



Facultad de Ciencias Económicas y Empresariales
Grado en Administración y Dirección
de Empresas

Trabajo Fin de Grado

**El impacto de los
agentes de IA en la
estrategia empresarial:**

Del riesgo de reemplazo a la creación
de valor sostenible

Alumno: Pablo Gómez Noverques

Directora: Carmen Escudero Guirado

Madrid, marzo 2026

Resumen

Los agentes de inteligencia artificial permiten a las empresas delegar procesos complejos con distintos grados de autonomía, pero la decisión sobre cómo implementarlos sigue siendo fundamentalmente estratégica. Este trabajo analiza esa decisión a través de una dicotomía entre dos enfoques: *cost-out*, orientado a la sustitución de trabajadores y la reducción de costes, y *capacity-up*, orientado a ampliar las capacidades del trabajador mediante colaboración humano-agente. Para ello, se construye un marco teórico que integra la *Turing Trap* de Brynjolfsson, los factores de delegación identificados por Strunk y otros, y un modelo de creación de valor de elaboración propia, con el objetivo de examinar no solo el impacto económico de estas tecnologías, sino también sus implicaciones organizativas, competitivas y regulatorias. Sobre esa base, se analizan dos casos de estudio: Klarna, que adoptó un enfoque de sustitución en atención al cliente, y McKinsey, que desarrolló el agente Lilli como herramienta de productividad sin reducción de plantilla. La evidencia sugiere que el enfoque *capacity-up* resulta más defendible estratégica, organizativa y regulatoriamente para empresas consolidadas. No obstante, el enfoque *cost-out* puede ser legítimo como fase transitoria en organizaciones con recursos limitados o en tareas altamente estandarizadas, siempre que sus riesgos de calidad, aceptación interna y sostenibilidad se gestionen adecuadamente.

Palabras clave: agentes de inteligencia artificial, estrategia empresarial, automatización, augmentación, *Turing Trap*, creación de valor, gobernanza de IA

Abstract

AI agents enable companies to delegate complex processes with varying degrees of autonomy, yet the decision on how to implement them remains fundamentally strategic. This paper examines that decision through a dichotomy between two approaches: cost-out, aimed at replacing workers and reducing costs, and capacity-up, aimed at expanding human capabilities through human-agent collaboration. To do so, it develops a theoretical framework that integrates Brynjolfsson's Turing Trap, the delegation factors identified by Strunk et al., and a proprietary value creation model, with the aim of examining not only the economic impact of these technologies, but also their organisational, competitive, and regulatory implications. On that basis, two case studies are analysed: Klarna, which adopted a substitution approach in customer service, and McKinsey, which developed the Lilli agent as a productivity tool without headcount reduction. The evidence suggests that the capacity-up approach is more defensible from a strategic, organisational, and regulatory standpoint for established firms. However, the cost-out approach may still be legitimate as a transitional phase in resource-constrained organisations or in highly standardised tasks, provided that its risks in terms of quality, internal acceptance, and long-term sustainability are properly managed.

Keywords: AI agents, business strategy, automation, augmentation, Turing Trap, value creation, AI governance

Índice

I. Introducción	5
I.1. Disrupción tecnológica en apuros	5
I.2. Metodología	7
I.3. Objetivos del trabajo	9
II. Marco teórico	10
II.1. Delegación, autonomía y tipología de agentes	10
II.1.1 Factores de delegación clave	10
II.1.2 Tipos de agentes por nivel de autonomía	12
II.2. Una dicotomía ante el cambio: <i>Cost-out & Capacity-up</i>	13
II.2.1 Implicaciones financieras	14
II.2.2 Matriz comparativa: cost-out frente a capacity-up	15
II.3. Modelo de creación de valor	15
II.4. La <i>Turing Trap</i> como marco analítico	17
II.5. Implicaciones para la gobernanza organizativa	19
III. Análisis	21
III.1. De la teoría a la práctica: dos caminos para una misma tecnología	21
III.2. Caso cost-out: Klarna y la sustitución en atención al cliente	21
III.2.1 Contexto y objetivos	21
III.2.2 Características del sistema y nivel de autonomía	22
III.2.3 Mecanismos de control y supervisión	22
III.2.4 Resultados y contrapunto	23
III.3. Caso capacity-up: McKinsey y el agente Lilli	24
III.3.1 Contexto y objetivos	24
III.3.2 Características del sistema y nivel de autonomía	25
III.3.3 Mecanismos de control y supervisión	25
III.3.4 Resultados y contrapunto	26
III.4. Importancia de la implementación	27
IV. Conclusión	30
V. Declaración del uso de IA	35
VI. Bibliografía	36

I. INTRODUCCIÓN

I.1. Disrupción tecnológica en apuros

A lo largo de toda la historia, las empresas han automatizado procesos: desde Henry Ford con la producción en serie hasta robots industriales o los diferentes *softwares* de gestión. Cada disrupción tecnológica que ha prometido eficiencia ha requerido una contraparte que decidiese qué tareas automatizar y cuáles mantener en manos humanas. Los agentes de inteligencia artificial¹ plantean una pregunta distinta. No solo qué automatizar, sino cuánta autonomía delegar en sistemas que pueden llegar a pensar, planificar y adaptarse independientemente.

A efectos de este trabajo, es fundamental empezar diferenciando un LLM (*large language model*) convencional de un agente de IA. Un LLM, como pueden ser ChatGPT o Gemini, responde a peticiones individuales, es decir, espera a recibir una instrucción, genera texto y se detiene. Un agente, en cambio, combina razonamiento, memoria contextual y acceso a sistemas externos para ejecutar procesos de múltiples pasos, adaptarse dinámicamente y mejorar su desempeño con el uso (Ransbotham, Kiron, Khodabandeh, Iyer, & Das, 2025). La diferencia no es de grado, es de naturaleza.

Un ejemplo permite comprender mejor este concepto que su mera definición. En el ámbito de una empresa aseguradora, un agente de inteligencia artificial puede analizar los daños sufridos por un vehículo tras un accidente, gestionar simultáneamente la interacción con el cliente y, de forma paralela, realizar una estimación de los desperfectos. Posteriormente, el sistema comunica su evaluación a un perito humano, quien valida el peritaje y culmina el proceso. De este modo, la intervención del trabajador humano se centra principalmente en la supervisión y en la fase final de la gestión.

Esta capacidad de autonomía da lugar a un mundo de posibilidades desde el punto de vista organizativo, pero también dilemas estratégicos sin precedentes. Las empresas no están esperando a resolver esos dilemas para actuar. El 35% de las organizaciones ya utilizan sistemas agénticos, y un 44% adicional planea hacerlo a corto plazo (Ransbotham, Kiron, Khodabandeh, Iyer, & Das, 2025). Para entender lo que eso significa, basta compararlo con la trayectoria de la IA tradicional que tardó ocho años en

¹ Agentes de inteligencia artificial, de aquí en adelante agentes de IA.

alcanzar el 72% de penetración, frente a los 2 años que ha necesitado la IA agéntica² para alcanzar el 35% (Ransbotham, Kiron, Khodabandeh, Iyer, & Das, 2025).

Sin embargo, esa velocidad es parte del problema. Gartner predice que más del 40% de los proyectos de IA agéntica serán cancelados antes de finales de 2027, por costes crecientes, falta de claridad sobre el valor de negocio o controles de riesgo inadecuados (Gartner, 2025). De cada diez empresas que invierten hoy en agentes, cuatro abandonarán habiendo perdido la inversión y, probablemente, habiendo generado tensiones internas que dificultarán cualquier iniciativa futura. Los datos de McKinsey confirman la brecha entre adopción e impacto. El 88% de las organizaciones usa IA en al menos una función, pero solo el 39% reporta un efecto medible en su EBIT³, y en la mayoría de los casos ese efecto no supera el 5% del total (McKinsey, 2025).

Esto no es la consecuencia de un fallo tecnológico. La tecnología, en la mayoría de los casos, funciona. El problema es estratégico. Comprar tecnología avanzada es sencillo; integrarla de forma que genere valor sostenible para empleados, clientes, accionistas y reguladores, entre otros *stakeholders*, no lo es. Asimismo, las decisiones adoptadas en los niveles más altos de la dirección evidencian claramente esta tendencia. En febrero de 2026, Block, la *fintech* cofundada por Jack Dorsey, anunció la reducción de su plantilla de más de 10.000 a menos de 6.000 empleados, citando la inteligencia artificial como principal motivo. En su carta a accionistas del cuarto trimestre de 2025, Dorsey afirmó que las herramientas de inteligencia artificial habían cambiado lo que significa construir y dirigir una empresa, y que un equipo significativamente más reducido podía hacer más y hacerlo mejor (Dorsey, 2026). Llegó a afirmar que, en el plazo de un año, la mayoría de las empresas llegarían a la misma conclusión y tomarían decisiones estructurales similares.

Casi simultáneamente, Anthropic publicó a principios de marzo de 2026, un estudio que introduce una métrica nueva denominada “*observed exposure*”, para medir el impacto real de la IA en el mercado laboral, combinando la capacidad teórica de los modelos de lenguaje con datos reales de uso (Massenkoff & McCrory, 2026). Su hallazgo principal es revelador: la cobertura real de la IA sigue siendo una pequeña parte de lo técnicamente

² El término agéntico es una traducción directa del inglés *agentic*. No cuenta aún con reconocimiento por parte de la Real Academia Española (RAE), pero se emplea en este trabajo por ser la denominación consolidada en la literatura académica y ámbito de la inteligencia artificial.

³ Del inglés “*Earnings before interest and taxes*”, abreviatura que hace referencia a los beneficios antes de intereses e impuestos (DEGIRO, s.f.).

posible. En la categoría de profesiones informáticas y matemáticas, por ejemplo, los modelos cubren apenas el 33% de las tareas pese a que el 94% sería teóricamente automatizable. El estudio no encuentra un aumento sistemático del desempleo en las ocupaciones más expuestas desde finales de 2022, aunque sí detecta señales tentativas de una ralentización en la contratación de trabajadores jóvenes, entre 22 y 25 años, en esas mismas ocupaciones.

Ambas evidencias refuerzan la misma idea desde ángulos distintos. El caso de Block muestra cómo algunas empresas están vinculando la IA a decisiones estructurales de reducción de plantilla. Mientras que el estudio de Anthropic matiza la magnitud del impacto; la sustitución masiva que muchos anticipan está lejos de materializarse, pero las señales de cambio son visibles y ya afectan a segmentos concretos del mercado laboral. ¿Responde la adopción de la IA en las empresas a una lógica de eficiencia orientada a la reducción de costes, o a una estrategia de expansión de capacidades y crecimiento? Esa dicotomía, que en este trabajo se articula como *cost-out* frente a *capacity-up*, es el eje central del análisis que se desarrolla en las siguientes páginas.

