

Universidad Pontificia Comillas

**Doctorate of Business Administration in
Management and Technology**

**La Adopción de la
Inteligencia Artificial en el
Sector Asegurador Español:
Análisis cualitativo de los Factores
Organizativos, Tecnológicos y
Ambientales según el Nivel de Madurez**

Autor: Antonio López López

Directora: Cristina Domínguez Soto

Codirector: David Contreras Bárcena

MADRID | Septiembre de 2025

Agradecimientos

La culminación de esta tesis doctoral no habría sido posible sin el apoyo de numerosas personas e instituciones, a quienes expreso mi más sincero agradecimiento.

En primer lugar, a mis directores de tesis, la Dra. Cristina Domínguez y el Dr. David Contreras, por su experta orientación, sus valiosas sugerencias y su constante apoyo durante todo este proceso de investigación.

Extiendo mi reconocimiento a la Universidad Pontificia Comillas, a su claustro de profesores y al personal de administración y servicios, por brindarme un entorno de exigencia intelectual y acompañamiento que ha sido fundamental en este recorrido académico.

Quiero agradecer de manera especial la generosidad y amabilidad de todas las personas que participaron en las entrevistas, cuyos testimonios y tiempo dedicado constituyen la materia prima de esta investigación.

En el ámbito profesional, agradezco sinceramente a mi empresa, Mutual Médica, las facilidades brindadas para compatibilizar mis responsabilidades laborales con la dedicación que esta tesis requería.

Finalmente, en lo personal, esta tesis no habría sido posible sin el apoyo de mis seres más queridos. A mis padres, por su inmenso esfuerzo y sacrificio para darnos la mejor formación posible y por ser un ejemplo constante de trabajo y perseverancia. Asimismo, a mi hermano, el Dr. David López, por su lúcida perspectiva y sus valiosos consejos.

Y, por encima de todo, a mi mujer, Isabel, y a mis hijos, Claudia y Marc. Gracias por vuestra paciencia, por vuestro cariño incondicional y por comprender mis largas horas de ausencia, tanto física como mental. Habéis sido mi refugio y mi mayor motivación. Sin vosotros, nada de esto tendría sentido.

Índice General

AGRADECIMIENTOS.....	2
ÍNDICE GENERAL	3
ÍNDICE DE FIGURAS	6
ÍNDICE DE TABLAS	8
TABLA DE ACRÓNIMOS	10
ABSTRACT	13
1. INTRODUCCIÓN.....	14
1.1. Propósito y contextualización del estudio	14
1.2. Brecha y preguntas de investigación	16
1.3. Relevancia y contribución del estudio	18
1.4. Enfoque metodológico	19
1.5. Estructura de la tesis	22
2. REVISIÓN DE LA LITERATURA Y BRECHA DE INVESTIGACIÓN	23
2.1. Potencial de la IA	23
2.2. Inteligencia Artificial en el sector asegurador	24
2.3. Marcos de adopción de tecnología e innovación	28
2.4. Literatura existente sobre factores de éxito en la adopción de IA	30
2.4.1. Factores organizativos	31
2.4.2. Factores tecnológicos	35
2.4.3. Factores ambientales.....	38
2.5. Evaluación del nivel de madurez en inteligencia artificial	41
2.6. Evidencia reciente sobre la “GenAI”	48
3. METODOLOGÍA DE LA INVESTIGACIÓN	50
3.1. Enfoque metodológico	50
3.2. Consideraciones y retos metodológicos	51
3.3. Técnica de recolección de datos.....	52
3.3.1. Entrevistas semiestructuradas.....	52
3.3.2. Selección y composición de la muestra	56
3.3.3. Trabajo de campo, desarrollo y grabación	59
3.3.4. Procedimiento de la transcripción	61
3.4. Codificación y análisis del discurso	63
3.5. Asignación de niveles de madurez	66
3.5.1. Marco Teórico y Metodológico de Referencia	66
3.5.2. Proceso de Asignación de Niveles de Madurez	67
3.6. Criterios de evaluación	73
4. RESULTADOS	75
4.1. Dimensión Organización (O).....	81
4.1.1. Coste-Beneficio y ROI.....	81
4.1.1.1. Ventaja Relativa	82
4.1.1.2. Análisis coste-beneficio	87
4.1.1.3. Rentabilidad tangible e intangible	95
4.1.1.4. Medición del retorno	98
4.1.1.5. Selección y Priorización de Casos de Uso de IA.....	100
4.1.2. Talento y Cultura	103
4.1.2.1. Brecha de capacidades	103
4.1.2.2. Atracción y Retención de Talento Especializado	111
4.1.2.3. Formación y Upskilling	117
4.1.2.4. Clima y Sentido de Pertenencia	121

4.1.2.5.	Cultura Organizativa y Resistencia al Cambio	122
4.1.2.6.	Cultura de Innovación	127
4.1.3.	Organización y Gobierno.....	137
4.1.3.1.	Estructura de Liderazgo: papel del Comité de Dirección	137
4.1.3.2.	Centros de Competencia y Estructuras de Gobierno de IA	141
4.1.3.3.	Reingeniería de Procesos (BPR)	144
4.1.3.4.	Influencia del Tamaño	146
4.1.3.5.	Modelo Operativo (por producto, transversal, etc.)	153
4.1.3.6.	Complejidad organizativa	156
4.1.3.7.	Relaciones Grupo-Filial	157
4.1.4.	Implementación y gestión del cambio	160
4.1.4.1.	Planificación y gobierno del cambio	160
4.1.4.2.	Enfoque Incremental.....	162
4.1.4.3.	Métodos de Priorización y Evaluación de Casos	165
4.1.4.4.	Gobernanza de los modelos de IA	169
4.1.4.5.	Acompañamiento a los empleados	173
4.1.4.6.	Relación con proveedores y consultoras	176
4.1.5.	Visión y Estrategia	181
4.1.5.1.	Integración de la IA en el Plan Estratégico	181
4.1.5.2.	Alineación con la Visión de la Alta Dirección	185
4.1.5.3.	La IA como Eje Transformador	186
4.2.	<i>Dimensión Tecnología (T)</i>	190
4.2.1.	Madurez y Expectativas	190
4.2.1.1.	Madurez de la Tecnológica.....	190
4.2.1.2.	“Hype” y expectativas infladas.....	193
4.2.1.3.	Evolución Progresiva vs. Disrupción	197
4.2.1.4.	Adopción Gradual	198
4.2.2.	Datos e Infraestructura	201
4.2.2.1.	Sistemas <i>Legacy</i>	202
4.2.2.2.	Arquitectura Tecnológica.....	203
4.2.2.3.	Repositorios de datos centralizados.....	204
4.2.2.4.	Calidad del Dato	205
4.2.2.5.	Gobernanza del Dato	206
4.2.2.6.	Plataformas Tecnológicas (<i>CoPilot</i> , <i>Salesforce</i> , etc.)	208
4.2.2.7.	Dependencia Tecnológica / Lock-in.....	209
4.2.3.	Riesgos.....	211
4.2.3.1.	Caja negra y explicabilidad de los modelos.....	212
4.2.3.2.	Alucinaciones en modelos generativos.....	214
4.2.3.3.	Riesgos éticos y discriminación	215
4.2.3.4.	Pérdida de control sobre procesos	216
4.2.3.5.	Reputación y confianza	218
4.3.	<i>Dimensión Entorno (E)</i>	220
4.3.1.	Entorno y factores externos	221
4.3.1.1.	Presión Competitiva y Papel de las <i>InsurTech</i>	221
4.3.1.2.	Preparación y aceptación de los clientes	225
4.3.1.3.	Papel de los Mediadores.....	227
4.3.1.4.	Preocupaciones Éticas y Sociales	229
4.3.1.5.	Colaboración con socios externos	231
4.3.2.	Regulación	234
4.4.	<i>Niveles de Adopción AIMM</i>	236
4.5.	<i>Casos de uso</i>	242
4.5.1.	Casos de uso y niveles de adopción AIMM	245
4.5.2.	Casos de uso en la cadena de valor aseguradora	247
5.	DISCUSIÓN	251

5.1.	<i>Dimensión Organización</i>	251
5.2.	<i>Dimensión Tecnología</i>	256
5.3.	<i>Dimensión Entorno</i>	260
5.4.	<i>Niveles de Adopción AIMM</i>	264
6.	CONCLUSIONES	269
6.1.	<i>Conclusiones fundamentales</i>	269
6.2.	<i>Contribuciones teóricas principales</i>	272
6.3.	<i>Recomendaciones prácticas</i>	273
6.4.	<i>Limitaciones de la investigación</i>	277
6.5.	<i>Líneas futuras de investigación</i>	278
	REFERENCIAS	280
	ANEXOS	290
	<i>Anexo 1: Manual de códigos</i>	290
	<i>Anexo 2: Libro de códigos de NVivo: Descripciones, número de entrevistas y número de referencias</i>	315
	<i>Anexo 3: Matriz de codificación de entrevistas: distribución de referencias por categorías temáticas y entrevistas</i>	323
	EXTENDED SUMMARY	325

Índice de Figuras

Figura 1. Esquema del diseño metodológico	21
Figura 2: Comparativa 2023-2024 de problemas percibidos en la adopción de inteligencia artificial en aseguradoras españolas que trabajan con IA	46
Figura 3: Comparativa 2023-2024 de problemas percibidos en la adopción de inteligencia artificial en aseguradoras españolas que no trabajan con IA.....	47
Figura 4: Esquema metodológico.....	72
Figura 5: Treemap de categorías NVivo según volumen de referencias y número de entrevistas	78
Figura 6: Representación gráfica de la distribución de referencias por dimensiones TOE	79
Figura 7: Entrevistas y referencias por subcategorías de Coste-beneficio y ROI	81
Figura 8: Distribución de referencias y entrevistas por dimensiones de la ventaja relativa de la IA ..	83
Figura 9: Distribución de referencias y entrevistas por dimensiones de la rentabilidad intangible de la IA.....	96
Figura 10: Distribución de entrevistas y referencias por subcategorías de talento y cultura	103
Figura 11: Distribución de entrevistas y referencias en los principales desafíos de talento en IA..	112
Figura 12: Distribución de entrevistas y referencias en las subcategorías de organización y gobierno	137
Figura 13: Modelos de liderazgo en la adopción de IA según la categoría de tamaño.....	140
Figura 14: Modelos de liderazgo en la adopción de IA según nivel de madurez	141
Figura 15: Evolución de la gobernanza de la IA según niveles de madurez AIMM.....	144
Figura 16: Relación entre tamaño de las entidades y nivel de madurez en IA (AIMM)	151
Figura 17: Madurez promedio AIMM por categoría de tamaño de entidad.....	152
Figura 18: Distribución de entrevistas y referencias por subcategorías de implementación y gestión del cambio.....	160
Figura 19: Distribución de entrevistas y referencias en las subcategorías de madurez y expectativas sobre la IA.....	190
Figura 20: Percepción de la madurez tecnológica según nivel AIMM (número de entidades)	192
Figura 21. Percepción de la madurez tecnológica según nivel AIMM (porcentaje de entidades) ...	193
Figura 22: Percepción de existencia de “hype” según nivel AIMM (número de entidades)	197
Figura 23: Distribución de entrevistas y referencias en las subcategorías de datos e infraestructura	202
Figura 24: Distribución de entrevistas y referencias en las subcategorías de riesgos asociados a la adopción de IA	212
Figura 25: Distribución de entrevistas y referencias en las subcategorías de Entorno y factores externos	221
Figura 26: Mapa de calor de referencias por nivel de madurez AIMM y código temático:.....	237

Figura 27: drivers y barreras de adopción de IA en nivel Initial, clasificados en las dimensiones TOE 238

Figura 28: drivers y barreras de adopción de IA en nivel Assessing, clasificados en las dimensiones TOE 239

Figura 29: drivers y barreras de adopción de IA en nivel Determined, clasificados en las dimensiones TOE 240

Figura 30: drivers y barreras de adopción de IA en nivel Managed, clasificados en las dimensiones TOE 241

Figura 31: evolución de drivers y barreras en el ciclo de madurez organizativa..... 241

Índice de Tablas

Tabla 1. Cadena de Valor del Seguro y Aplicaciones de IA	26
Tabla 2. Resumen de factores organizativos (TOE).....	33
Tabla 3. Resumen de factores tecnológicos (TOE)	36
Tabla 4. Resumen de factores del entorno (TOE)	39
Tabla 5: Problemas percibidos en la adopción de inteligencia artificial en aseguradoras españolas	44
Tabla 6: Ejemplo de correspondencia entrevista E03 – guion TOE–DOI–AIMM	54
Tabla 7: Frecuencia de aparición de los principales códigos temáticos en las entrevistas	65
Tabla 8. Criterios operativos para la asignación de niveles de madurez en IA según el AIMM.....	71
Tabla 9: Clasificación de los códigos temáticos de las entrevistas según las dimensiones TOE	75
Tabla 10: Resumen cuantitativo de códigos NVivo.....	78
Tabla 11: Distribución de referencias por dimensiones TOE en las entrevistas	79
Tabla 12: Dimensiones de la ventaja relativa de la IA en aseguradoras españolas.....	82
Tabla 13: Ventaja relativa de la IA: comparación entre modelos predictivos y generativos	87
Tabla 14: Dimensiones de la rentabilidad intangible de la IA	95
Tabla 15: Brechas de talento, culturales y estratégicas	104
Tabla 16: Desafíos de talento en la adopción de IA.....	111
Tabla 17: Síntesis de brechas y respuestas organizativas en la adopción de IA	132
Tabla 18: Distribución de modelos de liderazgo	138
Tabla 19: Evolución de los modelos operativos según el nivel de madurez	155
Tabla 20: Fases de adopción de la IA en aseguradoras españolas: PoC, piloto y escalado	164
Tabla 21: Factores de priorización y evaluación de casos de uso de IA en aseguradoras españolas	168
Tabla 22: Mecanismos de acompañamiento a empleados en la adopción de IA	175
Tabla 23: Evolución de la relación con proveedores y consultoras según niveles de madurez AIMM	179
Tabla 24: Integración de la IA en los planes estratégicos según niveles de madurez AIMM.....	183
Tabla 25: Visiones estratégicas de la IA en el sector asegurador según niveles de madurez AIMM	188
Tabla 26: Distribución de entidades aseguradoras por nivel de madurez en IA según el modelo AIMM.....	236
Tabla 27: Casos de uso de inteligencia artificial en aseguradoras españolas por área funcional y estado de adopción	243
Tabla 28: Casos de uso de IA en la cadena de valor aseguradora: contraste entre las aplicaciones según la literatura y la evidencia empírica	248

Tabla 29: Hallazgos empíricos y correspondencia con la literatura en la dimensión organizativa de la adopción de IA.....	253
Tabla 30: Hallazgos empíricos y correspondencia con la literatura en la dimensión tecnológica de la adopción de IA	258
Tabla 31: Hallazgos empíricos y correspondencia con la literatura en la dimensión entorno de la adopción de IA	262
Tabla 32: Coincidencias con la literatura académica y matices emergentes de la adopción de IA en aseguradoras españolas según el marco TOE y la progresión AIMM.....	265

Tabla de Acrónimos

Acrónimo	Término en inglés	Traducción
AI Act	Artificial Intelligence Act	Reglamento de Inteligencia Artificial de la Unión Europea
AIMM	Artificial Intelligence Maturity Model	Modelo de Madurez de Inteligencia Artificial
API	Application Programming Interface	Interfaz de Programación de Aplicaciones
BI	<i>Business intelligence</i>	Inteligencia de Negocio
BPO	Business Process Outsourcing	Externalización de Procesos de Negocio
BPR	Business Process Reengineering	Reingeniería de Procesos
BYOK	Bring Your Own Key	Aporte/custodia de claves del cliente
CEO	Chief Executive Officer	Consejero Delegado / Director General
CIO	Chief Information Officer	Director de Sistemas de Información / Director de TI
CMMI	Capability Maturity Model Integration	Integración del Modelo de Madurez de Capacidades
CoE	Center of Excellence	Centro de Excelencia
CRM	Customer Relationship Management	Gestión de Relaciones con Clientes
CTO	Chief Technology Officer	Director de Tecnología
DOI	Diffusion of Innovations	Difusión de Innovaciones
ERP	Enterprise Resource Planning	Planificación de Recursos Empresariales
FTE	Full-Time Equivalent	Equivalente a Tiempo Completo
GANs	Generative Adversarial Networks	Redes Generativas Antagónicas
GenAI	Generative Artificial Intelligence	Inteligencia Artificial Generativa

Acrónimo	Término en inglés	Traducción
GPT	Generative Pre-trained Transformer	Transformador Pre-entrenado Generativo
IA	—	Inteligencia Artificial
ICEA	—	Investigación Cooperativa entre Entidades Aseguradoras y Fondos de Pensiones
IS	Information Systems	Sistemas de Información
IT (Incapacidad Temporal)	—	Prestación por Incapacidad Temporal (no confundir con TI)
KPI	Key Performance Indicator	Indicador Clave de Rendimiento
LLMs	Large Language Models	Grandes Modelos de Lenguaje
ML	Machine Learning	Aprendizaje Automático
MLOps	Machine Learning Operations	Operaciones de Aprendizaje Automático
MVP	Minimum Viable Product	Producto Mínimo Viable
NPS	Net Promoter Score	Índice de Promotores Neto (lealtad del cliente)
OMPI	—	Organización Mundial de la Propiedad Intelectual
PIB	—	Producto Interior Bruto
PoC	Proof of Concept	Prueba de Concepto
PyME	—	Pequeña y Mediana Empresa
RACI	Responsible, Accountable, Consulted, and Informed	Responsable, Aprobador, Consultado e Informado
RGPD	General Data Protection Regulation (GDPR)	Reglamento General de Protección de Datos
ROI	Return on Investment	Retorno de la Inversión
RRHH	—	Recursos Humanos
SaaS	Software as a Service	Software como Servicio
SAFe	Scaled <i>Agile</i> Framework	Marco de escalado ágil

Acrónimo	Término en inglés	Traducción
TAM	Technology Acceptance Model	Modelo de Aceptación Tecnológica
TI	—	Tecnologías de la Información
TIR	—	Tasa Interna de Retorno
TOE	Technology–Organization–Environment	Tecnología–Organización–Entorno
TPB	Theory of Planned Behaviour	Teoría del Comportamiento Planificado
TRA	Theory of Reasoned Action	Teoría de la Acción Razonada
TRI	Technology Readiness Index	Índice de Preparación Tecnológica
UTAUT	Unified Theory of Acceptance and Use of Technology	Teoría Unificada de Aceptación y Uso de Tecnología

Nota: En esta tesis, el acrónimo IT se emplea exclusivamente para referirse a la prestación por Incapacidad Temporal. Para el concepto de tecnología se utiliza de forma sistemática el acrónimo TI (Tecnologías de la Información).

Abstract

Esta tesis analiza cómo las aseguradoras españolas adoptan la inteligencia artificial (IA) como proceso sociotécnico donde interactúan personas, cultura organizativa, regulación y estrategia. Bajo un enfoque interpretativo–constructivista, se realizaron 16 entrevistas en profundidad a altos directivos de entidades que, en conjunto, representan aproximadamente el 60% del mercado español por volumen de primas. El diseño combina un marco deductivo (Tecnología–Organización–Entorno, Difusión de Innovaciones y Artificial Intelligence Maturity Model (AIMM) con la lógica inductiva de Grounded Theory. El análisis temático híbrido (deductivo–inductivo) permite identificar impulsores y barreras en cada etapa de madurez, ofreciendo una visión dinámica y contextualizada del proceso de adopción.

Los hallazgos sugieren que la adopción de la inteligencia artificial depende menos de la tecnología disponible y más de dimensiones humanas y organizativas — cultura, liderazgo, talento y gestión del cambio—. El proceso de adopción habitual es escalonado: comienza con una prueba de concepto, continúa con un piloto y, si se confirma el valor, culmina en el despliegue; la priorización de casos de uso se rige por la ventaja relativa. Asimismo, se distingue entre la IA predictiva —que suele ofrecer retornos financieros incrementales e inmediatos (eficiencia, ahorro, reducción de tiempos)— y la IA generativa —vinculada a beneficios estratégicos e intangibles (aprendizaje organizativo, reputación, preparación cultural)—. Esta dualidad conduce a una gobernanza bimodal con criterios diferenciados. En este marco, los pilotos cumplen un doble propósito: legitiman internamente las iniciativas y, a la vez, contribuyen a mitigar riesgos.

La tesis aporta un modelo integrado TOE–DOI–AIMM que explica cómo varía la relevancia de los factores tecnológicos, organizativos y ambientales según la etapa de madurez, ofreciendo una guía práctica para concentrar esfuerzos en cada momento. Asimismo, pone en valor intangibles como la capacidad de absorción, la productividad asistida y la reputación como parte del retorno de la IA. Se presentan recomendaciones para aseguradoras, proveedores y reguladores orientadas a un escalado seguro, medible y sostenible, junto con limitaciones (enfoque cualitativo, contexto español, visión directiva) y líneas futuras comparativas e internacionales.

Palabras clave: inteligencia artificial; sector asegurador; adopción tecnológica; TOE; DOI; madurez; Grounded Theory; gobernanza de IA; España.

1. Introducción

1.1. Propósito y contextualización del estudio

El propósito de esta tesis es analizar los factores que facilitan o dificultan la adopción de IA en aseguradoras incumbentes que operan en España, considerando las distintas etapas de madurez tecnológica. El estudio se apoya en un marco teórico que integra el modelo Tecnología–Organización–Entorno (TOE) de Tornatzky & Fleischer (1990), con la teoría de la Difusión de Innovaciones (DOI) de Rogers (1995) y el Artificial Intelligence Maturity Model (AIMM) de Alsheibani et al. (2019). Este enfoque combinado permite identificar impulsores y barreras en cada fase del ciclo de despliegue, ofreciendo una visión dinámica y contextualizada del proceso de adopción.

La IA se ha consolidado como una tecnología transformadora en sectores intensivos en datos como son los sectores de la sanidad, el transporte, la manufactura, la educación y las finanzas (Dwivedi et al., 2021). En este contexto, la industria aseguradora, parte integrante del sector financiero, está particularmente bien posicionada para beneficiarse de su adopción: puede revolucionar la interacción con clientes, automatizar procesos clave, optimizar la selección de riesgos y mejorar la gestión de siniestros.

Su integración en la economía global impulsa mejoras operativas, el desarrollo de nuevos productos y la apertura de mercados. No obstante, la dependencia de grandes volúmenes de datos plantea retos regulatorios y riesgos de sesgo que pueden derivar en resultados discriminatorios. Además, la autonomía de decisión de algunos sistemas y su limitada comprensión contextual generan inquietudes sobre su impacto social, especialmente en el empleo y la desigualdad (Reillon, 2018).

A nivel internacional, el interés por la IA es compartido por la academia, la industria, los gobiernos y la sociedad civil. El AI Index de la Universidad de Stanford (2023) reporta un fuerte crecimiento de publicaciones, patentes, inversión privada y actividad legislativa entre 2010 y 2021 (Maslej et al., 2023). Según la OMPI (2019), las áreas con mayor número de patentes se concentran en telecomunicaciones, transporte, ciencias de la vida y computación personal, destacando el machine learning como principal campo de aplicación y el *deep learning* y las redes neuronales como las tecnologías de mayor crecimiento.

Las estimaciones económicas de consultoras de primer nivel ponen de manifiesto su potencial: McKinsey Global Institute (2018) estimó que la IA podría aportar 13 billones de dólares al PIB mundial en 2030 (Bughin et al., 2018), mientras PwC (2017) proyectó un impacto de 15,7 billones (Rao & Verweij, 2017). Con el auge de la IA generativa, estas cifras se han revisado al alza: McKinsey & Company prevé que

podría añadir entre 2,6 y 4,4 billones de dólares anuales (Chui et al., 2023) y Goldman Sachs Research (2023) calcula un incremento del 7 % del PIB mundial. Aunque la IA generativa se conocía desde 2019 (GPT-2), su potencial disruptivo para los negocios se evidenció tras la popularización de herramientas de uso masivo a finales de 2022 y principios de 2023 (MIT Technology Review Insights, 2023).

La IA ya ha empezado a transformar la operativa de las entidades aseguradoras, con aplicaciones en prácticamente todas sus áreas de negocio (Ceylan, 2022; Gupta et al., 2022), desde la suscripción hasta el servicio al cliente, permite optimizar procesos, mejorar resultados técnicos y redefinir la propuesta de valor (Eling & Lehmann, 2018). Sin embargo, también plantea nuevos riesgos, dilemas éticos y retos de gobernanza (Dutt, 2020; Mullins et al., 2021).

Entre sus principales ventajas destacan:

Relación con los asegurados: los *Chatbots* y asistentes virtuales mejoran su experiencia mediante respuestas inmediatas y personalizadas, optimizando marketing, ventas y retención. El análisis avanzado de datos facilita el paso de un enfoque reactivo (“detectar y reparar”) a uno preventivo (“predecir y prevenir”), impulsando un cambio hacia la prevención de pérdidas (Balasubramanian et al., 2018; Eling & Lehmann, 2018; Kelley et al., 2018).

Automatización de procesos: la digitalización y la automatización de tareas manuales (como la introducción de datos o la tramitación de siniestros) reducen costes y errores, y liberan recursos para actividades de mayor valor (Balasubramanian et al., 2018; Eling & Lehmann, 2018).

Mejora en la toma de decisiones: la analítica multifuente permite tarificación precisa y en tiempo real, detección de fraude y una mayor satisfacción del cliente (Balasubramanian et al., 2018; Eling & Lehmann, 2018).

Pese a su potencial, la adopción de IA en el sector asegurador español ha sido más lenta que en otras industrias (Rangwala et al., 2020), limitándose con frecuencia a pruebas de concepto y pilotos con escaso escalado (Kruse et al., 2019).

El VIII Termómetro de Inteligencia Artificial y Big Data en el Sector Asegurador (ICEA, 2023) muestra que, en España, el 73% de las aseguradoras ha empezado a trabajar en proyectos de IA, pero solo el 5,7% se encuentra en fase de desarrollo y un 20 % aún no tiene ninguna iniciativa. Estos datos evidencian un interés creciente en la IA, pero también un gap entre su potencial y su despliegue efectivo en las entidades, lo que justifica la necesidad de este estudio.

1.2. Brecha y preguntas de investigación

“La tecnología existe, pero no la ponemos en marcha. Y la pregunta es ¿por qué?” (E01).

Esta reflexión, expresada por uno de los directivos entrevistados, resume el núcleo del problema que aborda esta investigación: la brecha entre la disponibilidad técnica de la inteligencia artificial y su adopción efectiva en las organizaciones.

La revisión de la literatura pone de relieve cuatro vacíos principales que ayudan a contextualizar esta brecha y justifican la presente tesis:

1. **Aplicación limitada del marco TOE al caso de la IA.**

Aunque el modelo Tecnología–Organización–Entorno (TOE) se ha consolidado como referencia en los estudios de adopción tecnológica, todavía son escasos los trabajos que lo aplican de manera sistemática al ámbito específico de la IA. Esta carencia ha derivado en un cuerpo de evidencias fragmentado, con análisis que enfatizan factores aislados y que ofrecen resultados poco acumulables entre sí.

2. **Escasez de evidencia sectorial en el seguro español.**

La mayor parte de la literatura disponible se centra en sectores distintos o en contextos internacionales, lo que limita la comprensión de las particularidades del mercado asegurador español. Factores como la regulación, la estructura de distribución o la cultura de aversión al riesgo condicionan la adopción de IA y hacen necesario un análisis contextualizado.

3. **Falta de incorporación de la dimensión de madurez.**

Son pocos los estudios que analizan cómo evolucionan los factores de adopción a lo largo de las diferentes etapas, desde la prueba de concepto hasta el despliegue a escala. Esta ausencia impide capturar dinámicamente cómo varían las barreras y los facilitadores en función del grado de madurez tecnológica y organizativa.

4. **Carencia de marcos combinados que integren TOE, DOI y AIMM.**

Existen escasos intentos de conectar los factores TOE con modelos evolutivos como la Difusión de Innovaciones (DOI) y el modelo de madurez en IA (AIMM). Esta integración permitiría mapear de manera más precisa qué factores son más relevantes en cada fase y ofrecer hojas de ruta de adopción ajustadas a la realidad de las organizaciones.

A la luz de estos vacíos, y de la paradoja señalada por los propios directivos —la existencia de la tecnología frente a la dificultad de ponerla en marcha—, esta tesis plantea dos preguntas de investigación centrales:

- **P1:** ¿Qué factores facilitan o dificultan la adopción de proyectos de IA en aseguradoras españolas consolidadas?
- **P2:** ¿Qué factores adquieren mayor relevancia en cada etapa del proceso de adopción?

1.3. Relevancia y contribución del estudio

Esta tesis busca aportar valor tanto en el plano teórico como en el práctico, abordando de forma directa los vacíos identificados en la literatura.

Contribución teórica.

El estudio enriquece la investigación sobre adopción tecnológica organizativa al aplicar y extender el marco TOE al caso específico de la inteligencia artificial en el sector asegurador. Además, combina dicho marco con la teoría de la Difusión de Innovaciones (DOI) y con el Artificial Intelligence Maturity Model (AIMM), lo que permite analizar no solo los factores que influyen en la adopción, sino también cómo estos cambian en función de la etapa de madurez. Esta integración ofrece una visión más dinámica y evolutiva, superando los enfoques estáticos o parciales predominantes en la literatura actual.

Contribución práctica.

En el plano aplicado, los hallazgos proporcionan orientaciones útiles para distintos actores:

- Para las aseguradoras: sirven como guía para priorizar inversiones, diseñar hojas de ruta de adopción y maximizar el valor estratégico de la IA.
- Para los reguladores: ofrecen insumos para formular políticas que faciliten una adopción responsable y sostenible en un sector crítico como el asegurador.
- Para el conjunto del ecosistema: generan aprendizajes extrapolables a otros sectores con retos similares en términos de regulación, madurez tecnológica y presión competitiva.

En un contexto marcado por la presión de las *InsurTech*, la reducción de márgenes y la erosión de ventajas tradicionales (Eling & Lehmann, 2018; Ceylan, 2022; Xu & Zweifel, 2020), este estudio ofrece un marco interpretativo y estratégico que contribuye tanto al avance de la literatura como al fortalecimiento competitivo del sector.

1.4. Enfoque metodológico

El presente estudio analiza la adopción de IA en compañías aseguradoras, un fenómeno que no puede entenderse únicamente como un proceso técnico, sino como una realidad compleja, dinámica y profundamente contextual. La implementación de la IA no puede entenderse de forma aislada, sino como un proceso condicionado por múltiples factores —tecnológicos, organizativos, estratégicos, regulatorios y culturales— cuya interacción dinámica produce tensiones y contradicciones difíciles de aprehender desde aproximaciones puramente cuantitativas.

Por ello, el análisis de este proceso requiere un marco metodológico capaz de ir más allá de la medición y de aproximarse a los significados que los actores atribuyen a la IA en sus contextos concretos. Más que describir resultados numéricos, se busca comprender cómo los directivos construyen, negocian y transforman las narrativas en torno a la IA, qué expectativas depositan en ella y cómo estas expectativas se reconfiguran a medida que avanza su integración en las organizaciones.

Este enfoque responde a la convicción de que la adopción de tecnologías emergentes, y en particular de la IA, debe estudiarse como un proceso sociotécnico: un entramado donde los algoritmos, los datos y las infraestructuras conviven con personas, estructuras de poder, rutinas y regulaciones sectoriales. De ahí la elección de un enfoque interpretativo como vía de análisis, sustentado en entrevistas cualitativas y análisis temático, que permita captar tanto los discursos explícitos como las lógicas implícitas de decisión y de acción en las aseguradoras.

Siguiendo la propuesta de Hudson y Ozanne (1988), esta investigación se fundamenta en una ontología constructivista, que concibe la realidad como una construcción social generada a partir de interacciones, percepciones y marcos de referencia compartidos por los individuos. Esto implica que no existe una única “verdad” objetiva sobre la adopción de IA, sino múltiples realidades que dependen del contexto cultural, organizativo y temporal en el que se sitúan los actores.

Este posicionamiento ontológico se articula con una epistemología interpretativista, que sostiene que el conocimiento se obtiene a través de la comprensión profunda (Verstehen) de las experiencias, motivaciones y procesos tal como son vividos y relatados por los participantes. A diferencia del paradigma positivista, que busca establecer leyes universales y predicciones, el interpretativismo pone el foco en entender el significado que las personas atribuyen a sus acciones y decisiones, considerando el contexto en el que estas se producen.

En el plano metodológico, el estudio adopta un diseño híbrido que combina:

1. **Un marco teórico deductivo:** la integración del marco TOE-DOI (Rogers, 1995; Tornatzky & Fleischer, 1990) y el modelo de madurez de Alsheibani et al. (2019), que proporcionan una estructura inicial para la categorización y el análisis.
2. **La lógica inductiva de la Grounded Theory** (Corbin & Strauss, 2008): un enfoque cualitativo que permite que las categorías y relaciones surjan directamente de los datos, mediante un proceso de codificación abierta, axial y selectiva, junto con comparación constante entre casos.

Este enfoque mixto ofrece varias ventajas:

- **Identificación de categorías emergentes** y relaciones no contempladas inicialmente en el marco integrado TOE-DOI.
- **Enriquecimiento y matización del modelo teórico** gracias a evidencias derivadas directamente de la experiencia de los participantes.
- **Integración de lo inductivo y lo deductivo**, combinando la flexibilidad analítica propia de la Grounded Theory con la solidez de un marco teórico consolidado.

Este planteamiento permite:

- Reconocer la pluralidad de realidades que coexisten en el sector asegurador, donde cada organización y actor interpreta la IA desde su cultura corporativa, su trayectoria y su posición en el mercado.
- Comprender la influencia de la regulación y del contexto competitivo y sociocultural en el que operan las aseguradoras españolas en el proceso de adopción de la IA.
- Entender las dinámicas internas a nivel organizativo (tensiones, resistencias, estrategias de implementación, etc.).

La técnica principal de recolección de datos fue la entrevista en profundidad semiestructurada, seleccionada por su idoneidad para un enfoque interpretativista y constructivista como el adoptado en esta investigación. Este formato ofrece un equilibrio entre estructura —necesaria para garantizar la cobertura de las dimensiones clave del marco teórico— y flexibilidad —indispensable para permitir que emerjan categorías no previstas, conforme a la lógica inductiva de la Grounded Theory (Corbin & Strauss, 2008)—.

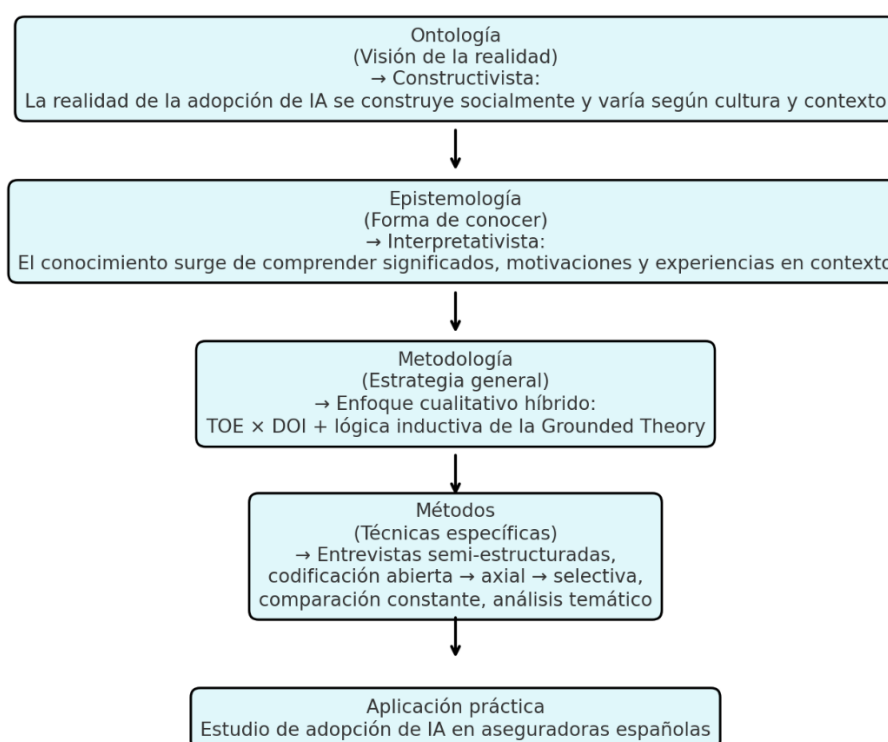
El guion de entrevista se elaboró a partir de los marcos de referencia TOE (Tecnología–Organización–Entorno) de Tornatzky & Fleischer (1990), DOI (Difusión de Innovaciones) de Rogers (1995) y el modelo de madurez de Alsheibani et al. (2019), asegurando la inclusión de dimensiones tecnológicas, organizativas y

ambientales relevantes para la adopción de IA. No obstante, su estructura se diseñó de forma abierta y adaptable, de manera que las respuestas de los participantes pudieran redireccionar la conversación hacia áreas emergentes de interés analítico.

