journal of marketing research*, 37(1), 60–71.
- Dias, T., Gonçalves, R., da Costa, R. L., Pereira, L. F., y Dias, Á. (2023). The impact of artificial intelligence on consumer behaviour and changes in business activity due to pandemic effects. *Human Technology*, 19(1), 121–148.
- European Parliament and Council. (2016). *Regulation (eu) 2016/679 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data (general data protection regulation)*. Official Journal of the European Union. (L 119/1)
- Fan, Y., y Liu, X. (2022). Exploring the role of ai algorithmic agents: The impact of algorithmic decision autonomy on consumer purchase decisions. *Frontiers in psychology*, 13, 1009173.
- Field, A. (2013). *Discovering statistics using ibm spss statistics* (4.^a ed.). London: SAGE Publications.

- Glikson, E., y Woolley, A. W. (2020). Human trust in artificial intelligence: Review of empirical research. *Academy of management annals*, 14(2), 627–660.
- Gonzales, J. T. (2023). Implications of ai innovation on economic growth: a panel data study. *Journal of Economic Structures*, 12(1), 13.
- Guerra-Tamez, C. R., Kraul Flores, K., Serna-Mendiburu, G. M., Chavelas Robles, D., y Ibarra Cortés, J. (2024). Decoding gen z: Ai's influence on brand trust and purchasing behavior. *Frontiers in artificial intelligence*, 7, 1323512.
- Hermann, E., y Puntoni, S. (2024). Artificial intelligence and consumer behavior: From predictive to generative ai. *Journal of Business Research*, 180, 114720.
- Honnibal, M., y Montani, I. (2017). *spacy 2: Natural language understanding with Bloom embeddings, convolutional neural networks and incremental parsing*. (To appear)
- Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90–95. doi: 10.1109/MCSE.2007.55
- Krueger, R. A., y Casey, M. A. (2014). *Focus groups: A practical guide for applied research* (5.^a ed.). Thousand Oaks, CA: SAGE Publications.
- Likert, R. (1932). A technique for the measurement of attitudes. *Archives of Psychology*, 22(140), 1–55.
- Malhotra, N. K. (2008). *Investigación de mercados* (5.^a ed.). México: Pearson Educación.
- Mantilla Gonzales de la Cotera, E. J. (2019). La paradoja de la privacidad de la información en los servicios de internet.
- Mogaji, E., y Jain, V. (2024). How generative ai is (will) change consumer behaviour: Postulating the potential impact and implications for research, practice, and policy. *Journal of consumer behaviour*, 23(5), 2379–2389.
- Morgan, D. L. (1997). *Focus groups as qualitative research* (2.^a ed.). Thousand Oaks, CA: SAGE Publications.
- Mueller, A. (2012). *Wordcloud for Python*. Descargado de https://github.com/amueller/word_cloud (Python library for generating word clouds)
- Oppenheimer, D. M., Meyvis, T., y Davidenko, N. (2009). Instructional manipulation checks: Detecting satisficing to increase statistical power. *Journal of Experimental Social Psychology*, 45(4), 867–872.
- Osgood, C. E., Suci, G. J., y Tannenbaum, P. H. (1957). *The measurement of meaning*. Urbana: University of Illinois Press.
- Reif, J. A., Larrick, R. P., y Soll, J. B. (2025). Evidence of a social evaluation penalty for using ai. *Proceedings of the National Academy of Sciences*, 122(19), e2426766122.
- Rohden, S. F., y Zeferino, D. G. (2023). Recommendation agents: an analysis of consumers' risk perceptions toward artificial intelligence. *Electronic Commerce Research*, 23(4), 2035–2050.
- Tanlamai, J., Khern-Am-Nuai, W., y Adulyasak, Y. (2024). Identifying arbitrage opportunities in retail markets with artificial intelligence. *AI & SOCIETY*, 39(5), 2615–2630.

- Wagner, D. N. (2020). Economic patterns in a world with artificial intelligence. *Evolutionary and Institutional Economics Review*, 17(1), 111–131.
- Waller, R. R., y Waller, R. L. (2022). Assembled bias: Beyond transparent algorithmic bias. *Minds and Machines*, 32(3), 533–562.
- Zhang, C., Zhu, D., y Wang, Y. (2023). A systematic review of technology adoption among older adults: Influencing factors and future directions. *Public Understanding of Science*, 32(8), 1012–1030.