Este trabajo parte de la premisa de que el problema con los agentes de IA no es tecnológico, sino estratégico. El propósito es ofrecer un marco que ayude a entender cómo implementar agentes de forma que generen valor real, y qué condiciones pueden llegar a marcar la diferencia entre las implementaciones exitosas y aquellas que se quedan en la superficie.

I.2. Metodología

El trabajo adopta un enfoque cualitativo de carácter exploratorio, articulado mediante dos casos de estudio. Se combina revisión de literatura académica con informes de consultoras estratégicas que analizan de forma continua la adopción de inteligencia artificial en las organizaciones. Se ha optado por esta combinación porque permite contrastar el rigor conceptual del análisis con la visión aplicada de firmas que trabajan directamente con empresas en procesos de transformación digital, un tipo de evidencia que, en un campo tan reciente como este, resulta difícil de sustituir por publicaciones académicas con el mismo nivel de actualización.

La revisión de literatura se ha realizado a partir de bases de datos académicas y repositorios institucionales, empleando términos de búsqueda como *AI agents*, *agentic AI*, *human-AI delegation*, *AI augmentation* y *AI business strategy*. Los criterios de

selección han sido la actualidad de las publicaciones (preferentemente 2022-2026, dado el ritmo de evolución del campo), su impacto académico y su pertinencia para la dicotomía *cost-out/capacity-up*. Los informes de consultoras (principalmente McKinsey, BCG y Gartner) se han incluido por su reputación en el análisis de adopción tecnológica, su acceso privilegiado a datos reales de empresas y su capacidad de capturar tendencias que la literatura académica, por sus plazos de publicación, aún no refleja.

Se han seleccionado dos casos de estudio atendiendo a criterios específicos de comparabilidad y contraste. Klarna y McKinsey comparten marco temporal (2023-2024), base tecnológica (agentes de IA) y operan en sectores intensivos en conocimiento, lo que permite aislar la variable estratégica como factor diferencial. Al mismo tiempo, difieren en dimensiones relevantes para el análisis: sector (*fintech* frente a consultoría estratégica), modelo de negocio (plataforma B2C⁴ de servicios financieros frente a firma de servicios profesionales B2B⁵), intensidad de la relación con el cliente y, sobre todo, enfoque de implementación, *cost-out* en Klarna y *capacity-up* en McKinsey. Esta combinación de similitudes y diferencias permite examinar cómo una misma tecnología produce resultados distintos en función de la decisión estratégica adoptada. Para analizar cada caso se ha seguido un esquema común: (1) contexto de la empresa, (2) objetivos de la implementación, (3) características del sistema desplegado, (4) nivel de autonomía otorgado al agente, (5) mecanismos de control y supervisión, y (6) resultados observables. Las conclusiones se derivan de una comparación sistemática entre ambos casos, orientada a la identificación de patrones comunes y divergentes en las dimensiones financiera, organizativa, regulatoria y competitiva. Esta estructura permite extraer conclusiones que vayan más allá de la anécdota particular.

El alcance del trabajo es deliberadamente acotado. No se pretende una revisión exhaustiva de todos los sectores ni de todos los modelos de implementación posibles, sino profundizar en los dos enfoques estratégicos identificados con suficiente detalle como para que las conclusiones sean útiles para la toma de decisiones directivas. Este diseño metodológico permite abordar de forma estructurada la pregunta central del trabajo: qué enfoque de implementación de agentes de IA maximiza la creación de valor sostenible y la aceptación organizacional, y en qué condiciones cada estrategia resulta más defendible.

⁴ B2C: modelo de negocio en el cual la transacción de compra de un producto o servicio se hace entre una empresa y el consumidor final (BBVA, 2021).

⁵ B2B: modelo de negocio que está orientado a la venta de productos y servicios entre empresas.

I.3. Objetivos del trabajo

El objetivo principal es analizar el impacto de los agentes de inteligencia artificial en la estrategia empresarial, con especial énfasis en identificar qué enfoque de implementación maximiza el valor generado y la aceptación organizacional.

Para articular ese análisis, el trabajo parte de una revisión y síntesis de la literatura académica y profesional disponible, estableciendo un marco conceptual integrado que sirve de base para el análisis empírico posterior. Sobre esa base, se han definido seis objetivos específicos que estructuran el desarrollo del trabajo:

1. Definir los agentes de IA y los factores que influyen en la delegación de tareas de humanos a agentes
2. Desarrollar un marco teórico que combine perspectivas de estrategia, modelo de negocio, estructura organizativa y finanzas
3. Comparar dos enfoques estratégicos de implementación: *cost-out* (sustitución) y *capacity-up* (colaboración híbrida)
4. Analizar casos reales de implementación en sectores relevantes para extraer evidencia empírica sobre resultados y condiciones de éxito
5. Identificar riesgos y factores críticos que pueden suponer el fracaso en proyectos agénticos
6. Formular recomendaciones estratégicas para directivos sobre cómo implementar agentes de IA orientados al crecimiento de ingresos y *wallet share*⁶

⁶ *Wallet share*: participación de una empresa en la porción de gastos de determinado cliente. (Salesforce, 2024).

II. MARCO TEÓRICO

Este capítulo construye el marco conceptual necesario para analizar la implementación de agentes de IA desde una perspectiva de alta dirección. Partiendo de la definición funcional establecida en la introducción, el desarrollo se organiza en cuatro bloques. El primero aborda la delegación y los niveles de autonomía en la relación humano-agente. El segundo desarrolla la dicotomía *cost-out/capacity-up* y su traducción financiera. El tercero introduce la *Turing Trap* como marco analítico y revisa la evidencia empírica sobre aumentación, lo que permite fundamentar académicamente la tensión entre ambos enfoques. El cuarto, y último, analiza las implicaciones organizativas, los riesgos de adopción superficial y las condiciones que separan los proyectos que generan valor de los que no.

II.1. Delegación, autonomía y tipología de agentes

Como se definió en la introducción, un agente de IA se diferencia de un LLM convencional por su capacidad de ejecutar procesos de varios pasos con cierto grado de autonomía. Esa definición, útil como punto de partida, resulta insuficiente desde un punto de vista directivo si no se precisa qué decisiones se delegan, bajo qué límites y con qué nivel de supervisión. No todos los agentes operan igual, ni todas las tareas toleran el mismo grado de delegación, por eso necesitamos desarrollar esa gradación antes de plantear cualquier implementación.

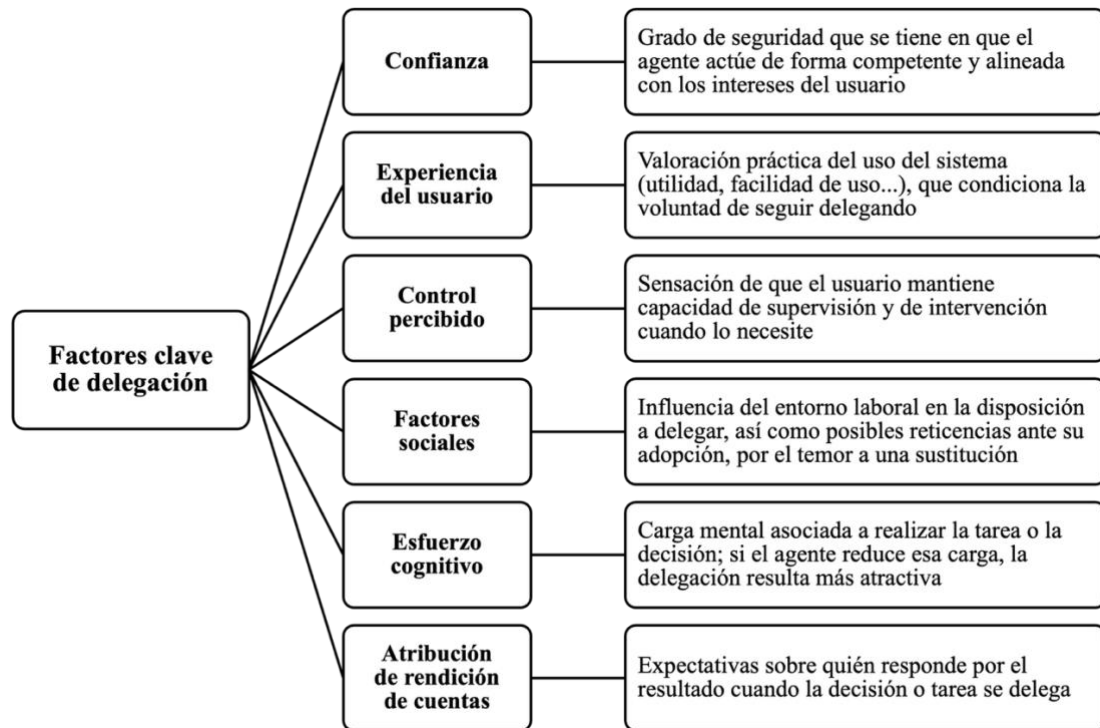
II.1.1 Factores de delegación clave

La literatura sobre sistemas agénticos identifica un conjunto de factores que condicionan la disposición a delegar tareas en un agente. El artículo "*To Delegate or Not to Delegate?*" propone seis factores clave de delegación junto a tres grupos de atributos que condicionan la delegación (Strunk, Banh, Nissen, Strobel, & Smolnik, 2024).

El esquema resume los seis factores clave de delegación que ayudan a explicar por qué una persona decide delegar (o no) una tarea a un agente y hasta qué punto está dispuesta a hacerlo. En la práctica, la delegación tiende a ser más probable cuando aumenta la confianza en el sistema, la experiencia de uso es positiva, el control percibido se mantiene y el esfuerzo cognitivo se reduce. La rendición de cuentas bien definida también facilita la transferencia, y el contexto social puede actuar como acelerador o como freno. Lo relevante es que estos factores no operan de forma aislada, sino que se ven influenciados

por atributos del usuario, del agente y de la tarea, así como por el nivel de delegación permitido, que condiciona los riesgos asumidos y el tipo de supervisión necesaria. No hay una metodología mágica que garantice el éxito, sino que el peso relativo de cada factor depende del contexto, pero este esquema es un buen punto de partida para el análisis (Strunk, Banh, Nissen, Strobel, & Smolnik, 2024).