Durante las entrevistas, se prestó especial atención a crear un clima de confianza que facilitara la expresión libre de percepciones, experiencias y ejemplos concretos, favoreciendo la producción de descripciones ricas y matizadas (thick descriptions). Estas descripciones no solo recogen aspectos técnicos y organizativos, sino también narrativas internas, tensiones, expectativas y estrategias desplegadas por los equipos directivos frente a la adopción de IA (Geertz, 1973).

Este abordaje no solo amplía la comprensión del fenómeno, sino que produce un conocimiento más profundo, contextualizado y útil para comprender los procesos de adopción de IA en aseguradoras españolas, a la vez que explicita los mecanismos para manejar las tensiones metodológicas y garantizar el rigor del análisis.

Figura 1. Esquema del diseño metodológico



Fuente: elaboración propia

1.5. Estructura de la tesis

Tras este primer capítulo introductorio, el segundo capítulo revisa la literatura académica existente sobre la adopción de IA. Para establecer el marco teórico de la tesis, se examinan los modelos de adopción tecnológica, describiéndose diferentes teorías como el marco Tecnología–Organización–Entorno (TOE) y la Teoría de la Difusión de Innovaciones (DOI), que se han utilizado a la hora de presentar y discutir los resultados. Posteriormente, se aborda el concepto de madurez organizativa a través del Artificial Intelligence Maturity Model (AIMM). Por último, se comenta la evidencia más reciente sobre el impacto de la IA generativa.

Una vez establecido el marco conceptual, en el capítulo tercero se aborda la metodología utilizada para el estudio cualitativo de la tesis, su fundamentación y estructuración. Se utiliza un enfoque cualitativo de tipo interpretativo y combina un enfoque deductivo (basado en el marco integrado TOE-DOI y modelo de madurez de Alsheibani et al., 2019) con la lógica inductiva de la Grounded Theory.

El capítulo cuarto presenta los resultados del estudio. Se describe cómo las aseguradoras españolas gestionan la adopción de la IA, teniendo en cuenta los factores críticos en las dimensiones organizacional, tecnológica y del entorno. Estos resultados se discuten en diálogo con la literatura académica existente en el capítulo quinto.

Finalmente, en el capítulo seis se presentan las principales conclusiones del estudio, las contribuciones teóricas, las implicaciones prácticas, las limitaciones y las futuras líneas de investigación que se derivan de este análisis.

2. Revisión de la literatura y brecha de investigación

2.1. Potencial de la IA

La definición y el alcance de la IA son variados y multifacéticos, sin que exista un consenso universal (Wirtz et al., 2019). Para Haenlein & Kaplan (2019), la IA consiste en la capacidad de un sistema para interpretar datos, aprender de ellos y aplicar tales aprendizajes de manera flexible para alcanzar objetivos específicos. Chakraborty & Kar (2017) destacan su potencial para razonar, aprender y adaptarse mediante algoritmos computacionales. Otros autores ponen el énfasis en la dimensión de agente: Russell & Norvig (2021) definen la IA como sistemas inteligentes capaces de interactuar con su entorno y modificarlo. Desde una perspectiva más técnica, Kar (2016) la entiende como mecanismos sofisticados que emulan la inteligencia orgánica, mientras que Kelley et al. (2018) destacan su capacidad para percibir, comprender y actuar.

Más recientemente, la irrupción de la IA generativa ha ampliado este horizonte conceptual. Esta rama de la IA, basada principalmente en arquitecturas de modelos fundacionales como las Generative Adversarial Networks (GANs) o los Large Language Models (LLMs), no se limita a clasificar o predecir a partir de datos, sino que crea nuevos contenidos —texto, imágenes, audio o código— que no existían previamente en los datos de entrenamiento (Dwivedi et al., 2023; Eloundou et al., 2023). Su emergencia supone un cambio cualitativo, ya que introduce capacidades de producción creativa y conversacional, lo que multiplica sus aplicaciones potenciales en sectores como el asegurador, especialmente en ámbitos de interacción con clientes, generación documental y análisis semántico de grandes volúmenes de información.

2.2. Inteligencia Artificial en el sector asegurador

La digitalización y la inteligencia artificial (IA) han transformado profundamente la cadena de valor del seguro, actuando no solo como palancas de eficiencia, sino también como factores que redefinen la insurabilidad de los riesgos.

Eling y Lehmann (2018) muestran que la digitalización afecta de forma transversal a cuatro grandes tareas del sector: mejora de la experiencia del cliente, optimización de procesos, desarrollo de nuevos productos y preparación frente a la competencia de otras industrias. Aplicando la cadena de valor de Porter (1985) adaptada al seguro (Rahlf, 2007) y los criterios de insurabilidad de Berliner (1982), los autores identifican tres impactos clave: (i) acceso a información masiva y reducción de asimetrías, (ii) alteración de la frecuencia y severidad de los siniestros, y (iii) creciente interdependencia tecnológica que aumenta los riesgos de acumulación, especialmente en el ámbito cibernético.

De forma complementaria, Eling, Nuesse y Staubli (2022) sistematizan cómo la IA abarca todas las etapas de la cadena de valor, desde marketing hasta la gestión de activos, contribuyendo tanto a mejoras de eficiencia como a una segmentación más precisa de clientes y al desarrollo de productos para riesgos emergentes. Entre los casos de uso más consolidados de IA tradicional se incluyen los chatbots para consulta y venta de productos estandarizados, el análisis de texto y sentimientos en suscripción y tarificación, el análisis de imagen y vídeo en siniestros, el underwriting automatizado, los motores de recomendación, el reconocimiento biométrico en autenticación y los robo-advisors en gestión de carteras.

Más recientemente, la IA generativa (GenAI) ha ampliado este espectro de aplicaciones. Owen, Sheehan y Mullins (2025), a partir de entrevistas con directivos de aseguradoras, identifican 37 casos de uso de GenAI a lo largo de la cadena de valor, incluyendo clasificación y resumen de documentos, copilotos para agentes, generación automática de pólizas, automatización avanzada de siniestros y pricing en salud y vida. Algunos de estos casos se clasifican como de alto riesgo regulatorio bajo el EU AI Act.

Por su parte, Bhattacharya, Castignani, Masello y Sheehan (2025), mediante una revisión sistemática PRISMA, señalan que mientras la investigación académica ha tendido a concentrarse en pricing y riesgo, la práctica empresarial avanza hacia aplicaciones más equilibradas que incluyen automatización de siniestros, detección de fraude, personalización del cliente y explicabilidad (XAI). Este hallazgo confirma que la integración de la IA no solo responde a la búsqueda de eficiencia, sino también a la necesidad de construir confianza, asegurar transparencia y mantener la viabilidad del principio mutualista en un contexto de creciente presión ética y regulatoria.

En esta línea, Yang et al. (2025) aportan evidencia experimental sobre cómo los consumidores perciben la intervención humana en decisiones mediadas por IA en el sector asegurador. Sus resultados muestran que la colaboración humano-IA no reduce la calidad de las recomendaciones, pero sí incrementa la disposición de los clientes a seguirlas y mejora su bienestar material. El elemento humano funciona como un mecanismo de confianza, actuando como “señal periférica” que incrementa la aceptación de la IA, incluso sin alterar objetivamente la calidad del consejo. Estas conclusiones son especialmente relevantes en un sector basado en la confianza y la percepción de equidad, pues sugieren que mantener un human-in-the-loop puede favorecer tanto la adopción de la IA como su legitimidad social. Además, respaldan la orientación regulatoria de exigir supervisión humana en sistemas de alto riesgo, al demostrar que la intervención humana aporta valor no solo técnico, sino también psicológico y reputacional.

Asimismo, van Bekkum (2025) advierte que el uso intensivo de datos y la proliferación de modelos de seguros basados en el comportamiento plantean riesgos significativos de discriminación y diferenciación injusta. Aunque parte de estas prácticas pueden no infringir la legislación vigente, generan tensiones éticas al segmentar con excesiva granularidad y trasladar costes desproporcionados a colectivos vulnerables. En particular, la telemática, los programas de salud digital y el análisis de variables no tradicionales pueden derivar en correlaciones espurias con atributos sensibles, erosionando los principios de solidaridad y equidad que sustentan el seguro. Estas preocupaciones amplían el debate sobre insurabilidad, subrayando la necesidad de políticas de fairness, auditorías algorítmicas y marcos regulatorios que aseguren tanto la transparencia como la aceptabilidad social del uso de IA en seguros.

En paralelo, Alam et al. (2024) demuestran que los modelos de aprendizaje automático —especialmente XGBoost y Random Forest— ofrecen una gran capacidad predictiva para anticipar reclamaciones en seguros de salud, apoyándose en variables como índice de masa corporal, presión arterial, historial médico y hábitos de vida. Si bien estos resultados confirman el potencial de la IA para mejorar la precisión del pricing y la gestión de riesgos, los autores enfatizan la importancia de avanzar hacia una IA responsable que combine precisión con explicabilidad, respeto a la privacidad y mitigación de sesgos. Sin estos mecanismos, los modelos predictivos corren el riesgo de reproducir desigualdades estructurales y socavar la confianza de los asegurados.

En conjunto, la literatura reciente apunta a un escenario donde la IA, tanto en su vertiente tradicional como generativa, impulsa la eficiencia y la innovación, pero su adopción exitosa depende de factores de confianza, equidad y gobernanza. La incorporación de marcos de responsable AI y la exigencia de explicabilidad se

convierten así en condiciones indispensables para garantizar que la digitalización del seguro no erosione sus fundamentos mutualistas, sino que los fortalezca mediante una aplicación transparente, justa y socialmente aceptada..

La Tabla 1 sintetiza las aplicaciones más relevantes a lo largo de la cadena de valor aseguradora, integrando tanto la IA tradicional como la generativa. Este marco servirá como punto de contraste con la evidencia empírica derivada de las entrevistas realizadas en aseguradoras españolas.

Tabla 1. Cadena de Valor del Seguro y Aplicaciones de IA

Etapas de la cadena de valor	Aplicaciones de IA tradicional	Aplicaciones de IA generativa (GenAI)
Marketing	Segmentación avanzada con <i>big data</i> ; <i>sentiment analysis</i> básico; motores de recomendación (Eling et al., 2022). Riesgos de diferenciación injusta si se emplean señales conductuales o variables no tradicionales sin control de sesgos (van Bekkum, 2025).	Generación automática de contenidos y microsegmentación; chatbots multimodales (Bhattacharya et al., 2025; Owen et al., 2025). HIL para comunicación sensible puede mejorar aceptación y confianza (Yang et al., 2025).
Desarrollo de productos	Telemática en autos y salud, <i>wearables</i> en vida, ciberseguros (Eling & Lehmann, 2018). Atención a la solidaridad y a potenciales correlaciones espurias con atributos sensibles (van Bekkum, 2025).	Detección de oportunidades con datos no estructurados; diseño asistido de coberturas (clima, reputación) (Owen et al., 2025; Bhattacharya et al., 2025). Revisión HIL en productos sensibles para mitigar riesgos reputacionales/regulatorios (Yang et al., 2025).
Ventas y distribución	<i>Chatbots</i> de primera generación; plataformas y agregadores; CRM con ML (Eling et al., 2022; Eling & Lehmann, 2018).	Copilotos para mediadores y <i>chatbots</i> contextuales; traducción/simplificación contractual (Owen et al., 2025). HIL: la intervención humana incrementa la disposición a seguir recomendaciones (Yang et al., 2025).
Suscripción y tarificación	<i>Underwriting</i> automatizado; IoT/telemática para riesgos dinámicos; <i>pricing</i> en tiempo real (Eling et al., 2022; Eling & Lehmann, 2018). Responsable AI en salud: modelos predictivos (XGBoost/RF) con explicabilidad, privacidad y control de sesgos (Alam et al., 2024).	Resumen y análisis de historiales; evaluación por imágenes/vídeo; pricing automático en vida/salud (alto riesgo EU AI Act) (Owen et al., 2025). HIL recomendado en decisiones de alto impacto; controles de fairness para evitar diferenciación injusta (Yang et al., 2025; van Bekkum, 2025).
Administración de contratos y	Automatización de cambios; <i>chatbots</i> básicos; portales <i>self-</i>	Clasificación y resumen de documentos; generación automática de

Etapas de la cadena de valor	Aplicaciones de IA tradicional	Aplicaciones de IA generativa (GenAI)
servicio al cliente	<i>service</i> (Eling et al., 2022; Eling & Lehmann, 2018).	pólizas; copilotos de atención (Owen et al., 2025; Bhattacharya et al., 2025). HIL en reclamaciones y disputas sensibles para aumentar satisfacción/percepción de justicia (Yang et al., 2025).
Gestión de siniestros	Peritación con imagen/vídeo; detección de fraude con ML; automatización de siniestros simples (Eling et al., 2022; Eling & Lehmann, 2018). Responsible AI: trazabilidad y explicabilidad en decisiones automatizadas (Alam et al., 2024).	Claims automation end-to-end; análisis de sentimiento en llamadas (alto riesgo); evaluación automática de daños (Owen et al., 2025; Bhattacharya et al., 2025). HIL reduce fricción y mejora bienestar del cliente en decisiones complejas (Yang et al., 2025).
Gestión de activos y riesgos	<i>Robo-advisors</i> ; modelos predictivos; simulación de escenarios (Eling et al., 2022; Eling & Lehmann, 2018).	Generación de datos sintéticos; monitoreo reputacional en tiempo real; modelización climática/ESG (Bhattacharya et al., 2025; Owen et al., 2025). Controles de sesgo en señales de riesgo y transparencia de modelos (van Bakkum, 2025).
Funciones de soporte (IT, RRHH, Legal, PR)	Reclutamiento y formación digital; automatización de <i>reporting</i> ; <i>cloud</i> y <i>blockchain</i> en contratos (Eling & Lehmann, 2018; Eling et al., 2022).	Generación de informes regulatorios; asistentes de <i>upskilling</i> ; análisis automático de cambios normativos (Owen et al., 2025; Bhattacharya et al., 2025). Gobernanza de IA: auditorías de sesgo, privacidad, explicabilidad y supervisión humana en sistemas de alto riesgo (Alam et al., 2024; Yang et al., 2025; van Bakkum, 2025).

Fuente: Adaptado de Eling y Lehmann (2018); Eling et al. (2022); Owen et al. (2025); Bhattacharya et al. (2025); Yang et al. (2025); van Bakkum (2025); Alam et al. (2024).

2.3. Marcos de adopción de tecnología e innovación

La investigación sobre adopción de tecnología se clasifica en tres niveles: individual, organizativo y de equipo o grupo, concentrándose la mayoría de los estudios en la adopción a nivel individual. Sin embargo, con el avance de las aplicaciones tecnológicas, se ha producido un cambio hacia un mayor enfoque en la adopción a nivel organizativo (Salahshour Rad et al., 2018).

Aunque existe una gran cantidad de estudios sobre adopción de innovación a nivel organizativo, que introducen diversos factores influyentes, falta una visión integrada entre dichos factores, lo que con frecuencia conduce a resultados empíricos contradictorios (Vagnani et al., 2019).

En una revisión de la literatura, se identificaron cerca de 60 modelos, teorías y marcos para el estudio de la adopción de tecnología e innovación. La mayoría se aplican a nivel individual, algunos a nivel organizativo y unos pocos en ambos niveles. Entre los marcos más utilizados a nivel individual destacan la Theory of Reasoned Action (TRA) (Fishbein & Ajzen, 1975), la Theory of Planned Behaviour (TPB) (Ajzen, 1991), el Technology Acceptance Model (TAM) (Davis, 1989), sus extensiones TAM2 y TAM3 (Venkatesh & Davis, 2000; Venkatesh & Bala, 2008), la Unified Theory of Acceptance and Use of Technology (UTAUT) (Venkatesh et al., 2003) y su versión extendida UTAUT2 (Venkatesh et al., 2012). Otros modelos relevantes en este nivel son el Task–Technology Fit (TTF) (Goodhue & Thompson, 1995), el Information Systems Success Model (DeLone & McLean, 1992; 2003), el Technology Readiness Index (TRI) (Parasuraman, 2000) y la Innovation Resistance Theory (IRT) (Ram & Sheth, 1989).

En el plano organizativo, los marcos más utilizados son la Diffusion of Innovation (DOI) (Rogers, 1995), el Technology–Organization–Environment (TOE) (Tornatzky & Fleischer, 1990), la Resource-Based View (RBV) (Barney, 1991), la Teoría Institucional (DiMaggio & Powell, 1983), el modelo de Iacovou et al. (1995) para la adopción de EDI en pymes y el enfoque de Dynamic Capabilities (Teece, 2007).

La DOI, propuesta por Rogers (1995), analiza cómo se difunden nuevas tecnologías e ideas dentro de las organizaciones, centrándose en características de la innovación como la ventaja relativa, la compatibilidad, la complejidad, la posibilidad de prueba (trialability) y la observabilidad. Por su parte, el marco TOE (Tornatzky & Fleischer, 1990) describe factores de los contextos tecnológico, organizativo y ambiental que influyen en la adopción e implementación de innovaciones, y se considera un marco integrador que proporciona una base teórica holística para evaluar facilitadores y barreras.

En la literatura, es habitual combinar TOE y DOI para obtener una comprensión más completa de los procesos de adopción (Oliveira & Martins, 2011). La razón es doble:

Nivel adecuado: ambos se enfocan en la adopción a nivel de empresa, no individual, lo que los hace idóneos para estudios organizativos.

Complementariedad: TOE se centra en la tecnología disponible, la organización y el entorno competitivo/regulatorio, mientras que DOI aporta la percepción de la innovación (ventaja relativa, compatibilidad, complejidad). Juntos ofrecen un marco holístico que combina condiciones objetivas y percepciones subjetivas de la innovación.

Alineación con la literatura: diversas revisiones (Oliveira & Martins, 2011; Fonseka et al., 2020) confirman que TOE y DOI son los marcos dominantes en estudios firm-level (e-business, cloud, big data, IA), lo que permite situar la investigación en un debate académico consolidado y asegurar comparabilidad con estudios previos.

En el caso específico de la inteligencia artificial, se han desarrollado adaptaciones y extensiones de estos marcos. Zhu et al. (2006) ya señalaban la necesidad de enfoques más abarcadores para tecnologías emergentes, mientras que Pumplun et al. (2019) adaptaron TOE a la IA, incorporando factores como la ventaja relativa de las soluciones de IA, su compatibilidad con procesos existentes y la identificación de casos de uso. Radhakrishnan & Chattopadhyay (2020) destacaron otros factores organizativos específicos de la IA, como las competencias técnicas, la hoja de ruta estratégica, el apoyo de la alta dirección y la madurez digital de la organización.

En esta investigación se adopta la combinación TOE–DOI como marco principal de análisis, precisamente por estas tres razones: (1) su idoneidad para estudios a nivel organizativo, (2) la complementariedad de factores objetivos y percepciones de la innovación que ofrecen, y (3) su alineación con la literatura previa, que los consolida como los marcos dominantes en estudios de adopción de tecnologías complejas como la inteligencia artificial.

2.4. Literatura existente sobre factores de éxito en la adopción de IA

La investigación académica en el ámbito de la IA ha crecido significativamente en los últimos años. La mayoría de las investigaciones se centran mayoritariamente en el análisis de tecnologías específicas de IA, y en menor medida a los requisitos y factores que condicionan su adopción por parte de las entidades (Kinkel et al., 2022).

Comprender este proceso resulta esencial, dado que las organizaciones se enfrentan numerosos retos en la adopción de IA y requieren identificar tanto los factores que la favorecen como aquellos que la obstaculizan (Radhakrishnan & Chattopadhyay, 2020). En el ámbito de los sistemas de información (IS), solo recientemente los investigadores han comenzado a estudiar la preparación organizativa para la IA (Alsheiabni et al., 2018), sin haber adaptado plenamente marcos como el TOE para reflejar las particularidades de esta tecnología en diferentes sectores y etapas de adopción (Pumplun et al., 2019).

Las teorías más usadas en los estudios de adopción de IA a nivel organización son DOI y TOE y entre los factores más citados a nivel organizativo se incluyen las competencias técnicas, la planificación estratégica, el apoyo de la alta dirección y la madurez digital de la organización (Radhakrishnan & Chattopadhyay, 2020). Hamm & Klesel (2021) realizaron una revisión exhaustiva de la literatura enfocada exclusivamente en factores de éxito para la adopción de IA, diferenciándola de otras tecnologías. Identificaron 36 factores específicos, que clasificaron mediante el marco TOE en 12 tecnológicos, 13 organizativos y 11 ambientales. Su trabajo confirma la necesidad de un análisis más detallado de los condicionantes particulares de la IA, incluyendo dimensiones distintivas como la disponibilidad y calidad de los datos, la explicabilidad de los modelos o la gestión de dilemas éticos.

La presente investigación se basa en la revisión de Hamm & Klesel (2021), completándola con publicaciones posteriores especialmente centrados en la adopción de IA en banca y seguros. La literatura sobre este ámbito sigue siendo escasa, y es aún más limitada la referida al sector asegurador (Gupta et al., 2022). A continuación, se presentan los factores identificados en la literatura organizados de acuerdo con las dimensiones TOE.

2.4.1. Factores organizativos

Entre los 13 factores organizativos de éxito identificados por Hamm & Klesel (2021), el apoyo de la alta dirección, las competencias técnicas y los recursos fueron destacados en ocho de los trece estudios analizados. La literatura más reciente amplía esta visión al incorporar dimensiones adicionales como la cultura organizativa, la confianza, la gobernanza de datos, la preparación digital y la experimentación con modelos híbridos de innovación.

Apoyo de la alta dirección. Se trata de un factor crítico y consistente en la adopción de nuevas tecnologías, incluida la inteligencia artificial. Este respaldo se ha identificado de manera reiterada como un predictor clave del éxito en los procesos de adopción (Jeyaraj et al., 2006). La alta dirección refuerza valores organizativos, articula una visión estratégica y crea un entorno propicio para la innovación (Thong, 1999; Premkumar & Roberts, 1999; Grover & Goslar, 1993). En el caso de la IA, los decisores —a menudo miembros de la alta dirección— resultan fundamentales para asignar recursos, comunicar la necesidad de la tecnología y motivar al personal (Alsheiabni et al., 2020; Gupta et al., 2022; Matsepe & Van der Lingen, 2022). Estudios recientes confirman que el apoyo directivo actúa como mediador entre la presión competitiva, la preparación organizativa y la adopción de IA generativa (Xu, Ramayah & Shi, 2025). Este liderazgo, sin embargo, requiere asumir riesgos e invertir en contextos donde los beneficios son inciertos, algo que en el sector asegurador se afronta con especial cautela dada su naturaleza aversa al riesgo.

Competencias técnicas. La aplicación eficaz de la IA exige conocimientos sólidos en estadística y matemáticas, así como procesos de capacitación y transferencia de conocimiento (Kordon, 2020; Schäfer et al., 2021). La experiencia previa con tecnologías constituye un impulsor positivo en la disposición a adoptar nuevas soluciones (Kuan & Chau, 2001; Fink, 1998). En sectores como banca y seguros, la experiencia práctica en IA ha sido identificada como un factor decisivo para la adopción (Kruse et al., 2019; Gupta et al., 2022; Matsepe & Van der Lingen, 2022). No obstante, la brecha de competencias digitales en la plantilla es uno de los mayores desafíos actuales: la dificultad para captar y retener perfiles especializados, como los *data scientists*, limita la escalabilidad de los proyectos de IA (Lopez-García & Manrique Rojas, 2024).

Recursos. El acceso a recursos adecuados es otro de los factores centrales. Incluye tanto la disponibilidad y calidad de datos de entrenamiento, esenciales para el desarrollo de modelos robustos (Kruse et al., 2019), como la capacidad financiera para invertir en hardware, software y talento especializado (Demlehner & Laumer, 2020; Pumplun et al., 2019). Además, abarca el soporte humano necesario para gestionar el cambio y para interpretar los resultados algorítmicos. La literatura

destaca que la falta de datos de calidad y el elevado coste de implementación siguen constituyendo los principales límites a la adopción (Bhattacharya et al., 2025).

Tamaño y estructura organizativa. La influencia del tamaño en la adopción tecnológica presenta resultados ambiguos. Las grandes empresas disponen de más recursos y datos, además de un mayor poder de negociación con proveedores, pero pueden enfrentarse a estructuras rígidas y burocráticas que dificulten la innovación (Jeyaraj et al., 2006; Alsheibani et al., 2020). Las pequeñas, en cambio, pese a sus limitaciones financieras y de capacidades, suelen mostrar una mayor agilidad (Kruse et al., 2019). En el sector asegurador, el debate sobre el peso de este factor sigue abierto, y se observa la proliferación de modelos híbridos como los laboratorios de innovación internos, que buscan equilibrar la agilidad con la integración estructural (Pumplun et al., 2019; Eling & Lehmann, 2018).

Estrategia, preparación organizativa y cultura. La madurez digital y la alineación estratégica entre la innovación tecnológica y los valores corporativos resultan decisivas para reducir resistencias al cambio. Culturas organizativas abiertas a la innovación, basadas en la colaboración y la comunicación, facilitan la integración de la IA (Rogers, 2003; Premkumar & Roberts, 1999). Por el contrario, culturas aversas al riesgo o con temores a la obsolescencia de competencias pueden ralentizar la adopción y generar escepticismo (Matsepe & Van der Lingen, 2022). En el ámbito de los chatbots y servicios digitales, la confianza se convierte en un elemento clave: tanto la confianza interna como la de los clientes resultan determinantes para evitar el fracaso en la implementación (de Andrés-Sánchez & Gené-Albesa, 2024). Además, la preparación organizativa y la presión competitiva solo impulsan realmente la adopción cuando la alta dirección actúa como catalizador del proceso (Xu, Ramayah & Shi, 2025).

Otros factores emergentes. Más allá de los factores tradicionales, la literatura reciente identifica elementos adicionales que cobran cada vez mayor relevancia. La confianza en la tecnología se erige como variable transversal crítica en la aceptación de la IA conversacional y de los sistemas de soporte automatizados (de Andrés-Sánchez & Gené-Albesa, 2024). La gobernanza del dato y la explicabilidad se consolidan como pilares regulatorios, necesarios tanto para asegurar la calidad de los datos como para garantizar la transparencia de los modelos (Eling & Lehmann, 2018; Bhattacharya et al., 2025). Asimismo, los estudios sugieren que la resistencia organizacional y la motivación tecnológica son las dos fuerzas principales que explican la adopción de IA en sectores como seguros y manufactura (Lopez-García & Manrique Rojas, 2024). Finalmente, la sostenibilidad y los criterios ESG emergen como nuevos marcos en los que se inserta la innovación digital, impulsando a las aseguradoras a integrar la IA en estrategias de negocio

responsables y alineadas con objetivos ambientales y sociales (Bhattacharya et al., 2025).

En la Tabla 2 se presentan de forma enumerativa los factores organizativos identificados en la revisión de la literatura.

Tabla 2. Resumen de factores organizativos (TOE)

Factor	Descripción	Referencias
Apoyo de la alta dirección	Patrocinio, asignación de recursos financieros, humanos y técnicos; articulación de visión estratégica; liderazgo con apetito por el riesgo; catalizador de la preparación organizativa y la presión competitiva.	Jeyaraj et al., 2006; Thong, 1999; Premkumar & Roberts, 1999; Grover & Goslar, 1993; Alsheiabni et al., 2020; Gupta et al., 2022; Matsepe & Van der Lingen, 2022; Xu, Ramayah & Shi, 2025
Competencias técnicas	Experiencia previa con tecnología; conocimientos en IA/estadística/matemáticas; formación y transferencia de conocimiento; atracción y retención de talento especializado; reto por la escasez de <i>data scientists</i> .	Kuan & Chau, 2001; Fink, 1998; Kordon, 2020; Schäfer et al., 2021; Kruse et al., 2019; Gupta et al., 2022; Matsepe & Van der Lingen, 2022; Lopez-García & Manrique Rojas, 2024
Recursos	Disponibilidad/calidad de datos de entrenamiento; presupuesto para hardware, software y personal; soporte humano; infraestructura IT robusta.	Pumplun et al., 2019; Demlehner & Laumer, 2020; Kruse et al., 2019; Gupta et al., 2022; Bhattacharya et al., 2025
Tamaño y estructura	Grandes empresas con más recursos y datos, pero riesgo de rigidez; pequeñas con mayor agilidad pero limitaciones financieras; modelos híbridos con laboratorios de innovación.	Jeyaraj et al., 2006; Kruse et al., 2019; Alsheiabni et al., 2020; Pumplun et al., 2019; Eling & Lehmann, 2018
Estrategia y preparación organizativa	Madurez digital; alineación estratégica con objetivos corporativos; integración con procesos y sistemas; mediada por el apoyo directivo.	Hamm & Klesel, 2021; Rogers, 2003; Premkumar & Roberts, 1999; Xu, Ramayah & Shi, 2025
Cultura organizativa	Colaboración y comunicación abierta; apertura a la innovación; aversión al riesgo; temor a la obsolescencia de competencias; resistencia cultural y escepticismo.	Rogers, 2003; Matsepe & Van der Lingen, 2022; Kruse et al., 2019; Lopez-García & Manrique Rojas, 2024
Confianza en la tecnología	Percepción de fiabilidad, transparencia y explicabilidad de sistemas IA; confianza	de Andrés-Sánchez & Gené-Albesa, 2024; Owens et al.,

Factor	Descripción	Referencias
	organizativa y de clientes como condición crítica de adopción.	2022; Bhattacharya et al., 2025
Gobernanza de datos y explicabilidad	Calidad, protección y disponibilidad de datos; marcos regulatorios (GDPR, AI Act); necesidad de IA explicable (XAI) para reducir sesgos y reforzar legitimidad.	Eling & Lehmann, 2018; Owens et al., 2022; Bhattacharya et al., 2025
Resistencia organizacional vs. motivación tecnológica	Dos factores estructurales que explican la adopción: resistencia (costes, falta de skills, regulación, escepticismo) y motivación (eficiencia, reducción de costes, seguridad, cobertura de carencias).	Lopez-García & Manrique Rojas, 2024
Sostenibilidad y criterios ESG	La adopción de IA se enmarca en objetivos de sostenibilidad y responsabilidad social corporativa; presión de criterios ESG en innovación aseguradora.	Bhattacharya et al., 2025

Fuente: Elaboración Propia

2.4.2. Factores tecnológicos

La dimensión tecnológica constituye un eje fundamental para comprender la adopción de inteligencia artificial (IA) en el sector asegurador. La revisión de Hamm & Klesel (2021) identifica la compatibilidad con la infraestructura de TI existente como el factor más citado, presente en diez de los estudios analizados. Este hallazgo refleja que la viabilidad de la IA no depende solo de sus capacidades técnicas, sino también de su integración con sistemas heredados y procesos organizativos.

Compatibilidad e infraestructura. Alsheiabni et al. (2020) subrayan que la compatibilidad con los sistemas existentes aumenta significativamente la probabilidad de adopción de IA. Sin embargo, como apuntan Kruse et al. (2019), muchas aseguradoras mantienen arquitecturas tecnológicas en expansión desde los años ochenta que no han sido renovadas de forma continua, generando una pesada carga heredada que limita la transformación digital. De ahí que la literatura coincida en la necesidad de infraestructuras actualizadas, flexibles y escalables, capaces de soportar las demandas de algoritmos modernos y grandes volúmenes de datos.

Plataformas y procesos. Los estudios destacan que una plataforma robusta, un rendimiento eficaz de la infraestructura de TI y la existencia de interfaces de datos estandarizadas son requisitos esenciales para el despliegue de IA (Nortje & Grobbelaar, 2020; Demlehner & Laumer, 2020; Bauer et al., 2020). Además, Pumplun et al. (2019) señalan que la adopción exitosa exige no solo compatibilidad tecnológica, sino también adaptación de procesos de negocio a los nuevos requerimientos.

Metodologías y evaluación. A diferencia de los proyectos tradicionales de TI, la implementación de IA se caracteriza por la incertidumbre en resultados y plazos. Los indicadores clásicos como el ROI se consideran insuficientes, lo que ha impulsado la adopción de metodologías ágiles y la necesidad de desarrollar métricas específicas para evaluar proyectos de IA (Pumplun et al., 2019). El concepto de experimentabilidad (trialability) de Rogers (2003) cobra especial relevancia: la posibilidad de realizar pruebas piloto a pequeña escala reduce el riesgo percibido y favorece la disposición a adoptar la tecnología, especialmente en sectores altamente regulados como el financiero y asegurador (Matsepe & Van der Lingen, 2022).

Ventaja relativa. Otro factor clave es la percepción de la ventaja relativa. Rogers (2003) la define como el grado en que una innovación se percibe como superior a la práctica a la que sustituye. La literatura confirma que cuando los beneficios son tangibles —reducción de costes, eficiencia operativa o entrada a nuevos mercados— la probabilidad de adopción aumenta (Lee, 2004; Alsheiabni et al., 2018). Xu, Ramayah y Shi (2025) corroboran que la ventaja relativa y el apoyo de la alta dirección son los predictores más influyentes en la adopción de IA generativa

en aseguradoras, actuando este último como mediador entre la preparación organizativa y la presión competitiva.

Disponibilidad y calidad de datos. La IA depende de datos abundantes, diversos y de alta calidad. Su carencia limita el entrenamiento de modelos y reduce la capacidad de generar valor (Kruse et al., 2019). Este reto, identificado en cinco estudios de Hamm & Klesel (2021), se amplía en trabajos recientes que insisten en la necesidad de marcos sólidos de gobernanza del dato y explicabilidad (Eling & Lehmann, 2018; Bhattacharya et al., 2025). Estos estudios señalan que los sesgos, la opacidad y los problemas de integridad en los datos erosionan tanto la fiabilidad de los modelos como la confianza de clientes y reguladores.

Seguridad, transparencia y confianza. Los riesgos asociados a la IA como “caja negra” constituyen otro freno relevante (Kruse et al., 2019). La falta de interpretabilidad dificulta la validación de resultados y genera resistencias internas y regulatorias. En el ámbito de la IA generativa, de Andrés-Sánchez & Gené-Albesa (2024) muestran que la confianza es el factor determinante en la aceptación de chatbots en seguros, incluso por encima de la utilidad percibida y la facilidad de uso. Este hallazgo refuerza la idea de que la transparencia y la explicabilidad (XAI) son condiciones indispensables para la legitimidad de la IA en seguros (Owens et al., 2022).

Complejidad y riesgos percibidos. La complejidad técnica y organizativa continúa siendo una barrera significativa (Gupta et al., 2022; Matsepe & Van der Lingen, 2022). La literatura reciente amplía este argumento al introducir la noción de resistencia organizacional frente a motivación tecnológica como las dos fuerzas principales que explican la adopción: mientras la resistencia proviene de costes, falta de competencias, regulación y escepticismo, la motivación tecnológica se asocia a eficiencia, reducción de costes, seguridad y ventaja competitiva (Lopez-García & Manrique Rojas, 2024).

En la Tabla 3 se presentan de forma enumerativa los factores tecnológicos identificados en la revisión de la literatura.

Tabla 3. Resumen de factores tecnológicos (TOE)

Factor	Descripción	Referencias
Compatibilidad y arquitectura	Alineación con TI existente; necesidad de infraestructuras actualizadas, flexibles y escalables; plataformas robustas; interfaces de datos estandarizadas; procesos adaptados a nuevos requisitos.	Alsheiabni et al., 2020; Bauer et al., 2020; Demlehner & Laumer, 2020; Nortje & Grobbelaar, 2020; Pumplun et al., 2019; Kruse et al., 2019; Eling & Lehmann, 2018
Ventaja relativa	Beneficios percibidos: reducción de costes, eficiencia, entrada a nuevos mercados, personalización, mejora en calidad de servicio; factor más influyente en adopción de Gen-AI en seguros.	Rogers, 2003; Lee, 2004; Alsheiabni et al., 2018; Pumplun et al., 2019; Rzepka & Berger, 2018; Xu, Ramayah & Shi, 2025

Factor	Descripción	Referencias
Datos: disponibilidad y calidad	Entrenamiento suficiente y fiable; dependencia de la tarea; gobernanza y explicabilidad como requisitos críticos; sesgos y falta de integridad de datos erosionan confianza y adopción.	Hamm & Klesel, 2021; Kruse et al., 2019; Eling & Lehmann, 2018; Bhattacharya et al., 2025
Herramientas y soporte externo	Ecosistema de proveedores tecnológicos y consultoras; soporte fiable y continuidad del servicio; acceso a insurtechs y soluciones colaborativas.	Premkumar & Roberts, 1999; Hamm & Klesel, 2021; Owen et al., 2025
Necesidad de negocio y casos de uso	La IA debe responder a un problema definido y alineado con los objetivos organizativos; business case claro y medible; IA como medio, no fin.	Pumplun et al., 2019; Bhattacharya et al., 2025
Complejidad y trialability	La complejidad técnica y organizativa dificulta la adopción; la posibilidad de pruebas piloto (trialability) reduce riesgos y aumenta la aceptación en entornos regulados.	Rogers, 2003; Premkumar & Roberts, 1999; Gupta et al., 2022; Matsepe & Van der Lingen, 2022; Owen et al., 2025
Seguridad, transparencia y confianza	Riesgos asociados a la “caja negra” de la IA; sesgos y falta de explicabilidad; preocupaciones sobre privacidad y protección de datos; confianza como variable crítica en IA conversacional.	Kruse et al., 2019; de Andrés-Sánchez & Gené-Albesa, 2024; Bhattacharya et al., 2025
Resistencia vs. motivación tecnológica	Dos fuerzas contrapuestas: resistencia (costes, skills, regulación, escepticismo) y motivación (eficiencia, reducción de costes, seguridad, ventaja competitiva).	Lopez-García & Manrique Rojas, 2024
Otros factores	Escalabilidad de sistemas, madurez tecnológica, satisfacción con sistemas existentes, capacidad de gestión tecnológica, adaptación cultural a la digitalización.	Hamm & Klesel, 2021; Eling & Lehmann, 2018

Fuente: elaboración propia

2.4.3. Factores ambientales

La revisión de Hamm & Klesel (2021) identificó once factores ambientales con influencia en la adopción de IA. Entre ellos, destacan la presión competitiva y las regulaciones gubernamentales, aunque la literatura reciente incorpora también la preparación y confianza del cliente, la influencia de socios externos, el acceso a experiencia y financiación, así como factores emergentes vinculados a sostenibilidad y marcos ESG.