Figura 1. Factores clave de delegación en agentes de IA



Fuente: elaboración propia a partir de (Strunk, Banh, Nissen, Strobel, & Smolnik, 2024)

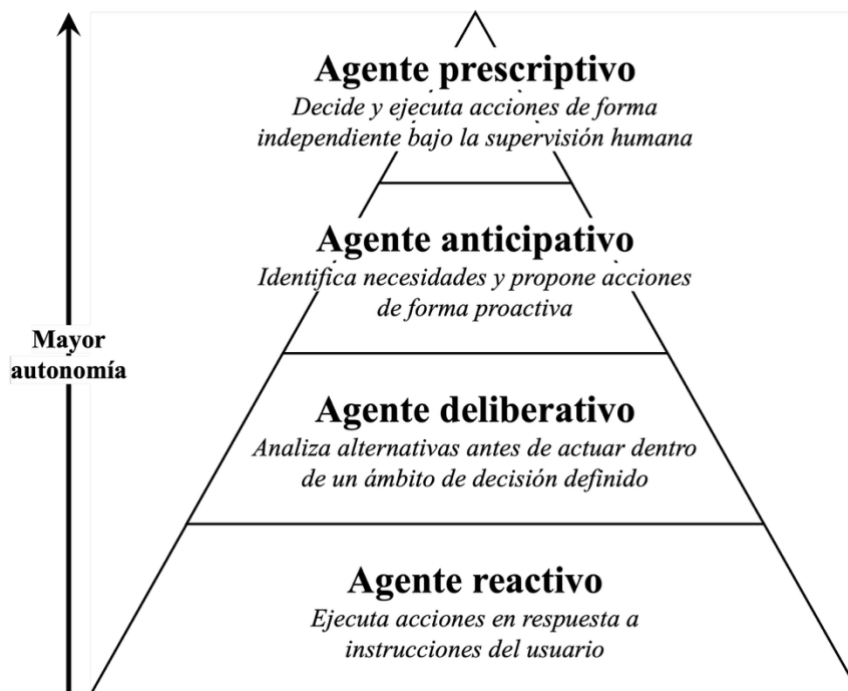
En paralelo a estos factores de decisión encontramos tres grupos de atributos que también influyen. Los atributos del usuario como el nivel de conocimiento o la experiencia previa influyen sobre la confianza y el esfuerzo cognitivo percibido. Los del agente (claridad en las respuestas, facilidad de uso) afectan a la experiencia de usuario y a la rendición de cuentas. Los de la tarea ganan protagonismo a medida que aumenta su complejidad o la importancia del resultado.

Por último, el nivel de delegación actúa como variable transversal ya que no es lo mismo usar el agente como apoyo que delegar una decisión completa; ese grado de delegación cambia qué factores pesan más y qué controles son necesarios.

II.1.2 Tipos de agentes por nivel de autonomía

La evidencia distingue cuatro arquetipos de agentes ordenados por autonomía creciente: reactivos, deliberativos, anticipativos y prescriptivos (Strunk, Banh, Nissen, Strobel, & Smolnik, 2024). En el nivel más básico, los agentes reactivos ejecutan acciones en respuesta a instrucciones explícitas. Los agentes deliberativos incorporan razonamiento para comparar alternativas antes de actuar, normalmente dentro de un ámbito acotado. Los agentes anticipativos operan de forma proactiva, identificando necesidades y proponiendo acciones sin una orden directa. Mientras que los agentes prescriptivos pueden tomar decisiones y ejecutar acciones con la mayor independencia de los cuatro arquetipos, ya sea basándose en patrones de comportamiento o en resultados esperados (Strunk, Banh, Nissen, Strobel, & Smolnik, 2024).

Figura 2. Niveles de autonomía en los agentes de IA



Fuente: elaboración propia a partir de (Strunk, Banh, Nissen, Strobel, & Smolnik, 2024).

Esta clasificación tiene una gran importancia estratégica porque facilita encontrar el equilibrio entre eficiencia operativa y control humano deseado. A mayor autonomía, aumentan velocidad y escalabilidad, pero también crece la exposición a fallos o desviaciones y disminuye la supervisión directa. Según Ransbotham y otros, (2025), en un informe conjunto del MIT Sloan y BCG, hay que añadir un matiz relevante: la IA agéntica difumina la frontera entre herramienta y trabajador, de modo que un mismo

sistema puede comportarse como automatismo en tareas rutinarias y como colaborador con mayor autonomía en decisiones más complejas (Ransbotham, Kiron, Khodabandeh, Iyer, & Das, 2025). Para un directivo, esto significa que la elección del arquetipo no es solo técnica, es una decisión sobre cuánto control se cede y en qué circunstancias.

II.2. Una dicotomía ante el cambio: *Cost-out & Capacity-up*

A la hora de implementar agentes de IA, las empresas deben definir una estrategia que determine no solo el alcance de la adopción, sino también su lógica financiera y su viabilidad organizativa. En este trabajo se adopta una clasificación binaria, *cost-out* frente a *capacity-up*, no porque sean mutuamente excluyentes, sino porque permiten aislar con claridad las diferencias en objetivos, métricas e implicaciones para la estructura de costes.

El primero de estos enfoques, *cost-out*, entiende los agentes como sustitutos de trabajadores humanos. Su objetivo es reducir el gasto de personal automatizando roles completos, y su métrica central es el número de FTEs⁷ eliminados. La justificación financiera es evidente, la inversión inicial (tecnología, integración, formación y, cuando proceda, costes de reestructuración) contrasta con el ahorro recurrente en costes laborales, y el ROI⁸ se proyecta a partir de esa relación. Su atractivo reside precisamente en eso, la visibilidad del retorno a corto plazo y en la facilidad de comunicarlo en un comité.

Los riesgos de este enfoque son considerables. La resistencia interna tiende a ser alta cuando los empleados perciben los agentes de IA como una amenaza directa a su puesto. Existe también un riesgo de pérdida de conocimiento cuando se eliminan roles sin transferir adecuadamente la experiencia acumulada.

El enfoque *capacity-up* parte de una lógica distinta, los agentes no reemplazan al trabajador, sino que amplían lo que ese trabajador puede hacer. El objetivo es incrementar la productividad, calidad y alcance del trabajo humano mediante colaboración persona-agente. Las métricas cambian en consecuencia (productividad por empleado, tasa de conversión, retención de clientes, *wallet share*) y con ellas cambia también el horizonte temporal del retorno. La propuesta financiera se vuelve, por tanto, más compleja de

⁷ Del inglés “*Full Time Equivalent*”, métrica que permite conocer cuántas jornadas completas de trabajo representan las horas totales trabajadas por el personal de una empresa (Randstad, 2025).

⁸ Retorno de la Inversión: métrica financiera que evalúa el rendimiento económico de una inversión en relación con su coste (BBVA, 2024).

construir y más difícil de defender en un comité de dirección, aunque su potencial de creación de valor a largo plazo es cualitativamente diferente.

Este enfoque también conlleva riesgos específicos. La integración real de agentes en flujos de trabajo existentes es compleja y exige un rediseño de procesos que muchas organizaciones subestiman. A esto hay que sumarle el cambio cultural necesario, que los empleados pasen de ejecutar tareas a supervisar y complementar sistemas autónomos, requiere programas de capacitación que añaden coste y tiempo al despliegue.

Ambos planteamientos son válidos y de hecho parten del uso de la misma tecnología, pero su impacto en las organizaciones puede ser muy distinto. Esta decisión refleja la identidad y valores de la empresa, sus aspiraciones competitivas, la visión que tienen sobre sus propios trabajadores en el proceso de creación de valor, y, por último, el tipo de ventaja competitiva al que aspiran como empresa.

II.2.1 Implicaciones financieras

Desde la perspectiva empresarial, cada enfoque basa su éxito en unas métricas y lógicas financieras distintas. El enfoque *cost-out* se apoya en un cálculo directo, la inversión inicial (CAPEX⁹ en tecnología, integración y formación, además de costes de reestructuración cuando proceda) contrasta con el ahorro recurrente en costes laborales (reducción de OPEX¹⁰), y el ROI se proyecta a partir de la relación entre el ahorro anual y la inversión. Su atractivo reside en la mayor visibilidad del retorno a corto plazo y en su facilidad de comunicación ante órganos de gobierno corporativo.

El enfoque *capacity-up*, en cambio, se basa en una lógica de crecimiento y captura de valor. Su racional financiero se articula en torno a incrementos más que a ahorros directos. Esto tiende a desplazar el horizonte temporal del retorno y a hacer más compleja la cuantificación, lo que puede dificultar su aprobación en comités de alta dirección.

La evidencia de encuestas también apunta a una tensión entre objetivos de eficiencia y de crecimiento. En la McKinsey Global Survey, la mayoría de organizaciones declara que la eficiencia es un objetivo central de sus iniciativas de IA (McKinsey, 2025). Al mismo tiempo, el grupo que McKinsey identifica como *AI high performers* combinan eficiencia

⁹ CAPEX: gastos de capital son los gastos que se realizan para conseguir activos con la idea de que estos generen un beneficio a largo plazo para la empresa (OVB, 2023).

¹⁰ OPEX: gastos que se realizan en la gestión diaria de la empresa (salarios, gastos de alquiler, suministros de oficina, etc.) (OVB, 2023).

con metas de crecimiento e innovación (McKinsey, 2025). Estos resultados se basan en respuestas declaradas por las propias empresas y no prueban causalidad, pero apuntan a que rediseñar los flujos de trabajo e integrar la IA más allá de pilotos se asocia con mayor valor. Los datos de la propia encuesta lo respaldan: las *AI high performers* casi triplican al resto en declarar un rediseño profundo de sus flujos de trabajo (55% vs. 20%) y, en la mayoría de funciones, también son al menos tres veces más propensas a decir que están escalando el uso de agentes.

II.2.2 Matriz comparativa: *cost-out* frente a *capacity-up*

La Tabla 1 establece una base comparativa estructural entre ambos enfoques en las dimensiones más relevantes para la toma de decisiones directiva. No constituye un juicio normativo sobre qué enfoque es superior puesto que ambos son legítimos, sino un marco analítico para evaluar las implicaciones de cada elección antes de comprometer recursos.

Tabla 1. *Comparativa estratégica entre los modelos cost-out y capacity-up*

	<i>Cost-out</i>	<i>Capacity-up</i>
Objetivo	<i>Reducir costes de personal</i>	<i>Aumentar capacidad, ingresos y wallet share</i>
Relación humano-agente de IA	<i>Reemplazo de trabajadores (Reducción de FTEs)</i>	<i>Colaboración (Amplificar capacidades)</i>
Lógica financiera	<i>Ahorro directo en OPEX (salarios)</i>	<i>Crecimiento de ingresos y mejora de márgenes</i>
Métrica de éxito	<i>FTEs eliminados, reducción de costes</i>	<i>Productividad/empleado, conversión, wallet share</i>
Horizonte de ROI	<i>Corto plazo</i>	<i>Medio-largo plazo</i>
Impacto en plantilla	<i>Reducción neta de empleo</i>	<i>Reconfiguración de roles</i>
Crispación organizacional	<i>Alta (Temor, resistencia al cambio)</i>	<i>Baja o moderada (Percepción habilitadora)</i>
Riesgo reputacional	<i>Alta</i>	<i>Baja</i>
Gobernanza requerida	<i>Control del agente autónomo</i>	<i>Supervisión humana integrada</i>
Tipo de valor generado	<i>Defensiva (proteger márgenes)</i>	<i>Ofensiva (robar wallet share)</i>

Fuente: elaboración propia basada en (Brynjolfsson, 2022), (Brynjolfsson & Unger, 2023), (Ransbotham, Kiron, Khodabandeh, Iyer, & Das, 2025) y (McKinsey, 2025)

II.3. Modelo de creación de valor

La Tabla 2 propone un modelo de ocho etapas que conecta la inversión inicial en agentes de IA con su impacto financiero y competitivo. Este modelo busca servir como referencia analítica para estructurar la evaluación de los casos de estudio.