Presión competitiva. La presión de mercado constituye uno de los impulsores más sólidos de la adopción tecnológica. Estudios clásicos confirman que la competencia sectorial acelera la incorporación de innovaciones (Jeyaraj et al., 2006; Gatignon & Robertson, 1989; Premkumar & Ramamurthy, 1995). En servicios financieros, el papel de la IA como diferenciador estratégico es evidente: cuando competidores logran eficiencias con su despliegue, fuerzan a las demás entidades a reaccionar (Eitle & Buxmann, 2020). Este efecto se amplifica con la irrupción de FinTech e InsurTech, que presionan a bancos y aseguradoras tradicionales a optimizar procesos y productos (Kruse et al., 2019; Matsepe & Van der Lingen, 2022). Estudios recientes muestran que la presión competitiva impacta indirectamente en la adopción al impulsar el apoyo de la alta dirección, que actúa como mediador en la toma de decisiones estratégicas sobre IA generativa (Xu, Ramayah & Shi, 2025)

Regulaciones gubernamentales. El marco normativo es una de las principales fuerzas que condicionan la adopción de IA en seguros. Normativas como el RGPD en Europa han obligado a anonimizar datos, dificultando en ocasiones el entrenamiento de algoritmos (Pumplun et al., 2019). Al mismo tiempo, la regulación presenta una doble cara: por un lado, la sobreregulación puede frenar la innovación y generar elevados costes de cumplimiento; por otro, la falta de regulación específica en startups FinTech e InsurTech ofrece ventajas competitivas frente a aseguradoras tradicionales, que deben dedicar grandes recursos a garantizar el cumplimiento normativo (Kruse et al., 2019; Matsepe & Van der Lingen, 2022). Además, la IA Act europea (2023) introduce un marco de clasificación por niveles de riesgo que impactará directamente en la implantación de sistemas de pricing, underwriting y reclamaciones (Bhattacharya et al., 2025)

Preparación y confianza del cliente. La disposición de los clientes a utilizar servicios basados en IA, como chatbots o robo-advisors, influye directamente en las decisiones de adopción. Mientras algunos segmentos demandan personalización y servicios digitales, persisten resistencias asociadas a la desconfianza, los sesgos algorítmicos y el temor a la sustitución del empleo humano (Kruse et al., 2019). En seguros, la **confianza** se confirma como factor decisivo: estudios recientes demuestran que, en la interacción con chatbots, la confianza explica en mayor medida la aceptación que la utilidad percibida o la facilidad de uso (de Andrés-Sánchez & Gené-Albesa, 2024).

Presión gubernamental. Más allá de la regulación técnica, las decisiones políticas y de supervisión sectorial pueden actuar como impulsores de la adopción, especialmente en el sector público o en áreas de interés social como ciberseguridad, fraude o gestión de riesgos sistémicos (Schäfer et al., 2021).

Influencia de la industria. El contexto sectorial condiciona significativamente la adopción de IA. Cada industria impone exigencias específicas —legales, de riesgos o de relación con clientes— que facilitan o dificultan la innovación (Levenburg et al., 2006; Raymond, 2001). En el seguro, la digitalización de la cadena de valor está reconfigurando no solo los procesos internos, sino también las condiciones de insurabilidad de riesgos (Eling & Lehmann, 2018)

Otros factores ambientales. La literatura también identifica la influencia de socios externos y comerciales, con efectos tanto positivos como negativos en la adopción (Bauer et al., 2020; Eitle & Buxmann, 2020), el acceso a experiencia externa y financiación pública (Demlehner & Laumer, 2020), así como el apoyo de comunidades y clientes en la introducción de innovaciones (Kruse et al., 2019). Finalmente, emergen nuevos marcos como los criterios ESG, que sitúan la sostenibilidad y la responsabilidad social como condicionantes externos de la adopción tecnológica, reforzando la necesidad de IA explicable y regulada (Bhattacharya et al., 2025)

En la Tabla 4 se presentan de forma enumerativa los factores ambientales identificados en esta revisión preliminar de la literatura.

Tabla 4. Resumen de factores del entorno (TOE)

Factor	Descripción	Referencias
Presión competitiva	Competencia sectorial como impulsor clave de la adopción; necesidad estratégica para competir; presión de FinTech/InsurTech; efectos indirectos a través del apoyo de la alta dirección.	Jeyaraj et al., 2006; Gatignon & Robertson, 1989; Premkumar & Ramamurthy, 1995; Eitle & Buxmann, 2020; Kruse et al., 2019; Matsepe & Van der Lingen, 2022; Xu, Ramayah & Shi, 2025
Regulación	RGPD y marcos regulatorios sectoriales; altos costes de cumplimiento para incumbentes frente a mayor flexibilidad de startups; ambigüedad regulatoria; impacto del AI Act europeo (2023) en pricing, underwriting y siniestros.	Pumplun et al., 2019; Matsepe & Van der Lingen, 2022; Bhattacharya et al., 2025
Disposición y del confianza cliente	La aceptación de servicios basados en IA depende de la percepción de utilidad y facilidad de uso, pero sobre todo de la confianza ; los clientes valoran rapidez y personalización, pero muestran reticencias	Kruse et al., 2019; Matsepe & Van der Lingen, 2022; de Andrés-Sánchez & Gené-Albesa, 2024

Factor	Descripción	Referencias
	por riesgos éticos, sesgos y temor al reemplazo humano.	
Requisitos sectoriales	Cada sector impone leyes, regulaciones y factores externos específicos; en seguros, la digitalización de la cadena de valor redefine procesos, productos y la insurabilidad de riesgos; peso de sistemas legados.	Levenburg et al., 2006; Raymond, 2001; Pumplun et al., 2019; Kruse et al., 2019; Eling & Lehmann, 2018
Socios externos y financiación pública	Influencia de socios externos y comerciales (positiva o negativa); acceso a expertise y colaboración con InsurTechs; disponibilidad de financiación pública; apoyo de clientes y comunidades en la introducción de innovaciones.	Bauer et al., 2020; Eitle & Buxmann, 2020; Demlehner & Laumer, 2020; Schäfer et al., 2021; Kruse et al., 2019
Presiones gubernamentales y sociales	Políticas públicas y tendencias sociales como impulsores de adopción; intervenciones regulatorias y sociales en sectores estratégicos (p.ej. ciberseguridad, salud, sostenibilidad).	Schäfer et al., 2021; Bhattacharya et al., 2025

Fuente: Elaboración propia

2.5. Evaluación del nivel de madurez en inteligencia artificial

La adopción de innovaciones tecnológicas suele concebirse como un proceso secuencial; por ello, es fundamental identificar en qué nivel de adopción se encuentran las entidades para determinar si una innovación puede integrarse de forma estable en la práctica diaria (Hameed et al., 2012).

En el ámbito específico de la IA, Alsheiabni et al., (2019) han propuesto el Artificial Intelligence Maturity Model (AIMM) que establece cinco niveles de madurez (inspirado en el Capability Maturity Model Integration (CMMI)) en función de cuatro dimensiones clave:

1. **Funciones de IA** (herramientas y tecnologías para operar IA a escala).
2. **Estructura de datos** (cantidad, calidad, disponibilidad y capacidad analítica de los datos).
3. **Personas** (talento, competencias y formación en IA).
4. **Organización** (estructura, procesos, liderazgo y alineación estratégica).

En este modelo, el nivel **initial** se caracteriza por funciones de IA muy limitadas o inexistentes, ausencia de planes claros y falta de un caso de uso; los datos son insuficientes para entrenar sistemas de IA y la organización carece de competencias técnicas.

En el nivel **assessing**, la organización comienza a explorar tecnologías de IA, identificando aplicaciones potenciales y realizando integraciones iniciales de datos, junto con acciones formativas y evaluaciones de infraestructura.

En el nivel **determined**, algunos proyectos superan la fase experimental, se introducen datos estandarizados y se despliegan procedimientos operativos y gestión del cambio, reforzados por apoyo directivo y asignación de recursos.

En el nivel **managed**, la IA está plenamente integrada en procesos críticos de negocio, la ciencia de datos se utiliza para la toma de decisiones y los empleados incorporan la IA como parte habitual de su productividad, respaldados por una visión estratégica clara de la alta dirección.

Finalmente, en el nivel **optimized**, la organización alcanza un estado de integración total, con infraestructura estandarizada, análisis de datos en tiempo real, liderazgo centralizado y una cultura organizativa consolidada en torno a la IA.

La teoría DOI identifica cinco fases en el proceso que recorre una entidad en su toma de decisiones sobre la adopción de una innovación.: knowledge (conocimiento de la innovación), persuasion (formación de una actitud favorable o desfavorable), decision (adopción o rechazo), implementation (uso inicial) y

confirmation (consolidación y continuidad). El AIMM, en cambio, no describe las decisiones, sino el estado de madurez alcanzado tras esas decisiones. Existe, por tanto, una correspondencia entre ambos marcos. De este modo, la DOI aporta una visión procesual y secuencial de la adopción, mientras que el AIMM ofrece una perspectiva estructural y acumulativa de la madurez. Su combinación permite entender no solo qué pasos sigue una organización para adoptar la IA, sino también qué nivel de capacidades ha alcanzado en ese recorrido.

Neumann et al. (2022) combinaron el marco TOE con los niveles de madurez AIMM, en un estudio sobre adopción de IA en entidades públicas. Sus resultados muestran que la relevancia de los factores varía en cada etapa. Los factores tecnológicos tienen importancia media en el nivel assessing, pero se vuelven críticos en los niveles determined y managed. Los factores organizativos, en cambio, evolucionan de forma escalonada: en assessing predominan la estructura del proyecto, la colaboración y la motivación intrínseca; en determined se amplían para incluir apoyo directivo, gestión del cambio, alineación estratégica y recursos; y en managed vuelven a concentrarse en el apoyo de la alta dirección, la colaboración y la afiliación organizativa. Los factores ambientales, por su parte, apenas fueron relevantes salvo la preparación del cliente, identificada en el nivel determined.

En el caso del mercado asegurador español, los datos del IX Termómetro de Inteligencia Artificial y Datos de ICEA (2024) muestran que, de las 57 entidades participantes —que representan aproximadamente el 70,7 % del volumen de primas—, el 80 % ya trabaja en proyectos de inteligencia artificial, lo que confirma una evolución respecto al 73 % registrado en la edición anterior. Entre ellas, más de dos tercios cuentan con áreas específicas dedicadas al desarrollo y despliegue de IA, lo que refleja un compromiso organizativo cada vez más claro con estas iniciativas. En contraste, todavía un 20 % de las compañías no ha iniciado ninguna iniciativa de IA, lo que sigue marcando una segmentación entre organizaciones que han integrado la tecnología en su operativa y aquellas que permanecen al margen.

La tabla 5 muestra los principales problemas identificados por las aseguradoras en relación con la adopción de iniciativas de inteligencia artificial y analítica avanzada. En la nueva edición, el obstáculo más recurrente continúa siendo la falta de personal especializado, citada por la mayoría de las entidades, lo que refleja la dificultad para atraer y retener perfiles técnicos y de negocio capaces de impulsar proyectos de IA en el sector asegurador español. En segundo lugar, se mantienen los problemas con los datos, vinculados a la escasez, calidad o dificultad de integración, que confirman la centralidad de la gobernanza del dato como requisito previo a la madurez tecnológica.

El presupuesto insuficiente también sigue apareciendo como limitante, especialmente en las compañías que ya trabajan activamente en IA, lo que sugiere

que, a medida que las iniciativas avanzan hacia fases de escalado, los requerimientos financieros se intensifican. En paralelo, el informe señala como barrera creciente la alineación entre negocio y tecnología, destacando que una parte significativa de las entidades percibe dificultades para conectar las capacidades analíticas con objetivos estratégicos.

Otro hallazgo relevante es que, aunque la falta de un backlog de casos de uso sigue presente en algunas aseguradoras sin proyectos, la tendencia muestra que las compañías más maduras disponen ya de agendas claras de aplicaciones prácticas, especialmente en ámbitos como operaciones, siniestros, detección de fraude y experiencia de cliente.

Finalmente, el estudio destaca que cerca del 80 % de las entidades están adoptando medidas para prepararse ante las exigencias regulatorias del AI Act, lo que refleja un cambio en la percepción del marco normativo: ya no se interpreta únicamente como una amenaza, sino como un incentivo para fortalecer la gobernanza y los mecanismos de transparencia de la IA.

La comparación entre los resultados del VIII Termómetro de Inteligencia Artificial y Big Data en el sector asegurador español (ICEA, 2023) y el IX Termómetro de IA y Datos (Minsait-ICEA, 2024) permite observar cómo han evolucionado las principales barreras percibidas por las aseguradoras en la adopción de la inteligencia artificial. Mientras que en 2023 las limitaciones se centraban en aspectos de talento, calidad de los datos y disponibilidad presupuestaria, en 2024 estas mismas barreras no solo persisten, sino que se intensifican, alcanzando a más de la mitad de las entidades participantes. En paralelo, otras dificultades de madurez temprana, como la falta de backlog de casos de uso o la consideración de que la IA “no es prioritaria”, pierden relevancia, lo que indica un mayor grado de consolidación en la agenda estratégica de las aseguradoras.

Además, en la edición de 2024 aparecen nuevas categorías de obstáculos, vinculadas a la seguridad y la regulación, reflejando que el sector empieza a prestar mayor atención a los riesgos de ciberseguridad y a la adaptación al marco normativo europeo sobre inteligencia artificial. En suma, la transición entre 2023 y 2024 revela un cambio de fase: de barreras conceptuales y estratégicas hacia barreras operativas, regulatorias y de escalado, que condicionan la consolidación de los proyectos de IA en el seguro español.

La Tabla 5 sintetiza esta evolución, mostrando para cada problema el peso relativo en la muestra total y en la diferenciación entre entidades que ya trabajan con IA y aquellas que aún no lo han hecho.

Tabla 5: Problemas percibidos en la adopción de inteligencia artificial en aseguradoras españolas

Problema	VIII 2023 Total	VIII 2023 Trabaj.	VIII 2023 Sin trabajar	IX 2024 Total	IX 2024 Trabaj.	IX 2024 Sin trabajar	Evolución destacada
Falta de personal especializado	47,0 %	49,0 %	40,0 %	59,6 %	42,1 %	70,0 %	Sube con fuerza: de ~47 % a ~60 %. Principal barrera en 2024, sobre todo entre entidades sin proyectos (70 %).
Problemas con los datos (escasez, calidad, obtención)	39,4 %	43,1 %	26,7 %	63,8 %	59,6 %	40,0 %	Gran incremento: de ~40 % a más del 60 %. Los datos pasan a ser la segunda barrera más citada.
Presupuesto insuficiente	30,3 %	37,3 %	6,7 %	24,6 %	29,8 %	–	Ligera bajada: sigue siendo un freno operativo, pero menos citado que en 2023.
Problemas tecnológicos	15,2 %	15,7 %	13,3 %	24,6 %	29,8 %	–	Crecen: de un problema menor (~15 %) a uno más visible (~25–30 %).
Falta de alineamiento TI & negocio	9,1 %	9,8 %	6,7 %	19,3 %	21,3 %	10,0 %	Se duplica: pasa a ser una barrera organizativa más relevante en 2024.
No se dispone de backlog de casos de uso	18,2 %	11,8 %	40,0 %	10,5 %	10,5 %	4,3 %	Fuerte descenso: muchas compañías ya disponen de agendas claras de casos.
No es prioritario	16,7 %	–	73,3 %	12,3 %	4,3 %	50,0 %	Disminuye, pero sigue pesando en entidades sin proyectos (baja del 73 % al 50 %).
Otros (VIII)	19,7 %	21,6 %	13,3 %	–	–	–	En 2023 “otros” agrupaba varias incidencias dispersas.
Problemas de seguridad (IX)	–	–	–	15,8 %	14,9 %	20,0 %	Nueva categoría en 2024: refleja mayor atención a ciberseguridad.
Problemas regulatorios (IX)	–	–	–	5,3 %	6,4 %	–	Nueva categoría en 2024: refleja mayor atención al cumplimiento (AI Act).

Problema	VIII 2023 Total	<i>VIII 2023 Trabaj.</i>	<i>VIII 2023 Sin trabajar</i>	IX 2024 Total	<i>IX 2024 Trabaj.</i>	<i>IX 2024 Sin trabajar</i>	Evolución destacada
Otros (IX)	–	–	–	8,8 %	–	10,0 %	Se mantiene un nivel bajo de incidencias no clasificadas.

Fuente: VIII Termómetro de Inteligencia Artificial y Big Data en el Sector Asegurador Español; ICEA (2023) y IX Termómetro de Inteligencia Artificial y Data en el Sector Asegurador Español; ICEA (2024)

El análisis comparado de la tabla 5 sugiere diferenciación en los problemas percibidos según el grado de implicación de las entidades en proyectos de inteligencia artificial. Entre las compañías que ya están trabajando con IA, los principales obstáculos se relacionan con la ejecución y el escalado de proyectos: destacan la falta de personal especializado (49%), los problemas con los datos (43,1%) y las limitaciones presupuestarias (37,3%). Estos resultados sugieren que, en fases activas de adopción, las dificultades dejan de ser conceptuales y se convierten en barreras operativas y de recursos que condicionan la consolidación de los proyectos.


Por el contrario, entre las entidades que no trabajan con IA predominan problemas de naturaleza más estratégica y organizativa. El 73,3 % indica que “no es prioritario”, y un 40% señala la ausencia de un *backlog* de casos de uso, lo que refleja una falta de orientación clara sobre cómo la IA puede aportar valor al negocio. Asimismo, aunque la falta de personal especializado también aparece (40%), el peso relativo es menor que en las entidades activas, lo que indica que la carencia de talento se percibe sobre todo cuando se intenta desplegar proyectos concretos.

Las aseguradoras que ya han iniciado iniciativas se enfrentan a retos de ejecución (talento, datos, presupuesto), aquellas que aún no han comenzado se ven condicionadas por retos de priorización y definición estratégica. Esta divergencia sugiere que la naturaleza de las barreras a la adopción de IA evoluciona con el grado de madurez de la organización, confirmando que los factores limitantes no son estáticos, sino dinámicos y dependientes del estadio en el que se encuentra cada compañía.

La Figura 2 muestra que, mientras en 2023 la falta de talento especializado aparecía como la principal dificultad, en 2024 este obstáculo, aunque todavía relevante, parece ceder protagonismo frente a los problemas con los datos, que pasan a ser la barrera más citada por casi seis de cada diez entidades. Este desplazamiento parece indicar que, a medida que las iniciativas maduran, la calidad, integración y gobernanza del dato se convierten en un reto cada vez más central. En paralelo, se

observa un aumento de los problemas tecnológicos y de la falta de alineamiento entre TI y negocio, lo que sugiere que las dificultades ya no se sitúan únicamente en la fase conceptual, sino en la integración y el escalado de las soluciones. Finalmente, la práctica desaparición del argumento “no es prioritario” parece confirmar que, para las compañías activas, la IA ha dejado de percibirse como un experimento marginal y empieza a consolidarse como un elemento estratégico en la agenda de transformación.

Figura 2: Comparativa 2023-2024 de problemas percibidos en la adopción de inteligencia artificial en aseguradoras españolas que trabajan con IA




Fuente: VIII Termómetro de Inteligencia Artificial y Big Data en el Sector Asegurador Español; ICEA (2023) y IX Termómetro de Inteligencia Artificial y Data en el Sector Asegurador Español; ICEA (2024)

La figura 3 sugiere que, incluso entre las entidades que aún no trabajan con IA, se está produciendo un cambio en la percepción de las barreras. La falta de personal especializado, que ya era relevante en 2023, crece con fuerza hasta alcanzar al 70 % de las compañías, lo que parece indicar que el déficit de talento se percibe como un obstáculo previo incluso antes de iniciar proyectos concretos. También aumentan los problemas con los datos, lo que sugiere que la gobernanza y la disponibilidad de información se consideran requisitos básicos para avanzar. Al mismo tiempo, la caída de la barrera “no es prioritario” del 73 % al 50 % apunta a una mayor concienciación estratégica, aunque todavía hay una parte significativa del sector que no sitúa la IA en un lugar central. De forma consistente, la fuerte reducción en la ausencia de backlog de casos (del 40 % al 4,3 %) indica que incluso las compañías sin proyectos comienzan a identificar aplicaciones potenciales, lo que podría facilitar la transición hacia pilotos en el corto plazo. Finalmente, la aparición de nuevas preocupaciones vinculadas a la seguridad y la regulación en

2024 muestra que la discusión ya no se limita a la oportunidad tecnológica, sino que empieza a incorporar los riesgos de ciberseguridad y el marco normativo europeo, lo cual sugiere un cambio de enfoque hacia barreras más complejas y sistémicas.

Figura 3: Comparativa 2023-2024 de problemas percibidos en la adopción de inteligencia artificial en aseguradoras españolas que no trabajan con IA



2.6. Evidencia reciente sobre la “GenAI”

Un informe reciente (agosto de 2025) de MIT NANDA (2025) ofrece un aporte especialmente relevante para comprender los retos actuales en la adopción empresarial de la inteligencia artificial generativa (GenAI). Basado en un diseño multimétodo —con revisión de más de 300 iniciativas públicas, 52 entrevistas estructuradas y 153 encuestas a directivos— el estudio identifica una marcada brecha entre la adopción superficial y la transformación efectiva, que los autores denominan la GenAI Divide.

Los resultados son contundentes: pese a inversiones globales estimadas en 30–40 mil millones de dólares, el 95% de las organizaciones no logran retorno medible de sus proyectos de IA generativa, mientras que solo un 5% de los pilotos integrados generan valor económico tangible. Esta brecha no obedece a la calidad de los modelos ni a las limitaciones regulatorias, sino a la incapacidad de los sistemas para aprender, adaptarse al contexto y retener memoria organizativa.

El informe constata que, si bien más del 80% de las organizaciones han experimentado con herramientas como ChatGPT o *Copilot*, el impacto se limita a incrementos de productividad individual, sin efectos significativos sobre el rendimiento empresarial. Por el contrario, las soluciones personalizadas y de nivel corporativo rara vez alcanzan la fase de producción, con tasas de éxito cercanas al 5%. Este “abismo” entre piloto y despliegue revela la principal manifestación de la GenAI Divide.

Otro hallazgo central es el fenómeno de la *shadow AI*, en el que los empleados utilizan de forma informal herramientas personales de IA (ChatGPT, Claude) con mayor frecuencia y eficacia que las soluciones oficiales promovidas por las empresas. Este uso paralelo demuestra que, cuando las herramientas son flexibles y fáciles de integrar, los trabajadores consiguen mejoras de eficiencia sustanciales, aunque estas prácticas queden fuera de los marcos de control y gobernanza corporativa.

El informe también resalta un sesgo de inversión: aproximadamente el 70% de los presupuestos de IA se destinan a funciones visibles como ventas y marketing, donde las métricas son fáciles de atribuir, mientras que las áreas de *back-office* —con mayor potencial de retorno por reducción de costes externos (BPO, agencias, consultoría)— permanecen infrainvertidas.

Finalmente, MIT NANDA identifica un conjunto de patrones comunes en las organizaciones que logran situarse en el lado “positivo” de la brecha. Entre ellos destacan:

- **Comprar en lugar de construir** internamente, privilegiando alianzas estratégicas con proveedores especializados.

- **Exigir personalización profunda** de los sistemas, con métricas ligadas a resultados de negocio más que a benchmarks técnicos.
- **Impulsar la adopción desde los niveles operativos** mediante “prosumidores” y equipos de línea, en lugar de depender exclusivamente de laboratorios centrales de innovación.
- **Apostar por sistemas *agentic*** con memoria persistente, aprendizaje iterativo y capacidad de orquestación de procesos.

La relevancia de este estudio para el sector asegurador es doble. Por un lado, confirma que los servicios financieros se encuentran entre las industrias con mayor experimentación en GenAI, pero con una transformación estructural aún limitada, circunscrita sobre todo a procesos internos. Por otro, introduce un marco interpretativo que conecta directamente con los hallazgos de esta investigación: proliferación de pilotos sin escalado, dificultades de integración con los sistemas *core*, dependencia de proveedores externos y un sesgo hacia casos de uso visibles más que hacia áreas de mayor impacto potencial.

En este sentido, la GenAI Divide se presenta como una noción que complementa los marcos clásicos de adopción tecnológica (TOE, DOI, AIMM), aportando una categoría analítica emergente que permite explicar por qué la adopción de IA generativa, aun cuando es masiva en términos de pruebas piloto, sigue resultando incipiente en cuanto a transformación organizativa y creación de valor.

Aunque este informe se centra en la inteligencia artificial generativa, sus hallazgos tienen un valor transversal para el análisis de la adopción de IA en general. La GenAI Divide refleja dinámicas que no son exclusivas de la IA generativa, sino que también se observan en iniciativas de IA tradicional: proliferación de pruebas piloto sin escalado, dificultades de integración con procesos críticos, sesgos en la asignación de inversión hacia funciones más visibles y falta de sistemas que aprendan y se adapten de forma continua. Por ello, este marco se incorpora en la revisión como complemento a los modelos clásicos (TOE, DOI, AIMM), aportando una lente contemporánea que ayuda a comprender por qué la adopción de IA, en cualquiera de sus formas, sigue enfrentando una brecha entre experimentación y transformación efectiva.

3. Metodología de la investigación

3.1. Enfoque metodológico

Esta investigación adopta un enfoque cualitativo de tipo interpretativo, adecuado para comprender fenómenos complejos y dependientes del contexto, como es la adopción de IA en compañías aseguradoras. Tal como exponen Hudson y Ozanne (1988), el interpretativismo parte de una ontología constructivista, que asume que la realidad no es única ni objetiva, sino que se construye socialmente a través de interacciones, percepciones y marcos de referencia compartidos.

Este planteamiento se diferencia del paradigma positivista —centrado en la explicación y predicción mediante leyes generales— y se orienta hacia la comprensión profunda de significados, motivaciones y procesos desde el punto de vista de los actores implicados. El objetivo fundamental es alcanzar *Verstehen*, es decir, una comprensión interpretativa que incorpora las significaciones compartidas dentro de un entorno social y cultural específico.

En el ámbito de estudio de esta investigación —la transformación digital de las aseguradoras españolas a través de la IA—, se reconoce que los procesos de adopción tecnológica están atravesados por factores estructurales, culturales, estratégicos y humanos que no pueden reducirse a simples variables cuantificables. Por ello, se opta por un enfoque metodológico que reconoce la pluralidad de realidades, la importancia del contexto y el carácter dinámico del cambio organizativo.

3.2. Consideraciones y retos metodológicos

Integración de enfoques deductivo-inductivo. La investigación combina un **enfoque deductivo** (basado en el marco integrado TOE-DOI y modelo de madurez de Alsheibani et al., 2019) con la lógica inductiva de la Grounded Theory. Esta combinación tiene que ser muy cuidadosa para evitar que el marco teórico inicial “contamine” la aparición de categorías emergentes. Para preservar la esencia inductiva, se estableció una distinción explícita entre códigos derivados del marco y aquellos emergentes del análisis, siguiendo las recomendaciones de Fereday & Muir-Cochrane (2006).

Profundidad y rigor en la aplicación de la Grounded Theory. Además de las fases de codificación abierta, axial y selectiva, el estudio incorpora principios metodológicos de la Grounded Theory como el muestreo teórico (selección de casos según necesidades analíticas) y la saturación teórica (punto en el que los nuevos datos dejan de aportar información adicional relevante) (Corbin & Strauss, 2008). Estos elementos refuerzan la coherencia y el rigor analítico.

Reflexividad del investigador. En un enfoque constructivista e interpretativo como el de la presente tesis, el investigador forma parte del proceso de construcción de significado. Es necesario reconocer y gestionar sus prejuicios para garantizar la transparencia y credibilidad del estudio.

En la presente investigación, el autor cuenta con experiencia de casi 30 años en el sector asegurador español, lo que por un lado facilitó que se estableciera un clima de confianza en las entrevistas, pero por otro exigió un ejercicio constante de autorreflexión y control de sesgos.

En línea con Berger (2015), la investigación cualitativa requiere reconocer que el investigador no es un observador neutral, sino un actor cuya experiencia, trayectoria y creencias pueden influir en todo el proceso analítico. La reflexividad se entiende como “un proceso de diálogo interno continuo y de autoevaluación crítica de la posición del investigador, así como el reconocimiento explícito de que esta posición puede afectar tanto el proceso como los resultados de la investigación” (Berger, 2015). Para atender a esta exigencia metodológica, el presente estudio incorporó memos reflexivos (registro sistemático de percepciones y posibles sesgos) y revisión intersubjetiva de categorías, garantizando así mayor transparencia, credibilidad y rigor interpretativo en los hallazgos.

3.3. Técnica de recolección de datos

3.3.1. Entrevistas semiestructuradas

La técnica principal de recolección de datos fue la entrevista semiestructurada en profundidad, idónea para un enfoque interpretativista y constructivista (Kvale, 1996; Brinkmann, 2018). Este formato combina dos características clave:

- Estructura, que garantiza la cobertura de las dimensiones teóricas relevantes.
- Flexibilidad, indispensable para que emerjan categorías no previstas, en línea con la lógica de la Grounded Theory.

El guion de entrevista se elaboró a partir de los marcos TOE (Tecnología–Organización–Entorno), DOI (Difusión de Innovaciones) y el modelo de madurez de Alsheibani et al. (2019). Se diseñó de manera abierta y adaptable, permitiendo que las respuestas de los participantes orientaran la conversación hacia áreas emergentes de interés analítico.

Principios neutralidad y apertura.

Para minimizar sesgos de formulación se aplicaron buenas prácticas de entrevista cualitativa (Kvale, 1996; Brinkmann, 2018):

- Formulación no inductiva y no evaluativa (evitar juicios de valor y verbos direccionales como “debería”).
- Preguntas abiertas con subpreguntas (*probes*) para profundización, evitando dobles preguntas y tecnicismos innecesarios.
- Secuencias “embudo” (de experiencias concretas a juicios más abstractos) y contraste (p. ej., “¿puedes recordar un proyecto que funcionó y otro que no? ¿qué cambió?”) para favorecer *thick descriptions*.
- Control de orden y efecto halo: los temas sensibles (riesgos éticos, sesgos, empleo) se pospusieron tras consolidar el clima de confianza.
- Durante las entrevistas se prestó especial atención a generar un clima de confianza que favoreciera la expresión libre de percepciones y experiencias, facilitando descripciones ricas y matizadas (*thick descriptions*) que abarcaran tanto aspectos técnicos como narrativas internas, tensiones, expectativas y estrategias directivas frente a la adopción de la IA (Geertz, 1973).

Validación del guion.

El borrador inicial del guion se sometió a:

1. Revisión de expertos (directores de tesis, un consultor con experiencia en implantación de proyectos de IA, un académico experto en innovación y dos

directivos del sector asegurador) para asegurar validez de contenido y cobertura teórica;

2. Revisión tras las primeras cinco entrevistas (reunión metodológica del 28/05/2024): ajustes de claridad, orden, tiempos, comprensión de términos; Introducción de preguntas relacionadas con factores emergentes: riesgos éticos y de desmutualización, lock-in, Hype, y refuerzo de preguntas sobre madurez organizativa, coste-beneficio, diferenciación entre IA predictiva y generativa.

Estrategias para favorecer emergencia inductiva.

Aunque el guion proporciona sistematicidad, el formato se mantuvo flexible:

- Probes no directivos (“¿podrías darme un ejemplo reciente?”),
- Contrafácticos y contraejemplos (“si hoy volvieras a empezar, ¿qué harías distinto?”),
- Anclajes situacionales (casos de uso, incidentes críticos, *timeline* de proyectos),
- Preguntas de variación (misma cuestión, distintas áreas/unidades),
- Triangulación discursiva (estrategia-datos-personas), para facilitar categorías emergentes (Grounded Theory).

Control de sesgos y calidad.

Para reducir sesgos de deseabilidad social y halo en informantes clave (CEOs), se emplearon:

- Preguntas comparativas y de contraste (éxito/fracaso, antes/después, interno/externo),
- Secuencia de “normalización” antes de temas sensibles (“muchas compañías reportan X; en su caso, ¿cómo lo gestionaron?”),
- Verificación de consistencia dentro de la entrevista (replanteo sintético: “si entiendo bien...”) y entre entrevistas (comparación constante). La reflexividad del investigador se documentó con memos tras cada sesión (posibles sesgos, reacciones, pistas analíticas), que también retroalimentaron la guía en pequeños ajustes de orden y *probes*.

A modo ilustrativo, la tabla 6 muestra la correspondencia entre algunas preguntas formuladas en la entrevista E03 y los principios metodológicos aplicados.

Tabla 6: Ejemplo de correspondencia entrevista **E03** – guion TOE–DOI–AIMM

Pregunta del entrevistador	Bloque TOE	Subfactor operacional	Principio metodológico aplicado
“¿Crees que la IA va a ser disruptiva en el negocio asegurador?”	E	Presión competitiva / disrupción sectorial	Pregunta abierta y no inductiva → visión general antes de concreciones (secuencia embudo)
“¿Tienes sensación de urgencia, de que vamos tarde respecto a otras entidades?”	O	Cultura / estrategia / apoyo directivo	Explora percepción cultural y estratégica → normalización comparativa con otras compañías
“¿Habéis identificado casos de uso en los que realmente aporte valor?”	T	Trialability / ventaja relativa	Pregunta abierta con probe (“¿cuáles?”) → fomenta ejemplos concretos
“Has hablado de competencias técnicas... ¿cuál crees que es el principal problema?”	O	Competencias / talento disponible	Neutral, permite emergencia inductiva (“¿el problema es retorno o falta de perfiles?”)
“¿Cómo determináis si un caso de uso tiene suficiente retorno?”	O	Recursos / evaluación coste–beneficio	Pregunta comparativa con otras inversiones → fomenta thick description
“Cuando abordáis proyectos, ¿el principal driver es eficiencia, calidad u objetivos comerciales?”	O–T	Ventaja relativa / estrategia organizativa	Secuencia de variación (distintos drivers) → induce contraste sin sesgo
“¿Crees que la mejora de experiencia de cliente será diferencial, una palanca competitiva?”	E	Presión competitiva / preparación cliente	Abierta, permite juicio sobre impacto competitivo y adaptación a demanda del cliente
“¿Tenéis miedo de que alguna otra compañía lo esté haciendo ya?”	E	Competencia sectorial	Contraste comparativo (“otros CEOs dicen...”) → reduce sesgo de deseabilidad
“¿Qué rol juegan partners como Google y Microsoft?”	E	Dependencia de proveedores externos	Pregunta situacional, fomenta reflexión sobre riesgos y costes

Pregunta del entrevistador	Bloque TOE	Subfactor operacional	Principio metodológico aplicado
“¿El datapool os ha generado problemas de integración con sistemas?”	T	Calidad de datos / compatibilidad IT	Probe específico para explorar barreras técnicas
“¿Trabajáis en Agile o con metodologías de producto mínimo viable?”	T	Complejidad / adaptación de procesos	Pregunta exploratoria, abierta, sin juicios de valor
“¿De dónde surgen los casos de uso, negocio o IT?”	O	Gobernanza / bottom-up vs. top-down	Pregunta estructural, permite emergencia de categorías sobre dinámica organizativa
“¿El cumplimiento normativo y preocupaciones éticas os tiran para atrás?”	E	Regulación (AI Act, sesgos, riesgos altos)	Tema sensible pospuesto tras generar confianza → control del efecto halo
“¿Qué impacto tiene pertenecer al grupo [...]?”	O/E	Apoyo directivo / tamaño y estructura	Pregunta contextual que vincula tamaño organizativo con capacidades
“El tema del tamaño... ¿cómo lo veis frente a compañías más pequeñas?”	O/E	Tamaño / estructura / agilidad vs. complejidad	Pregunta comparativa → triangulación con otros casos
“¿Cómo decidís el presupuesto de IA? ¿Es porcentaje fijo o parte del plan de transformación?”	O	Recursos financieros	Abierta, fomenta thick description sobre decisiones estratégicas

3.3.2. Selección y composición de la muestra

La muestra se construyó de forma intencional y teóricamente orientada, siguiendo criterios de máximo contraste y el modelo de cinco etapas de madurez en la adopción de IA (Alsheiabni et al., 2019). Se han incluido entidades aseguradoras de diferente perfil que operan en España, tanto filiales de grupos internacionales, entidades de capital nacional, entidades sin ánimo de lucro, etc. con el fin de tener representados distintos niveles de madurez tecnológica, tamaños, estructuras de propiedad y modelos de negocio.