Tabla 2. Modelo de creación de valor mediante la implementación de agentes de IA

Cadena de valor	¿Qué ocurre?	Indicador financiero clave	Dato empírico de referencia
1. Inversión inicial	<i>La empresa destina presupuesto digital a tecnología de agentes IA</i>	<i>Gasto en IA / Presupuesto digital total (%)</i>	<i>Los high performers destinan >20% de su presupuesto digital a IA (x4,9 más que el resto)</i>
2. Despliegue y rediseño de procesos	<i>Rediseño de los flujos de trabajo para que el agente IA se integre en la operación diaria</i>	<i>% de flujos de trabajo rediseñados con IA</i>	<i>Los high performers rediseñan sus flujos x2,8 más que el resto (55% vs. 20%)</i>
3. Incremento de la productividad	<i>A medida que aprenden los empleados, van resolviendo más tareas por hora. El efecto es mayor en perfiles junior</i>	<i>Producción por hora Tiempo medio de resolución</i>	<i>Productividad +14% de media; +34% para trabajadores junior Trabajadores con 2 meses de experiencia + IA rinden igual que veteranos con >6 meses sin IA</i>
4. Reducción de costes	<i>Al producir más por hora, el coste por unidad de servicio baja. Esto fortalece la posición competitiva en costes (liderazgo en costes, Porter)</i>	<i>Coste por caso resuelto (€) Tasa de rotación de empleados (%)</i>	<i>56% de encuestados reportan reducciones de coste en software de ingeniería e IT Rotación de juniors: -40%</i>
5. Crecimiento orgánico	<i>Mejor atención al cliente → mayor satisfacción → mayor retención y upselling. El agente de IA libera capacidad humana para tareas de mayor valor añadido</i>	<i>Ingreso por empleado (€) % crecimiento orgánico de ingresos</i>	<i>67% reportan aumento de ingresos en Marketing & Ventas con IA Sentimiento del cliente mejora +0,5 desviaciones típicas</i>
6. Innovación y diferenciación	<i>La capacidad liberada se dirige a innovar. Esto genera diferenciación sostenible frente a competidores (estrategia de diferenciación, Porter)</i>	<i>% de ingresos por nuevos productos/servicios Nº de casos de uso IA escalados</i>	<i>64% de las empresas que usan IA reportan mejora en innovación. Los high performers persiguen innovación (79%) además de eficiencia (84%)</i>
7. Impacto en la rentabilidad	<i>La suma de menores costes, mayores ingresos e innovación, se traduce en mejora del margen operativo (EBIT)</i>	<i>Δ EBIT atribuible a IA (%) Margen EBIT (%)</i>	<i>Los high performers superan el 5% de EBIT atribuible a IA</i>
8. Ventaja competitiva sostenible	<i>Menores costes + diferenciación por innovación + mejor servicio = barreras más difíciles de replicar</i>	<i>Cuota de mercado relativa Diferenciación competitiva percibida</i>	<i>45% reportan mejora en diferenciación competitiva 25% reportan ganancia de cuota de mercado High performers son x3,6 más propensos a buscar transformación</i>

Fuente: elaboración propia basada en (Porter, 1998), (McKinsey, 2025) y (Brynjolfsson, Li, & Raymond, 2023)

La lógica del modelo es acumulativa, es decir, cada etapa es condición necesaria para que se produzca la siguiente. Sin inversión inicial suficiente no hay despliegue real; sin

rediseño de procesos la herramienta se superpone a flujos de trabajo existentes; sin transformación no hay incremento de productividad; y sin productividad no hay base para el crecimiento orgánico, la innovación ni, la ventaja competitiva sostenible. Este encadenamiento es lo que distingue una implementación de valor de lo que la literatura denomina *AI theater*.

II.4. La *Turing Trap* como marco analítico

La sección anterior ha descrito dos estrategias de implementación con lógicas financieras y organizativas distintas. Pero la evidencia muestra que la mayoría de las empresas se inclina, al menos inicialmente, por el enfoque *cost-out*. Entender por qué exige revisar un sesgo que Brynjolfsson ha conceptualizado con precisión y que explica la inercia hacia la sustitución.

Durante años, el avance de la IA se ha medido por lo "humano" que parece. Brynjolfsson denomina *Turing Trap* a la inercia a evaluar el progreso de la IA por su capacidad de imitar al ser humano, en lugar de diseñarla para complementarlo (Brynjolfsson, *The Turing Trap: The Promise & Peril of Human-Like Artificial Intelligence*, 2022). No es un sesgo nuevo. Reproduce una idea recurrente en la historia de la innovación: entender la tecnología ante todo como sustituto del trabajo. Cuando este criterio guía el desarrollo de la IA hacia la automatización de tareas completas, Brynjolfsson advierte que los beneficios tienden a concentrarse en los propietarios de la tecnología, lo que puede ampliar la desigualdad de rentas (Brynjolfsson, *The Turing Trap: The Promise & Peril of Human-Like Artificial Intelligence*, 2022). Un enfoque orientado a la complementación, en cambio, mantiene al trabajador como eje del proceso productivo y busca ampliar sus capacidades, facilitando, al menos sobre el papel, una distribución más amplia de las ganancias de productividad y una mayor aceptación.

La conexión con la dicotomía de este trabajo es directa. El enfoque *cost-out* cae en la *Turing Trap* cuando el éxito se mide exclusivamente por FTEs eliminados y reducción de OPEX. En la contraparte, *capacity-up*, cambia ese criterio por la capacidad adicional generada; más producción, mejor servicio, mayor velocidad; con la misma plantilla o con una estructura reconfigurada. La tecnología deja de ser sustituto para convertirse en palanca (Brynjolfsson, *The Turing Trap: The Promise & Peril of Human-Like Artificial Intelligence*, 2022). Esta diferencia define si el proyecto se presenta como un recorte o como una inversión en crecimiento.

En otro artículo, el propio Brynjolfsson junto a Unger, plantean una idea similar desde la perspectiva macroeconómica. Cuando la IA se aplica a tareas rutinarias, el impacto sobre la productividad agregada es menor; cuando se integra como complemento del trabajo, su potencial de creación de valor y distribución de beneficios es significativamente mayor (Brynjolfsson & Unger, 2023). Estas conclusiones no son directamente extrapolables al nivel de empresa, pero su lógica sí resulta útil para percatarnos de la visión de la empresa.

La pregunta que se deriva de esto es si la *augmentación* funciona en la práctica. La evidencia disponible sugiere que sí, aunque con matices importantes. El estudio "*Generative AI at work*" analizó la introducción gradual de un asistente conversacional de IA en atención al cliente y observó un aumento de productividad medio del 14-15% en una muestra de 5.179 agentes (Brynjolfsson, Li, & Raymond, 2023). El efecto fue más pronunciado en trabajadores con menor experiencia, en la medida en que la herramienta facilita el acceso a conocimiento acumulado que los empleados más veteranos ya poseen. Para este trabajo, el dato más relevante no es el porcentaje en sí, sino el mecanismo. La IA actúa como apoyo, el agente humano mantiene el control de la interacción y puede aceptar o ignorar las sugerencias del sistema. También se observaron mejoras en experiencia del cliente y retención de empleados, aunque estas métricas al ser más difíciles de traducir a ROI que la reducción de FTEs, complican su uso como argumento financiero frente a un enfoque *cost-out*.

Un segundo estudio introduce un detalle importante, la IA no mejora el rendimiento de forma uniforme. Dell'Acqua y otros trabajaron con 758 consultores y encontraron que la IA mejora el rendimiento en tareas situadas dentro de la denominada "*jagged technological frontier*"¹¹, pero lo reduce en tareas fuera de ella. El problema no es que la herramienta falle, sino que los usuarios tienden a delegar justo donde es menos fiable, porque no identifican con claridad sus límites. La *augmentación*, por tanto, requiere formación previa, supervisión y criterios explícitos para decidir qué tareas se apoyan con IA y cuáles deben permanecer bajo control humano, más que asumirse como un beneficio automático (Dell'Acqua, y otros, 2023). Esta afirmación refuerza el dato de Anthropic sobre la mayor exposición de los perfiles *junior*. Pese a ser el grupo que más gana en productividad con la IA, al carecer de criterio experto, tienen mayor dificultad para identificar los límites de fiabilidad de la herramienta, lo que genera dos consecuencias:

¹¹ La *jagged technological frontier* es la frontera que separa las tareas en las que la IA rinde bien de aquellas en las que falla, sin que ese límite siga una lógica predecible de complejidad (Dell'Acqua, y otros, 2023).

dependen más de la IA (porque les aporta conocimiento que aún no tienen), pero sin la supervisión necesaria, su uso puede derivar en errores que refuerzan la preferencia empresarial por perfiles más *senior*.

El mismo estudio describe dos patrones de integración asociados a mejores resultados. Centauros, aquellos que reparten deliberadamente el trabajo entre humano y sistema, asignando subtareas según las fortalezas de cada uno y, *cyborgs*, que integran la IA en un flujo continuo e iterativo, sin una separación clara de roles. En ambos casos, el trabajador permanece en el proceso como supervisor, la lógica que define el enfoque *capacity-up* (Dell'Acqua, y otros, 2023).

II.5. Implicaciones para la gobernanza organizativa

Si los agentes pueden operar con distintos niveles de autonomía, no podemos pensar en una política de gobernanza única. El 58% de las organizaciones líderes en IA agéntica anticipa cambios significativos en sus estructuras de gobernanza en los próximos tres años (Ransbotham, Kiron, Khodabandeh, Iyer, & Das, 2025). Las medidas anunciadas para estas reestructuraciones incluyen la creación de comités transversales que integren tecnología, recursos humanos, finanzas y operaciones; protocolos de escalado de autonomía que establezcan qué tareas se delegan a cada nivel y en qué condiciones; y mecanismos de auditoría y reversión.

Este énfasis en supervisión y trazabilidad no es solo una buena práctica: en el contexto europeo, es también una exigencia regulatoria. El Reglamento (UE) 2024/1689, Ley de Inteligencia Artificial, basado en el riesgo distingue categorías que van desde usos prohibidos hasta la definición de sistemas de alto riesgo con obligaciones reforzadas en materia de transparencia, supervisión humana y evaluación de conformidad (High-level summary of the AI Act, 2024). Para las empresas que operan en Europa, este marco actúa como condición de contorno en el diseño de proyectos agénticos, especialmente en ámbitos como empleo, crédito o seguros. En el día a día, lo que esta regulación supone es que las configuraciones plenamente autónomas posiblemente se vean limitadas.

Estos cambios regulatorios se manifiestan también en la estructura interna de las organizaciones. Cuando un agente asume tareas que antes requerían coordinación entre varios niveles jerárquicos, cada mando intermedio puede supervisar más procesos porque el agente absorbe parte de la carga de coordinación y seguimiento. El informe de MIT Sloan y BCG señala que la IA agéntica difumina la frontera entre herramienta y

trabajador, lo que obliga a repensar las líneas de reporte y los mecanismos de supervisión (Ransbotham, Kiron, Khodabandeh, Iyer, & Das, 2025). En un enfoque *cost-out*, esto se traduce en la eliminación de capas jerárquicas; en un enfoque *capacity-up*, en la reconfiguración de roles hacia funciones de mayor valor añadido.

La gestión del cambio emerge como variable crítica. Las organizaciones que McKinsey identifica como *AI high performers* no solo invierten más en tecnología, sino que rediseñan sus flujos de trabajo con mayor frecuencia (55% frente al 20% del resto) y escalan el uso de agentes en más funciones (McKinsey, 2025). Esto sugiere que el diferenciador no es la herramienta, sino la capacidad organizativa de absorber el cambio: programas de capacitación que permitan a los empleados transitar hacia nuevos roles, protocolos claros sobre qué decisiones permanecen bajo control humano, y una comunicación que reduzca la percepción de amenaza.

La argumentación desarrollada hasta aquí podría dar la impresión de que adoptar una lógica *capacity-up* es condición suficiente para obtener resultados positivos. La evidencia no lo confirma. La mayoría de los proyectos de IA, independientemente del enfoque, no consiguen generar valor a escala (McKinsey, 2025), y ese fracaso tiene causas identificables como costes crecientes, falta de claridad sobre el valor o controles inadecuados (Gartner, 2025). Este apartado introduce ese contrapunto con el objetivo de delimitar por qué se producen implementaciones superficiales (*AI theater*) y qué condiciones aparecen asociadas a los casos en los que la IA agéntica sí aporta valor.

Como se explicó en la introducción, Gartner predice que más del 40% de los proyectos de IA agéntica serán cancelados antes de finales de 2027. La mayoría de estos proyectos se encuentran aún en fase de prueba, impulsados más por las propias expectativas que por un caso de negocio sólido. Gartner estima además que, de los miles de proveedores que afirman ofrecer soluciones agénticas a día de hoy, solo unos 130 poseen capacidades reales. El resto practica lo que denominan *agent washing*, que consiste en presentar herramientas convencionales (LLMs o automatizaciones estándar) como “agentes” sin que el sistema tenga capacidad real de autonomía, planificación ni ejecución de procesos de múltiples pasos (Gartner, 2025).

III. ANÁLISIS

III.1. De la teoría a la práctica: dos caminos para una misma tecnología

Conforme a lo desarrollado en el trabajo hasta este punto, la diferencia entre *cost-out* y *capacity-up* no reside en la tecnología empleada, sino en la decisión estratégica sobre cómo integrarla. Esa distinción, convincente en el plano conceptual, necesita confirmarse a través de casos reales de empresas que ya han tomado esa decisión y han experimentado sus consecuencias.

Este capítulo analiza dos casos representativos. El primero, Klarna, ilustra un enfoque *cost-out* en servicios financieros donde se sustituyeron empleados de atención al cliente por un agente de IA, con reducción de plantilla como métrica principal. El segundo, McKinsey y su agente Lilli, representa un enfoque *capacity-up* en consultoría. En este caso, la intención era incrementar las capacidades de los consultores, su productividad y calidad manteniendo la plantilla intacta.

Estos casos han sido elegidos porque ambos comparten marco temporal (2023-2024), ambos emplean agentes de IA como base tecnológica, y ambos operan en sectores intensivos en conocimiento. Lo que los diferencia es lo que este trabajo pretende examinar, la estrategia de implementación y sus efectos sobre la organización, los empleados, los clientes y, la posición competitiva.

III.2. Caso *cost-out*: Klarna y la sustitución en atención al cliente

III.2.1 Contexto y objetivos

Klarna es una *fintech* sueca especializada en servicios de pago aplazado basada en el modelo de negocio “*buy now, pay later*” que para la fecha del caso contaba ya con más de 114 millones de usuarios y 3,4 millones de transacciones diarias. En febrero de 2024 anunciaron que su asistente de IA, desarrollado en colaboración con OpenAI, había gestionado dos tercios de todas las conversaciones de servicio al cliente durante su primer mes de funcionamiento global. La compañía afirmó que ese volumen equivalía al trabajo de 700 agentes humanos a tiempo completo (Klarna, 2024). El dato fue presentado por el CEO, Sebastian Siemiatkowski, no como un efecto secundario sino como el objetivo central de la implementación.

La estrategia de Klarna era evidentemente *cost-out*. Por aquel entonces, la compañía, se preparaba para una salida a bolsa y necesitaba demostrar rentabilidad, para ello, consideraron la reducción de costes de personal la vía más directa y fácil de comunicar para mejorar sus resultados operativos. La plantilla total se redujo de aproximadamente 5.500 empleados a finales de 2022 a unos 3.400 a mediados de 2024 (Corbin, 2026).

III.2.2 Características del sistema y nivel de autonomía

El asistente de Klarna operaba en atención al cliente de primer nivel. Entre las tareas delegadas estaban la gestión de consultas sobre pagos, devoluciones, estado de pedidos o la resolución de incidencias estándar. Conforme a la clasificación de este trabajo (apartado II.1), se trataba fundamentalmente de un agente reactivo con capacidades deliberativas limitadas: respondía a instrucciones del cliente dentro de un ámbito predefinido, con cierta capacidad de seleccionar entre opciones de resolución, pero sin autonomía para tomar decisiones fuera de su dominio de entrenamiento.

La autonomía del sistema era alta dentro de su perímetro de trabajo (resolución autónoma sin intervención humana en la mayoría de consultas), pero acotada en alcance. La intervención de agentes humanos se producía únicamente cuando el sistema detectaba situaciones fuera de sus parámetros, aunque los criterios exactos de escalado no fueron publicados con detalle.

III.2.3 Mecanismos de control y supervisión

Aquí es donde el caso Klarna revela sus debilidades desde la perspectiva de este trabajo. La implementación priorizó velocidad de despliegue y métricas de ahorro sobre mecanismos de gobernanza. La compañía no publicó protocolos de auditoría del sistema, ni estructuras de supervisión humana integrada en el flujo operativo, ni métricas de calidad vinculadas a la toma de decisiones sobre el alcance de la autonomía del agente.

El contraste con el marco desarrollado en el apartado II.1 es claro. Los factores de delegación clave (Strunk, Banh, Nissen, Strobel, & Smolnik, 2024) sugerían que la confianza, el control percibido y la rendición de cuentas son condiciones necesarias para una delegación exitosa. En Klarna, la decisión de delegar se tomó desde la dirección sin que necesariamente se dieran esas condiciones en la base organizativa. Los factores sociales, que en el esquema de delegación actúan como acelerador o freno, operaron aquí como freno. Los empleados que mantuvieron su empleo percibieron la implementación como una amenaza directa a sus puestos, no como una herramienta habilitadora.

III.2.4 Resultados y contrapunto

A corto plazo, los resultados financieros cumplieron los objetivos. Klarna reportó una mejora en su margen operativo y una reducción significativa del gasto en atención al cliente, métricas que reforzaron la narrativa frente a inversores, especialmente en el contexto de su inminente salida a bolsa. Querían reestructurar sus equipos, consolidar funciones y recortar costes, para venderse como una empresa más ágil y disciplinada (Mann, 2025). El ROI del proyecto, medido exclusivamente en ahorro de OPEX, fue positivo y visible.

A medio plazo, el intento de Klarna de alcanzar una automatización total empezó a mostrar sus límites. Pocos meses después de celebrar la capacidad de la IA para sustituir trabajo humano, la propia empresa reconoció que, al haber priorizado en exceso la eficiencia y el coste, el resultado había sido una atención de menor calidad, especialmente en interacciones donde seguía siendo relevante el juicio humano (Corbin, 2026). Para solucionar esto, Klarna reanudó la contratación de personal de atención al cliente y pasó a defender un modelo híbrido en el que los usuarios pudiesen recurrir siempre a un agente humano.

Este desenlace conecta directamente con dos advertencias del marco teórico. Primera, la predicción de Gartner sobre la cancelación del 40% de proyectos agénticos por costes crecientes o falta de claridad sobre el valor de negocio; Klarna no canceló el proyecto, pero sí tuvo que rectificar su alcance. Segunda, y más relevante, el hecho de que optasen por despedir empleados en favor de la IA y terminasen arrepintiéndose.

Desde la perspectiva de la *Turing Trap*, este caso confirma el sesgo. El proyecto se diseñó para imitar al trabajador humano, y por tanto, para sustituirlo. El éxito se midió por la capacidad de sustituir, y cuando la sustitución reveló limitaciones, la empresa tuvo que recurrir precisamente al recurso que había eliminado. La decisión generó crispación entre los empleados, de los cuales, los que permanecieron en la empresa lo hicieron con la incertidumbre de si correrían la misma suerte que buena parte de sus compañeros y no iban mal encaminados. En febrero de 2026, Siemiatkowski declaró que espera que la plantilla descienda por debajo de los 2.000 empleados antes de 2030, frente a los aproximadamente 3.000 actuales y los 7.000 de 2022, mediante una combinación de despidos y atrición natural (Shahidi, 2026). Es decir, a pesar del ajuste hacia un modelo híbrido la voluntad *per se* sigue siendo la de seguir un modelo *cost-out*.

III.3. Caso capacity-up: McKinsey y el agente Lilli

III.3.1 Contexto y objetivos

McKinsey & Company es la firma líder en consultoría estratégica a nivel global, con más de 45.000 empleados y unos ingresos récord de 16 billones (americanos) de dólares en 2023, impulsados en parte por la demanda de asesoramiento en inteligencia artificial (Varanasi, 2024). Cuando ChatGPT irrumpió en noviembre de 2022, la firma vio en esta herramienta la posibilidad de solucionar un problema que arrastraban desde hace décadas, ser capaces de acceder a todo el conocimiento documentado a lo largo de sus entonces 96 años de historia. Los empleados dedicaban demasiado tiempo a localizar la información y los expertos internos adecuados (McKinsey & Company, 2024). La IA generativa ofrecía una solución a ese cuello de botella, pero desde McKinsey decidieron ir más allá. Los primeros *testers* de un prototipo rudimentario lo utilizaron no solo para investigación, sino para análisis de datos, planificación y resolución creativa de problemas, lo que indicó que la herramienta podía convertirse en una plataforma que transformase la operativa completa (McKinsey & Company, 2024).