Se ha optado por realizar las entrevistas en profundidad a los *CEOs* de las entidades seleccionadas, dado su papel determinante en la definición estratégica, la asignación de recursos y el liderazgo cultural de la transformación tecnológica.

Elección de *CEOs* como informantes clave en la investigación

La decisión de entrevistar únicamente a los *CEOs* de compañías aseguradoras responde los siguientes criterios:

En primer lugar, la literatura sobre adopción tecnológica señala recurrentemente a la alta dirección como clave para el éxito en la adopción de innovaciones (Jeyaraj et al., 2006; Thong, 1999; Premkumar & Roberts, 1999; Grover & Goslar, 1993). En el caso específico de la inteligencia artificial, los *CEO's* son los principales responsables de asignar recursos, articular una visión estratégica y crear un entorno favorable a la innovación, aun cuando los beneficios potenciales de la tecnología sean inciertos (Alsheiabni et al., 2020; Gupta et al., 2022; Matsepe & Van der Lingen, 2022).

En segundo lugar, el *CEO* dispone de una visión integral del negocio por lo que su perspectiva permite situar la adopción de la IA dentro del marco más amplio de la transformación digital y la estrategia corporativa, algo que no sería posible a partir de entrevistas centradas exclusivamente en directivos de áreas técnicas o de innovación.

En tercer lugar, en el contexto específico del sector asegurador español, las decisiones estratégicas de inversión y de orientación tecnológica se encuentran altamente centralizadas en la figura del *CEO*.

En consecuencia, entrevistar a *CEOs* no solo asegura acceso a los principales decisores estratégicos, sino que también alinea el diseño metodológico con los factores teóricos identificados como determinantes en la literatura, reforzando la pertinencia y la validez del enfoque adoptado en esta investigación.

Aunque la intención inicial fue entrevistar exclusivamente a *CEOs*, en una de las entidades el *CEO* delegó la entrevista en su CTO, miembro del comité de dirección. Consideramos que esta circunstancia no desvirtúa el análisis ya que, en primer

lugar, el CTO forma parte de la alta dirección y, por tanto, participa en la definición estratégica de la compañía. En segundo lugar, su perfil aporta una perspectiva complementaria sobre las capacidades técnicas, la arquitectura y la gobernanza del dato, dimensiones críticas en la adopción de IA. Finalmente, el hecho de que la delegación proviniera del propio *CEO* refuerza la legitimidad de la entrevista como voz representativa de la dirección. En relación con el análisis de codificación, esta entrevista no mostró divergencias sustantivas respecto al resto de entrevistas realizadas a *CEOs*. La distribución de los códigos dentro de las dimensiones del marco TOE fue equivalente y la densidad temática comparable. La única diferencia reseñable fue una mayor presencia de referencias técnicas vinculadas a la gobernanza del dato, la arquitectura y las capacidades analíticas, que aportaron un matiz complementario a la visión estratégica predominante en el resto de entrevistas, sin alterar los patrones globales identificados en el estudio.

Composición de la muestra y saturación teórica

La muestra final incluyó 16 entrevistas en profundidad con directivos del más alto nivel —en su mayoría *CEO*, y en un caso CTO por delegación—, consideradas suficientes tras alcanzarse la saturación teórica (Corbin & Strauss, 2008). En conjunto, las entidades participantes representaban un volumen de 56.933 millones de euros en primas emitidas, equivalente a, aproximadamente, el 60% del mercado español en 2024 según datos públicos del sector.

Se incluyeron compañías de distintos tamaños y modelos de negocio: desde grandes grupos internacionales con más de 30.000 empleados, hasta mutualidades pequeñas con apenas unas decenas; y desde entidades multirramo hasta especializadas, directas o mutualistas. La muestra también presenta diversidad en los perfiles directivos entrevistados: edades entre 45 y 63 años, procedentes de disciplinas como economía, administración, ciencias actuariales y derecho, junto con algunos perfiles técnicos e híbridos, reflejo de la creciente importancia de las competencias digitales en la alta dirección.

En términos de madurez, la distribución final de entidades es: 1 entidad en Initial (6,3 %), 4 en Assessing (25,0 %), 7 en Determined (43,8 %) y 4 en Managed (25,0 %), sin ninguna en Optimized. Esta muestra permite el contraste entre fases incipientes, intermedias y avanzadas de adopción.

La saturación teórica se alcanzó de forma progresiva. A medida que avanzaban las entrevistas, los datos comenzaron a reiterar patrones previamente identificados y a densificar categorías ya establecidas, sin aportar dimensiones conceptuales nuevas. En las últimas entrevistas, la ausencia de códigos emergentes y la repetición sistemática de temas confirmaron que el sistema categorial era estable. La comparación constante y los memos analíticos permitieron verificar esta estabilidad, tanto dentro de cada estrato (por nivel AIMM y por tamaño) como entre

estratos, evitando que la saturación se limitara a un subgrupo particular. En este sentido, la muestra no solo alcanza volumen suficiente, sino que garantiza diversidad y exhaustividad en los factores de análisis.

3.3.3. Trabajo de campo, desarrollo y grabación

Una vez completada la fase de planificación metodológica y definido el marco teórico y empírico del estudio, se dio paso a la ejecución del trabajo de campo, consistente en la realización de entrevistas en profundidad a altos cargos del sector asegurador español. El objetivo de estas entrevistas era recoger testimonios cualificados y reflexivos sobre los factores que condicionan la adopción de la IA en sus respectivas organizaciones.

Las 16 entrevistas fueron presenciales, en los despachos de los directivos o salas de reuniones en sus sedes. La presencialidad favoreció la observación directa del lenguaje corporal, tono de voz, pausas, silencios y gestos no verbales, elementos fundamentales para interpretar el discurso en su contexto (Opdenakker, 2006).

También favoreció que se generase en la mayoría de casos un clima de proximidad y confianza que facilitó la narrativa abierta por parte del entrevistado. La experiencia ejecutiva del investigador en el mismo sector que los entrevistados, facilitó una relación de reconocimiento profesional mutuo que contribuyó notablemente a construir una atmósfera de respeto y colaboración intelectual.

Con el fin de contextualizar las conversaciones, antes de cada entrevista se llevó a cabo una preparación de la misma, que incluía la revisión del perfil del entrevistado, analizando su trayectoria profesional, formación, evolución dentro de la organización, responsabilidades actuales y posición estratégica respecto a la transformación digital. Esta información se obtuvo principalmente a través de plataformas como LinkedIn, artículos en prensa especializada, memorias corporativas y notas de prensa institucionales.

Una de las entrevistas se realizó a dos CEO's simultáneamente y otra de las entrevistas se realizó en catalán, siendo transcrita y traducida posteriormente por el investigador.

Al inicio de cada entrevista, el investigador explicó el objetivo de la investigación, así como el compromiso de confidencialidad, anonimización y uso exclusivo para fines académicos. Se solicitó el consentimiento explícito para grabar la conversación a través de un documento firmado o mediante consentimiento verbal al inicio de la grabación. La mayoría de los entrevistados aceptaron la grabación sin reservas, y ninguno solicitó posteriormente revisar ni modificar las transcripciones, a pesar de que se les ofreció esta posibilidad. En dos casos no se obtuvo autorización para grabar; sin embargo, se aplicó una estrategia de notas detalladas y reconstrucción inmediata, lo que aseguró la fidelidad de la información.

Como medida de seguridad ante eventuales fallos técnicos, para grabar las entrevistas se utilizaron dos dispositivos (móvil e iPad). Posteriormente, se procedió a la transcripción literal completa de cada entrevista. En el caso de las entrevistas

no grabadas, se elaboró una transcripción lo más fiel posible a partir de las notas tomadas manualmente durante la entrevista.

Durante el desarrollo de las sesiones, el investigador aplicó técnicas de escucha activa y entrevista empática (Valles, 2002; Wengraf, 2001). La escucha activa se tradujo en señales verbales y no verbales que mostraban atención plena al discurso del entrevistado, como asentimientos, recapitulaciones breves (“si entiendo bien, lo que señalas es que...”) o preguntas aclaratorias que invitaban a profundizar. La entrevista empática, por su parte, implicó situarse en la perspectiva del entrevistado y validar sus experiencias sin emitir juicios, creando un clima de confianza que favoreció la apertura. Por ejemplo, ante declaraciones sobre el escepticismo inicial de la organización frente a la IA, el investigador respondió con expresiones de comprensión (“entiendo que esto pudiera generar dudas en ese momento”), lo que facilitó que el directivo ampliara espontáneamente su relato y compartiera detalles adicionales sobre temas potencialmente sensibles como miedos, tensiones internas o resistencias culturales.

La estructura de la entrevista fue la siguiente:

1. Una **introducción** con explicación del propósito del estudio;
2. Un **núcleo central** sobre la experiencia del entrevistado en relación con la adopción de IA, sus casos de uso, facilitadores, barreras, oportunidades y estrategia organizativa;
3. Un **cierre** con agradecimiento explícito, posibilidad de contacto posterior para validación y emplazamiento a reunirse nuevamente para compartir los resultados de la tesis.

3.3.4. *Procedimiento de la transcripción*

Las entrevistas se fueron transcribiendo a medida que se iban realizando. Dada la densidad argumentativa de los testimonios y el enfoque interpretativo de la investigación, se optó por la transcripción literal completa de todas las entrevistas grabadas, manteniendo pausas, repeticiones, expresiones coloquiales y vacilaciones, elementos cruciales para la interpretación cualitativa de los discursos (Wengraf, 2001; Kvale, 1996).

Para las transcripciones iniciales se empleó el *software* Sonix.ai, un sistema de transcripción automática que permitió generar un primer borrador textual con un grado de precisión aceptable (cerca del 80%), sujeto a ajustes según la calidad del audio y el estilo conversacional del entrevistado. A partir de esta base, se realizó una revisión manual completa por parte del investigador, quien escuchó cada grabación en varias ocasiones para asegurar una correspondencia fiel entre el discurso oral y el texto transcrito. En el caso de la entrevista realizada en catalán, se procedió a su transcripción en lengua original y posterior traducción contextualizada al castellano.

Las dos entrevistas que no fueron grabadas por petición de los entrevistados se reconstruyeron mediante notas tomadas en tiempo real, ampliadas ese mismo día con una narración ordenada de la conversación, manteniendo la estructura del guion temático utilizado y registrando con precisión los contenidos tratados.

Este proceso de transcripción no fue concebido como una tarea meramente técnica, sino como una fase preliminar de análisis cualitativo. A medida que se transcribían las entrevistas, se anotaban en un diario metodológico impresiones sobre la actitud del entrevistado, contradicciones internas, silencios significativos y posibles categorías emergentes, que posteriormente sirvieron como base para ajustar el guion, enriquecer la codificación y alimentar el análisis inductivo.

El guion de entrevista, derivado del marco TOE y complementado con elementos de la teoría de la difusión de innovaciones (DOI), se estructuró en tres bloques: organizacional, tecnológico y ambiental. El guion sirvió de guía, pero no se usó como cuestionario rígido manteniendo así el equilibrio entre sistematicidad y apertura, permitiendo discursos espontáneos que han permitido recoger tanto los factores esperados como dimensiones emergentes.

Tras las primeras cinco entrevistas, se celebró una reunión de revisión con los directores de la tesis. Como resultado, se ajustaron algunas preguntas de cierre, se reforzaron temas poco tratados (como riesgos éticos o gobernanza del dato) y se incorporaron preguntas específicas sobre la madurez organizativa y el coste-beneficio percibido. Estas modificaciones se documentaron en el diario de campo, junto con reflexiones como la siguiente:

“En las entrevistas E04 y E05 han surgido dos temas no anticipados (o no suficientemente): El riesgo de “desmutualización” del seguro por el uso extremo de algoritmos en el *pricing* o la selección de riesgos y la dificultad añadida para atraer talento técnico por el bajo reconocimiento interno de los proyectos de IA. Incorporamos preguntas directas sobre ambos temas al cierre de la entrevista.”
(Diario metodológico: Reunión de ajuste del protocolo, 28 de mayo de 2024)

En total, las 16 entrevistas transcritas están conformadas por 135.186 palabras y tienen una duración aproximada conjunta de 1.050 minutos (más de 17 horas de grabación efectiva). La extensión media por entrevista es de 8.449 palabras, con una duración media estimada de 65,2 minutos. La entrevista más breve contiene 3.970 palabras (30,5 min) y la más extensa alcanza 12.172 palabras (93,6 min).

3.4. Codificación y análisis del discurso

Para poder gestionar el elevado volumen de texto transcrito, se utilizó el *software* NVivo (versión Release 15.0.0).

Como se ha mencionado anteriormente, el enfoque metodológico combinó de manera híbrida una lógica deductiva con una inductiva. En una primera fase, se elaboró un manual de códigos derivado de los marcos teóricos TOE y DOI. Este manual funcionó como plantilla deductiva inicial y se aplicó en una primera etapa de codificación a fin de garantizar la cobertura de las dimensiones analíticas identificadas en la literatura académica. Posteriormente, el análisis permitió la incorporación de códigos emergentes de carácter inductivo, extraídos directamente de las entrevistas, lo que permitió la captura de factores no previstos en el marco conceptual inicial.

El procedimiento de codificación se desarrolló de manera iterativa, en varias fases complementarias:

- **Codificación deductiva inicial**, fundamentada en los factores identificados en la literatura y en el marco integrado TOE-DOI.
- **Codificación inductiva abierta**, que incorporó categorías no previstas inicialmente.
- **Codificación axial y selectiva**, en la que se reorganizaron y relacionaron las categorías entre sí, integrando los hallazgos emergentes con las dimensiones del marco teórico.

Como apuntan Fereday y Muir-Cochrane (2006), este procedimiento metodológico asegura la coherencia entre teoría y evidencia empírica, al tiempo que preserva la apertura analítica característica de la investigación cualitativa interpretativa.

Asimismo, se elaboraron memos analíticos a lo largo del proceso, con el fin de registrar interpretaciones intermedias, hipótesis provisionales y reflexiones metodológicas, así como documentar decisiones de codificación.

También, se aplicaron principios de muestreo y saturación teóricos, incorporando nuevas entidades a entrevistar cuando el análisis revelaba vacíos o la necesidad de contrastar hipótesis emergentes, hasta alcanzar el punto en que entrevistas adicionales dejaron de aportar información diferente a las categorías existentes.

El manual de codificación completo se presenta como anexo a esta tesis.

Ejemplo ilustrativo del proceso de codificación en tres niveles

El procedimiento de codificación seguido avanzó desde la identificación inicial de fragmentos significativos en el discurso hacia su integración final en las dimensiones del marco TOE.

1. Codificación abierta (códigos libres)

En primer lugar, se asignaron códigos a los fragmentos de entrevista, sin tener en cuenta los factores identificados a priori en la literatura. Ejemplo: “Perfiles escasos”, “Rotación alta de personal especializado”, “Difícil retener talento en IA”, “Formación interna insuficiente”, “Temor de empleados al cambio” y “Falta de competencias”.

2. Codificación axial (agrupación y relaciones)

Posteriormente, estos códigos libres se agruparon en categorías más amplias si compartían un significado común y se identificaron las relaciones. Siguiendo con el ejemplo anterior, los códigos se agruparon en la categoría *Talento y cultura*, que se desglosa en subcategorías como:

- Atracción y retención de talento (Perfiles escasos, Difícil retener talento en IA).
- Brecha de capacidades (Formación interna insuficiente, Falta de competencias en Python).
- Cultura organizativa y resistencia al cambio (Temor de empleados al cambio).

Esta fase permitió evidenciar que todos estos códigos se referían a factores humanos y culturales que influyen directamente en la adopción de IA en las aseguradoras.

3. Codificación selectiva (integración en el modelo teórico)

Por último, la categoría *Talento y cultura* se codificó dentro de la dimensión Organización (O) del marco TOE, al tratarse de un factor interno de las entidades.

Resultado final en el modelo TOE:

- Organización (O)
 - Talento y cultura
 - Atracción y retención de talento
 - Brecha de capacidades

- Cultura organizativa y resistencia al cambio

A continuación, se resumen los principales códigos y su frecuencia de aparición:

Tabla 7: Frecuencia de aparición de los principales códigos temáticos en las entrevistas

Código NVivo	Nº entrevistas	Nº referencias
8. Coste-beneficio y ROI	16	389
5. Implementación de IA	16	333
4. Talento y cultura	16	296
2. Organización y gobierno	16	278
9. Madurez y expectativas	16	271
10. Implementación y gestión cambio	16	266
3. Datos e infraestructura	16	265
1. Estrategia y visión	15	183
11. Entorno y factores externos	15	145
6. Riesgos	15	113
7. Regulación	12	58

Fuente: Elaboración propia

3.5. Asignación de niveles de madurez

En este apartado se detalla el procedimiento metodológico seguido para evaluar el nivel de madurez en IA de las organizaciones analizadas. Se describe el marco de referencia adoptado, el proceso de codificación, los criterios operativos para la asignación de niveles, la regla de decisión para la puntuación global y el análisis cuantitativo de los resultados.

3.5.1. *Marco Teórico y Metodológico de Referencia*

El análisis se sustenta en la integración de dos marcos conceptuales clave: el Artificial Intelligence Maturity Model (AIMM) para la evaluación de la madurez y el modelo Technology–Organization–Environment (TOE) para la contextualización de los factores explicativos.

La evaluación del nivel de madurez en IA se fundamentó en el AIMM propuesto por Alsheibani, et al., (2019). Este modelo, de carácter multidimensional, establece cinco niveles de madurez (Initial, Assessing, Determined, Managed, Optimized) y cuatro dimensiones de análisis: Funciones de IA, Estructura de datos, Personas y Organización.

Según los autores, el AIMM combina estos dominios con una escala de cinco niveles inspirada en modelos de referencia como el CMMI, y constituye un marco inicial para la evaluación del grado de madurez de las organizaciones en inteligencia artificial.

3.5.2. *Proceso de Asignación de Niveles de Madurez*

El proceso de asignación se diseñó para garantizar la rigurosidad y la consistencia en la evaluación de cada una de las dieciséis entidades analizadas.

Triangulación Interna y Revisión Cruzada

Para asegurar la validez de las puntuaciones, se implementó un proceso en varias fases:

- **Triangulación interna:** antes de asignar un nivel, se contrastaron sistemáticamente las evidencias obtenidas dentro de cada entrevista, considerando la estrategia declarada, los casos de uso descritos, la gestión de datos, el talento, la gobernanza y las métricas de seguimiento.
- **Asignación preliminar y revisión cruzada:** en una primera fase, se realizó una puntuación individual para cada una de las cuatro dimensiones sintetizados en la tabla 8. Posteriormente, en una segunda fase, se llevó a cabo una revisión global de todas las evaluaciones con el fin de garantizar la coherencia longitudinal y distinguir entre prácticas consolidadas frente a iniciativas puntuales.

Criterios Operativos de Asignación por Dimensión (según Alsheibani et al., 2019)

a) Funciones de IA

- *Nivel 1 – Initial:* Función de IA muy limitada o inexistente; no existen planes.
- *Nivel 2 – Assessing:* Descubrimiento de tecnología de IA.
- *Nivel 3 – Determined:* Proyecto de IA en fase avanzada; determinación de la infraestructura necesaria para implementar IA.
- *Nivel 4 – Managed:* Los procesos de IA están definidos en toda la organización.
- *Nivel 5 – Optimized:* Adopción completa e infraestructura de IA estandarizada.

b) Estructura de datos

- *Nivel 1 – Initial:* Estructura de datos regular; no existen datos para entrenar IA.
- *Nivel 2 – Assessing:* Integración del uso actual de IA en los datos requeridos para entrenar IA.
- *Nivel 3 – Determined:* Se introducen datos personalizados de IA; existen estándares de datos.
- *Nivel 4 – Managed:* Existe ciencia de datos adecuada para tomar decisiones críticas con IA.
- *Nivel 5 – Optimized:* Análisis de datos proactivo; los datos están disponibles en tiempo real.

c) Personas

- *Nivel 1 – Initial:* Habilidades de TI generales; las organizaciones carecen de competencias para evaluar, construir y desplegar soluciones de IA.
- *Nivel 2 – Assessing:* Formación relacionada con IA; evaluación de la infraestructura existente respecto a IA.
- *Nivel 3 – Determined:* Apoyo activo de la dirección; se asignan recursos; formación de empleados en IA.
- *Nivel 4 – Managed:* La IA se realiza plenamente como parte de la productividad de los empleados.
- *Nivel 5 – Optimized:* Los empleados están comprometidos; liderazgo centralizado.

d) Organización

- *Nivel 1 – Initial:* No existe un *business case* relacionado con IA; las estructuras existentes se utilizan de manera informal.
- *Nivel 2 – Assessing:* Estrategia inicial de IA en la organización; para cada aplicación de IA se ha definido una propuesta de valor.
- *Nivel 3 – Determined:* La organización dispone de procedimientos operativos estándar que cubren escenarios de IA; se introduce la gestión del cambio.

- *Nivel 4 – Managed*: Existe un valor bien definido que sustenta la IA y pleno apoyo de la alta dirección.
- *Nivel 5 – Optimized*: Roles, responsabilidades y rendición de cuentas claramente definidos en cada proyecto de IA; cultura de IA consolidada.

Regla de Decisión para la Asignación del Nivel Global

Cada una de las cuatro dimensiones del modelo AIMM fue puntuada en una escala de 1 a 5, correspondiendo a los niveles definidos por el marco. Para determinar el nivel global de madurez de cada organización se aplicó la regla del mínimo, también conocida como criterio del “cuello de botella”. Según este enfoque, el nivel general se corresponde con la puntuación más baja obtenida en cualquiera de las dimensiones. Esta práctica, habitual en modelos de madurez como CMMI y en el propio AIMM, refleja que el avance en la madurez está necesariamente condicionado por el eslabón más débil de la organización.

En cualquier caso, hemos realizado también los cálculos aplicando también el criterio de la media, y los resultados no difieren de manera significativa de los empleados en esta tesis, dado que únicamente la aplicación del criterio de cuello de botella afectaba a una entidad concreta.

En esta investigación se ha optado por utilizar el criterio del mínimo para determinar el nivel global de madurez en IA de cada organización, en lugar de la media aritmética de las dimensiones por las siguientes razones teóricas y metodológicas:

1. Alineamiento con los modelos de referencia

- El modelo AIMM, inspirado en marcos consolidados como CMMI, establece que el progreso en madurez depende del desarrollo equilibrado de todas las dimensiones analizadas.
- Bajo esta lógica, la dimensión más débil marca el límite real de la organización, pues ninguna entidad puede considerarse madura si carece de capacidades críticas en datos, personas, funciones u organización.

2. Evitar sobreestimación

- El uso de la media suaviza las carencias y puede ofrecer una visión demasiado optimista del nivel alcanzado, al compensar debilidades estructurales con fortalezas parciales.
- El criterio del mínimo, en cambio, proporciona una estimación más conservadora, reduciendo el riesgo de clasificar como avanzadas a organizaciones que aún presentan limitaciones significativas.

3. Coherencia diagnóstica

- Este enfoque facilita la identificación de cuellos de botella: al señalar la dimensión que fija el nivel global, permite entender dónde deben concentrarse los esfuerzos de mejora para progresar hacia etapas superiores de madurez.
- Desde una perspectiva aplicada, resulta más útil para la formulación de recomendaciones estratégicas, ya que visibiliza con claridad las limitaciones críticas.

4. Consistencia con la literatura académica

- Diversos estudios sobre adopción de tecnologías (p.ej., Alsheibani et al., 2019) recomiendan un criterio conservador en la medición de madurez, al tratarse de procesos que requieren coordinación sistémica entre múltiples factores.
- El criterio del mínimo es, por tanto, más consistente con la idea de que la madurez en IA no depende únicamente de éxitos puntuales o áreas aisladas, sino de la consolidación de capacidades transversales.

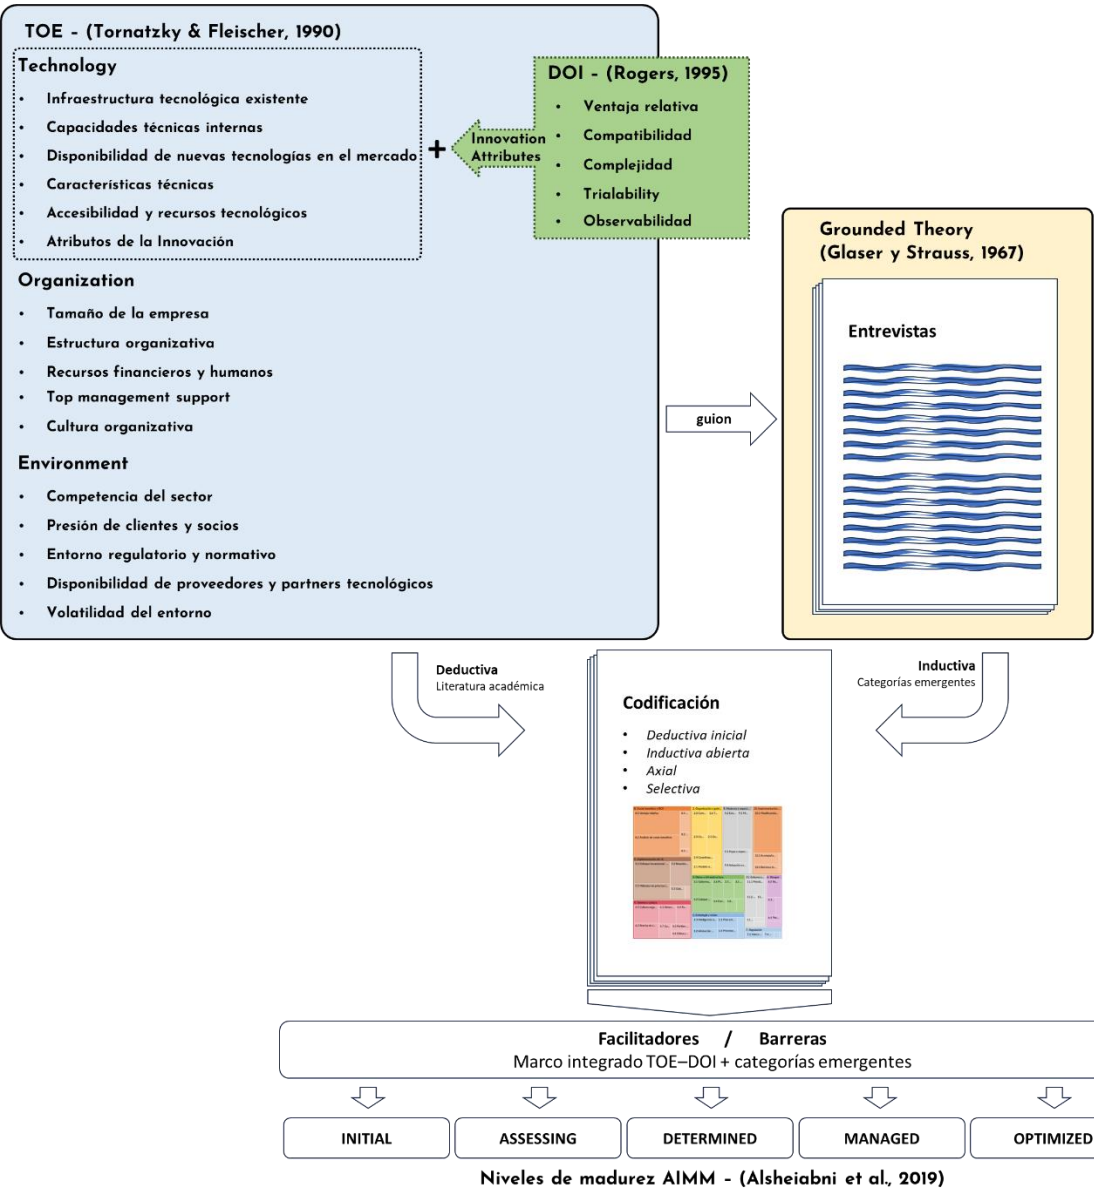
La Figura 4 presenta el marco metodológico empleado en esta investigación, que combina los marcos TOE (Technology–Organization–Environment; Tornatzky & Fleischer, 1990) y DOI (Diffusion of Innovations; Rogers, 1995) con la lógica de la Grounded Theory (Glaser & Strauss, 1967) para identificar los factores que influyen en la adopción de la inteligencia artificial en cada uno de los niveles de adopción (AIMM) identificados por Alsheibani et al. (2019).

Tabla 8. Criterios operativos para la asignación de niveles de madurez en IA según el AIMM)

Dimensión	Nivel 1 – Initial	Nivel 2 – Assessing	Nivel 3 – Determined	Nivel 4 – Managed	Nivel 5 – Optimized
Funciones de IA (uso y estandarización)	No existen funciones de IA o se utilizan de forma ad hoc sin planificación.	Ejecución de pilotos o pruebas de concepto; exploración inicial de la tecnología.	Proyectos avanzados que identifican requerimientos de infraestructura y potencial de escalabilidad.	Procesos de IA definidos y desplegados de forma transversal en la organización.	Infraestructura y procesos estandarizados que permiten operar IA a gran escala.
Estructura de datos (calidad y disponibilidad)	Datos no aptos para entrenar modelos; calidad y disponibilidad limitadas.	Integración inicial de fuentes de datos mínimas para entrenar modelos.	Datos personalizados y estandarizados para su uso en IA.	Gobernanza del dato y capacidades de <i>data science</i> que permiten decisiones críticas con IA.	Datos en tiempo real y capacidad de analítica proactiva.
Personas (talento, capacitación, liderazgo)	Personal con competencias TI generales, sin capacidades específicas en IA.	Formación inicial en IA y evaluación de capacidades.	Recursos dedicados, programas de <i>upskilling</i> y apoyo activo de la dirección.	IA integrada de forma sistemática en la productividad del personal.	Liderazgo centralizado, roles y responsabilidades definidos, cultura organizacional orientada a IA.
Organización (estrategia, gobernanza, cambio)	Ausencia de estrategia o <i>business case</i> para IA; uso informal.	Estrategia inicial focalizada en aplicaciones concretas y propuesta de valor incipiente.	Procedimientos estandarizados para escenarios de IA y gestión del cambio organizativo.	Apoyo integral de la alta dirección y valor corporativo definido para IA.	Roles y responsabilidades establecidos, gobernanza robusta y cultura organizacional consolidada en torno a IA.

Fuente: tabla adaptada a partir de Alsheibani et al., (2019)

Figura 4: Esquema metodológico



3.6. Criterios de evaluación

En el diseño y ejecución de la investigación se han tenido en cuenta los criterios de calidad propuestos por Lincoln y Guba (1985): credibilidad, confirmación, consistencia y aplicabilidad.

Credibilidad

Este criterio de calidad se ha abordado mediante:

- Una muestra intencional de 16 entrevistas a altos cargos (principalmente CEOs) que, en conjunto, representan aproximadamente el 60% del mercado español por volumen de primas.
- Diversidad de perfiles organizativos (aseguradoras tradicionales, mutuas, filiales de grupos internacionales, directas y con distintos niveles de madurez tecnológica).
- Triangulación metodológica entre entrevistas, notas de campo y revisión documental previa (memorias, entrevistas públicas, trayectorias profesionales).
- Transcripción literal de 14 entrevistas y reconstrucción detallada de dos no grabadas, seguida de un proceso de codificación iterativo.
- Sistema de codificación deductivo-inductivo, integrado posteriormente con el marco TOE.

Confirmación

Se ha utilizado un diario en el que se registraron reflexiones, dudas y posibles sesgos en todas las fases del trabajo. Asimismo, se ha prestado atención en separar claramente la descripción y la interpretación. La confirmación se reforzó también a través de la revisión sistemática de los códigos durante la fase de codificación axial, contrastando entre. Finalmente, la experiencia profesional del investigador en el sector asegurador se acompañó de una práctica constante de autorreflexión y control de sesgos.

Consistencia

En este estudio se aseguró mediante la planificación sistemática del trabajo de campo, el uso de un guion inicial basados en la literatura académica ajustados posteriormente para incorporar categorías emergentes. La codificación progresiva y documentada en NVivo refuerza también la trazabilidad. Finalmente, la saturación temática en las últimas entrevistas confirmó la estabilidad de las categorías analíticas.

Aplicabilidad

En esta investigación, se aseguró mediante la selección de una muestra diversificada y la saturación temática. Aunque los resultados no son generalizables en términos estadísticos, sí proporcionan marcos de referencia útiles para aseguradoras que operan en entornos regulatorios similares.

4. Resultados

En este capítulo se presentan los resultados derivados del análisis de las entrevistas realizadas a directivos de compañías aseguradoras españolas, siguiendo la metodología descrita previamente. Los resultados se articulan utilizando el marco teórico Tecnología-Organización-Entorno (TOE), propuesto por Tornatzky y Fleischer (1990). Este modelo ha demostrado ser útil para investigar la adopción de una amplia gama de innovaciones en diferentes contextos. Debido a que la adopción de innovaciones se ve claramente influenciada por los contextos tecnológicos, organizativos y ambientales específicos de cada empresa, el marco TOE continúa proporcionando una guía valiosa tanto para investigadores como para profesionales (Baker, 2012).

La elección de este marco no es solo teórica, sino también analítica: en la fase de codificación axial, las categorías deductivas y los códigos emergentes fueron reorganizados y agrupados precisamente en torno a las dimensiones del TOE. Con ello se garantizó la coherencia entre teoría y evidencia empírica y se aseguró la trazabilidad entre los discursos de los entrevistados y las dimensiones conceptuales de referencia.

Este marco facilita, por tanto, el estudio de cómo el contexto específico de las aseguradoras influye en sus decisiones sobre la adopción e implementación de la IA. Para ello, se agruparon los códigos asignados a los fragmentos de entrevista dentro de cada uno de los elementos que conforman el marco TOE (ver tabla 9).

Tabla 9: Clasificación de los códigos temáticos de las entrevistas según las dimensiones TOE

Dimensión TOE	Código NVivo
Tecnología (T)	3. Datos e infraestructura
	3.1 Gobernanza del dato
	3.2 Calidad del dato
	3.3 Arquitectura tecnológica
	3.4 Fundaciones en datos (<i>Data Lake</i> , integración)
	3.5 Sistemas <i>legacy</i>
	3.6 Plataformas tecnológicas (<i>CoPilot</i> , Salesforce, etc.)
	3.7 Complejidad tecnológica
	3.8 Dependencia tecnológica / lock-in
	5. Implementación de IA
	5.1 Enfoque incremental / piloto / escalado
	5.3 Gobernanza de los modelos (control, escalado, caja negra)
	5.5 Métodos de priorización y evaluación de casos
	6. Riesgos
	6.1 Caja negra y explicabilidad
	6.2 Alucinaciones en modelos generativos
	6.3 Riesgos éticos y discriminación
	6.4 Pérdida de control sobre procesos

	6.5 Reputación y confianza 9. Madurez y expectativas 9.1 “Hype” y expectativas infladas 9.2 Evolución progresiva vs. disrupción inmediata 9.3 Comparación con otras modas tecnológicas 9.4 Adopción escalonada 9.5 Madurez tecnológica
Organización (O)	1. Estrategia y visión 1.1 Plan estratégico 1.2 Alineación con visión del CEO / Consejo 1.3 Inteligencia artificial como eje transformador 1.4 Priorización estratégica de la IA 1.5 Cultura de innovación 2. Organización y gobierno 2.1 Modelo operativo (por producto, transversal, etc.) 2.2 Comité de dirección / estructura de liderazgo 2.3 Centro de competencia / estructura de IA 2.4 Coordinación con grupo o filiales 2.5 Complejidad organizativa 2.6 Tamaño de la organización 2.7 Reingeniería de procesos 4. Talento y cultura 4.1 Atracción y retención de talento 4.2 Brecha de capacidades 4.3 Perfiles escasos y rotación 4.4 Formación interna y upskilling 4.5 Cultura organizativa y resistencia al cambio 4.6 Clima y sentido de pertenencia 4.7 Cultura de innovación (vívida) 5. Implementación de IA 5.4 Evaluación de costes y retorno (ROI, coste-beneficio) 8. Coste-beneficio y ROI 8.1 Análisis de coste-beneficio 8.2 Indicadores (KPIs, TIR, retorno) 8.3 Selección y priorización de casos de uso 8.4 Rentabilidad tangible e intangible 8.5 Ventaja relativa 10. Implementación y gestión del cambio 10.1 Planificación y gobernanza del cambio 10.2 Acompañamiento a empleados 10.3 Métricas de seguimiento 10.4 Barreras internas 10.5 Escalabilidad de pilotos
Entorno (E)	5. Implementación de IA 5.2 Relación con proveedores y consultoras 7. Regulación


	7.1 Marco regulatorio europeo (AI Act)
	7.2 Supervisión y transparencia
	7.3 Obligaciones específicas por nivel de riesgo
	7.4 Rol de protección de datos
	11. Entorno y factores externos
	11.1 Presión competitiva y <i>FinTechs</i>
	11.2 Preparación y aceptación del cliente
	11.3 Preocupaciones éticas y sociales
	11.4 Regulación y presión institucional (sector público)
	11.5 Colaboración con socios externos / fondos públicos
	11.6 Rol de la mediación

Fuente: Elaboración propia

La presentación de los resultados seguirá un orden basado en la relevancia observada en el análisis cualitativo, determinada por el volumen y la frecuencia de referencias asociadas a cada categoría NVivo, tal como puede observarse en el *treemap* generado por NVivo (Figura 5) y en la tabla 10. En este gráfico, el tamaño de cada área refleja la cantidad de referencias codificadas en cada categoría: a más referencias, mayor área. Asimismo, la intensidad del color de cada área indica el número de entrevistados que mencionan dicha categoría, siendo más intensa cuanto más entrevistados hayan hecho referencia al código correspondiente.

Esta estrategia narrativa permite presentar los resultados en un orden que evidencia claramente cuáles son los factores más significativas que según los entrevistados condicionan actualmente la adopción de la IA en el sector asegurador español.

Figura 5: Treemap de categorías NVivo según volumen de referencias y número de entrevistas



Fuente: Elaboración propia a partir del mapa jerárquico de nodos de NVivo

Tabla 10: Resumen cuantitativo de códigos NVivo

Código	Entrevistas	Referencias	% del total
8. Coste-beneficio y ROI	16	389	14,98
5. Implementación de IA	16	333	12,82
4. Talento y cultura	16	296	11,40
2. Organización y gobierno	16	278	10,70
9. Madurez y expectativas de la IA	16	271	10,44
10. Implementación y gestión del cambio	16	266	10,24
3. Datos e infraestructura	16	265	10,20
1. Estrategia y visión	15	183	7,05

Código	Entrevistas	Referencias	% del total
11. Entorno y factores externos	15	145	5,58
6. Riesgos	15	113	4,35
7. Regulación	12	58	2,23
Total	16	2.597	100,00

Fuente: Elaboración propia


Un primer hallazgo destacable es precisamente la mayor importancia que los directivos españoles atribuyen a los factores organizacionales frente a los tecnológicos y ambientales, como queda claramente reflejado en el análisis cualitativo realizado (ver tabla 11 y figura 6).

Tabla 11: Distribución de referencias por dimensiones TOE en las entrevistas

Dimensión TOE	Referencias	% del total
Organización (O)	1.423	54,79
Tecnología (T)	892	34,35
Entorno (E)	282	10,86
Total	2.597	100,00

Fuente: Elaboración propia

Figura 6: Representación gráfica de la distribución de referencias por dimensiones TOE



Fuente: Elaboración propia

Esta dimensión fue la que más se atención acaparó en todas las entrevistas, especialmente los códigos relacionados con la evaluación económica y la justificación financiera de los proyectos (Coste-beneficio y ROI – código 8), los aspectos vinculados a la implementación efectiva y escalable de iniciativas de IA (Implementación de IA – código 5), la gestión del talento interno y la cultura organizativa como palancas fundamentales del cambio (Talento y cultura – código 4), y la estructura interna, el liderazgo y la gobernanza corporativa (Organización y gobierno – código 2) como condicionantes clave en la adopción tecnológica.

La relevancia que los entrevistados otorgan a estos factores organizativos sugiere que, desde su perspectiva, el éxito en la integración de la IA está determinado principalmente por consideraciones estratégicas internas, aunque también puede estar condicionada por el perfil de los entrevistados, que al tener responsabilidades directivas y estratégicas de primer nivel pueden tener una visión más orientada a la gestión, la eficiencia, la optimización operativa y el desarrollo organizativo. No obstante, estos directivos también tienen la obligación de considerar cuidadosamente tanto los factores externos (como las presiones regulatorias, las expectativas del mercado o las dinámicas competitivas), como las tecnologías emergentes disponibles, debido a su impacto potencial sobre el desempeño global de la compañía.

4.1. Dimensión Organización (O)


Dado que los factores organizacionales han sido identificados como los más relevantes en las entrevistas realizadas, el análisis se inicia con esta dimensión, profundizando en los aspectos estratégicos internos que, según los directivos, condicionan en mayor medida el éxito en la integración de la IA. En particular, sobresalen cuatro ejes: la necesidad de asegurar retornos claros y cuantificables, la gestión eficiente del despliegue operativo, la disponibilidad de profesionales con las competencias adecuadas, y la promoción, desde las estructuras de liderazgo, de una cultura organizativa abierta al cambio tecnológico y a la innovación.

4.1.1. Coste-Beneficio y ROI

El análisis de las entrevistas confirma que la exigencia de retornos claros, cuantificables y sostenibles constituye uno de los factores organizativos más determinantes en la adopción de inteligencia artificial dentro del sector asegurador español. La categoría Coste-beneficio y ROI acumula un total de 389 referencias en las 16 entrevistas realizadas, lo que la sitúa como uno de los ejes centrales en la justificación y priorización de proyectos de IA.

Esta sección se presenta organizada en torno a cinco dimensiones identificadas en el discurso de los entrevistados: la ventaja relativa de la IA frente a tecnologías previas, el análisis coste-beneficio como filtro decisivo, la consideración de rentabilidades tangibles e intangibles, el uso de indicadores financieros y cuadros de mando para formalizar la medición del retorno, y la selección y priorización de casos de uso como ejercicio estratégico de focalización de recursos.

Figura 7: Entrevistas y referencias por subcategorías de Coste-beneficio y ROI



Fuente: Elaboración propia

4.1.1.1. Ventaja Relativa

Dentro de los factores organizativos relacionados con el coste-beneficio y ROI, la Ventaja Relativa ha emergido como un punto clave, con el mayor número de menciones (172 referencias).

El análisis de las entrevistas refleja una percepción dual y diferenciada acerca de la ventaja relativa asociada a la IA en función del tipo específico de tecnología considerada: por un lado, la IA predictiva, a la que los entrevistados suelen referirse como "tradicional", y por otro, la IA generativa. La primera es valorada como una herramienta madura, cuyo impacto incremental debe evaluarse desde un punto de vista "pragmático" basado en retornos claros y tangibles y, preferiblemente a corto plazo. En contraste, la segunda se concibe como una tecnología con un potencial transformador significativo, aunque con un mayor grado de incertidumbre respecto a su capacidad real para aportar valor inmediato y medible.

Dimensiones de la Ventaja Relativa

Los entrevistados identifican la ventaja relativa de la IA en las seis dimensiones principales que se recogen en la tabla 12.


Tabla 12: Dimensiones de la ventaja relativa de la IA en aseguradoras españolas

Dimensión	Justificación de la Ventaja	Grado de Consenso (N.º referencias / N.º entrevistas)
Retorno económico inmediato (ROI tangible)	Requisito indispensable para escalar proyectos; solo se aprueban iniciativas con retorno positivo, cuantificable y sostenible.	58 referencias / 15 entrevistas
Valor estratégico-intangible (IA generativa)	Inversiones controladas aun sin ROI inmediato, por su capacidad de preparar a la organización, generar aprendizaje y habilitar cambios culturales.	21 referencias / 9 entrevistas
Jerarquía de impacto en la generación de valor	Prioridad de proyectos ligados a adquisición de clientes, retención y <i>pricing</i> /fraude, por mayor elasticidad beneficio-coste.	26 referencias / 11 entrevistas
Escala y eficiencia organizativa	Mayor rentabilidad en procesos con grandes volúmenes y repetitividad; en compañías pequeñas, selectividad quirúrgica; en grandes, exigencia de retornos absolutos.	18 referencias / 10 entrevistas
Prudencia y estrategia <i>fast follower</i>	Se prefiere validar con pilotos antes de escalar; muchas aseguradoras optan por ser seguidoras rápidas para evitar riesgos y reducir costes iniciales.	14 referencias / 8 entrevistas

Dimensión	Justificación de la Ventaja	Grado de Consenso (N.º referencias / N.º entrevistas)
Costes ocultos y riesgos asociados	Dependencia de proveedores, aumento recurrente de licencias, mala calidad del dato y riesgos éticos (desmutualización).	10 referencias / 7 entrevistas

Fuente: Elaboración propia

Figura 8: Distribución de referencias y entrevistas por dimensiones de la ventaja relativa de la IA



Fuente: Elaboración propia

El grado de consenso se ha cuantificado contando el número de referencias codificadas y el número de entrevistas distintas (de un total de 16) en las que se menciona cada dimensión.

La percepción del valor por parte de los entrevistados en relación con estas seis dimensiones varía considerablemente según el tipo de IA analizada, ya sea generativa o no generativa.

a) **Eficiencia-Coste**

La ventaja de la IA predictiva se concibe como incremental y condicionada a un riguroso análisis económico. Los directivos evalúan su valor mediante un cuidadoso cálculo del retorno de la inversión (ROI), donde el beneficio incremental respecto a las técnicas de analítica de datos avanzada que ya usa el sector debe superar claramente el coste:

“Y entonces esto lo puedes llevar a muchas cosas, como por ejemplo los modelos analíticos de churn. ¿Los modelos analíticos de churn funcionan? Sí. El problema es que, a la hora de llevarlos a la realidad, como el embudo es muy estrecho, pues lógicamente el beneficio asociado a hacer todo el recorrido, hacer toda la acción predictiva, etcétera pues también suele ser pequeño, ¿no?” (E01)

“Nos dijeron: “oye, con esta solución [...] podéis tener una mejora de 300.000 € en fraude detectado, pero es que la solución cuesta 200.000”. Entonces les decimos: “oye, cuando estés más económico podemos hablar”. ¿Me entiendes? [...] Al final invertir para tener una ganancia de 100.000 €, cuando esto también te generará conflictos con clientes, pues aún no hay un retorno claro.” (E08).

En cambio, la IA generativa es percibida como un salto cualitativo, potencialmente disruptivo, capaz de reducir significativamente el tiempo dedicado a tareas intensivas en texto y programación, impactando así positivamente en la eficiencia de las entidades:

“Sí que hay eficiencias importantes en el caso de uso que tenemos. Tenemos un ahorro de un 50% del tiempo, una tarea que se hace un 50% del tiempo. No son 20%, son 50%. ¡Y acabamos de empezar!” (E12)

b) Experiencia de Cliente

Los entrevistados perciben que la IA predictiva ejerce un impacto indirecto o colateral sobre la mejora de la experiencia del cliente, principalmente a través de la optimización de procesos internos, como la reducción del tiempo en la tramitación y el pago de siniestros:

“Te hablaba de Incapacidad Temporal: los siniestros de Incapacidad los pagábamos en 30 y pico días. Ahora los pagamos en tiempo real. Entonces imagínate: desde el punto de vista del cliente, es que es la noche y el día.” (E03)

En contraste, a la IA generativa le atribuyen la capacidad de transformar directamente la interacción con el cliente en el *frontend*, habilitando autoservicios conversacionales y facilitando que los agentes proporcionen respuestas más rápidas, precisas y eficientes:

“Nuestros operadores en el contact center [...] ahora no hay tanta necesidad de formación técnica sobre los productos [...] porque tienen la posibilidad de preguntar [...]. Entonces ahora todo es mucho más ágil, la llamada es más corta y el cliente obtiene una respuesta mucho antes. Aquí ha ayudado mucho a mejorar.” (E02)

c) Rentabilidad y Gestión del Riesgo

La IA predictiva muestra un grado avanzado de consolidación en áreas como la detección de fraude, el pricing y la retención de clientes, entre otras. Los

entrevistados destacan su contribución a la mejora de la competitividad y rentabilidad:

“Todo lo que son procesos masivos a nivel de eficiencia puede notarse mucho. En atención al cliente y siniestros también, y en la parte analítica, en el ajuste de prima. Cuanto más afinado tengas el modelo, mejor será la competitividad y rentabilidad.” (E04)

Por otra parte, el rol de la IA generativa se percibe aún como exploratorio, aunque su capacidad para interpretar información no estructurada abre nuevas oportunidades, llegando incluso a superar las capacidades humanas en determinados contextos:

“Le hemos subido nuestros condicionados. [...] Le hemos hecho una pregunta. Nos ha dado alternativas. Incluso el técnico me decía: “Pensé que esto estaba excluido y en cambio la máquina lo ha sabido”. La IA ha sabido interpretar el condicionado [...] y dar una respuesta coherente y mejor que el técnico.” (E09)

d) Productividad

La IA predictiva ha permitido automatizar y optimizar significativamente las tareas analíticas. El grado avanzado de madurez de esta tecnología se refleja en su despliegue consolidado y a gran escala, sobre todo en las entidades más grandes y sofisticadas:

“Cuando yo llegué aquí hace tres años ya, lo primero que pregunto es ¿cuántos módulos tenemos en producción?, No sabían cuántos, el número de módulos que había en producción, ¿no? Al final ya tenemos una cifra: hay pues más de 100 modelos puestos en producción.” (E11)

Por otra parte, la IA generativa es percibida como una disrupción directa en las tareas propias del trabajo intelectual, potenciando de forma considerable la productividad de perfiles profesionales especializados y de alto valor:

“Perdón, ¿esto no es disruptivo?, perdóname, es que tú sabes el tiempo que... que yo me pasaba cuando hacía presentaciones en... en pensar en los mensajes y cómo plasmarlos en una PPT. Es que es brutal. Y ahora la herramienta con una serie de... de premisas te construye y tú lo que haces es corregir o modular, O sea, el nivel de productividad que ganas es tan brutal que... que no sé cómo no, cómo no va a ser disruptivo.” (E12)

“Yo tengo relación con bastantes startups y una de las startups con la que tenía relación me dijo: “He aplicado IA escuchando GPT y donde tenía que tener 14 desarrolladores tengo diez”. Y le dije: “vente a la compañía y explica a todo el comité de dirección cómo lo has hecho.” (E09)

e) Diferenciación Competitiva

La IA predictiva es percibida ya como una tecnología consolidada y ampliamente disponible (*commodity*), de modo que la ventaja competitiva no reside tanto en la tecnología en sí, sino en la calidad diferencial de los datos y del talento asociado. En contraste, la IA generativa representa un nuevo escenario competitivo donde la rapidez en su adopción puede conferir ventajas significativas, aunque posiblemente temporales. En este sentido, los directivos manifiestan cierto escepticismo acerca de la sostenibilidad a largo plazo de las ventajas generadas por la IA, dada la facilidad con la que podrían ser replicadas por otros competidores. Como señala uno de los entrevistados:

“Y yo creo (incluso el otro día lo escuchaba) que al final, que si ChatGPT, que si, que si generative, al final todos estos van a ser una commodity, como tenemos hoy bases de datos y lo que importará es lo que has construido sobre esa commodity.” (E09).

Otro directivo profundiza en esta cuestión, enfatizando la incertidumbre sobre la duración real de estas ventajas competitivas:

“Al final yo creo que subyace un punto en ese tema de, oye, la inteligencia artificial... es decir, ¿cómo puede crear para mí una ventaja competitiva, y esa ventaja competitiva, cuán sostenible la puedo hacer en el tiempo para que realmente sea una ventaja competitiva?” (E01).

f) Agilidad y Barreras de Entrada

Los entrevistados coinciden en que la IA predictiva ha favorecido en mayor medida a las entidades grandes, tanto por el mayor volumen de datos del que disponen como por su capacidad financiera. En cambio, la IA generativa es percibida como una tecnología más “democrática”, es decir, con barreras de entrada reducidas para compañías más pequeñas y ágiles.

“Nosotros somos una compañía pequeñita y somos capaces, a nivel de máquina, de lanzar un producto a nivel de sistemas en cuatro semanas, un producto nuevo desde cero. [...] Yo creo que en este caso el tamaño es una ventaja para las pequeñas. O sea, creo que si somos inteligentes podemos competir de tú a tú con una grande en determinadas cosas.” (E09)

Sin embargo, los entrevistados también destacan que, independientemente del tipo de IA, la calidad de los datos continúa siendo un requisito indispensable, como queda ilustrado en la siguiente metáfora:

“Es un Fórmula uno dentro del mercado, que en un primer momento no podíamos meter. El problema es que tú metes un Fórmula uno en el Jarama con lo que tienes y ha habido que esperar año y medio o dos años para poder decir: 'Bueno, después de modificar lo que hemos modificado, ahora puedo

incorporarlo! Hasta este momento no se podía incorporar porque no te sirve de nada si los datos los tienes mal.” (E14)

En la Tabla 13 se sintetizan las principales diferencias percibidas por los directivos en torno a seis dimensiones de análisis: eficiencia-coste, experiencia de cliente, rentabilidad y gestión del riesgo, productividad, diferenciación competitiva y agilidad/barreras de entrada.

Tabla 13: Ventaja relativa de la IA: comparación entre modelos predictivos y generativos

Dimensión	IA Predictiva (tradicional)	IA Generativa
Eficiencia-Coste	Impacto incremental . Se evalúa con rigor financiero (ROI a corto plazo). Retornos limitados cuando el beneficio marginal no supera claramente el coste.	Impacto cualitativo . Reducción sustancial del tiempo en tareas intensivas en texto y programación (ahorros del 50%). Potencial disruptivo.
Experiencia de Cliente	Mejora indirecta mediante procesos más rápidos (ej. pagos de siniestros en tiempo real).	Mejora directa en la interacción: autoservicios conversacionales, soporte a agentes con respuestas ágiles y precisas.
Rentabilidad y Gestión del Riesgo	Consolidada en fraude, pricing, retención . Genera competitividad y rentabilidad verificable.	Aún exploratoria , pero capaz de interpretar información no estructurada mejor que humanos en ciertos casos.
Productividad	Automatización y despliegue masivo de modelos (ej. >100 modelos en producción). Incrementos en eficiencia analítica.	Disruptiva para el trabajo intelectual. Duplica la productividad en tareas administrativas y especializadas.
Diferenciación Competitiva	Ya es una commodity . La ventaja depende de datos y talento, no de la tecnología en sí.	Puede generar ventajas temporales por rapidez de adopción, pero existe incertidumbre sobre su sostenibilidad en el tiempo.
Agilidad y Barreras de Entrada	Favorece a grandes entidades por su escala y recursos .	Más democrática : permite competir a compañías pequeñas y ágiles, aunque sigue requiriendo datos de calidad.

Fuente: Elaboración propia

4.1.1.2. Análisis coste-beneficio

Tras analizar cómo los directivos perciben las ventajas relativas de la inteligencia artificial en sus dos vertientes (predictiva y generativa), abordamos el análisis coste-beneficio, segundo subcódigo más relevante dentro del código “8. Coste-beneficio y ROI”, con un total de 147 referencias, mostrando cómo el rigor financiero

actúa como filtro decisivo para convertir las ventajas potenciales de la IA en proyectos tangibles e inversiones viables.

Los altos directivos del sector asegurador entrevistados coinciden en que la adopción de la inteligencia artificial se rige por criterios pragmáticos y financieros. En este sentido, las decisiones de inversión no responden a modas, sino que han de superar un riguroso análisis coste-beneficio. Únicamente reciben autorización aquellos proyectos cuya propuesta de valor, ya sea mediante reducción de costes, incremento de ingresos o mejora en la productividad, es clara, cuantificable y supera de manera sostenible la inversión requerida en un tiempo razonable.

Retorno económico como requisito

La viabilidad económica emerge como requisito en cualquier iniciativa de inteligencia artificial. Los directivos entrevistados coinciden en que ningún proyecto avanza hacia la fase de escalado sin demostrar previamente un retorno de la inversión (ROI) positivo y significativo. Este análisis financiero previo actúa como filtro, eliminando aquellas tecnologías o casos de uso cuyo coste de adquisición e integración excede el beneficio tangible esperado.

Este rigor financiero resulta especialmente relevante en contextos de recursos limitados y mercados maduros. Un directivo de una aseguradora mediana ejemplifica esta lógica mediante un caso concreto relacionado con una aplicación para detectar fraude:

“Nosotros no lo cogimos por una cuestión de precios y se lo dijimos así. Y además el caso nos lo hicieron ellos. Es decir que [...] nos dijeron Oye, con esta solución, tal como estáis vosotros, podéis tener una mejora de 300.000 € en fraude detectado, pero es que la solución cuesta 200.000. Entonces le decimos Oye, cuando estés más económicos podemos hablar.” (E08)

Esta lógica es coherente con la idiosincrasia y la trayectoria reciente del sector asegurador que ha conocido múltiples ejemplos de tecnologías en principio prometedoras que no alcanzaron una adopción generalizada precisamente por no superar el umbral de rentabilidad:

“La tecnología existe, pero no la ponemos en marcha. ¿Y la pregunta es por qué? Bueno, pues porque evidentemente lo que te costaría esa tecnología pues es mucho mayor. El beneficio que puede sacar es muy inferior a lo que puedes [...] hacer.” (E01)

Este prerrequisito financiero actúa Incluso en grandes entidades con capacidad inversora relevante. Todas las iniciativas deben contar con un caso de negocio sólido que justifique destinarle recursos:

“Todas las iniciativas que tenemos tienen su propio plan de negocio detrás. [...] Todos tienen un impacto económico que lógicamente sale positivo. Sí, y además

relevante, si no, ni nos metemos. O sea, si con dudas vemos que no sale, pues no.” (E11)

“Intentamos que vaya todo con una metodología un poco financiera, por así decirlo. Es decir, ¿cuál es el coste beneficio de adoptar eso antes de tomar la decisión? [...] El hecho de que la herramienta sea inteligencia artificial es porque el coste beneficio primeramente nos ha salido para abordarlo.” (E10)

No obstante, la irrupción de la inteligencia artificial generativa introduce un matiz importante. Aunque se mantiene la exigencia de un retorno claro, algunos directivos reconocen que este puede ser no explícito o inmediato. Se consideran, por tanto, inversiones controladas en proyectos de IA que ayuden a construir activos intangibles que preparen a la organización para cambios estratégicos o culturales que los entrevistados consideran que serán necesarios a medio y largo plazo:

“Yo creo que ahí estamos todos gestionando esa tensión entre una urgencia, no para tener un retorno inmediato, porque yo creo que el retorno inmediato no es tan claro, pero sí que yo al menos sí que tengo una urgencia de que toda la organización entre a comprender dónde podemos tener oportunidades de mejora.” (E3)

“Tenemos que definir efectivamente cuál es el retorno, que a lo mejor a plazo corto no es muy evidente, pero sí que creo que a medio largo plazo va a tener sus impactos.” (E12)

En definitiva, aunque predomina un enfoque pragmático financiero centrado en el retorno explícito e inmediato, existe también un enfoque que reconoce la IA, especialmente la generativa, como un cambio inevitable y estratégico. Más allá de considerarla únicamente como ventaja competitiva sostenible, la IA se percibe como una tecnología que se transformará en un recurso esencial, indispensable para mantener la operativa futura:

“El futuro será absolutamente digital, todo será digital, no solo las... las compañías de seguros, sino en general nuestra sociedad.” (E15)

Desde esta perspectiva, los directivos consideran que no IA no es una opción. La inacción constituye un riesgo mayor que la asunción de inversiones controladas:

“¿Qué alternativa tienes? La alternativa no es quedarte mirando cómo los demás avanzan.” (E12)

En consecuencia, incluso cuando el retorno inmediato no es claro, la inversión se justifica por el valor intangible de capacitar a la organización y explorar nuevas oportunidades, partiendo de la certeza de que esta tecnología será parte integral del negocio en el futuro:

“Sabemos que independientemente de que te dé o no te dé un retorno [...] hay un intangible que es [...] formar a la organización alrededor de una tecnología que sí estamos convencidos de que formará parte de nuestro día a día.” (E03)

Jerarquía en la generación de valor

Las entrevistas muestran que los directivos no consideran todas las aplicaciones de inteligencia artificial tengan el mismo impacto potencial, sino que existe una jerarquía determinada por el impacto esperado por cada euro invertido. Un directivo expresa esta jerarquía en tres niveles diferenciados:

“Uno es todo aquello que tiene que ver con la adquisición del cliente. Bueno, pues seguramente [...] en términos de euro invertido, estos casos de uso son los que potencialmente deberían tener más retorno. Un segundo elemento es [...] la conservación de los portafolios de clientes. [...] Y el tercero son aquellos que tienen que ver con la propia eficiencia, que lógicamente también van a ser importantes.” (E01)

La inteligencia artificial tradicional sigue siendo la elección preferente para funciones core del negocio asegurador, especialmente en áreas como la tarificación y la detección del fraude, donde su capacidad predictiva está validada y ofrece un impacto significativo en la cuenta de resultados:

“Yo creo que está más en si la inteligencia artificial te permite tener unas primas más adecuadas al riesgo que suscribes [...] y aquello te dé unas ventajas de puntos básicos en tasas que no en reducción de gastos.” (E08)

“Un ámbito evidente ¿vale? Para el uso de tecnología de inteligencia artificial, que nos ha ido y nos está yendo muy bien, es en identificación de fraude. Y eso es, lo ves, lo ves económicamente, lo ves económicamente con datos.” (E02)

En contraste, la inteligencia artificial generativa encuentra su principal ámbito de aplicación en la mejora de la experiencia del cliente y en la optimización de los procesos de comunicación, actuando fundamentalmente como herramienta de apoyo que incrementa la productividad de los equipos humanos:

“La idea es que esta ayuda no interactúe directamente con el cliente, sino que dé soporte a nuestro equipo. Por ejemplo, que cuando alguien envíe un correo, el “bicho” prepare una respuesta sin necesidad de intervención, y el agente solo la revise o ajuste si es necesario.” (E04)

Entre los beneficios más valorados por los directivos destaca especialmente el aumento de productividad. Las métricas empleadas para medir estos incrementos incluyen la reducción del tiempo medio de gestión, la disminución de horas-hombre dedicadas y la posibilidad de gestionar mayores volúmenes de trabajo con los mismos recursos. Algunos directivos señalan que las expectativas generadas por la inteligencia artificial generativa son considerablemente superiores a las

atribuidas a la IA tradicional, pudiendo incluso duplicar los incrementos de productividad observados previamente, especialmente en tareas administrativas, donde la implementación de IA permite reducir drásticamente el tiempo necesario para procesos realizados tradicionalmente manuales:

“Estábamos dedicando dos personas como 15 días. Y ahora, en un par de días, una persona nos lo deja resuelto.” (E06)

En el ámbito del *contact center*, la IA generativa funciona como un asistente que disminuye significativamente las necesidades de formación y acelera la resolución de consultas, impactando positivamente en la eficiencia operativa y en la calidad del servicio al cliente:

“Nuestros operadores en el contact center [...] ahora no hay tanta necesidad de formación técnica de los productos [...] porque tienen la posibilidad de preguntar. [...] Ahora eso es mucho más ágil, la llamada es mucho más corta y el cliente obtiene una respuesta mucho antes.” (E02)

Este incremento en productividad no conduce necesariamente a una reducción de personal, sino más bien a la liberación de recursos que pueden reasignarse hacia actividades de mayor valor, como una atención más proactiva y personalizada al cliente:

“Un 30% en productividad para poder incrementar el volumen de servicio y sobre todo cosas que hoy no estamos haciendo y quizá podríamos dedicarle más tiempo a atender al cliente o atenderlo mejor.” (E09)

Influencia del tamaño y del nivel de eficiencia

Existe consenso entre los directivos sobre que el retorno de la inversión en iniciativas de inteligencia artificial depende fundamentalmente de la escala del proceso. Las aplicaciones de IA resultan rentables principalmente en procesos con elevados volúmenes y alta repetitividad, como la gestión de siniestros o la clasificación masiva de documentación. En funciones gestionadas por equipos reducidos, el impacto en los resultados es poco significativo, reduciendo el atractivo de la inversión:

“El volumen de datos es el driver [...] el que determina si vamos a necesitar herramientas o el uso de inteligencia artificial.” (E16)

Esta circunstancia obliga a las entidades más pequeñas a seleccionar sus inversiones de forma “quirúrgica”, focalizando sus recursos, que son relativamente más limitados, en proyectos muy concretos con alto potencial de impacto. Un directivo de una entidad mediana lo sintetiza de la siguiente manera:

“Yo sé que las grandes pueden abordar 100 proyectos y si fallan 50 no pasa nada, porque tienen presupuesto. Y yo, siendo consciente de mi tamaño, tengo que

definir ya solo aquellos que sí o sí puedo abordar, tanto por recursos como por presupuesto.” (E10)

Por el contrario, las grandes aseguradoras tienen capacidad para acometer inversiones a gran escala y buscan retornos absolutos significativos, descartando iniciativas cuyo impacto no sea suficientemente relevante respecto a sus abultadas magnitudes financieras:

“Les devolví todas las iniciativas que habían presentado [...] quería más potencia y quería más impacto. Que todo este circo para 2 millones de euros, me da igual.” (E15)

La concentración estratégica de recursos en pocos proyectos clave es percibida como una ventaja competitiva que permite agilidad frente a actores mayores del sector:

“Cuando tú abres un proyecto y concentras recursos en ese proyecto, va como un cohete. [...] En cambio, si tengo a la gente haciendo 50 cosas, pues avanzamos como los ejércitos de Napoleón en el invierno ruso.” (E07)

Adicionalmente, en aseguradoras que ya han alcanzado elevados niveles de optimización, el beneficio incremental derivado de implementar inteligencia artificial tiende a ser considerado como limitado por parte de los entrevistados.:

“Esta aseguradora, recorrido por productividad tiene poco, es decir, es una aseguradora que está muy optimizada.” (E08)

Esta percepción es compartida incluso por grandes grupos aseguradores, donde se reconoce que los primeros casos de uso, pese a ser rentables, no logran transformar significativamente la cuenta de resultados:

“Después de todos los ejercicios que hemos hecho [...] los primeros casos de uso nos dan un cierto margen, pero que no nos cambian la cuenta de resultados.” (E15)

En organizaciones más pequeñas, la inteligencia artificial puede aportar mejoras evidentes en eficiencia operativa, pero estas no siempre alcanzan una relevancia estratégica suficiente como para justificar inversiones importantes:

“A mí ahora me está aportando eficiencia, me está aportando rapidez [...] pero [...] no me aporta suficiente.” (E07)

En resumen, el tamaño organizativo y el nivel previo de eficiencia condicionan decisivamente la rentabilidad percibida de la inteligencia artificial en el sector asegurador. Mientras las entidades pequeñas y medianas deben ser extremadamente selectivas y concentrar sus limitados recursos en proyectos con impacto inmediato y tangible, las grandes aseguradoras disponen de capacidad para acometer múltiples iniciativas, pero exigen retornos absolutos de gran

magnitud para que un proyecto sea considerado estratégico. Por su parte, las compañías altamente optimizadas perciben rendimientos decrecientes: aun cuando los primeros casos de uso son rentables, no transforman de manera significativa la cuenta de resultados.

Estrategias prudentes de adopción tecnológica

Ante la incertidumbre tecnológica y económica, la posición predominante en la adopción de inteligencia artificial es la de prudencia. El enfoque mayoritario consiste en implementar proyectos piloto limitados y controlados que permitan validar tanto la tecnología como el caso de negocio antes de proceder a un despliegue a escala:

“Nosotros definimos tres fases. Una fase es el PoC, es decir, el PoC es ver si es tecnológicamente viable. Después pasa a piloto. [...] Tú no lo escalas hasta que no ves cuáles son los beneficios que tienes en el piloto.” (E12)

Muchas aseguradoras, especialmente las medianas, optan deliberadamente por la estrategia conocida como *fast follower* (seguidor rápido). Prefieren que otras organizaciones asuman los costes y riesgos iniciales, adoptando posteriormente las soluciones una vez demostrada su madurez tecnológica y cuando su precio se ha vuelto más asequible o razonable:

“Nos conviene ser seguidores y no los primeros.” (E04)

“La última innovación suele costar el doble de lo que costará 6 meses después. [...] Si otros están un poco por delante no me preocupa porque luego yo también sabré.” (E07)

“Estaremos atentos a estos paquetes cuando veamos que están maduros y a unos precios económicos y entonces los implantaremos.” (E08)

Esta cautela está respaldada por experiencias negativas anteriores con proyectos tecnológicos que no cumplieron las expectativas, generando una cierta aversión al riesgo de ser pioneros y una preferencia por adoptar tecnologías ya contrastadas:

“Me gusta que las cosas estén contrastadas [...] y hacer experimentos con gaseosa. [...] Al final, cuando las cosas no salen y te gastas el dinero, la gente no está contenta arriba. Tienes que ir un poco a lo seguro también.” (E1 4)

El análisis muestra que la prudencia constituye la norma en la adopción de inteligencia artificial dentro del sector asegurador español. La mayoría de las entidades implementan un proceso secuencial de prueba de concepto (PoC), piloto y eventual escalado, lo que permite minimizar riesgos financieros y tecnológicos antes de comprometer recursos significativos. Este enfoque se complementa con la estrategia *fast follower*, especialmente extendida entre las aseguradoras de

tamaño medio, que prefieren esperar a que la tecnología madure y sus costes se reduzcan antes de adoptarla.

La cautela se encuentra reforzada por experiencias pasadas con proyectos tecnológicos fallidos, que han generado una aversión institucional al riesgo de ser pioneros. En este sentido, la preferencia por soluciones ya contrastadas refleja tanto la naturaleza conservadora del negocio asegurador como la necesidad de asegurar un retorno claro y previsible.

Costes ocultos, dependencia tecnológica y riesgos éticos

La evaluación del retorno de la inversión considera también los costes ocultos y riesgos potenciales, que pueden reducir significativamente o incluso eliminar los beneficios esperados.

Entre los condicionantes fundamentales más mencionados destaca la calidad del dato. Los entrevistados enfatizan que disponer de datos bien gobernados, accesibles y fiables es un requisito indispensable, sin el cual cualquier iniciativa de inteligencia artificial está destinada al fracaso:

“Con este enfoque integral que es la inteligencia artificial, con un dato malo no sirve para nada.” (E05)

En cuanto a costes, el coste recurrente más mencionado por los directivos es el asociado con la adquisición de licencias y la dependencia respecto a grandes proveedores tecnológicos, cuyos modelos de suscripción pueden derivar en compromisos económicos indefinidos, sujetos a incrementos no anticipables que afectan negativamente al retorno del proyecto:

“Cuando veo lo que me cuesta todos los años las [...] licencias, digo, esto es una renta vitalicia porque ya no te puedes salir. Y ahora te piden 400, pero hace dos años me pedían 200, ahora ya vamos por 400. [...] Hay cierto miedo a [...] que me meto en esto sabiendo que a partir de ahora me va a optimizar. ¿Pero cuáles son los costes que tengo con esta automatización?” (E14)

Asimismo, se mencionan riesgos éticos, especialmente relacionados con la posibilidad de que una hipersegmentación derivada del uso de inteligencia artificial pueda afectar negativamente al principio mutualista tradicional del seguro:

“Si le metemos una capa de inteligencia artificial que incrementa esas capacidades, al final estamos desnaturalizando el seguro, porque a cada uno le vamos a cobrar por el riesgo que tiene y usted está perdiendo la parte de [...] el concepto mutualista.” (E02)

Este riesgo es particularmente señalado por las entidades mutualistas y constituye una inquietud que influye en la adopción y aplicación de analítica avanzada en la tarificación:

“El principio desmutualización es absoluto. Llevan al riesgo individualizado [...] El principio mutual se lo cargan. Nosotros seguimos manteniendo el sistema [...] el principio mutual lo seguimos manteniendo.” (E16)

4.1.1.3. Rentabilidad tangible e intangible

El análisis de las entrevistas revela que, más allá del retorno económico inmediato, los directivos perciben que la IA aporta retornos que van más allá de la lógica económica.

Esta sección amplía y complementa esta perspectiva inicial sobre retorno de la inversión mediante el análisis de los fragmentos codificados bajo el subcódigo “8.4. Rentabilidad tangible e intangible”, el tercero más destacado dentro del código principal “8. Coste-beneficio y ROI”, que acumula un total de 33 referencias procedentes de 11 entrevistados. Los directivos reconocen el rol de la inteligencia artificial como una palanca que, más allá de sus impactos inmediatos y tangibles, puede impulsar una transformación estratégica y cultural profunda y significativa en el sector asegurador español.

Atendiendo al discurso de los directivos, la rentabilidad intangible de la IA se materializa en cinco aspectos: capital humano, capacidades relacionales, estructura operativa, capacidad de innovación y aprendizaje, y reputación.

La Tabla 14 sintetiza estas dimensiones junto con su justificación y el grado de consenso obtenido en las entrevistas, mientras que la Figura 9 muestra la distribución de referencias y entrevistas asociadas a cada una de ellas, reflejando visualmente su peso relativo en el discurso de los entrevistados.