Así nació Lilli, una herramienta agéntica que sintetiza más de cien años de conocimiento propietario distribuido en más de 100.000 documentos e informes (Varanasi, 2026). La herramienta permite a los consultores acceder mediante lenguaje natural a marcos analíticos, *benchmarks* sectoriales, casos previos y publicaciones internas, no como un buscador de documentos, sino como un sintetizador que cruza fuentes, sugiere *frameworks* relevantes y acelera la preparación de entregables.

McKinsey entendía que el enfoque que maximizaría el valor de sus consultores era *capacity-up*. La firma no buscaba reducir plantilla; de hecho, ha mantenido sus niveles de contratación e incluso ha expandido sus servicios de consultoría en IA. El objetivo declarado era que cada consultor pudiera hacer más con la misma jornada, reduciendo el tiempo dedicado a tareas de búsqueda y síntesis para redirigirlo a análisis de mayor valor, interacción con clientes y desarrollo de recomendaciones estratégicas. En palabras de Erik Roth, socio responsable del desarrollo de Lilli, la plataforma se concibió para transformar cómo la firma gestiona y accede a su conocimiento, que es la base de su organización y de su ventaja competitiva (McKinsey & Company, 2024).

III.3.2 Características del sistema y nivel de autonomía

Lilli combina características de agente deliberativo y anticipativo. No se limita a responder preguntas como haría un agente reactivo, sino que compara alternativas, sugiere líneas de análisis y, en ocasiones, propone aproximaciones que el consultor no había considerado. Sin embargo, no ejecuta acciones de forma autónoma ni toma decisiones sobre el entregable final. El consultor humano mantiene el control completo sobre qué información utiliza, cómo la estructura y qué recomienda al cliente.

Desde el punto de vista técnico, Lilli no depende de un único modelo de lenguaje. La firma desarrolló una capa de orquestación patentada que dirige cada consulta al LLM o tipo de IA más adecuado según la intención del usuario, optimizando coste y calidad de respuesta. Para poder hacer esto, la plataforma combina un modelo pre-entrenado alojado en la nube con cinco modelos expertos más pequeños, entrenados internamente para interpretar la intención del usuario y mejorar la relevancia de las respuestas (McKinsey & Company, 2024).

Este diseño refleja lo que (Dell'Acqua, y otros, 2023) denominan el patrón centauro, una división deliberada del trabajo entre humano y sistema, donde cada uno aporta lo que mejor hace. La IA acelera la investigación y la síntesis; el consultor aporta juicio, contexto y relación con el cliente. El modelo *cyborg*, que implica una integración más fluida e iterativa, también se observa en la práctica pues los consultores utilizan Lilli de forma continua durante la elaboración de un entregable, alternando entre producción propia y sugerencias del sistema. Los datos de uso confirman que esta integración no se quedó en piloto. El 72% de los 45.000 empleados de la firma utiliza la plataforma de forma activa, con una frecuencia media de 17 interacciones semanales por usuario y más de 500.000 *prompts* mensuales, y el 100% de la plantilla tiene acceso (McKinsey & Company, 2024).

III.3.3 Mecanismos de control y supervisión

A diferencia de Klarna, el diseño de Lilli incorpora la supervisión humana como elemento estructural. El consultor no recibe una respuesta final que transmitir al cliente, sino *inputs* intermedios que debe evaluar, completar y, cuando procede, descartar. Este mecanismo aborda directamente uno de los riesgos identificados en la literatura que es la tendencia a delegar en la IA allí donde es menos fiable. Al mantener al trabajador en el proceso de decisión de forma constante, el sistema reduce la probabilidad de que errores del modelo se trasladen al entregable final.

McKinsey ha integrado protocolos de gobernanza específicos que van más allá de lo habitual en herramientas internas. El acceso al sistema está restringido por niveles de confidencialidad. Cada nueva funcionalidad pasa por fases de *testing* con usuarios *alpha* y *beta* antes de su despliegue general, evaluando métricas como profundidad de interacción y calidad de los *outputs* (McKinsey & Company, 2024).

En el contexto regulatorio europeo, este modelo de supervisión humana integrada resulta más compatible con las exigencias del Reglamento (UE) 2024/1689 (AI Act), que establece obligaciones reforzadas para sistemas de alto riesgo en materia de transparencia y control humano. Aunque la consultoría estratégica no está directamente clasificada como alto riesgo, los clientes de McKinsey en sectores como banca, seguros o empleo sí lo están, lo que crea una presión indirecta por garantizar la trazabilidad de los análisis generados con apoyo de IA.

III.3.4 Resultados y contrapunto

McKinsey no ha publicado métricas de productividad auditadas externamente sobre Lilli, lo que constituye una limitación relevante del caso. Sin embargo, la evidencia disponible sugiere resultados positivos en varias dimensiones. La firma ha declarado reducciones significativas en el tiempo de investigación por proyecto, lo que se traduce en más horas disponibles para trabajo de mayor valor. Durante la fase de *alpha testing*, con 200 usuarios, la calidad de las respuestas mejoró un 52% en la primera semana y un 32% en la segunda, antes de que la plataforma se ofreciese de forma gradual al resto de la firma que ya alcanza una adopción del 72% (McKinsey & Company, 2024).

La propia firma identificó inseguridad sobre qué preguntar a la herramienta por aquellos que no estaban familiarizados con este tipo de herramientas, siendo esta la principal barrera de adopción inicial. La solución era sencilla, una sola hora de formación en *prompting* incrementaba sustancialmente el uso de la plataforma entre los consultores (McKinsey & Company, 2024). Este dato tiene relación directa con la advertencia de (Dell'Acqua, y otros, 2023) sobre la necesidad de formación previa para que la *augmentación* funcione porque sin criterio para interactuar con la IA, los usuarios tienden a infrutilizarla o a delegar donde no deben.

Un indicador del valor que da la firma a Lilli es que desde principios de 2026, se está integrando su uso incluso durante las entrevistas de caso para candidatos del programa *graduate* con el objetivo de evaluar cómo los aspirantes trabajan con la herramienta

(Varanasi, 2026). El hecho de que la firma considere la competencia en el uso de su agente interno como un criterio de selección revela hasta qué punto Lilli ha pasado de ser una herramienta complementaria a convertirse en un elemento estructural.

Desde la perspectiva de *wallet share*, que es la métrica competitiva central del enfoque *capacity-up*, el razonamiento es el siguiente: si cada consultor puede generar entregables de mayor calidad en menos tiempo, la firma puede asumir más proyectos por equipo, responder con mayor rapidez a solicitudes de clientes y dedicar más tiempo a la relación comercial. El efecto no se traduce necesariamente en crecimiento inmediato de cuota de mercado, pero sí en una posición competitiva más defendible frente a firmas que no han integrado estas herramientas o que lo han hecho de forma superficial.

III.4. Importancia de la implementación

La comparación entre Klarna y McKinsey no pretende establecer que un enfoque sea intrínsecamente superior al otro, de hecho, ambos proyectos son considerados exitosos dentro de las respectivas empresas. Ambos son respuestas estratégicas legítimas y, ambos comparten la misma base tecnológica. Lo que la evidencia sí permite afirmar es que el modo de implementación condiciona de forma significativa los resultados organizativos, la aceptación interna y la sostenibilidad del proyecto en el tiempo.

En la dimensión de crispación organizacional, la diferencia es notable. Klarna generó un entorno de temor donde los empleados restantes operaban con la percepción de que sus puestos eran los siguientes en ser eliminados. McKinsey, al desarrollar Lilli como herramienta de productividad y no de sustitución, logró una recepción más positiva lo que se refleja en la tasa de utilización. No se eliminaron puestos; se redefinieron tareas. Los factores sociales de delegación (Strunk, Banh, Nissen, Strobel, & Smolnik, 2024) operaron como freno en Klarna y como acelerador en McKinsey.

En la dimensión financiera, Klarna mostró resultados más inmediatos y cuantificables: menos empleados, menos coste, margen mejorado. McKinsey presenta un caso financiero más difuso, pero potencialmente más profundo: más capacidad por consultor, mejor posicionamiento competitivo, mayor captura de valor por proyecto. La Tabla 2 del marco teórico (modelo de creación de valor) predice esta diferencia. El enfoque *cost-out* se detiene en la etapa 4 (reducción de costes), mientras que el *capacity-up* tiene recorrido hasta la etapa 8 (ventaja competitiva sostenible).

En la dimensión de gobernanza, McKinsey incorporó la supervisión humana como parte del diseño desde el inicio, mientras que Klarna priorizó la autonomía del sistema sobre los controles. Esto explica, al menos parcialmente, la necesidad de Klarna de rectificar y reincorporar agentes humanos, dado que la ausencia de supervisión integrada generó problemas de calidad que el sistema por sí solo no podía resolver.

En la dimensión regulatoria, el modelo de Klarna es más vulnerable. Un sistema que toma decisiones autónomas en la interacción con clientes de servicios financieros se sitúa más cerca de las categorías de alto riesgo del *EU AI Act* que una herramienta interna de apoyo a consultores. La supervisión humana integrada de Lilli no solo es buena práctica operativa; es también un factor de mitigación regulatoria.

¿Significa esto que el *cost-out* no funciona? No necesariamente. En contextos donde las tareas son altamente estandarizadas, el volumen es masivo, la tolerancia al error es amplia y la regulación es menos restrictiva, la sustitución directa puede ser viable. Lo que el caso Klarna ilustra es que, cuando se aplica en contextos con mayor variabilidad, mayor regulación y mayor contacto con el cliente, los riesgos se multiplican y la reversibilidad se complica.

La conclusión intermedia, que prepara el cierre del trabajo, es la siguiente. El enfoque *capacity-up* no es intrínsecamente mejor, pero tiende a ser más defendible estratégicamente porque distribuye los beneficios de forma más amplia (empresa, empleados y clientes), reduce la crispación organizacional, es más compatible con los marcos regulatorios europeos y, sobre todo, genera las condiciones para una ventaja competitiva sostenible que el *cost-out*, por su naturaleza defensiva, difícilmente puede construir. Para que esto sea cierto, sin embargo, el *capacity-up* exige supervisión humana real, rediseño profundo de procesos, un gobierno corporativo actualizado y una inversión sostenida que muchas empresas no están dispuestas a realizar. Sin estas condiciones, el *capacity-up* degenera en *AI theater*, y el resultado no es mejor que el del *cost-out* fallido.