Tabla 14: Dimensiones de la rentabilidad intangible de la IA

Dimensión	Justificación de la Rentabilidad	Grado de Consenso (N.º referencias / N.º entrevistas)
Capacidad de innovación y aprendizaje	La IA se percibe como una inversión estratégica en aprendizaje y experimentación, clave para mantener la inercia tecnológica y evitar el coste de la inacción.	10 referencias / 6 entrevistas
Capital humano	La eficiencia generada por la IA se valora como palanca intangible: libera tiempo para tareas de mayor valor, acelera el aprendizaje y reduce la ansiedad tecnológica del personal.	7 referencias / 5 entrevistas
Capacidades relacionales	El vínculo humano con agentes y clientes se considera insustituible; la IA lo complementa mediante omnicanalidad y segmentación inteligente que refuerza la confianza.	6 referencias / 4 entrevistas

Dimensión	Justificación de la Rentabilidad	Grado de Consenso (N.º referencias / N.º entrevistas)
Estructura operativa	La implementación de IA impulsa mejoras en la calidad y gobierno de datos y promueve la adopción de metodologías ágiles y proyectos transversales.	6 referencias / 3 entrevistas
Reputación	La adopción de IA proyecta una imagen de modernidad, fortalece la legitimidad corporativa y aumenta la capacidad de atraer talento tecnológico.	4 referencias / 3 entrevistas

Fuente: Elaboración propia

Figura 9: Distribución de referencias y entrevistas por dimensiones de la rentabilidad intangible de la IA



Fuente: Elaboración propia

a) Capacidad de innovación y aprendizaje

El retorno intangible más significativo a largo plazo, según la opinión de los entrevistados, es la mejora de la capacidad de innovación y aprendizaje de las entidades. Las aseguradoras invierten estratégicamente en proyectos exploratorios de IA, creando así un portafolio de experimentación que incrementa la capacidad de absorción tecnológica de la organización. Esta decisión consciente, que busca evitar el alto coste de la inacción tecnológica, queda reflejada en palabras de este directivo:

“...estoy bastante convencido de que es algo en lo que tenemos que estar y que seguramente con cierto “hype” y esto yo lo comparto, pero no quiere decir que no tengamos que estar.” (E03)

Directivos de empresas más pequeñas comparten esta perspectiva, conscientes de que frenar iniciativas en este ámbito podría suponer la pérdida de la inercia necesaria para abordar el futuro tecnológico:

“Si ahora desconectamos, sí que pierdo la inercia que estoy cogiendo ahora para abordarlo.” (E10)

Mediante la transparencia en la comunicación sobre los cambios tecnológicos se fortalece la confianza interna, facilitando la difusión de innovaciones y minimizando resistencias:

“La gente no tiene miedo a la tecnología porque ha visto que no les ha afectado para mal.” (E13)

b) Capital humano

El capital humano emerge como uno de los principales beneficiarios de la adopción de inteligencia artificial. Si bien algunos directivos subrayan la mejora de la eficiencia operativa en términos cuantificables —como la posibilidad de gestionar un mayor volumen de trabajo con los mismos recursos—, la mayoría destacan que el verdadero valor no reside únicamente en el ahorro de costes, sino en la liberación de tiempo para tareas de mayor calidad y orientación al cliente. Como señaló un entrevistado:

“vamos a ganar un 30% de eficiencia, vamos a poder dedicar más tiempo a lo que aporte valor hacia el cliente y vamos a poder asumir un poco más de volumen con el mismo equipo” (E09).

Desde esta perspectiva, la eficiencia se interpreta como un activo intangible, vinculado a la mejora del capital humano más que a la reducción de *headcount*. Los directivos apuntan que la IA permite incrementar la motivación, disminuir la carga de tareas rutinarias y habilitar un uso más estratégico de las capacidades de los equipos. En este sentido, la introducción de herramientas generativas —frecuentemente conceptualizadas bajo la metáfora del *copilot*— se percibe como un acelerador de la curva de aprendizaje, que ayuda a desarrollar nuevas competencias y reduce la ansiedad tecnológica entre los empleados, facilitando así su adopción.

c) Capacidades relacionales

Las aseguradoras destacan también la relevancia estratégica del capital relacional. Este activo intangible es reconocido explícitamente por los directivos

entrevistados, quienes subrayan que la relación humana no puede ser plenamente sustituida por la tecnología:

“...me ahorro estas 20 personas, ya te digo, medio millón de euros más, pero todo lo que es creación de vínculo, todo esto no me lo dará la máquina. Y al final los directores de suscripción son gente de referencia para los agentes.” (E08)

En este sentido, las compañías con redes agenciales sólidas apuestan por modelos omnicanal, preservando las opciones de contacto presencial y telefónico para evitar la erosión del vínculo con sus redes comerciales. Este planteamiento queda claramente reflejado en la siguiente afirmación:

“Nosotros no hemos cerrado [canales]... Aquí no se cierra nada. Aquí la gente que quiere un delegado se va a ver al delegado. El que quiera llamar al call center, el call center y el que quiere la app se va a la app.” (E05)

Adicionalmente, la segmentación inteligente facilitada por la IA aumenta la pertinencia y precisión de las recomendaciones, fortaleciendo así la confianza y fidelidad del cliente hacia la entidad.

d) Estructura operativa

La estructura operativa también puede verse beneficiada. Los requerimientos técnicos de la IA impulsan una mejora sustancial en la calidad, limpieza y gobierno de los datos, sentando “los cimientos”, que no son otros que “bases de datos potentes” (E05). La implementación de estas tecnologías, además, institucionaliza la adopción generalizada de metodologías ágiles para gestionar proyectos de transformación (E13).

e) Reputación

Finalmente, los directivos también apuntan a un impacto reputacional positivo significativo relacionado con la adopción de IA. Esta tecnología genera una imagen de modernidad que un directivo califica como “brutal” (E12). Esta mejora en la reputación aumenta las capacidades de atracción de talento tecnológico.

4.1.1.4. Medición del retorno

Respecto a los indicadores empleados para medir el retorno de la inversión (ROI) en proyectos de IA, el análisis destaca, en primer lugar, el ahorro en costes operativos, en la forma de una reducción directa en euros o en personal dedicado (FTE). Este enfoque es particularmente relevante en proyectos de IA Predictiva orientados a la automatización de procesos. Un directivo proporciona una estimación ilustrativa al afirmar:

“Bien, pues esta productividad a mí me podría dar una mejora en mi cuenta de resultados de 1 millón de euros si hago unos cálculos, diríamos, a trazo grueso, sencillos. No es para no dormir. No sé si me entiendes. No es para coger y llamar

aquí a Accenture y decir oiga, comience a hacer todos los casos de uso porque igual me estoy perdiendo algo y mi empresa deje de ser competitiva.” (E08)

Estrechamente ligado con el ahorro de costes, se encuentra el importante incremento de la productividad en áreas caracterizadas por procesos repetitivos:

“...cuando escuchas un poquito los gurús te hablan que los departamentos administrativos pues igual te puede dar una productividad de un 25%, un 30% o un 40 %.” (E08)

Esta percepción sobre el potencial de la IA es compartida incluso por entidades que aún no han culminado su implementación completa:

“No hemos llegado ahí, pero yo creo que la productividad se puede incrementar más de un 30 % tranquilamente.” (E09)

Asimismo, la IA Predictiva contribuye a generar ingresos adicionales mediante una mayor retención de clientes y una tarificación más precisa. Como explica un directivo, la mejora en la suscripción de riesgos permite obtener ventajas competitivas:

“...yo creo que está más en si la inteligencia artificial te permite tener unas primas más adecuadas al riesgo que suscribes, ¿me entiendes? Y aquello te da unos unas ventajas de punto en tasas que no en reducción de gastos.” (E08)

Otro directivo recalca que los retornos no solo provienen de la eficiencia, sino también del crecimiento del negocio:

“Y el retorno económico puede ser de más ingresos. Por ejemplo, una mayor retención de pólizas es más ingresos para la compañía y una, por ejemplo, entre otras medidas que hacemos, es una reducción del tiempo de atención a los clientes en las llamadas de teléfono. Eso es, genera menos costes.” (E11)

La detección del fraude emerge claramente como uno de los casos de uso paradigmáticos donde el retorno de la IA Predictiva es particularmente tangible:

“Un ámbito evidente, ¿vale? para uso de tecnología, de inteligencia artificial, que nos ha ido y nos está yendo muy bien, es en identificación de fraude. Y eso es, vamos, lo ves económicamente, lo ves económicamente con datos.” (E02)

Además de estos indicadores específicos, el análisis también evidencia el uso frecuente de métricas financieras clásicas, como el Pay-back o la Tasa Interna de Retorno (TIR), empleadas para evaluar si los beneficios generados por la IA justifican la inversión inicial realizada:

“utilizamos métricas tradicionales. Las métricas tradicionales de, digamos, las mismas, el mismo KPI que podrías estar utilizando con cualquier otro tipo de... de aplicación... de aplicación de la tecnología si quieres o de aplicación de la forma de pensar, de la forma de pensar.” (E01)

El requisito de un período de recuperación razonable puede condicionar significativamente las decisiones de inversión, particularmente cuando el éxito es incierto:

“...no me voy a gastar yo 7 millones de euros para desarrollar un paquete que no sé si será, si triunfará, si no triunfará, ¿de acuerdo? ¿Cuándo es que lo amortizaré? Como mínimo en siete años, porque si me gasto 7 millones...” (E01)

Las compañías más maduras en la adopción tienden a desarrollar cuadros de mando unificados que consolidan datos sobre inversiones y retornos, ofreciendo así una visión integrada del impacto global de la IA:

“...hemos montado un BI de inteligencia artificial. Entonces distinguimos cada mes los retornos, las inversiones y según en qué lo estás haciendo, ¿lo estoy haciendo en la relación, en mejorar la relación con el cliente... o lo estoy haciendo para ganar productividad?” (E05)

El presupuesto asignado a IA, como porcentaje del gasto total en tecnologías de la información (TI), también se utiliza como indicador del compromiso estratégico hacia esta tecnología:

“...se invierte en general en analítica, comparado con el presupuesto total, y aproximadamente eso está en una banda entre el cuatro y el seis por ciento en algunos de los tramos para gente que ya se lo toma un poco en serio.” (E05)

Finalmente, la escalabilidad y el efecto acumulativo también se apuntan como indicadores clave del valor estratégico a largo plazo.:

“...esto es acumulativo. O sea, si aprendes a mejorar el fraude ahora ya lo has aprendido para el siguiente, entonces ya el año que viene ya lo haces mejor. Y si el año que viene lo haces todavía un poco mejor, pues lo haces, el siguiente lo haces dos veces mejor.” (E11)

4.1.1.5. Selección y Priorización de Casos de Uso de IA

La selección y priorización de casos de uso de Inteligencia Artificial en las aseguradoras depende principalmente de tres factores estratégicos: el impacto económico potencial, las capacidades internas disponibles y el modelo de negocio.

El impacto económico potencial es el filtro principal para abordar proyectos de IA. Como se ha visto anteriormente, las aseguradoras buscan maximizar el retorno de cada euro invertido, estableciendo un orden de prelación para abordarlos.

Una vez superado este filtro, el tamaño y la cultura organizativa influyen considerablemente en la priorización de inversiones en este ámbito. Las aseguradoras grandes, con alta demanda interna, utilizan metodologías

estructuradas para identificar y gestionar ideas y asegurar su alineación estratégica:

“Entonces hemos hecho una metodología de unificar y hemos hecho otra metodología de seleccionar, porque aquí hay ideas para el fin del mundo. Entonces lo que hemos puesto es una metodología que en función de determinados parámetros te dice oye, deberías de priorizar este caso de uso.”
(E05)

Por otro lado, entidades más pequeñas o con culturas tradicionales confían en la intuición y el conocimiento profundo del negocio acumulado por sus directivos, para identificar áreas de impacto:

“Y claro, cuando además tienes el conocimiento y conoces negocio, ves enseguida dónde tiene más aplicación, dónde menos. [...] claro, es un poco de trampa porque nos ayudamos en nuestra trayectoria [tecnológica].” (E08)

Además del impacto económico, la calidad de los datos se identifica unánimemente como condición indispensable, especialmente para los modelos predictivos. Sin datos confiables, las iniciativas son descartadas independientemente de su atractivo económico:

“¿Qué es lo que limita muchas veces la inteligencia artificial? Con este enfoque integral que es la inteligencia artificial, con un dato malo no sirve para nada.”
(E05)

Además, aunque la mayoría prioriza iniciativas con un ROI inmediato, algunas aseguradoras aprueban inversiones en pruebas de concepto (PoC) orientadas al aprendizaje y exploración tecnológica, particularmente con tecnologías emergentes como la IA generativa:

“Oye, vamos a probar. No nos vamos a volver locos. Vamos a buscar una prueba controlada. [...] El objetivo es aprender. Si el objetivo es aprender, no el retorno económico. Si nos planteamos hacer una carrera concepto y tiene que haber retorno económico o no, dejamos claro cuál es el objetivo antes de empezarla. [...] Es muy importante tener claro cuál es el objetivo. Si el objetivo es aprender, es aprender. Punto. No hay más.” (E09)

La estrategia de negocio y el contexto regulatorio influyen directamente en la priorización específica de proyectos. Especialmente las aseguradoras de seguros generales con grandes bases de clientes minoristas priorizan iniciativas centradas en las primeras etapas del embudo de ventas:

“Estamos trabajando sobre todo en la parte de recomendaciones de productos y en las fases iniciales del funnel de marketing.” (E04)

En cambio, las aseguradoras especializadas en salud o vida priorizan casos relacionados con pricing y underwriting, buscando precisión actuarial:

“El siguiente va a ser técnico. Con todo lo que es el análisis de todo lo que es reaseguros, siniestralidad, tarificación, etcétera. Lo vamos a implementar en técnico.” (E10)

“Básicamente hay dos [casos de uso]. Uno es la propia contratación en el propio proceso de suscripción. [...] Un análisis prospectivo en base a un modelo de riesgo basado en costes medios y frecuencias de los últimos diez años.” (E16)

Por último, el cumplimiento ético y normativo opera como una barrera fundamental. Responsabilidad y seguridad son principios básicos que eliminan cualquier iniciativa que contradiga el marco regulatorio:

“Lo que nosotros buscamos es no [...] lanzar la inteligencia artificial porque sí, [...] sino buscando impacto económico y mejoras en la experiencia del cliente, pero luego también de una manera responsable y segura. [...] En el reglamento hay una serie de temas que están claramente prohibidos y cuando nos hemos leído hemos dicho lógico que estén prohibidos.” (E11).

4.1.2. Talento y Cultura


La totalidad de los entrevistados identifica el factor Talento y Cultura como relevante en la adopción de la IA (296 referencias codificadas en las 16 entrevistas).

Los testimonios recabados muestran que el éxito de la transformación tecnológica no depende únicamente de disponer de algoritmos avanzados o infraestructuras de datos robustas, sino de la capacidad de las organizaciones para atraer, formar y retener talento especializado, gestionar la resistencia cultural al cambio y consolidar un clima organizativo que fomente la innovación.

Para comprender cómo los factores humanos y culturales condicionan la adopción de la IA en las aseguradoras españolas, la sección se estructura en siete subcategorías principales: brecha de capacidades, atracción y retención de talento especializado, formación interna y upskilling, cultura organizativa y resistencia al cambio, clima y sentido de pertenencia, y cultura de innovación vivida. Cada uno de estos apartados aporta una perspectiva complementaria sobre los desafíos y palancas que configuran el papel decisivo del talento y la cultura en el despliegue de la inteligencia artificial.

la Figura 10 muestra el número de entrevistas y de referencias codificadas en cada dimensión.

Figura 10: Distribución de entrevistas y referencias por subcategorías de talento y cultura



Fuente: Elaboración propia

4.1.2.1. Brecha de capacidades

Este bloque aborda las brechas estructurales de capacidades que condicionan la adopción de la inteligencia artificial en el sector asegurador. La siguiente tabla

(tabla 15) sintetiza las brechas de capacidades identificadas en las entrevistas, agrupadas en tres grandes dimensiones (talento, cultura/organización y estrategia). Para cada subcategoría se incluyen las citas más representativas, así como el número de referencias y entrevistas en las que emergió el tema, lo que permite visualizar tanto la intensidad del discurso como su grado de consenso entre los directivos.

Tabla 15: Brechas de talento, culturales y estratégicas

Dimensión	Subcategoría	Cita representativa	Nº referencias	Nº entrevistas
Brechas de talento	Perfiles híbridos	“Si no entrenas estos algoritmos en función de tu entidad, solo tienes un ‘bicho’ genérico” (E04)	9	6
	Nuevos roles	“Normalmente busco un actuario, pero ahora no sabía qué tenía que buscar” (E10)	3	2
	Curva de aprendizaje y retención	“Tenerlos el tiempo suficiente como para que la curva de aprendizaje se amortice” (E09)	4	3
	Talento especializado en IA avanzada	“No los tenemos, no hay talento de eso aún” (E05)	6	3
	Masa crítica / tamaño de equipos	“Sí que tenemos un área en concreto de analítica de datos, donde tenemos a 20 personas” (E02)	5	3
	Output educativo insuficiente	“Hay un gap entre lo que la empresa pide y lo que produce la universidad con la formación” (E15)	3	2
Brechas culturales / organizativas	Resistencia cultural y upskilling	“¿Tienes gente preparada en tu organización para adoptar esta tecnología? La respuesta es no” (E12)	7	4
	Dependencia de consultoría externa	“Llamas a Indra, venga, te queda un proyecto, un millón de euros que a lo mejor no llega a nada” (E14)	8	5

Dimensión	Subcategoría	Cita representativa	Nº referencias	Nº entrevistas
	Liderazgo distribuido insuficiente	“Nos falta algún componente mental disruptivo dentro de la organización. No puede ser que uno de los más disruptivos sea el director general” (E07)	2	2
	Gobernanza del dato	“Necesitas tener unos foundations en data súper potentes. Si no, no vas a ser capaz de escalar” (E12)	3	2
	Generacional / coexistencia de culturas	“Ha habido una cierta desconfianza en una entidad muy tradicional [...] y de repente aparece ese [externo]” (E16)	2	2
	Alineamiento negocio-tecnología	“El reto es conformar un equipo multidisciplinar donde puedas aprovechar el talento que tenemos en todo el mundo” (E05)	2	2
	Incentivos y reconocimiento	“Estamos trabajando mucho en que esa gente se sienta reconocida” (E05)	2	2
Brechas estratégicas	Velocidad tecnológica vs. adaptación cultural	“La tecnología avanza muy rápidamente y [...] como seres humanos tienes tu proceso de adaptación” (E12)	4	3
	Autonomía estratégica frente a proveedores	“Al final esto se basa todo en consultores, que esa es la jodienda. [...] Nos estamos acostumbrando a ceder absolutamente todo a consultoría externa” (E14)	5	3

Fuente: Elaboración propia

El número total de referencias recogidas en la tabla (65) supera el total absoluto de citas codificadas en esta categoría (58). Esta diferencia se explica porque una misma cita puede haberse codificado en más de una subcategoría cuando abordaba simultáneamente aspectos distintos. Por ejemplo, un directivo que menciona la falta de *upskilling* interno y, a la vez, la resistencia de los empleados al cambio aparece contabilizado tanto en *resistencia cultural* como en *upskilling*. Este

solapamiento es deliberado: refleja la naturaleza transversal de las narrativas directivas, en las que los límites entre talento, cultura y estrategia resultan difusos. Por ello, el recuento no debe interpretarse como sumatorio lineal, sino como una medida relativa de la densidad y diversidad de menciones en torno a cada brecha.

a) Brechas de talento

La carencia de profesionales adecuados se confirma como uno de los principales frenos a la adopción de la inteligencia artificial. Más allá de la escasez numérica, destacan carencias estructurales como la falta de perfiles híbridos, el tamaño reducido de los equipos y la indefinición de roles emergentes. Estas limitaciones explican por qué la atracción y retención de talento se ha convertido en un reto estratégico, cuestión que se desarrolla en el apartado siguiente.

i. Falta de perfiles híbridos

Los directivos subrayan la necesidad de contar con profesionales que combinen el conocimiento del negocio asegurador (actuarial, siniestros, suscripción) con competencias digitales y analíticas. Sin esta conexión, los proyectos de IA corren el riesgo de quedarse en ejercicios técnicos desconectados de la realidad operativa:

“Hay un poco de confusión pensando que esta transformación la hacen los especialistas en inteligencia artificial o lo hacen los especialistas en datos, o lo hace el área de informática o el área de procesos” (E15).

“Esta es una transformación y un cambio que tiene que nacer de la gente que está en el negocio, que entiende los procesos de seguro y que, con la ayuda tecnológica, es capaz de pensarlos a través de la tecnología” (E15).

Incluso en compañías con equipos técnicos competentes, la falta de integración con el negocio se percibe como un freno clave. Un directivo reconocía que en su equipo solo “dos o tres personas conocen muy bien el negocio”, lo que reduce el impacto de los modelos. Otro lo expresaba en términos más gráficos:

“Si no entrenas estos algoritmos en función de tu entidad, solo tienes un ‘bicho’ genérico” (E04).

ii. Nuevos roles emergentes

La novedad de la IA dificulta la identificación de los perfiles que realmente se necesitan. A diferencia de posiciones clásicas como actuario o suscriptor, no existen estándares consolidados para funciones emergentes como *prompt engineer* o *MLOps specialist*. Esto retrasa los procesos de selección y genera incertidumbre en la conformación de equipos:

“Para mí era muy difícil saber qué perfil incorporar, ya no solo es buscarlo, sino definirlo. [...] Normalmente busco un actuario, pero ahora no sabía qué tenía que buscar” (E10).

Otro directivo apuntaba la misma dificultad:

“hemos tardado muchísimo en definirlo [...] primero era muy difícil saber qué perfil incorporar, ya no solo es buscarlo, sino definirlo” (E13).

iii. Curva de aprendizaje y retención

El desarrollo de capacidades internas se enfrenta a un dilema temporal: formar perfiles requiere una inversión prolongada, pero la rotación de profesionales amenaza con impedir que esa curva de aprendizaje se amortice. Un directivo lo resumía así: “Tenerlos el tiempo suficiente como para que la curva de aprendizaje se amortice” (E09). La “pelea constante por el talento” (E11) refuerza la percepción de vulnerabilidad, donde incluso los perfiles formados pueden ser captados por sectores más atractivos antes de consolidar su contribución.

iv. Talento especializado en IA avanzada

Más allá de los analistas y *data scientists* ya existentes, varios directivos reconocen que no disponen aún de perfiles punteros en IA generativa o en tecnologías de vanguardia como *MLOps*:

“Que además el problema que tenemos es que no los tenemos, no hay talento de eso aún” (E03).

Del mismo modo, se señala que muchos equipos externos carecen de experiencia real en estas áreas:

“Nos hemos encontrado con que los equipos que nos ayudan no tienen mucha experiencia en el tema, porque básicamente se trata de elementos externos” (E04).

v. Masa crítica / tamaño de equipos

La posibilidad de consolidar equipos de datos de gran escala es desigual. Algunas aseguradoras disponen de unidades de 20 o más personas dedicadas exclusivamente a analítica, mientras que otras se ven limitadas por su tamaño:

“Sí que tenemos un área en concreto de analítica de datos, donde tenemos a 20 personas. Entonces estas 20 personas están durante todo el año haciendo proyectos concretos de mejora” (E02).

En contraste, directivos de compañías medianas reconocen que carecen de músculo suficiente:

“No somos una entidad eminentemente con gran tamaño, con un área tecnológica o de sistemas muy experimentada” (E16).

vi. Output educativo insuficiente

Varios entrevistados identifican un desajuste estructural entre la oferta formativa y las necesidades del mercado:

“Hay un gap entre lo que la empresa pide y lo que produce la universidad con la formación” (E15).

Otro lo resume en términos de velocidad:

“La demanda del mercado en estos últimos años ha sido muy superior a lo que han podido producir las universidades o escuelas tecnológicas” (E02).

b) Brechas culturales y organizativas

Más allá de la disponibilidad de perfiles, la cultura corporativa aparece como un factor decisivo en la velocidad de adopción. La resistencia al cambio, la dependencia de terceros, la gobernanza de los datos y la falta de liderazgo

distribuido dificultan que la IA trascienda el piloto para convertirse en práctica consolidada.

i. Resistencia cultural y necesidad de upskilling

Los entrevistados coinciden en que la mayoría de las plantillas no cuentan con un conocimiento básico de IA. Esto genera miedo, indiferencia o incapacidad para identificar oportunidades:

“¿Tienes gente preparada en tu organización para adoptar esta tecnología? La respuesta es no” (E12).

La falta de preparación se extiende también a mediadores y áreas comerciales, lo que obliga a un esfuerzo de gestión del cambio a gran escala:

“Yo al menos sí que tengo una urgencia de que toda la organización entre a comprender dónde podemos tener oportunidades de mejora a través de esta nueva tecnología” (E03).

ii. Dependencia de la consultoría externa vs. autonomía interna

Ante la falta de capacidades internas, muchas aseguradoras recurren a consultoras para ejecutar proyectos. Si bien esta solución permite ganar velocidad, también genera dependencia y dificulta la internalización del conocimiento crítico:

“El conocimiento es poder. Si queremos estar, tenemos que entender nosotros” (E13).

La externalización se percibe además como costosa y con resultados inciertos:

“Llamas a Indra, venga, te queda un proyecto, un millón de euros que a lo mejor no llega a nada” (E14).

iii. Liderazgo distribuido insuficiente

La transformación digital no puede depender solo de la visión de la alta dirección o de un reducido grupo de expertos. Para que la adopción sea sostenible, se requiere liderazgo distribuido y *champions* en distintos niveles de la organización:

“Nos falta algún componente mental disruptivo dentro de la organización. No puede ser que uno de los más disruptivos sea el director general. No es bueno” (E07).

iv. Gobernanza del dato

La gobernanza del dato aparece como requisito básico para escalar la IA. Sin *foundations* sólidas en datos, los proyectos carecen de legitimidad interna y no trascienden de las pruebas aisladas:

“Porque para poder hacer eso tú tienes que tener un sistema de datos, esta es otra, es decir, necesitas capacidades de las personas, pero necesitas tener unos foundations en data súper potentes. Si no, no vas a ser capaz de escalar” (E12).

v. Coexistencia de culturas y generaciones

En entidades con plantillas de elevada antigüedad media, la coexistencia de microculturas genera tensiones en la incorporación de nuevos perfiles digitales. Como señalaba un directivo:

“Ha habido una cierta desconfianza en una entidad muy tradicional, muy hecha a sí misma, donde la media de antigüedad es de 20 años y de repente aparece ese [externo] sin ninguna experiencia en la entidad. Entonces no es sencillo ganarte la confianza de la gente” (E16).

vi. Alineamiento negocio-tecnología

La falta de integración entre equipos técnicos y áreas de negocio también se menciona como un freno. “El reto es conformar un equipo multidisciplinar donde puedas aprovechar el talento que tenemos en todo el mundo” (E05).

vii. Incentivos y reconocimiento

El reconocimiento y la visibilización del impacto de los proyectos es otra brecha cultural. Un directivo enfatizaba que los equipos necesitan sentir que su contribución es valorada:

“Estamos trabajando mucho en que esa gente se sienta reconocida. [...] Dentro de que siempre es un inicio, pero lo estamos tratando de manejar un poco de esa manera” (E05).

c) Brechas estratégicas

Finalmente, emergen tensiones de carácter estratégico que condicionan la capacidad de las aseguradoras para sostener la transformación.

i. Velocidad tecnológica vs. capacidad cultural de adaptación

La IA avanza a un ritmo muy superior al de la adaptación humana y organizativa:

“La tecnología avanza muy rápidamente y [...] como seres humanos tienes tu proceso de adaptación” (E12).

ii. Autonomía estratégica frente a proveedores

Varios directivos advierten del riesgo de dependencia respecto a proveedores tecnológicos globales, que puede limitar la autonomía de las aseguradoras:

“Lo que tenemos que hacer es demostrar porque estamos más cerca de la tecnología [...] pero tenemos que demostrar las cosas que se pueden hacer y cuando lo han visto [...] han salido 50 iniciativas más pegadas a negocio” (E11).

Otros lo expresan en términos de vulnerabilidad:

“Al final esto se basa todo en consultores, que esa es la jodienda. [...] Nos estamos acostumbrando a ceder absolutamente todo a consultoría externa para todo. Y eso es bueno por una parte y malo por otra, porque te pones en manos de los externos” (E14).

4.1.2.2. Atracción y Retención de Talento Especializado

Las brechas de capacidades identificadas en el apartado anterior reflejan la dificultad de las entidades para contar con el talento que necesitan. La falta de perfiles híbridos, el reducido tamaño de algunos equipos o la dependencia de proveedores externos forman parte del trasfondo que explica por qué atraer y retener profesionales especializados se ha convertido en un reto estratégico para el sector.

En este apartado se analizan las estrategias desplegadas por las aseguradoras para captar y fidelizar a estos perfiles en un mercado altamente competitivo.

La evidencia empírica recogida en las entrevistas permite clasificar los desafíos de atracción y retención de talento en torno a cinco grandes apartados: escasez de talento, tensión salarial, estrategias de atracción y retención no monetarias, percepción sectorial e implicaciones organizativas y estratégicas. La siguiente tabla (tabla 16) y el gráfico (figura 11) resumen el grado de consenso observado en cada dimensión, considerando tanto el número de referencias codificadas como el número de entrevistas en las que emergió el tema.

Tabla 16: Desafíos de talento en la adopción de IA

Apartado	Criterios de codificación (señales en las citas)	Grado de consenso (N.º referencias / N.º entrevistas)
Implicaciones organizativas y estratégicas	Flexibilidad/teletrabajo/presencialidad; liderazgo y cohesión (“pegamento” organizacional); internalizar vs. proveedor; centros de IA; secuenciación por capacidades; cambio cultural.	32 / 12
Escasez de talento	Dificultad para encontrar/definir perfiles; “no hay talento”; brecha formativa; equipos externos sin experiencia; necesidad de “persona adecuada”.	14 / 11
Estrategias de atracción y retención	<i>Upskilling</i> / “cantera”; planes de carrera; movilidad interna; proyectos retadores y medición de impacto; equipos multidisciplinares; reconocimiento y orgullo de contribución.	18 / 9
Tensión salarial	Bandas retributivas tensionadas; excepciones; competencia pagando el doble/triple ; necesidad de	5 / 4

Apartado	Criterios de codificación (señales en las citas)	Grado de consenso (N.º referencias / N.º entrevistas)
	acelerar progresión; dinero + flexibilidad como condición de entrada.	
Percepción sectorial	Atractivo/“glamour” del seguro frente a banca de inversión, <i>Big Tech</i> y consultoras; menor presencia en <i>open days</i> ; rotación digital asociada a menor atractivo sectorial.	2 / 1

Fuente: Elaboración propia

Figura 11: Distribución de entrevistas y referencias en los principales desafíos de talento en IA



Fuente: Elaboración propia

El total de referencias recogidas en la tabla (71) no coincide con el volumen global de citas codificadas en esta categoría (52), ya que varias referencias fueron codificadas simultáneamente en más de un apartado (por ejemplo, una misma cita que hace alusión a la escasez de talento y, a la vez, a las tensiones salariales). Este solapamiento es deliberado y refleja la naturaleza interdependiente de los factores analizados, donde los límites entre escasez, tensiones retributivas, estrategias de retención y diseño organizativo son difusos en el discurso directivo.

El gráfico muestra, además, que las dimensiones con mayor consenso entre los entrevistados son las implicaciones organizativas y estratégicas (12 entrevistas, 32 referencias) y la escasez de talento (11 entrevistas, 14 referencias), seguidas de las

estrategias de atracción y retención (9 entrevistas, 18 referencias). En contraste, la tensión salarial aparece en 4 entrevistas con 5 referencias, y la percepción sectorial en una sola entrevista con 2 referencias, lo que indica que este último aspecto, si bien relevante, se encuentra menos extendido en el conjunto de compañías.

a) Escasez de talento

El primer hallazgo clave que emerge de las entrevistas es la percepción generalizada de una escasez estructural de perfiles especializados en datos y en IA, con especial énfasis en la IA generativa. Los directivos coinciden en señalar la dificultad para identificar y contratar profesionales con la experiencia requerida:

“Pues, por desgracia, uno de los problemas que encontramos es la falta de conocimiento, talento específico y experiencia en este tema, tanto en Cataluña como en España. [...] El problema es que quienes realmente conocen esta tecnología están en San Francisco, donde están muy bien remunerados. Aquí, en cambio, falta conocimiento.” [E04]

Esta situación configura un escenario de alta competencia por el talento, descrito por un entrevistado como una “muchísima pelea por el talento” en la que “no es nada fácil contratar a gente. Y no es nada fácil retenerlos” [E11].

b) Tensión salarial

Como consecuencia de esta escasez, los entrevistados destacan una tensión creciente entre las bandas salariales tradicionales y las pretensiones que marcan las dinámicas del mercado global de talento. Las aseguradoras se enfrentan así al dilema de ofrecer condiciones competitivas para atraer a estos perfiles sin poner en riesgo la coherencia y equidad interna de sus estructuras retributivas. En algunos casos, se aplican medidas excepcionales, aunque con cautela:

“Oye, tú tienes tus... tus bandas salariales, y de tal. O sea, para captar a determinado perfil se pueden hacer excepciones a las políticas. Pero procuramos tampoco volvernos demasiado locos.” [E02]

Algunos directivos apuntan que los dos factores determinantes en la atracción de estos perfiles son la remuneración y la flexibilidad en los modelos de trabajo:

“Hay perfiles que necesitamos. Que requerimos. Son escasos. Y atraerlos pasa por. Pasa. Primero por dinero. Porque, además, yo creo que una vez más, estamos engrosando su ego de una manera artificial. [...] Y también por una flexibilidad en el trabajo.” [E12]

Este hallazgo revela que la tensión salarial no constituye únicamente un ajuste coyuntural, sino un factor estratégico con implicaciones organizativas profundas. La “guerra por el talento” obliga a las aseguradoras a replantear sus políticas de

recursos humanos, equilibrando incentivos económicos con modelos laborales más flexibles y atractivos. Además, expone una brecha respecto a otros sectores más disruptivos —como el tecnológico o el financiero— que, al ofrecer condiciones salariales más competitivas y proyectos con mayor visibilidad estratégica, ejercen un efecto de atracción sobre los profesionales más cualificados.

c) Estrategias de Atracción y Retención

Frente a un mercado salarial inflacionado, las entidades exploran vías de atracción y retención complementarias a las monetarias. Una idea expresada recurrentemente por los directivos es que, para estos perfiles de alta capacitación, el estímulo (motivación intrínseca) y el propósito del trabajo (motivación trascendente) son factores tan decisivos de fidelización como la retribución pura (motivación extrínseca).

“Si te apoyas únicamente en lo económico, yo creo que tienes un problema, al final tienes que construir una historia o tienes que diseñar planes de carrera. [...] Al final es gente que se ve bastante estimulada por el tipo de reto y por el tipo de proyecto.” [E02]

En este contexto, la disyuntiva entre desarrollar talento interno (*build*) o fichar externamente (*buy*) cobra especial relevancia. La mayoría de entidades apuestan por la formación y el *upskilling* de sus plantillas como una vía para generar capacidades y, a la vez, reforzar el compromiso. Esta estrategia se percibe como una inversión a largo plazo en la fidelización del equipo.

“Nosotros trabajamos mucho la cantera, digamos, somos equipos relativamente pequeños, pero a la plantilla se la fideliza mucho y hay que desarrollar el talento interno.” [E07]

Complementariamente, se utilizan las carreras profesionales aceleradas y la movilidad interna como medidas de retención. Aunque se respetan las estructuras y niveles corporativos, se admite una progresión más rápida para estos perfiles críticos. No consiste en crear excepciones a las reglas, sino de aplicarlas de manera flexible.

“No te diría yo que son excepciones en cuanto a que las grandes normas en cuanto a bandas salariales las seguimos cumpliendo, pero a lo mejor una persona que no es de este equipo tarda a lo mejor cinco o seis años en recorrer una banda salarial y aquí a lo mejor los primeros años tarda menos. [...] Lo único que pasa es que a lo mejor sube más rápido de 6 a 5 y de 5 a 4 y eso. Pero no solo es el salario.” [E11].

Fomentar un sentido de pertenencia también actúa como medida de retención. En este sentido, la medición y comunicación del valor generado por las áreas operativas y su contribución a los logros de los objetivos de la entidad se convierte

en un instrumento muy potente para fomentar un orgullo compartido. Cuando se trasciende la simple métrica financiera para explicar cómo las mejoras operativas contribuyen al éxito global, se genera una conexión más profunda entre el empleado y la misión de la empresa. Como señala un CEO:

“explicarles bien a todas las áreas operativas cómo están contribuyendo al valor del negocio, porque muchas veces estamos con una con un ratio combinado de no sé qué ratio combinado. O sea, no es mérito del precio al que estás vendiendo ni de tal y cual cosa, sino que hay muchísimo de operativo por ahí. A lo que seas tú capaz de recobrar el fraude, que seas capaz de identificar eso al final, pues un poquito por aquí, un poquito por allá, pues acaba traduciendo en un ratio combinado. Entonces, oye, pues cualquier mejora, cualquier mejora en este sentido es importante compartirla con todo aquel con el que ha que ha que ha participado en ella.” (E02)

Esta práctica no solo mejora el clima al visibilizar los logros, sino que también actúa como un potente mecanismo de retención, al alinear el esfuerzo individual y de equipo con el propósito corporativo.

d) Percepción Sectorial

Un obstáculo adicional identificado es la pobre percepción de marca del sector asegurador, que los entrevistados consideran poco atractiva en comparación con competidores por el mismo talento como la banca de inversión, las *Big Tech* o las grandes consultoras. Esta falta de "glamour" obliga a las compañías a realizar un doble esfuerzo no solo para competir, sino para darse a conocer como empleadores tecnológicos de primer nivel.

“Yo creo que el sector asegurador en general tampoco se ha vendido nunca demasiado bien. [...] Además son términos, o sea de atracción de talentos. Yo creo que supone un reto doble, porque yo creo que no nace nadie en este mundo a no ser que le venga de familia y piense quiero dedicarme al sector asegurador.” [E02]

Estos tres factores (escasez, presión salarial y marca poco atractiva) acaba repercutiendo en una tasa de rotación creciente y notablemente superior a la media histórica de las compañías para otros roles, incluso en las mayores aseguradoras del país:

“Nuestras tasas de retención de talento son infinitamente mejores. Pero es verdad que el talento digital en general, nuestras tasas de retención, o sea las tasas de abandono, puede ser el doble o triple de las que tenemos, que son muy muy bajas, pero a nosotros nos preocupa.” [E05].

e) Implicaciones Organizativas y Estratégicas

Finalmente, los desafíos de talento tienen profundas implicaciones en el diseño organizativo y la estrategia a largo plazo.

i. Flexibilidad y Políticas Centradas en las Personas

La flexibilidad, especialmente en forma de teletrabajo y horarios adaptados, se identifica recurrentemente como un requisito fundamental para un clima laboral positivo, sobre todo en la atracción de talento digital escaso. Sin embargo, los entrevistados la posicionan como una condición “higiénica”, necesaria pero no suficiente para garantizar un sentido de pertenencia duradero. La atracción de perfiles jóvenes y especializados a menudo exige concesiones tanto económicas como de flexibilidad, lo que puede generar tensiones en la gestión:

“te encuentras con que hay perfiles escasos que atraerlos. Pasa por mucho dinero y también por una flexibilidad en el trabajo. No todas las compañías van a estar preparadas para ser capaces de dar los beneficios que estos perfiles requieren.” (E12)

El riesgo inherente a esta flexibilidad es la posible desconexión y la dilución de los vínculos afectivos si no se gestiona activamente:

“he visto reuniones, hecho desayunos con gente que se han conocido físicamente en el desayuno y llevaban tres años trabajando juntos y no habían desayunado. Una vez no lo habían visto y uno estaba en la planta uno y el otro estaba en la planta tres de vosotros.” (E5)

En este contexto, algunas entidades han adoptado modelos híbridos o remotos, mientras que otras mantienen una cultura de presencialidad fuerte, aunque ello suponga una dificultad adicional en la captación:

“Tenemos una cultura de presencialidad muy fuerte. Nosotros no queremos tener a gente trabajando en teletrabajo [...] es muy difícil de crear cultura y de trabajar hacia un mismo objetivo si cada uno está sus casas. Con lo cual eso nos ha añadido una dificultad añadida.” [E13]

ii. Coexistencia de Culturas

Más allá de la flexibilidad, la gestión del talento también se ve condicionada por la coexistencia de micro-culturas dentro de las organizaciones aseguradoras, especialmente en compañías con una larga trayectoria y una alta antigüedad media. En estos entornos, la orientación general hacia el cambio suele ser favorable, pero su aceptación no es homogénea y avanza de manera gradual. El fuerte sentido de pertenencia de los empleados veteranos puede chocar con la llegada de talento externo, generando desconfianza inicial si no se gestiona con sensibilidad:

“Ha habido una cierta desconfianza en una entidad muy tradicional, muy hecha a sí mismo, donde la media de antigüedad es de 20 años y de repente aparece ese sin, sin, sin ninguna experiencia en la entidad. Si con 20 años o 30 o 40 fuera, pero de repente aquí. Entonces no es sencillo el ganarte la confianza de la gente, ¿no?” (E16)

La clave para superar estas tensiones reside en construir confianza y en integrar a los recién llegados de forma que su pertenencia no sea percibida como frágil, evitando que el clima general se resienta.

iii. Estilo de Liderazgo

El estilo de liderazgo se menciona como un factor importante para un clima positivo y de pertenencia. Algunos entrevistados indican que un estilo cercano, colaborativo y orientado a las relaciones personales fomenta una cultura donde la movilidad interna se percibe como una oportunidad de desarrollo y no como una amenaza. Como lo resume un directivo con más de dos décadas en su organización:

“es una compañía muy especial. Con esa cultura como de... de ayudar al otro, de... de echar la mano de... ¿Y entonces? Pues esa es la verdad.” (E13)

Este tipo de cultura se fortalece a través de figuras clave que actúan como “pegamento organizacional”, capaces de sacar adelante proyectos de manera colaborativa, evitando resistencias y consolidando vínculos internos:

“no ha sido un elefante en cacharrería o Ella lleva con nosotros 5 años, la entrada dando bofetadas a nadie ha sido una persona modesta. Qué es feliz aquí y eso es muy importante, y que ha pasado una experiencia muy grande es una persona que ha estado en una empresa muy grande, que ha estado en reaseguro, que ha estado en... en directos, o sea, es decir, que es una senior.” (E07)

4.1.2.3. Formación y Upskilling

El análisis de las entrevistas evidencia que las aseguradoras españolas consideran la formación y la capacitación como elementos centrales en su estrategia de adopción de la IA. Se trata de un esfuerzo intencional y sistemático que no se limita a acciones puntuales, sino que forma parte de programas coordinados que abarcan a toda la organización, desde el Consejo de Administración hasta los equipos operativos. El objetivo es doble: crear una cultura común en torno a la IA y dotar a los distintos colectivos de las competencias específicas necesarias para integrar la tecnología en su actividad diaria.

a) Formaciones corporativas estructuradas

Muchas entidades han desarrollado programas de formación formal, con un diseño multinivel. En un primer nivel, se busca proporcionar un lenguaje común y un vocabulario básico para toda la plantilla, asegurando que todos los empleados, independientemente de su rol, sean capaces de comprender las implicaciones de

la IA. Posteriormente, se articulan itinerarios avanzados dirigidos a aquellos colectivos llamados a liderar la transformación.

Un entrevistado describe la creación de un máster corporativo en el que conviven formadores internos y expertos externos:

“Nosotros creamos hace dos años o cosa así un máster [...] hemos incorporado la parte de inteligencia artificial bajo la visión que tenemos nosotros, porque es un curso que tenemos tanto gente interna como externa, dándolo.” (E10)

Otro directivo explicaba cómo este modelo se articula en distintos niveles de profundidad:

“Nosotros tenemos un curso de formación muy básico para todos los empleados. [...] Luego tienes otro nivel más avanzado, que lo que yo quiero es ir engranando este segmento.” (E12)

La formación no se limita a lo teórico. Varias compañías han desplegado workshops de ideación en los que, tras recibir una introducción básica, los equipos de negocio y técnicos trabajan juntos para identificar oportunidades de aplicación:

“Se han hecho distintos workshops [...] previa formación básica, diciendo: yo lo que veo es que tendríamos una oportunidad en partes de lesiones, en grandes empresas, aquí, allá.” (E15)

“Ha habido como seis o siete grupos dentro de la organización que han pensado casos de uso, se han discutido y priorizado para ponerlos en marcha durante los próximos 12-18 meses.” (E15)

Este enfoque se complementa con estrategias menos habituales, pero igualmente valiosas, como el aprendizaje inverso: formar tecnólogos en el negocio asegurador, en lugar de asegurados en tecnología. Un directivo lo resumía así:

“Nosotros hemos sido al revés, entramos todos en tecnología y aprendimos de seguros.” (E08)

b) Upskilling de perfiles técnicos

Los equipos de TI son percibidos como el núcleo catalizador de la adopción. La estrategia predominante es dotarlos de nuevas herramientas y competencias que les permitan acelerar su propia productividad y, a la vez, servir como asesores internos del resto de las áreas. La formación prioriza el uso de copilotos de programación y técnicas de automatización de código.

“Vamos a ver si con sistemas, por ejemplo, tiene sentido hacer una formación para acelerar temas de programación con IA. [...] Yo creo que los equipos de TI son los que tienen una capacidad más grande para entender parte de la IA.” (E09)

“Estamos en procesos de formación [...] incluso de desarrollo de código de nuestra gente [...] lo estamos utilizando ya la inteligencia artificial a la hora de lanzar código.” (E16)

Este tipo de iniciativas son percibidas como clave para multiplicar la capacidad de los equipos internos sin necesidad de ampliar plantillas, algo crítico en un contexto de escasez de perfiles externos.

c) *Reskilling* de perfiles de negocio

En las áreas de negocio —siniestros, atención telefónica, *back-office*—, la formación se centra en el *reskilling*, es decir, en la adaptación de las competencias existentes para convivir con la IA. La lógica predominante es la de “aumentar” las capacidades humanas, liberando a los empleados de tareas repetitivas y permitiéndoles concentrarse en actividades de mayor valor añadido.

“La inteligencia artificial lo que permite es trabajar con muchos datos a la vez y, y como digo yo, dotar a los humanos de superpoderes.” (E09)

“Lo que estamos intentando es que esos perfiles vean que su intervención va a ser no tanto en la parte más automática, [...] sino en aportar el valor que ellos conocen porque lo han hecho durante años.” (E10)

“Hemos montado un sistema de inteligencia artificial para los empleados de call center. [...] El grado de complejidad es inmenso. Lo estamos ordenando en un sistema de IA de consulta para los operadores.” (E13)

Este enfoque se acompaña de mensajes tranquilizadores: la IA no elimina puestos, sino que redefine las funciones. En organizaciones con políticas de movilidad interna consolidadas, este planteamiento se percibe con menos resistencia:

“Nunca hemos echado a nadie porque hayamos metido una cosa que antes era parte de lo que hacían las personas y ahora lo hacen las máquinas. [...] No hay miedo a eso porque hay una cultura de hacer distintas cosas.” (E13)

d) Sensibilización del liderazgo

Formar al Consejo de Administración y al Comité de Dirección se considera esencial para garantizar que las decisiones estratégicas se tomen con conocimiento suficiente. En varios casos, se han diseñado programas de formación periódica en IA, similares a los que ya existían en materias como ciberseguridad.

“Hay formación de este tema en el Consejo, igual que se incorporaron en su momento cursos de ciberseguridad. [...] Este tema formó parte del Plan estratégico.” (E08)

“Dentro de lo que sería el Consejo está el tema de formación y, por ejemplo, todo esto que hemos hablado formó parte del plan estratégico.” (E10)

“Tengo una persona específica que es la que más sabe en el grupo y que la tengo de coach. Tengo sesiones mensuales con esta persona.” (E12)

Este esfuerzo se justifica porque los líderes deben comprender las implicaciones funcionales y estratégicas de la IA para evaluar correctamente inversiones y riesgos.

e) Autoaprendizaje y comunidades de práctica

Además de la formación estructurada, muchas aseguradoras fomentan el autoaprendizaje, apoyado en la relación con proveedores tecnológicos y en comunidades internas de práctica.

“Son ellos los que se han formado a sí mismos trabajando con proveedores. Tenemos mucha relación con Microsoft y nos ayuda a estar a la última.” (E11)

“Lo que hemos hecho es que las mismas personas que habían hecho todos los modelos predictivos se han formado en la generativa.” (E11)

“Las pocas personas que ahora mismo tienen conocimientos lo que estamos haciendo es juntarlas, para que se retroalimenten y generen su propia autoformación.” (E12)

f) Aprendizaje experiencial

El *learning by doing* es ampliamente mencionado. La formación teórica se considera insuficiente si no se acompaña de inmersión en proyectos reales, organizados bajo metodologías ágiles y equipos transversales.

“Nosotros trabajamos en metodología Ágile. [...] Hemos arrancado tres grupos de trabajo: eficiencia en operaciones, eficiencia fuera de operaciones y lanzamiento de producto. Todos estos grupos son transversales.” (E09)

“Es poner a la gente retos de cómo cambiar su forma de trabajar y que luego vuelvan a su día a día, después de haber visto las capacidades de la tecnología.” (E09)

La idea de “plantar semillitas” de transformación es recurrente: pequeños proyectos que sirven como catalizadores para que los empleados internalicen nuevas prácticas.

g) Diferencias de actitud ante el cambio

Las entrevistas reflejan la coexistencia de perfiles entusiastas y resistentes, incluso dentro de un mismo grupo generacional. La comunicación constante se plantea como la mejor herramienta para mitigar resistencias:

“Está el que dice tengo 62 años, ya me afeitarás, me da igual lo que me digas; tienes otros de 62 que dicen he visto no sé qué y tenemos que mirarlo. Te encuentras en los dos extremos. Aquí el tema es comunicar, comunicar, comunicar.” (E09)

Organizaciones con culturas de movilidad y reciclaje continuo de funciones muestran menor resistencia:

“Hay una cultura muy metida en la compañía de hacer distintas cosas. [...] No hay un miedo a eso, porque hay movilidad.” (E13)

h) Proveedores y ecosistema

Las alianzas con grandes proveedores tecnológicos y consultoras se perciben como un factor fundamental de actualización y transferencia de conocimiento. Estos actores no solo proveen herramientas, sino que ofrecen ventanas de anticipación tecnológica.

“Nos ayuda a estar a la última. [...] Siempre digo que tenemos que estar mucho más cerca de los grandes proveedores, porque ellos nos enseñan el futuro.” (E11)

De esta forma, los proveedores cumplen una doble función: asegurar competitividad tecnológica y reforzar la motivación y retención del talento interno.

4.1.2.4. Clima y Sentido de Pertenencia

El análisis de las entrevistas muestra que la adopción de la inteligencia artificial en las aseguradoras no se explica únicamente por capacidades, sino también por factores intangibles relacionados con el clima organizativo y el sentido de pertenencia. La cohesión interna, el orgullo de contribución y la confianza entre los equipos emergen como elementos que condicionan la capacidad de transformación tecnológica.

Una dimensión destacada por varios entrevistados es la retención asociada al orgullo de pertenencia y a la identificación con el proyecto colectivo. El clima organizativo se fortalece cuando la empresa es capaz de visibilizar los logros y reconocer de manera explícita las contribuciones individuales y de equipo. Mostrar cómo cada mejora operativa repercute en los resultados del negocio se convierte, así, en una práctica que alimenta la motivación y refuerza el vínculo con la compañía:

“Lo que sí que nos encanta es explicarles bien a todas las áreas operativas cómo están contribuyendo al valor del negocio [...]. Al final cualquier mejora se traduce en un ratio combinado, y es importante compartirla con todo aquel que ha participado en ella” (E02).

El **sentido de pertenencia** se fortalece también cuando las empresas logran articular un relato común que trasciende divisiones internas. En el caso de grandes grupos, se destaca la importancia de reconocer a todas las unidades como parte de un proyecto compartido:

“Estamos trabajando mucho en que esa gente se sienta reconocida. Saben que aquí en la compañía lo que hacen es importante, y eso también les da un sentido de pertenencia. Ven que no hay rencillas, que las buenas ideas se aplauden, que hay trasvase de gente entre países y corporativo sin problemas” (E03).

Este reconocimiento se combina con la **confianza interpersonal** y la valoración de perfiles singulares que actúan como nodos de cohesión y organización. Un directivo lo ejemplificaba al hablar de una persona clave de su equipo:

“Esa persona es la caña, porque sabe organizar, sistematizar y ponerlo en un papel. Además, no ha sido un elefante en cacharrería, lleva años aquí, ha sido modesta y es feliz en la compañía. Eso es muy importante” (E04).

Al mismo tiempo, se observan tensiones derivadas de la heterogeneidad cultural y generacional. Aunque en general predomina la apertura, la coexistencia de distintas “microculturas” obliga a gestionar ritmos diferentes de adaptación al cambio. Como reconocía un directivo:

“Hay dos o tres culturas diferentes. En general la gente está a favor del cambio, aunque depende mucho de la edad [...]. Aunque ha costado, la cultura está bastante orientada hacia este cambio” (E05).

Por último, varias compañías ponen en valor su cultura de ayuda mutua y compromiso a largo plazo, que funciona como antídoto frente al miedo a la sustitución tecnológica. La movilidad interna, la diversidad de experiencias profesionales y la estabilidad laboral alimentan un clima de confianza:

“Nunca hemos echado a nadie porque hayamos metido una cosa que antes hacía una persona y ahora la hace una máquina. No hay miedo porque hay una cultura muy metida de hacer distintas cosas a lo largo de la carrera” (E06).

4.1.2.5. Cultura Organizativa y Resistencia al Cambio

El examen de las entrevistas pone de manifiesto que la cultura organizativa constituye un factor tan decisivo como la tecnología o el talento en la trayectoria de adopción de la inteligencia artificial. Los testimonios muestran que las aseguradoras españolas no parten de un terreno cultural neutro: valores como el pragmatismo, la proximidad al cliente, la aversión al riesgo y la vigencia de estructuras tradicionales configuran el marco desde el que se interpretan y gestionan los proyectos de IA. Estas características explican tanto la aparición de resistencias específicas —miedo a la sustitución laboral, escepticismo, fatiga de iniciativas fallidas o brechas generacionales— como la necesidad de activar palancas culturales que faciliten el cambio. En este contexto emergen también tensiones organizativas que atraviesan a las compañías, reflejando el difícil equilibrio entre innovación y prudencia, eficiencia y trato humano, flexibilidad y cohesión interna.

a) Rasgos culturales

El discurso de los entrevistados permite identificar cuatro rasgos culturales predominantes en las entidades aseguradoras españolas, que condicionan el marco desde el cual las aseguradoras afrontan la adopción de la IA.

- **Pragmatismo:** Mayoritariamente, se observa que, en lugar de una carrera por ser pioneros en la innovación, prevalece una cultura pragmática. No se percibe que el valor esté en ser el primero en abordar un caso de uso, sino en desarrollar la agilidad organizacional necesaria para copiar e implementar rápidamente las innovaciones que se demuestren exitosas en otras entidades o industrias. Este posicionamiento prioriza la adaptabilidad sobre la invención, considerando que la ventaja competitiva del pionero es efímera. Un directivo lo resume de la siguiente manera:

"no sé si lo más importante es, o más bien te diría no sé, es no ser, el no ser el primero, sino ser capaz de copiar eso o de adoptar eso con mucha velocidad, con mucha velocidad, porque esa ventaja competitiva yo creo que va a ser... la vas a poder mantener durante poco tiempo, mientras que la ventaja competitiva de ser muy adaptable y muy rápido en poder hacer uso de esas tecnologías y adoptarlas, pues digamos eso es una ventaja competitiva mucho más difícil de copiar." (E01)

Una excepción son las grandes entidades, sobre todo con ámbito de actuación multinacional, que sienten una mayor presión competitiva a escala global, lo que las impulsa a adoptar posiciones de innovador pionero.

- **Vocación de Servicio y Trato Personal:** De manera generalizada, existe una fuerte cultura de la proximidad y la relación personal con el cliente y, en las entidades con negocio intermediado, con los agentes y corredores. Se defiende el valor de la "inteligencia emocional" y el rol artesanal de profesiones como el suscriptor o el mediador, que se ha de preservar frente a una automatización total que podría deshumanizar el servicio.

"El suscriptor no solo toma la decisión si sí o si no, ¿no? le va dando directrices, le va guiando, le va controlando, o sea, por el número de personas que estoy utilizando para esta labor, pues de momento es que no me lo plantearía, porque, aunque la máquina pudiera ser muy efectiva, ¿vale?, me ahorro estas 20 personas, ya te digo, medio millón de euros más, pero todo lo que es creación de vínculo, todo esto no me lo dará la máquina." (E08)

- **Aversión al Riesgo:** El sector, tiene una cultura de prudencia máxima incrustada en su ADN por estar sometido a un entorno regulatorio y supervisor muy riguroso. La prioridad otorgada al cumplimiento normativo y a la protección de datos actúa muchas veces como un freno a la experimentación y afecta a la velocidad de adopción de nuevas tecnologías.

"El freno es más freno cultural y freno regulatorio. Sobre todo, miedo a incumplir determinadas regulaciones. Y ahora que tenemos el reglamento de Inteligencia artificial que nos ha caído. (...) hemos ido muy tarde en la adopción de CoPilot, por ejemplo, internamente muy lentos, porque ha generado un miedo interno. La primera reacción fue vamos a cerrar todo esto para que no se filtren los datos... que no sabemos." (E11)

- **Organizaciones Tradicionales:** Las estructuras organizativas tradicionales, caracterizadas por su funcionamiento en cascada, departamentalizadas y con una burocracia arraigada arraigadas en respuesta a los altos y continuamente crecientes exigencias en materia de control y *governance*, chocan frontalmente con la agilidad y la transversalidad que demandan los proyectos de IA. Se reconoce que el modelo clásico es un obstáculo para integrar la IA como una ventaja competitiva real.

"si tú estás pensando que tú con una organización clásica, después vas a poder integrar la IA como una ventaja competitiva, lo que te estás equivocando" (E05)

b) Fuentes de Resistencia al Cambio

En paralelo a los rasgos culturales del sector que condicionan la adopción de IA, se ha identificado cinco fuentes principales de resistencia a su adopción:

- **Miedo a la Sustitución Laboral:** Es la resistencia más explícita y se concentra en roles operativos y de *back-office*. Los empleados tienen miedo de que la IA elimine sus puestos de trabajo, lo que genera una barrera activa o pasiva hacia la implementación de nuevas herramientas.

"una de las barreras que para nosotros está siendo importante a la hora de incluir la inteligencia artificial es el temor de la gente a perder sus trabajos. (...) porque los propios usuarios intentan protegerse. Entonces esa protección, que nosotros lo hemos notado, lo que hay que trabajarla mucho es con mensajes de, oye, que es que no quiero quitar y hacer lo mismo sino quiero hacer más contigo." (E10)

- **Escepticismo:** Existe cierta percepción de que la IA es un “*hype*”, una moda tecnológica como otras recientes.

"Te dicen que el mundo va a cambiar por la IA, y que no sé qué. Yo creo que se pasan mucho y nos auguran un futuro que, vendrá, pero posiblemente no mañana (...). Ha habido compañías aseguradoras que han llegado a abrir oficina en el metaverso, que han hecho pólizas en el metaverso y, no sé, o sea, me parece un poco de Pepe Gotera y Otilio. Para ser el más moderno de la clase" (E07)

- **Fatiga de Iniciativas:** Experiencias pasadas con proyectos de transformación fallidos han generado un cinismo y una desconfianza, especialmente en los equipos de TI y de negocio, que ahora reciben las nuevas iniciativas con recelo.

"No nos gusta decir que ahora vamos a cambiar todo, y la metodología que vamos a seguir es esta, porque en el pasado, hablo de hace años se intentó, pues eso: ahora los proyectos van a ser que todo tiene que estar en el Project Manager, cuando existía, y entonces todos dedicados a esto. Y no funcionó porque era cambiar la cultura para intentar adaptarla a algo que vino un consultor y nos dijo cómo hacerlo." (E10)

- **Diferencia de actitudes:** Los directivos, a pesar de que "no quieren generalizar", observan diferencias significativas en la apertura al cambio según la edad de la plantilla. A esto se suma la dificultad de reciclar perfiles tradicionales y la escasez de talento nativo en IA.

"Depende mucho de la edad. No únicamente, porque también hay gente que lleva muchos años y que, aunque son mayores, tienen mucho interés en los cambios, casi más que algunos jóvenes. Ahora, después de estos años, creo que la cultura está bastante orientada hacia este cambio, aunque ha costado." (E04)

- **Defensa de la "Inteligencia Humana":** Profesionales expertos, como suscriptores y mediadores, defienden su rol "artesanal" y el valor de su juicio y experiencia personal, resistiéndose a herramientas que perciben como una amenaza a su estatus y autonomía profesional.

"al final es crear profesionales, formarlos, que sean autónomos. Nosotros, todo nuestro modelo es siempre tener equipos que sean capaces de desarrollar profesionales, porque en el sector de seguros profesionales no hay. Los creamos siempre diríamos a pico y pala ¿no? Y entonces, Pues este es el trabajo que nosotros hacemos, ¿no? (...) Y este es un trabajo muy artesanal." (E08)

c) **Palancas Culturales para Gestionar la Resistencia**

Las aseguradoras avanzan en la gestión del cambio desplegando una serie de palancas culturales para neutralizar la resistencia.

- **Comunicación Continua y Transparente:** Se considera fundamental mantener un flujo de comunicación constante y transparente desde la alta dirección para reducir la rumorología y reforzar la seguridad psicológica de los equipos.

"yo creo que aquí el tema es comunicar, comunicar, comunicar, marcar cuál es el objetivo, el roadmap (...) Requiere mucha comunicación de arriba hacia abajo." (E09)

- **Narrativa Tranquilizadora:** Presentar la IA como una herramienta aliada que otorga "superpoderes" al profesional, en lugar de una tecnología que busca reemplazarlo, es clave para obtener la aceptación de los empleados.

"Aquí hacemos la inteligencia artificial para darle más herramientas a la gente, no para echarla. [...]. Pero aquí viene un proveedor, o un consultor y dice que te

elimina el call center ¿no?... pues ya te puedes ir, porque yo no quiero eliminar el call center." (E05)

- **Adopción Gradual:** Empezar con proyectos de coste y alcance limitado con el objetivo explícito de "aprender", en lugar de buscar un ROI inmediato, permite a la organización experimentar con la tecnología y conocer sus capacidades reales sin la ansiedad asociada al desconocimiento.

"Oye, vamos a probar. No nos vamos a volver locos. Vamos a buscar una prueba controlada. (...) ¿Y el objetivo cuál es? porque es importante marcarlo. El objetivo es aprender. Si el objetivo es aprender, es aprender, no el retorno económico." (E09)

- **Proyectos Transversales:** La creación de equipos multidisciplinares que en muchas ocasiones trabajan con metodologías ágiles ayuda a romper los silos departamentales, fomenta la co-creación y comparte la responsabilidad del éxito del proyecto entre negocio y tecnología.

"los equipos que están implantando inteligencia artificial trabajan en Agile. Entonces tenemos un... un apartado específicamente dedicado a eso." (E05)

- **Gestión de Talento:** Atraer y retener al talento escaso de IA exige políticas de flexibilidad y compensación que a menudo rompen con la equidad interna tradicional, un desafío que las empresas deben gestionar.

"te encuentras con que hay perfiles escasos que atraerlos. Pasa por mucho dinero y también por una flexibilidad en el trabajo. No todas las compañías van a estar preparadas para ser capaces de dar los beneficios que estos perfiles requieren." (E12)

- **Quick-wins:** Implementar soluciones que generan un valor tangible y visible, ya sea mejorando la experiencia del cliente o la eficiencia del empleado, sirve como prueba que legitima iniciativas de mayor envergadura.

"nosotros tenemos una plataforma de distribución de un determinado seguro donde pusimos el centro y el foco en el distribuidor. (...) O sea, el mediador está encantadísimo y el mensaje es trabajo con vosotros porque (...) me simplificáis la vida." (E09)

d) Tensiones Organizativas

La introducción de la IA genera en las entidades una serie de tensiones y dilemas que los directivos deben gestionar:

- **Trato Humano vs. Eficiencia Digital:** Mientras que la automatización del *back-office* es ampliamente aceptada, existe una fuerte resistencia a sustituir la interacción personal en los puntos de contacto con el cliente, defendiendo el valor de la "inteligencia emocional".

"podíamos haber puesto un Chatbot o podríamos ser la típica centralita que llamas pulse uno y tal. Eso está prohibido en esta organización, eso no lo vamos a hacer, vamos a seguir manteniendo señoras, señores, personas (...) no renunciaremos a la inteligencia emocional, la calidad de la persona" (E16)

- **Velocidad de Mercado vs. Gobernanza y Regulación:** La urgencia por competir e innovar choca con la cultura de aversión al riesgo y la necesidad de garantizar el cumplimiento normativo (*compliance*), la ciberseguridad y la protección de datos.
- **Centralidad del Mediador vs. Automatización del *Front-Office*:** Especialmente en los modelos mediados, existe el dilema de cómo digitalizar la relación con el cliente sin alienar o desintermediar al canal de agentes y corredores, que sigue siendo el pilar del negocio.
- **Atracción de Talento vs. Equidad Interna:** Las políticas salariales y de flexibilidad necesarias para atraer al talento digital, a menudo muy por encima de los estándares de la compañía, generan tensiones y resentimientos con la plantilla tradicional.

"cuando uno es joven y pide esta cantidad de dinero que estamos obligados a pagar por tiempo o talento, al final genera un egocentrismo que luego es muy difícil de gestionar desde un punto de vista de management." (E12)

- **Presencialidad vs. Flexibilidad:** La cultura corporativa de muchas aseguradoras, que valora la presencialidad para cohesionar equipos, entra en conflicto directo con las expectativas de teletrabajo y flexibilidad de los perfiles digitales más demandados.

"tenemos una cultura de presencialidad muy fuerte. Nosotros no queremos tener a gente teletrabajando (...) es muy difícil de crear cultura y de trabajar hacia un mismo objetivo si cada uno está en su casa, Con lo cual, eso nos ha añadido dificultad " (E13)

4.1.2.6. Cultura de Innovación

El análisis de las entrevistas revela que la cultura de innovación en el sector asegurador español no es uniforme, sino un mosaico en el que conviven tradiciones analíticas, estilos de liderazgo, formas de trabajo y actitudes generacionales diversas. Este entramado cultural determina el modo en que las aseguradoras se aproximan a la inteligencia artificial: no como una ruptura absoluta, sino como un proceso que se apoya en bases preexistentes (datos, eficiencia operativa, prudencia) y que al mismo tiempo requiere de nuevas dinámicas (curiosidad, tolerancia al error, agilidad y apertura externa).

a) Tradición Analítica como Base Cultural para Innovar

Una de las principales ventajas competitivas del sector asegurador, según identifican de manera generalizada sus directivos, para la adopción de nuevas tecnologías como la inteligencia artificial, reside en su tradicional cultura de análisis de datos. Los entrevistados perciben que esta familiaridad histórica con el manejo de grandes volúmenes de información actúa como un catalizador, reduciendo la fricción cultural y generando confianza interna. Esta base analítica se considera un ADN de la industria que posiciona favorablemente a las aseguradoras frente a otros sectores.:

"La ventaja que tiene el sector asegurador en términos de adopción es que hace muchos años que vamos oyendo hablar de analítica de datos [...] y somos organizaciones que estamos acostumbradas, es decir, tenemos en nuestro ADN lo que es el tratamiento, es decir, la toma de decisiones en base a lo que observamos en analítica, analizando datos. [...] Considero que estamos muchísimo mejor posicionados que otro tipo de compañías, otro tipo de sectores, porque ya tenemos una costumbre". (E02)

b) Curiosidad, Inquietud Técnica y Mejora Continua

Los directivos destacan como factor importante para la cultura de innovación contar con equipos con curiosidad y ambición intelectual constantes que investiguen y experimenten de manera proactiva:

"Evidentemente que yo ya tengo parte del equipo que, de manera natural, porque tiene esos skills, ya está investigando, que de manera natural los equipos ya están haciendo ‘pequeños bichos’ [...] para testar la tecnología". (E12)

c) Eficiencia Operativa

La búsqueda de la eficiencia operativa es un motor fundamental que ha impulsado tradicionalmente iniciativas de innovación en la industria aseguradora. En un sector con cadenas de valor complejas, la "obsesión por la eficiencia" y un "principio muy claro de austeridad" actúan como justificación económica para la adopción de tecnologías "eficientadoras". La innovación se vuelve imperativa cuando los métodos tradicionales demuestran haber alcanzado un límite en su capacidad de mejora, justificando así la inversión en nuevas soluciones.

"Nosotros hemos sido siempre bastante obsesos de la eficiencia operativa [...]. Y también tenemos un principio muy claro es de austeridad, ¿no? Es decir, austeridad es intentar, pues con menos, conseguir más. Y en ese sentido nos interesa ser cada vez más simples, sobre todo más eficientes. [...] Sí que ha habido ámbitos concretos donde hemos visto que con métodos tradicionales o como hacíamos de las cosas, pues nuestro margen de mejora, pues había quedado un poco un poco estancado". (E02)

d) Modelo de Liderazgo

El estilo de liderazgo se ha identificado en las entrevistas como crucial en el fomento de una cultura innovadora. Un modelo basado en la delegación y la confianza empodera a los equipos para que identifiquen retos y propongan soluciones de forma autónoma. Cuando el máximo responsable de la organización no solo delega, sino que muestra un interés personal por la tecnología, se refuerza la cultura de innovación en toda la estructura:

"El modelo de gestión que aplico yo es el de, es decir, delegar mucho. [...] La persona que está a primer nivel está en el comité de dirección donde compartimos todos los retos y todos los objetivos y ambiciones que tenemos. [...] Y, sobre todo, yo creo que en cierto modo se percibe esa capacidad de delegación que hay por mi parte, no únicamente delegación, sino de confianza total, absoluta". (E02)

e) Equipos Dedicados y Proyectos Estimulantes

Algunas entidades han creado áreas y equipos específicamente dedicados a los proyectos de transformación. Estas unidades, que combinan perfiles técnicos con expertos de negocio, se convierten en el epicentro de la innovación. Este talento, altamente cualificado, valora más los desafíos intelectuales y los proyectos estimulantes, lo que actúa como elemento de retención, más allá de la mera retribución económica:

"Al final es gente que se ve bastante estimulada por el tipo de reto y por el tipo de proyecto. Entonces, si tú les generas un entorno o un área como la que hemos creado nosotros, es decir, donde ellos realmente tienen que aceptar o asumir una serie de retos que intelectualmente les resulten estimulantes para ellos, lógicamente con un nivel retributivo adecuado, por norma general tienes capacidad para retenerlos". (E02)

f) Tolerancia al Error y Aceptación del Fracaso

Otra condición necesaria para la experimentación es la existencia de un clima de seguridad psicológica donde el error se considera parte del proceso de aprendizaje. Los entrevistados defienden una visión pragmática del riesgo, donde es necesario "atreverte a probar y a equivocarte". Se asume que el éxito es el resultado de

múltiples intentos, y que los aciertos deben ser lo suficientemente significativos como para compensar los fracasos inevitables.

"También te puedo contar muchas que han salido mal, muchas, porque la cosa de acertar está en equivocarse menos. [...] Si te equivocas más veces de las que aciertas, la vez que aciertas tiene que compensar. Tiene que merecer la pena". (E07)

g) Apertura y Colaboración Externa

Algunas de las entidades analizadas consideran que ser permeables al conocimiento y las prácticas externas a través de modelos de innovación abierta, colaborando activamente con *InsurTechs* y consultoras, también favorece la existencia de una cultura más innovadora, demuestran. Esta apertura permite no solo acceder a nuevas tecnologías, sino también aprender de las metodologías y la agilidad de las *startups*:

"Nosotros tenemos proyectos de innovación, de innovación abierta, ¿vale? O sea, a las InsurTech las hemos metido muchas veces en áreas de negocio para aprender cómo hacen las cosas ellos y que también ellos puedan aprender. Y en este sentido la verdad es que somos muy abiertos". (E02)

h) Formas de Trabajo Ágiles y Transversales

La adopción de metodologías ágiles y la configuración de equipos multifuncionales se consideran clave, mayoritariamente, para acelerar la innovación. Aunque no siempre se siga un modelo ágil "ortodoxo", se busca "coger lo mejor de los dos mundos". Una práctica destacada es la ubicación física de los equipos de tecnología y negocio en el mismo espacio para trabajar en proyectos específicos, lo que refuerza la cocreación y acelera el aprendizaje colectivo:

"Tenemos a los de tecnología y a los de negocio que se sientan físicamente juntos y cada vez más trabajamos en proyectos en los cuales hay una ubicación única, ¿no?, de gente que está o full time o bastante part time, pero con mucho part dedicado a un proyecto y que lo que te marca más es el proyecto más que la propia dirección funcional en la que estás". (E03)

i) Transversalidad del Cambio

Se percibe la transformación digital, y en particular la IA, no como un cambio departamental, sino como una revolución transversal que, tal vez no inmediatamente, pero que acabará afectando a toda la organización. Un directivo compara su impacto con la llegada de herramientas como "Microsoft Office o de la calculadora o de internet". Esta percepción genera una "sensación de urgencia" para sensibilizar y formar a toda la plantilla, manteniendo una tensión constructiva entre la necesidad de un despliegue rápido y la prudencia de hacerlo "con cabeza", estimulando la cultura de innovación de las entidades.

"Yo creo que es una revolución que nos va a afectar a todo lo que hacemos, ¿no? Esto yo siempre lo asimilo al uso del Microsoft Office o de una calculadora o de internet. Va a ser una cosa tremendamente transversal y por tanto es urgente en el sentido de que es necesario que culturalmente en la organización se genere esa sensibilidad, esa curiosidad". (E03)

j) Diversidad Cultural y Generacional

Finalmente, los directivos apuntan que la cultura corporativa no es homogénea, sino que coexisten "dos o tres culturas generacionales diferentes", con distintas velocidades de adopción. Sin embargo, se matiza que la receptividad al cambio no está exclusivamente ligada a la edad, sino a la predisposición individual. A pesar de esta heterogeneidad, la tendencia general es una convergencia hacia una cultura cada vez más orientada y favorable a la innovación.