Tabla 3. Análisis comparativo de los casos Klarna y McKinsey

Variable	Klarna	McKinsey - Lilli
Objetivo	<i>Reducir costes de atención al cliente mediante sustitución de agentes humanos por IA</i>	<i>Aumentar productividad y calidad del trabajo de consultoría sin reducir plantilla</i>
Sector	<i>Fintech de servicios financieros</i>	<i>Consultoría estratégica</i>
Tipo de tareas delegadas	<i>Atención al cliente: consultas sobre pagos, devoluciones, estado de pedidos, incidencias estándar</i>	<i>Investigación, síntesis de conocimiento, sugerencia de marcos analíticos, aceleración de entregables</i>
Nivel de autonomía del agente	<i>Reactivo con capacidades deliberativas limitadas. Alta autonomía dentro de un perímetro funcional acotado</i>	<i>Deliberativo-anticipativo. Sugiere y sintetiza, pero no ejecuta ni decide de forma autónoma. El consultor mantiene el control del output</i>
Cambios organizativos	<i>Reducción de plantilla (de 5.441 a 3.400) → Congelación de contrataciones → Roles de atención al cliente eliminados o reducidos</i>	<i>Redefinición de tareas → Menos búsqueda y síntesis más análisis de valor y relación con el cliente</i>
Supervisión humana	<i>Limitada. El sistema operaba de forma autónoma en la mayoría de interacciones. Escalado a humanos excepcionalmente</i>	<i>Integrada en el diseño. El consultor evalúa, completa o descarta los outputs de Lilli</i>
Impacto económico	<i>→ Corto plazo: mejora de margen operativo, reducción de OPEX en atención al cliente → Medio plazo: costes de rectificación (recontratación) y riesgo reputacional no cuantificado públicamente</i>	<i>→ Largo plazo: Reducción de horas de investigación por proyecto Mayor capacidad por consultor. Potencial de asumir más proyectos por equipo y mejorar wallet share</i>
ROI	<i>Positivo a corto plazo (ahorro directo vs. inversión en tecnología) Posible contrapunto a medio plazo por costes de rectificación</i>	<i>Menos visible y a medio-largo plazo. La cuantificación depende de métricas de productividad y captura de valor no publicadas</i>
Riesgos materializados	<i>Quejas de clientes por calidad</i>	<i>Dependencia de que los consultores usen el sistema de forma efectiva (jagged technological frontier)</i>
Adopción / aceptación (empleados)	<i>Baja → Percepción de amenaza → Contexto de incertidumbre laboral</i>	<i>Positiva → Percepción habilitadora</i>
Adopción / aceptación (clientes)	<i>Mixta a negativa → Aumento de quejas por la peor calidad de las respuestas automatizadas</i>	<i>Indirecta → Los clientes no interactúan con Lilli; reciben entregables de mayor calidad</i>
Resultado neto	<i>Ahorro de costes real pero no sostenible sin un modelo híbrido Ilustra la Turing Trap: la sustitución generó valor a corto plazo, pero supuso menor calidad, crispación interna y reputación a medio plazo</i>	<i>Aumento de capacidad sin eliminación de empleo Enfoque más defendible estratégica, regulatoria y organizativamente, pero pendiente de demostrar impacto cuantificable en wallet share y rentabilidad. Requiere inversión y rediseño de procesos</i>

Fuente: elaboración propia, basada en la estructura de la Tabla 1 y adaptada a los casos analizados

IV. CONCLUSIÓN

En febrero de 2026, Jack Dorsey anunció que Block reduciría su plantilla de más de 10.000 a menos de 6.000 empleados, citando la inteligencia artificial como principal motivo. Casi simultáneamente, McKinsey celebraba que el 72% de sus 45.000 empleados utilizaba activamente Lilli, su agente interno, sin haber eliminado un solo puesto. Ambas decisiones se tomaron en el mismo trimestre, con la misma tecnología de base, en sectores igualmente intensivos en conocimiento. Lo que las separa no es una diferencia de capacidad tecnológica, sino una diferencia de ambición estratégica. Esa diferencia es lo que este trabajo ha intentado articular.

A lo largo de estas páginas se ha construido una dicotomía, *cost-out* frente a *capacity-up*, que no pretende ser un juicio normativo sino un marco de análisis. Ambos enfoques son legítimos, y ambos pueden generar valor en contextos adecuados. Pero la evidencia disponible permite afirmar que no son equivalentes en sus consecuencias organizativas, competitivas ni laborales, y que la elección entre uno y otro revela algo más profundo que una preferencia táctica: revela la visión que una empresa tiene sobre el papel de sus propios trabajadores en el proceso de creación de valor.

El estudio de Anthropic publicado en marzo de 2026 permite contextualizar esta conclusión con datos recientes. Introducen una métrica llamada “*observed exposure*”, que combina la capacidad teórica de los LLMs con datos reales de uso, ponderando más el uso automatizado (vía API¹², sin intervención humana) que el uso de augmentación (donde el humano permanece en el proceso). Esa decisión metodológica es, en sí misma, un reflejo de la dicotomía planteada en estas páginas. Los propios investigadores reconocen implícitamente que no es lo mismo sustituir que complementar, y que el riesgo de desplazamiento laboral proviene principalmente del primer canal (Massenkoff & McCrory, 2026).

El hallazgo central del estudio es que la cobertura real de la IA sigue siendo una fracción de lo técnicamente posible. En profesiones informáticas y matemáticas, los modelos cubren apenas el 33% de las tareas pese a que el 94% sería teóricamente automatizable. En el conjunto de la economía, un 30% de los trabajadores tiene exposición cero porque sus tareas ni siquiera aparecen en los datos de uso (Massenkoff & McCrory, 2026). Esto

¹² API: mecanismos que permiten a dos componentes de software comunicarse entre sí mediante un conjunto de definiciones y protocolos (Amazon, s.f.)

significa que estamos en las fases iniciales de un proceso de adopción que se acelerará a medida que las capacidades mejoren, los costes bajen y las barreras regulatorias y organizativas se vayan resolviendo. Esa brecha entre lo posible y lo real debería leerse como una ventana de oportunidad, no como un motivo de tranquilidad. Las empresas que utilicen este periodo para construir las condiciones organizativas, culturales y de gobernanza necesarias estarán mejor posicionadas cuando esa brecha se cierre.

Resulta significativo que los representantes de atención al cliente aparezcan como la segunda ocupación más expuesta en el estudio, con un 70,1% de cobertura observada (Massenkoff & McCrory, 2026). El dato valida empíricamente la elección de Klarna como caso de estudio y refuerza la advertencia. Quienes que han apostado por sustituir estos roles están operando en el segmento de mayor exposición, donde los efectos de la automatización son más visibles y donde, como Klarna demostró, los límites de la sustitución total se revelan con mayor rapidez.

Junto a esta ventana de oportunidad, los datos revelan también señales tempranas que conviene no ignorar. El estudio de Anthropic no encuentra un aumento sistemático del desempleo en las ocupaciones más expuestas desde finales de 2022, pero sí detecta señales tentativas de una ralentización en la contratación de trabajadores jóvenes, entre 22 y 25 años, en esas mismas ocupaciones. La tasa de inicio de empleo para este grupo en ocupaciones expuestas ha caído un 14% respecto a 2022, mientras que en ocupaciones no expuestas se ha mantenido estable (Massenkoff & McCrory, 2026). Brynjolfsson, Chandar y Chen confirman esta tendencia desde otra fuente de datos, documentando una caída de entre el 6% y el 16% en el empleo de trabajadores de 22 a 25 años en ocupaciones expuestas, atribuida principalmente a una ralentización de la contratación y no a un aumento de los despidos (Brynjolfsson, Chandar, & Chen, *Canaries in the Coal Mine? Six Facts about the Recent Employment Effects of Artificial Intelligence*, 2025).

Hay un dato adicional que rompe la narrativa habitual. El perfil demográfico de los trabajadores más expuestos no es el que muchos asumirían. Son, de media, más educados, mejor pagados y con mayor proporción de titulación universitaria que los trabajadores no expuestos. Los titulados con grado de máster o superior representan el 17,4% del grupo más expuesto frente al 4,5% del grupo sin exposición (Massenkoff & McCrory, 2026). La IA no amenaza principalmente a trabajadores poco cualificados; amenaza a los trabajadores del conocimiento, que son, precisamente, el núcleo de las organizaciones analizadas en los capítulos anteriores. Esto refuerza la importancia de la decisión

estratégica, porque cuando una empresa aplica un enfoque *cost-out* en roles de conocimiento, no está eliminando mano de obra sustituible, sino capital intelectual acumulado cuya reconstrucción es costosa y lenta.

La implicación directa para la tesis de este trabajo es la siguiente. Si los efectos tempranos de la IA se manifiestan como una menor contratación de perfiles jóvenes en ocupaciones expuestas, las organizaciones que adopten un enfoque *cost-out* no solo están reduciendo plantilla hoy, sino que están contribuyendo a estrechar el mercado de talento del que dependerán mañana. Es una decisión racional a corto plazo que puede convertirse en una desventaja estructural a medio plazo. El caso de Klarna lo ilustra: la empresa logró mejorar su margen operativo mediante sustitución, pero tuvo que rectificar cuando la calidad del servicio se deterioró, y su CEO sigue declarando que la plantilla continuará reduciéndose hasta menos de 2.000 empleados antes de 2030 (Shahidi, 2026). Lo que el modelo de creación de valor de este trabajo (Tabla 2) predice es que ese enfoque se detiene en la etapa 4, reducción de costes, sin generar las condiciones para el crecimiento orgánico, la innovación ni la ventaja competitiva sostenible que las etapas posteriores describen.

Ahora bien, esta defensa del *capacity-up* debe contextualizarse según el tipo de empresa. El enfoque *capacity-up* resulta más defendible estratégicamente para empresas consolidadas que compiten por cuota de mercado y diferenciación. McKinsey ha demostrado que es posible integrar agentes de IA en el núcleo de la operación sin eliminar empleo, manteniendo la supervisión humana como elemento estructural y redirigiendo la capacidad liberada hacia tareas de mayor valor. Ese diseño es más compatible con el marco regulatorio europeo, genera menor crispación organizacional y sitúa a la empresa en una posición desde la que puede capturar valor de forma sostenible. No es casualidad que las empresas que McKinsey identifica como *AI high performers* combinen eficiencia con metas de crecimiento e innovación, ni que casi tripliquen al resto en rediseño profundo de flujos de trabajo (McKinsey, 2025).

Sin embargo, esta conclusión debe matizarse. No todas las empresas parten de la misma posición. Para una empresa pequeña con recursos limitados, un enfoque *cost-out* acotado, que automatice tareas altamente estandarizadas y libere capital para invertir en crecimiento, puede ser no solo legítimo sino necesario como primera etapa. La clave está en que ese primer paso no se convierta en el destino final. El *cost-out* como fase transitoria, orientada a generar margen que financie una evolución posterior hacia el

capacity-up, es una secuencia coherente. El *cost-out* como filosofía permanente, en cambio, es una trampa: la *Turing Trap* aplicada a la estrategia empresarial. En esa secuencia, la empresa pequeña utiliza la automatización para competir en costes mientras construye, gradualmente, las capacidades organizativas y de gobernanza que le permitirán transitar hacia un modelo de crecimiento basado en la colaboración humano-agente.

Desde una perspectiva práctica, defender un enfoque *capacity-up* ante un comité de dirección exige reconocer su principal debilidad: la cuantificación del retorno es más compleja y el horizonte temporal es más largo que en un enfoque *cost-out*. Pero esa dificultad constituye, ante todo, un desafío de comunicación que puede abordarse con las herramientas adecuadas. A partir de la evidencia analizada, se proponen las siguientes recomendaciones para directivos que consideren esta estrategia.

En primer lugar, presentar el proyecto como inversión en crecimiento, no como gasto en tecnología. El modelo de creación de valor (Tabla 2) ofrece una estructura para vincular la inversión inicial con métricas de productividad, ingresos y ventaja competitiva. Un comité de dirección necesita ver la cadena causal completa, no solo el coste del despliegue. Utilizar las etapas del modelo para mostrar en qué punto se encuentra la empresa y hacia dónde puede avanzar da concreción a una propuesta que, sin ese armazón, puede parecer difusa.

En segundo lugar, cuantificar el coste de no actuar. Los datos de Gartner sobre la cancelación del 40% de proyectos agénticos y la brecha entre adopción e impacto documentada por McKinsey (88% de adopción, pero solo 39% con efecto en EBIT) son argumentos poderosos para justificar un despliegue riguroso frente a un piloto superficial. El riesgo va más allá del fracaso del proyecto en sí; si la iniciativa genera las tensiones internas que Strunk y otros documentan, la organización puede desarrollar una resistencia institucional difícil de revertir ante cualquier intento futuro.

En tercer lugar, proponer métricas intermedias creíbles. La productividad por empleado, el tiempo medio de resolución por caso, la tasa de adopción interna y la calidad del *output* medida por satisfacción del cliente son indicadores que pueden reportarse trimestralmente y que generan evidencia incremental sin esperar al impacto en EBIT. McKinsey midió la calidad de las respuestas de Lilli semana a semana durante el *alpha testing*, ese tipo de granularidad es lo que permite a un comité de dirección mantener la confianza en un proyecto cuyo retorno pleno es a medio plazo.

Por último, anclar la propuesta en el marco regulatorio. En el contexto europeo, el Reglamento (UE) 2024/1689 impone obligaciones reforzadas de supervisión humana y transparencia para sistemas de alto riesgo. Un enfoque *capacity-up*, que mantiene al trabajador en el proceso de decisión, no solo es buena práctica operativa sino también un factor de mitigación regulatoria. Esto puede ser un argumento decisivo para consejeros y directivos con sensibilidad al riesgo jurídico.

En definitiva, la sustitución masiva que muchos anticipan no se ha materializado, pero las señales de cambio son visibles y ya afectan a los segmentos más vulnerables del mercado laboral. Las empresas que decidan cómo implementar agentes de IA en los próximos años no solo están tomando una decisión tecnológica; están definiendo qué tipo de organización quieren ser, qué relación quieren tener con sus empleados y qué tipo de ventaja competitiva quieren construir. En un contexto donde la tecnología es accesible para todos, la diferenciación vendrá de la decisión sobre cómo utilizar la herramienta, no de la herramienta en sí.

Brynjolfsson advierte que cuando la IA se orienta a complementar al ser humano en lugar de imitarlo, las personas siguen siendo indispensables para la creación de valor, y que la augmentación genera mucho más valor que la mera inteligencia artificial a imagen del ser humano (Brynjolfsson, *The Turing Trap: The Promise & Peril of Human-Like Artificial Intelligence*, 2022). La solución, concluye, no es frenar la tecnología, sino redirigir los esfuerzos para evitar la *Turing Trap*. Este trabajo ha intentado concretar esa redirección. La dicotomía *cost-out* frente a *capacity-up* no es un ejercicio teórico, sino la decisión que define si una empresa utiliza la IA para reducir lo que tiene o para ampliar lo que puede llegar a ser. Las organizaciones que entiendan esa diferencia a tiempo no solo sobrevivirán a la disrupción, sino que la convertirán en ventaja competitiva. Las que no lo hagan, correrán el riesgo de haber invertido en la herramienta correcta con la estrategia equivocada.

V. Declaración del uso de IA

Por la presente, yo, Pablo Gómez Noverques, estudiante de Administración y Dirección de Empresas de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado " El impacto de los agentes de IA en la estrategia empresarial", 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. **Estudios multidisciplinares:** Para comprender perspectivas de otras comunidades sobre temas de naturaleza multidisciplinar.
5. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
6. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
7. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
8. **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: 23/03/2026

Firma: Pablo Gómez Noverques

VI. Bibliografía

- Amazon. (s.f.). *¿Qué es una interfaz de programación de aplicaciones (API)?* Obtenido de <https://aws.amazon.com/es/what-is/api/>
- BBVA. (4 de Mayo de 2021). *B2B, B2C, E2E... ¿Qué son y en qué se diferencian? 6 términos interesantes para conocer.* Obtenido de BBVA Spark: <https://www.bbvaspark.com/es/noticias/glosario-open-innovation-b2b-b2c-e2e-que-son-y-en-que-se-diferencian-6-terminos-interesantes-para-conocer/>
- BBVA. (15 de Abril de 2024). *ROI: qué es el retorno de la inversión y cuál es su fórmula.* Obtenido de <https://www.bbva.com/es/empresas/roi-que-es-el-retorno-de-la-inversion-y-cual-es-su-formula/>
- Brynjolfsson, E. (2022). The Turing Trap: The Promise & Peril of Human-Like Artificial Intelligence. *Dædalus, the Journal of the American Academy of Arts & Sciences.*
- Brynjolfsson, E., & Unger, G. (2023). The Macroeconomics of Artificial Intelligence. *Finance & Development*, 20-25.
- Brynjolfsson, E., Chandar, B., & Chen, R. (2025). *Canaries in the Coal Mine? Six Facts about the Recent Employment Effects of Artificial Intelligence.* Stanford Digital Economy Lab.
- Brynjolfsson, E., Li, D., & Raymond, L. (2023). *Generative AI at work.* National Bureau of Economic Research.
- Corbin, J. (12 de Enero de 2026). *Fast Company.* Obtenido de Klarna tried to replace its workforce with AI: <https://www.fastcompany.com/91468582/klarna-tried-to-replace-its-workforce-with-ai>
- DEGIRO. (s.f.). *¿Cuál es la diferencia entre el EBIT y el EBITDA? Significados y cómo calcularlos.* Obtenido de DEGIRO: <https://www.degiro.es/estrategias/analisis-fundamental/ebit-ebitda>
- Dell'Acqua, F., McFowland III, E., Mollick, E., Lifshitz-Assaf, H., Kellogg, K., Rajendran, S., . . . Lakhani, K. (2023). *Navigating the Jagged Technological Frontier: Field Experimental Evidence of the Effects of AI on Knowledge Worker Productivity and Quality.* Harvard Business School.
- Dorsey, J. (2026). *Q4 2025 Shareholder Letter.* Block, Inc.
- Gartner. (25 de Junio de 2025). *Gartner predicts over 40% of agentic AI projects will be canceled by end of 2027.* Obtenido de <https://www.gartner.com/en/newsroom/press-releases/2025-06-25-gartner-predicts-over-40-percent-of-agentic-ai-projects-will-be-canceled-by-end-of-2027>

- High-level summary of the AI Act.* (27 de Febrero de 2024). Obtenido de EU Artificial Intelligence Act: <https://artificialintelligenceact.eu/high-level-summary/>
- Klarna. (27 de Febrero de 2024). *Klarna AI assistant handles two-thirds of customer service chats in its first month.* Obtenido de Klarna.com: <https://www.klarna.com/international/press/klarna-ai-assistant-handles-two-thirds-of-customer-service-chats-in-its-first-month/>
- Mann, J. (13 de Marzo de 2025). *Klarna wants to go public, but employees are worried about a 'Klarnageddon'.* Obtenido de Business Insider: <https://www.businessinsider.com/klarna-ipo-employees-in-limbo-2025-3>
- Massenkoff, M., & McCrory, P. (2026). *Labor market impacts of AI: A new measure and early evidence.* Anthropic.
- McKinsey & Company. (2024). *Rewiring the way McKinsey works with Lilli, our generative AI platform.* Obtenido de <https://www.mckinsey.com/capabilities/tech-and-ai/how-we-help-clients/rewiring-the-way-mckinsey-works-with-lilli>
- McKinsey. (Noviembre de 2025). *The state of AI in 2025: Agents, innovation, and transformation.* Obtenido de QuantumBlack - AI by McKinsey: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai>
- OVB. (17 de Marzo de 2023). *¿Invirtiendo en negocios? Descubre la diferencia entre Capex y Opex.* Obtenido de <https://www.ovb.es/blog/articulo/capex-opex.html>
- Porter, M. (1998). *Competitive Strategy: Techniques for Analyzing Industries and Competitors.* The Free Press.
- Randstad. (3 de Abril de 2025). *Qué es un FTE (Full Time Equivalent) y cómo calcularlo.* Obtenido de Randstad: <https://www.randstad.es/contenidos360/reclutamiento/fte-full-time-equivalent/>
- Ransbotham, S., Kiron, D., Khodabandeh, S., Iyer, S., & Das, A. (Noviembre de 2025). *The Emerging Agentic Enterprise: How Leaders Must Navigate a New Age of AI.* Obtenido de MIT Sloan Management Review; Boston Consulting Group: <https://www.bcg.com/publications/2025/machines-that-manage-themselves>
- Salesforce. (28 de Junio de 2024). Obtenido de Share of Wallet: *¿qué es y cómo aumentarla?:* <https://www.salesforce.com/mx/blog/share-of-wallet/>
- Shahidi, R. (17 de Febrero de 2026). *Klarna has 3,000 employees. The CEO says he expects that to be down to less than 2,000 employees by 2030.* Obtenido de Business Insider: <https://www.businessinsider.com/klarna-ceo-workforce-shrink-to-under-2000-by-2030-ai-2026-2>

- Strunk, J. A., Banh, L., Nissen, A., Strobel, G., & Smolnik, S. (2024). To Delegate or Not to Delegate? Factors Influencing Human-Agentive IS Interaction. *Proceedings of the 45th International Conference on Information Systems (ICIS 2024)*. Bangkok.
- Varanasi, L. (14 de Junio de 2024). *McKinsey exec tells summer interns that learning to ask AI the right questions is the key to success*. Obtenido de Business Insider: <https://www.businessinsider.com/mckinsey-prompt-engineer-ai-right-questions-key-to-success-interns-2024-6>
- Varanasi, L. (2 de Febrero de 2026). *How AI is changing the storied McKinsey interview*. Obtenido de Business Insider: <https://www.businessinsider.com/mckinsey-interview-case-study-ai-test-bcg-2026-1>