"Hay un poco de todo; hay dos o tres culturas diferentes. Pero creo que en general, la gente está bastante a favor del cambio, aunque depende mucho de la edad. No únicamente, porque también hay gente que lleva muchos años y que, aunque son mayores, tienen mucho interés en los cambios, casi más que algunos jóvenes. Ahora, después de estos años, creo que la cultura está bastante orientada hacia este cambio, aunque ha costado". (E04)

k) Matices culturales

Los testimonios permiten identificar patrones y matices culturales atribuibles a las características de cada entidad, como su tamaño, línea de negocio principal o su pertenencia a un grupo multinacional.

i. Similitudes Transversales a Todas las Entidades

Independientemente de su perfil, todas las compañías entrevistadas comparten un núcleo de prácticas innovadoras. La más destacada es la **experimentación continua mediante pilotos**. Todas recurren a pruebas de concepto o productos mínimos viables (MVP) para testar hipótesis con un riesgo controlado antes de escalar las soluciones. Esta práctica está profundamente interiorizada:

"Como siempre hacemos muchos pilotos, es el MVP típico, lanzamos algo que más o menos se aguante. Entonces ahí es cuando probamos en piloto a ver si realmente puede ser algo que se consolide". (E02)

Otro pilar común es la **colaboración entre las áreas de negocio y tecnología**. Aunque el grado de formalidad varía, la necesidad de crear equipos mixtos es una constante. Esta colaboración se considera fundamental para asegurar que las soluciones tecnológicas respondan a problemas de negocio reales, tal y como se refleja en la composición de los equipos de datos, donde perfiles *data scientist* conviven con "personas que conocen muy bien el negocio o los procesos de negocio" (E02).

ii. Discrepancias Vinculadas al Perfil de la Entidad

Las diferencias más significativas emergen en la percepción de la urgencia, el motor principal de la innovación y el grado de formalismo metodológico.

En las entidades de mayor tamaño o líderes de su segmento, la percepción de la IA como una "revolución transversal" que genera una "sensación de urgencia" para transformar la organización a gran escala es más intensa. En contraste, en compañías de menor tamaño esta presión se presenta como menos acuciante. La innovación se activa de manera más reactiva, bien por ambición personal o cuando se detecta un estancamiento operativo. Un directivo de una de estas entidades lo confirma explícitamente al ser preguntado al respecto:

"Y, sin embargo, no tengo, a lo que dices, sensación de urgencia". (E07)

La motivación para innovar también varía. En grandes corporaciones, la innovación está alineada con una transformación estratégica más amplia. En aseguradoras de tamaño medio, el motor más destacado por sus directivos es la eficiencia operativa y la "austeridad", donde la innovación debe justificarse con un retorno claro y medible.

Por último, las entidades grandes cuentan con una metodología *Agile* madura y consolidada desde hace años: *"llevamos ya 7 u 8 años"* (E02) o, implementan marcos de trabajo flexibles, aunque estructurados, como modelos *"híbridos"* que combinan *Agile* con enfoques tradicionales (E03). En las entidades de menor escala, los procesos pueden ser más informales y orgánicos, guiados más por una cultura de experimentación y la iniciativa individual de *"atreverte a probar"* (E07) que por un marco metodológico formalizado.

La Tabla 17 recoge de manera estructurada las evidencias más relevantes extraídas de los testimonios directivos sobre el talento y la cultura, ilustradas con citas representativas, así como las principales palancas o respuestas mencionadas por las entidades para mitigar dichas limitaciones.

Tabla 17: Síntesis de brechas y respuestas organizativas en la adopción de IA

Bloque	Brecha identificada	Descripción / Evidencia	Palancas o respuestas identificadas
Brechas de talento	Falta de perfiles híbridos	Dificultad para combinar negocio asegurador con competencias digitales. "Si no entrenas estos algoritmos en función de tu entidad, solo tienes un 'bicho' genérico" (E04).	Upskilling de negocio; equipos multidisciplinares mixtos.

Bloque	Brecha identificada	Descripción / Evidencia	Palancas o respuestas identificadas
	Nuevos roles emergentes indefinidos	Perfiles como MLOps o <i>prompt engineers</i> aún sin definición clara. “Normalmente busco un actuario, pero ahora no sabía qué tenía que buscar” (E10).	Aprendizaje iterativo mediante pilotos; apoyo externo para definir roles.
	Curva de aprendizaje y retención	Riesgo de no amortizar la inversión en formación por alta rotación. “Tenerlos el tiempo suficiente como para que la curva de aprendizaje se amortice” (E09).	Planes de carrera; proyectos retadores; movilidad interna; reconocimiento explícito.
	Escasez de talento especializado en IA avanzada	Ausencia de expertos en IA generativa/MLOps. “No los tenemos, no hay talento de eso aún” (E05).	Colaboración con proveedores globales; atracción selectiva con salario + flexibilidad.
	Tamaño reducido de equipos (masa crítica)	Capacidad desigual entre entidades grandes y medianas. “Sí que tenemos un área [...] de 20 personas” (E02) vs. “no somos una entidad con gran tamaño” (E16).	Estrategia de cantera interna; proyectos pequeños de alto impacto (“semillitas”).
	Output educativo insuficiente	Brecha entre lo que pide el mercado y lo que ofrecen universidades. “Hay un gap entre lo que la empresa pide y lo que produce la universidad” (E15).	Alianzas universidad–empresa; másteres corporativos; programas multinivel.
	Tensión salarial	Expectativas elevadas frente a bandas retributivas tradicionales. “Para captar determinado perfil se pueden hacer excepciones” (E02).	Excepciones puntuales; flexibilidad como complemento al salario.
	Percepción sectorial poco atractiva	Seguro visto como sector con poco “glamour” frente a banca o <i>Big Tech</i> . “El sector asegurador [...] no se ha vendido nunca demasiado bien” (E02).	Refuerzo de marca empleadora; visibilización de proyectos innovadores.
	Atracción de talento vs. equidad interna	Salarios altos a perfiles digitales generan tensiones con plantilla tradicional. “Genera un	Comunicación interna; políticas equilibradas; cultura de

Bloque	Brecha identificada	Descripción / Evidencia	Palancas o respuestas identificadas
		egocentrismo difícil de gestionar” (E12).	reconocimiento no solo económico.
	Presencialidad rígida vs. demanda de flexibilidad	Cultura de presencialidad fuerte frente a expectativas de teletrabajo. “Es muy difícil de crear cultura si cada uno está en su casa” (E13).	Modelos híbridos; gestión activa de encuentros presenciales de cohesión.
Brechas culturales / organizativas	Resistencia cultural al cambio	Plantillas sin nociones básicas de IA; miedo, escepticismo. “¿Tienes gente preparada? La respuesta es no” (E12).	Comunicación transparente; narrativa tranquilizadora (“IA como superpoder”); pilotos controlados.
	Miedo a la sustitución laboral	Temor en funciones de <i>back-office</i> . “El temor de la gente a perder sus trabajos” (E10).	Mensajes de “IA para aumentar, no sustituir”; movilidad interna.
	Escepticismo y fatiga de iniciativas	Cinismo tras transformaciones fallidas. “En el pasado [...] no funcionó porque era cambiar la cultura” (E10).	<i>Learning by doing</i> ; pilotos de bajo riesgo; quick wins.
	Brechas generacionales / ritmos dispares	Tensiones entre veteranos y perfiles digitales. “No es sencillo ganarte la confianza de la gente” (E16).	Integración progresiva de perfiles; movilidad interna; gestión de ritmos generacionales.
	Cultura excesivamente tradicional y jerárquica	Estructuras en cascada chocan con la agilidad que exige la IA. “Si tú estás pensando que con una organización clásica vas a poder integrar la IA [...] te estás equivocando” (E05).	Proyectos <i>Agile</i> ; equipos transversales; reducción de burocracia.
	Desconexión negocio–tecnología	Riesgo de proyectos técnicos sin impacto real. “El reto es conformar un equipo multidisciplinar” (E05).	Equipos mixtos; workshops de ideación con negocio y tecnología.
	Liderazgo concentrado en la cúpula	Innovación demasiado dependiente del CEO. “No puede ser que uno de los más disruptivos sea el director general” (E07).	Liderazgo distribuido; empoderar mandos intermedios; formación ejecutiva.

Bloque	Brecha identificada	Descripción / Evidencia	Palancas o respuestas identificadas
	Débil liderazgo innovador en niveles intermedios	Falta de “pegamento organizacional”. Innovación impulsada solo desde arriba.	Identificar figuras clave (<i>champions</i> modestos); empoderar mandos intermedios.
	Dependencia excesiva de consultoras	Externalización costosa y con resultados inciertos. “Nos estamos acostumbrando a ceder absolutamente todo” (E14).	Internalización progresiva de competencias; liderazgo distribuido; centros propios de IA.
	Gobernanza del dato insuficiente	Sin bases sólidas de datos, la IA no escala. “Necesitas foundations en data súper potentes” (E12).	Inversión en <i>Data Lakes</i> y MLOps; políticas de calidad y seguridad.
	Clima organizativo fragmentado	Dificultad para generar cohesión. Coexisten microculturas y divisiones internas. “Hay dos o tres culturas diferentes” (E05).	Relatos corporativos comunes; orgullo de contribución; reconocimiento explícito.
	Debilidad del sentido de pertenencia	Riesgo de rotación cuando no se articula un relato compartido. “Estamos trabajando mucho en que esa gente se sienta reconocida” (E03).	Reforzar orgullo colectivo; movilidad entre corporativo y filiales; proyectos compartidos.
	Falta de reconocimiento interno	Desmotivación cuando los logros no se visibilizan. “Estamos trabajando mucho en que esa gente se sienta reconocida” (E05).	Compartir logros sistemáticamente; explicar impacto de mejoras en el negocio.
Brechas estratégicas / innovación	Velocidad tecnológica vs. adaptación cultural	Ritmo tecnológico mayor que el de absorción humana. “La tecnología avanza muy rápidamente y [...] tienes tu proceso de adaptación” (E12).	Adopción gradual; quick wins para reforzar confianza.
	Dependencia estratégica de proveedores globales	Vulnerabilidad frente a <i>Big Tech</i> . “Nos estamos acostumbrando a ceder absolutamente todo” (E14).	Estrategias de autonomía relativa; centros internos de IA; reducción de dependencia.
	Débil cultura de innovación en algunas entidades	Innovación vista como moda pasajera. “Compañías que	Cultura de pilotos; tolerancia al error;


Bloque	Brecha identificada	Descripción / Evidencia	Palancas o respuestas identificadas
		abrieron oficinas en el metaverso [...] perdieron el tiempo” (E07).	proyectos estimulantes para talento clave.
	Falta de tolerancia al error	Miedo a equivocarse frena experimentación. “La cosa de acertar está en equivocarse menos” (E07).	Seguridad psicológica; gestión pragmática del error.
	Escasa apertura externa	Poca permeabilidad a startups o <i>InsurTechs</i> .	Innovación abierta; colaboración con <i>InsurTechs</i> y consultoras; co-creación con ecosistema.

Fuente: Elaboración propia

4.1.3. Organización y Gobierno

Los factores relacionados con organización y gobierno se pueden estructurar en las siete subcategorías que se muestran en la Figura 12.

Figura 12: Distribución de entrevistas y referencias en las subcategorías de organización y gobierno



Fuente: Elaboración propia

4.1.3.1. Estructura de Liderazgo: papel del Comité de Dirección

En las entrevistas se pueden identificar tres modelos de liderazgo en la adopción de la inteligencia artificial en el sector asegurador. El primero corresponde al modelo top-down, en el que el impulso procede de la alta dirección —CEO o Consejo de Administración—. En un segundo nivel se encuentra el modelo mixto, caracterizado por la interacción entre iniciativas surgidas desde áreas operativas y el respaldo estratégico de la dirección. Por último, se observa un modelo distribuido o reactivo, propio de organizaciones de menor madurez y escala, donde la adopción depende fundamentalmente de liderazgos individuales y carece de estructuras formales de gobernanza.

La Tabla 18 resume la frecuencia con que estos modelos fueron identificados en el corpus, mientras que la Figura 12 muestra gráficamente su distribución en número de entrevistas y referencias, evidenciando el predominio del liderazgo top-down frente a los demás enfoques.

Tabla 18: Distribución de modelos de liderazgo

Modelo de liderazgo	N.º de entrevistas
Top-down	5
Mixto	7
Reactivo / Distribuido	4
Total	16

Fuente: Elaboración propia

a) Liderazgo Top-Down

Este modelo predomina en grandes aseguradoras y grupos multinacionales. Se caracteriza por un mandato explícito desde la alta dirección, que establece la adopción de la IA como una prioridad estratégica incuestionable. No se trata simplemente de recomendaciones, sino de exigencias acompañadas de mecanismos de control estrictos:

“Esto es un top down que emana del propio CEO del grupo. [...] ¿no? es que tú no sabes..., es que estamos sometidos a examen todos los CEOs todos los días. Porque él lo tiene muy claro. Y es que tiene razón. Si esto no emana del CEO, esto no va a suceder”. (E12)

“El impulso viene de la altísima dirección, o sea, del Consejo, que es el que al final aprueba el plan”. (E11)

Este impulso estratégico se formaliza mediante una estructura de gobierno multinivel, donde las decisiones fluyen desde el Consejo hacia comités delegados con capacidad ejecutiva:

“Hay un órgano máximo que lo llamamos Comité de Transformación e Innovación, que lo presido yo y ese es un comité delegado del Comité Ejecutivo”. (E05)

Para reforzar la legitimidad y acelerar la agenda de innovación, algunas grandes corporaciones han creado consejos asesores externos integrados por figuras destacadas del ámbito tecnológico. Esta práctica aporta credibilidad y una visión externa valiosa para el consejo:

“Hacía ya dos años habíamos montado un Consejo Asesor externo de Transformación e Innovación [...] tenemos ahí casi todo externos, pero tenemos al español que ha llegado más alto en Google. Tenemos a la presidenta de Microsoft, al expresidente de Accenture...”. (E05)

b) Modelo Mixto

Este segundo modelo es el prevalente en aseguradoras medianas y grandes que, sin la estricta jerarquía de las grandes multinacionales, buscan un equilibrio dinámico entre las necesidades del negocio y las capacidades tecnológicas. Su característica principal es la colaboración e *“iteración continua entre tecnología y negocio”* (E02)

En este esquema, el liderazgo no necesariamente surge de un mandato corporativo explícito, sino que a menudo nace de la interacción entre departamentos. Las iniciativas pueden generarse en los equipos de negocio o ser propuestas desde el área tecnológica.

Asimismo, este enfoque promueve una significativa delegación del CEO hacia figuras clave como el CIO, quienes cuentan con la confianza y los recursos necesarios para explorar e implementar soluciones tecnológicas.

Para proyectos particularmente complejos y de gran alcance, estas organizaciones adoptan metodologías ágiles mediante la creación de equipos transversales específicos:

“Hemos empezado a utilizar metodología Agile [...] en proyectos muy transversales, muy transformacionales, donde nos va mucho en ello, ¿sabes? Y ahí sí que estamos apuntando a ese tipo de metodología”. (E13)

c) Modelo Reactivo

Este tercer patrón es común en aseguradoras de tamaño reducido. En estos casos, la adopción de la inteligencia artificial no responde a un mandato explícito del plan estratégico, sino que depende principalmente del impulso personal de líderes individuales, típicamente el director general o algún directivo especialmente interesado en temas de innovación:

“Nos falta algún componente mental disruptivo dentro de la organización, no puede ser que uno de los más disruptivos sea el director general. No es bueno”. (E07)

La gobernanza suele carecer de estructuras formales. Las decisiones tienden a tomarse tras demostraciones puntuales de proveedores o startups, y los proyectos se detienen ante la mínima duda regulatoria:

“Le dije vente a la compañía y explica a todo el comité de dirección cómo lo has hecho [...] ¿Qué pasa? Que empezamos con el tema de la regulación, Oye... riesgo de que suban datos. Entonces dijimos Para, para. Vamos a organizarlo un poco”. (E09)


Además, estas organizaciones suelen tener carencia de talento especializado en tecnología en sus órganos de gobierno, lo cual complica la toma de decisiones estratégicas en este campo:

“No tengo ningún tecnológico arriba y yo lo requiero y le digo al presidente: ¡Joder! tenemos que meter a alguien de tecnología [en el consejo] a quien le podamos contar lo que hacemos, porque yo no soy experto”. (E14)

En resumen, el resultado es un modelo de avance fuertemente dependiente de personas concretas y altamente vulnerable a interrupciones o discontinuidades.


La identificación de estos tres modelos de liderazgo permite analizar cómo se distribuyen en función de las características estructurales y del grado de madurez de las aseguradoras. Con este fin, los gráficos siguientes (figura 13 y figura 14) muestran la correspondencia entre cada patrón de liderazgo y dos dimensiones clave: el tamaño y el nivel de madurez en IA (AIMM). La comparación evidencia que, aunque ambos factores se encuentran correlacionados, ofrecen perspectivas complementarias: el tamaño refleja los recursos y las presiones competitivas que condicionan la gobernanza, mientras que la madurez captura el estadio en el que se encuentra cada entidad en su trayectoria de adopción.

Figura 13: Modelos de liderazgo en la adopción de IA según la categoría de tamaño



Fuente: Elaboración propia

Figura 14: Modelos de liderazgo en la adopción de IA según nivel de madurez



Fuente: Elaboración propia

El análisis comparado de los gráficos muestra un patrón consistente: los modelos de liderazgo en la adopción de IA no se distribuyen de manera aleatoria, sino que guardan relación tanto con la escala organizativa como con el grado de madurez alcanzado en el marco AIMM. En las entidades más maduras (niveles 3–4 AIMM) y de mayor tamaño, predomina el liderazgo top-down, que asegura alineamiento estratégico, control regulatorio y estandarización de procesos. En cambio, las compañías situadas en fases intermedias de madurez tienden hacia modelos mixtos, donde la interacción entre negocio y tecnología se convierte en un mecanismo de aprendizaje organizativo. Por su parte, las entidades menos maduras (niveles 1–2 AIMM) y de menor escala dependen de un liderazgo reactivo o distribuido, fuertemente condicionado por liderazgos individuales y con estructuras de gobernanza aún incipientes. Estos resultados sugieren que la madurez actúa como variable explicativa más robusta que el tamaño, aunque ambas dimensiones se encuentran correlacionadas.

4.1.3.2. Centros de Competencia y Estructuras de Gobierno de IA

El análisis de las entrevistas pone de manifiesto la heterogeneidad en los modelos adoptados para la gobernanza y despliegue de inteligencia artificial en las aseguradoras. Aunque algunas entidades han avanzado hacia estructuras formales y transversales, otras mantienen aproximaciones más incipientes y fragmentadas, lo que refleja distintos grados de madurez organizativa.

Modelos organizativos identificados en el sector

Las tres mayores aseguradoras de la muestra han establecido Centros de Excelencia (CoE) explícitos, aunque con variaciones en cuanto a su orientación y alcance. Una de ellas ha articulado su dirección de *Data Analytics* como un CoE transversal, diseñado para centralizar demandas, priorizar iniciativas e identificar oportunidades en toda la organización mediante perfiles multidisciplinares:

“Nosotros lo que hemos intentado es que la dirección de Data Analytics, que es un poco la que conjuntamente con medios lidera todo esto, la hemos construido como un centro de excelencia que realmente da servicio a toda la organización y de alguna forma lo que hace es recabar inputs de toda la organización, de dónde vienen o a donde se va a dedicar más tiempo” (E03).

Otra entidad multinacional creó en 2024 un Centro de Inteligencia Artificial con un mandato corporativo explícito, centrado en la estandarización y la medición homogénea del retorno de la inversión:

“Hay que tener un sistema de medición homogéneo, que de eso se encarga el Centro de Inteligencia Artificial, de ponerlo en práctica. Tenemos un sistema ya, y las cosas se miden allí” (E05).

De forma similar, otra gran aseguradora ha constituido un CoE como un órgano transversal donde confluyen áreas críticas como riesgos, legal, ciberseguridad o protección de datos, con la misión de definir políticas corporativas y supervisar proyectos:

“Hemos creado lo que se llama el Centro de competencia Inteligencia Artificial, donde están representados Ciberseguridad, personas, talento y cultura, riesgos y asesoría jurídica, protección de datos, nosotros, sin olvidar algún área de estrategia. Y entonces, ahí, todas estas iniciativas se tratan ahí. [...] Y de ahí es de donde van a salir las políticas de inteligencia artificial de la compañía” (E11).

Más allá de los CoE formales, varias entidades cuentan con áreas especializadas precursoras, que ejercen funciones similares, aunque sin la denominación oficial. En un caso, se ha consolidado un área de analítica de datos con un equipo estable de veinte personas que ejecuta proyectos a lo largo del año:

“Sí que tenemos un área en concreto de analítica de datos, la llamamos analítica de datos, donde ya tenemos a 20 personas. Entonces estas 20 personas están durante todo el año haciendo proyectos concretos de mejora, con aplicación de nuevas tecnologías” (E02).

En contraste, otras compañías en etapas más tempranas mantienen la responsabilidad de la IA en los departamentos de TI, sin estructuras transversales ni metodologías compartidas:

“El que había es el que me dijo hay que montar lo de la IA. Entonces yo creo que los equipos de TI son los que tienen una capacidad más grande para entender parte de la IA. Y deben estar ahí” (E09).

Funciones de los Centros de Competencia

Del análisis de las entrevistas emergen funciones recurrentes asociadas a los CoE. La primera es la gobernanza y estandarización, especialmente en lo relativo a métricas de retorno y control de calidad:

“Hicimos 111 recuento y unas reglas de juego para medir cuál es el impacto de la inteligencia artificial en [la entidad] [...] hay que tener un sistema de medición homogéneo, que de eso se encarga el Centro de Inteligencia Artificial” (E05).

Una segunda función clave es la gestión del talento y la reducción de la dependencia de proveedores externos, evitando soluciones opacas:

“Nuestro acercamiento ahí es que esto es tan crítico que preferimos internalizar el conocimiento. [...] No ir a las empresas de nicho con estos temas porque las empresas de nicho te suelen dar su caja negra y entonces no podemos tener siete cajas negras por ahí” (E11).

Los CoE también actúan como mediadores entre negocio y tecnología, recogiendo y priorizando demandas mediante figuras intermedias como los embajadores de datos:

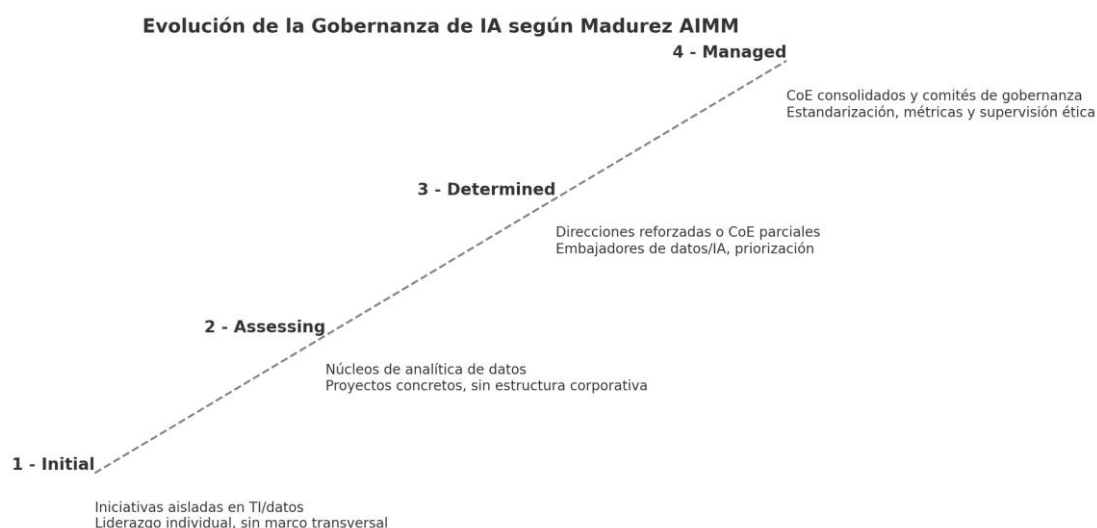
“Lo que intentamos es que cada una de las direcciones tenga como un embajador [...] que identifique realmente dónde se puedan generar las oportunidades” (E03).

Finalmente, los CoE cumplen un rol integrador al incorporar perfiles diversos — desde *data scientists* hasta expertos en negocio o legal— garantizando que los proyectos sean relevantes y conformes con la regulación:

“El perfil de gente que tienes ahí, pues son data scientist, etcétera y tal, pero tienes a dos o tres personas que conocen muy bien el negocio [...] tienes ahí un poco el match del conocimiento con la parte más puramente técnica” (E02).

Como muestra la Figura 15, el tránsito desde iniciativas aisladas hacia estructuras consolidadas de gobernanza refleja un proceso progresivo de institucionalización.

Figura 15: Evolución de la gobernanza de la IA según niveles de madurez AIMM



Fuente: Elaboración propia

4.1.3.3. Reingeniería de Procesos (BPR)

Los entrevistados coinciden en que la inteligencia artificial no debe entenderse como una mera herramienta de automatización incremental, sino como un catalizador para repensar de forma profunda los flujos de trabajo y la organización. La idea de que *“automatizar procesos obsoletos solo perpetúa y acelera los problemas de base”* (E05) está muy presente en el discurso directivo. Desde esta perspectiva, la IA se concibe como una palanca que exige un rediseño previo, no como un añadido tecnológico sobre estructuras ineficientes:

“Tiene poco sentido que yo al proceso tal y como está le meta inteligencia artificial. [...] lo lógico es que la inteligencia artificial... en el fondo lo que te permite es replantear el proceso de otra manera. [...] lo lógico es que venga precedida de un análisis de procesos y ver cómo queda el proceso después de que tú pongas inteligencia artificial en él”. (E05)

Foco en procesos de alto volumen

La priorización de ámbitos de aplicación responde a un criterio pragmático de impacto y viabilidad. Los procesos con una “masa crítica” de tareas repetitivas y personal asignado se convierten en los principales candidatos para la BPR apalancada en IA. Así lo ilustran los testimonios relativos a la tramitación de siniestros:

“¿Dónde ves el área que tienes más recorrido? En el área de siniestros [...] normalmente, hay más masa de personas”. (E08)

Por el contrario, en áreas con plantillas reducidas, como las financieras, los efectos de productividad apenas tienen reflejo en la cuenta de resultados:

“Aquí en el ámbito financiero, económico, pues es un departamento de 20 personas [...] pasar de que tengo una mejora de productividad de un 25%, cinco personas no van a ningún sitio, ¿no?, en la cuenta de resultados”. (E08)

Esta visión refuerza la idea de que el retorno de una reingeniería no depende solo de la eficiencia relativa, sino de la escala en la que se produce.

Gap tecnológico

El punto de partida tecnológico condiciona de manera crítica la profundidad del rediseño. En entidades con sistemas heredados especialmente obsoletos, la adopción ha seguido un enfoque de *clean-sheet*, saltando fases intermedias y provocando transformaciones radicales:

“Como la empresa envejece tecnológicamente. Veníamos de la prehistoria [...] hemos podido hacer pasos importantes sin necesidad de hacer pasos intermedios [...]. Vamos directamente a comprar esto, ponerlo y entonces el cambio es del día y la noche”. (E16)

IA generativa y nuevos roles

La aparición de la IA generativa amplía el ámbito tradicional de la BPR más allá de tareas transaccionales. Los directivos destacan su aplicación en procesos de carácter cognitivo, como la redacción de comunicaciones o la codificación de *software*, lo que implica un cambio en los roles laborales, que pasan de creadores a validadores:

“Con inteligencia artificial generativa, pues te puedes plantear si las cartas [...] ya podrán salir por este sistema y no necesitas tener, diríamos pues a una persona”. (E08)

Esta evolución también se observa en áreas técnicas:

“Yo puedo pensar [...] que, si ahora tengo 40 personas y me hacen tantos proyectos en un año, pues que me puedan hacer un 15% más [...]. Pero no veo tampoco que puedas prescindir de los informáticos. Imposible”. (E08)

De este modo, la IA generativa no sustituye, sino que redefine el valor del trabajo humano, obligando a rediseñar mecanismos de control, calidad y supervisión.

Metodologías de apoyo

La BPR se apoya en metodologías organizativas que buscan acelerar la adopción y reducir la resistencia interna. Varias aseguradoras han experimentado con marcos ágiles o híbridos:

“No es un Agile ortodoxo, pero sí que vamos intentando coger lo mejor de todos los mundos”. (E13)

“Lo que hemos hecho es un híbrido [...] conocemos las metodologías y vamos adaptándolas a nosotros”. (E06)

La tendencia es evitar enfoques rígidos que impliquen cambios culturales disruptivos, favoreciendo adaptaciones progresivas y contextuales.

4.1.3.4. Influencia del Tamaño

El tamaño de las entidades constituye un factor condicionante clave en la adopción de la IA al influir directamente en un conjunto de palancas fundamentales que van desde la capacidad inversora hasta la agilidad organizativa.

Capacidad Económica: Las grandes compañías disponen de una capacidad económica que les permite abordar múltiples casos de uso de manera simultánea y asimilar el coste de potenciales proyectos fallidos. Entidades de menor tamaño, en cambio, deben ser mucho más selectivas. Como describe un directivo de una entidad de tamaño mediano al compararse con los líderes del mercado:

"Es evidente que una compañía diez veces mayor tiene mucha más capacidad de invertir en tecnología, puede permitirse el lujo, además, de equivocarse y a lo mejor enterrar 20, 30, 50 o 100 millones de euros, y tampoco ha pasado gran cosa. Aquí tenemos que hilar mucho más fino, tenemos que ser mucho más escrupulosos". (E02)

Cuanto más pequeñas, más acusada es esta restricción, lo que las obliga a una selección minuciosa de proyectos y socios tecnológicos que se ajusten a su capacidad presupuestaria. Un directivo de este tipo de entidades los expresa así:

"Yo, siendo consciente de mi tamaño, tengo que definir ya solo aquellos que sí o sí puedo abordar, tanto por recursos como por como por presupuesto. Y en esos tengo que focalizarme. Y luego, como te decía antes, elegir compañeros de viaje para que sepan que mi tamaño es ese. Porque si pretendo hacerlo con los mismos consultores que las grandes, me van a vender su proyecto y yo no es el que necesito". (E10)

Volumen de Datos Disponibles: La escala también se traduce en la disponibilidad de un mayor volumen de datos de clientes y siniestros, lo que constituye una ventaja competitiva para entrenar modelos de IA más precisos. Un directivo de una entidad mediana reconoce explícitamente esta relación en el ámbito de la tarificación:

"Aquí el tamaño es realmente importante. Cuanto más tienes, más puedes segmentar y afinar la prima". (E04)

Complejidad Organizativa vs. Agilidad: Los directivos, tanto de entidades grandes como medianas y pequeñas, coinciden en que mientras las grandes compañías luchan contra la inercia que imponen sus propias estructuras, las entidades más

pequeñas gozan de mayor agilidad. Directivos de compañías pequeñas lo exponen de la siguiente forma:

"Las estructuras más livianas y más ágiles pueden ser, sabiéndolo hacer, las más beneficiadas, porque las grandes empresas, las muy grandes empresas, tienen procesos de decisión muy lentos [...] una empresa como puede ser la mía, si le pongo inteligencia a usar bien esto, puedo ser mucho más rápido y mucho más eficiente que mastodontes que mientras se lo están pensando, yo he ido y he vuelto dos veces". (E07)

"Nosotros somos una compañía pequeñita y somos capaces, a nivel de máquina, de lanzar un producto a nivel de sistemas en cuatro semanas, un producto nuevo de cero. Entonces yo hablo con una compañía grande y me dice cuatro meses para pensar el funcional". (E09)

Acceso a Proveedores y "Know-How": Las grandes corporaciones reportan ciertas ventajas en la negociación con las *Big Tech*. Un directivo de la filial de un gran grupo señala esta capacidad como un aspecto diferencial, aunque Incluso las aseguradoras más grandes a nivel nacional se perciben pequeñas en este escenario de negociación global:

"La posibilidad de entrar en acuerdos con Google, como te decía antes, o con Microsoft... Nuestra matriz es una pulga para ellos, es una auténtica pulga. Pero imagínate ir sola nuestra entidad". (E03)

Otro directivo de entidad de gran tamaño coincide:

"Para mí es muy importante estar cerca de un proveedor grande [...] pero nosotros para estos monstruos somos canijos también. O sea, España es canijo". (E11)

Umbral de Impacto: La misma mejora relativa de productividad tiene un impacto absoluto muy diferente según la escala. Un ahorro porcentualmente elevado en un equipo pequeño puede ser irrelevante en la cuenta de resultados global, lo que en muchos casos desincentiva la inversión. Un directivo de una aseguradora mediana lo ejemplifica con claridad:

"[...]Pues es un departamento de 20 personas [...] ¿Pasar de que tengo una mejora de productividad de un 25%, cinco personas no van a ningún sitio, no, en la cuenta de resultados [...] esta productividad a mí me podría dar una mejora en mi cuenta de resultados de 1 millón de euros si hago unos cálculos a trazo grueso, sencillos. No es para no dormir". (E08)

Estrategia Competitiva: La escala define el posicionamiento estratégico. Mientras los grandes sienten la exigencia (y pueden permitirse) ser pioneros, las entidades medianas adoptan una estrategia de *fast follower*, esperando a que las soluciones maduren para copiarlas de forma eficiente. Un entrevistado lo argumenta así:

"No ser el primero, sino ser capaz de copiar eso o de adoptar eso con mucha velocidad [...] la ventaja competitiva de ser muy adaptable y muy rápido en poder hacer uso de esas tecnologías y adoptarlas, pues digamos, eso es una ventaja competitiva mucho más difícil de copiar". (E01)

Autopercepción del Propio Tamaño

Del análisis de las entrevistas se desprende que los directivos perciben el tamaño de su propia entidad como fuente de ventajas, aunque reconociendo sus inconvenientes.

Grandes: Destacan su músculo financiero, la riqueza de sus datos y la capacidad para negociar con las *Big Tech* como ventajas competitivas diferenciales. Al mismo tiempo, son conscientes de que sus propias estructuras pueden resultar un lastre. Un directivo de una gran entidad admite el riesgo de ser "un poco burocráticos, un poco mastodónticos en algunos temas" (E15), lo que puede ralentizar el *time-to-market* y dar oportunidades a competidores más ágiles. Por otro lado, las filiales de grupos globales consideran una ventaja poder recibir casos de uso probados y financiados por la matriz:

"[Nuestra matriz], que tiene muchísimos más recursos de los que podamos tener nosotros, ellos están desarrollando un caso de uso que en el momento en el que lo escale vamos a poder escalar el resto de entidades". (E12)

Aseguradoras Medianas: Se autoperciben como actores con capacidad de reacción, evitando los costes y riesgos de ser los primeros. Confían en su agilidad para implementar soluciones una vez que han sido validadas por el mercado. Confían en su "*capacidad de reacción*" frente a los movimientos de los líderes. (E02). Reconocen, no obstante, una dependencia de proveedores externos y el riesgo de que el retorno de la inversión no sea suficiente en áreas con poca "masa crítica".

"Esperarás más que los consultores en la industria comiencen a desarrollarlo y después lo adoptarás [...] no vas a ser tú, diríamos, el que vayas a colonizar esto". (E08)

Aseguradoras Pequeñas: Reivindican su simplicidad y agilidad como la principal ventaja competitiva, que les permite competir en velocidad y *time-to-market*.

"Yo creo que ser pequeño en este caso es una ventaja relativa. Si somos inteligentes podemos competir de tú a tú con una grande en determinadas cosas. Pero claro, hay que saber dónde tocar la tecla". (E09)

Sin embargo, admiten las desventajas en otros ámbitos, como en atracción y retención de talento especializado y en las limitaciones presupuestarias.

"Cuesta, cuesta tener gente polivalente [...] siento la limitación de los recursos de los que dispongo para poder avanzar algunos caminos". (E07)

Análisis Cuantitativo de Resultados

Para explorar la relación entre el nivel de madurez y las características de las entidades, se construyó un conjunto de datos que combinaba la puntuación de madurez global con una estimación del tamaño de cada organización.

En este estudio se ha utilizado el volumen de negocio anual como indicador del tamaño de las aseguradoras, dado que constituye la métrica estándar del sector y un dato homogéneo y comparable entre entidades. Este indicador refleja no solo la escala comercial, sino también la capacidad de inversión en tecnología, datos y talento, factores clave para la adopción de IA. Frente a otras medidas (empleados, activos), el volumen de negocio ofrece una aproximación más fiable de la capacidad organizativa y económica para impulsar proyectos de innovación. Los datos se han obtenido a partir de registros públicos. Para mitigar la asimetría de la distribución y el efecto de casos extremos, esta variable fue transformada mediante el logaritmo natural.

Para cuantificar la relación entre madurez y tamaño, se utilizaron dos coeficientes de correlación no paramétricos:

- Rho de Spearman (r_s), que mide la fuerza y dirección de la asociación monótona entre dos variables.
- Tau de Kendall (τ), que evalúa la concordancia entre los rangos de las observaciones.

La elección de la transformación logarítmica y de coeficientes de correlación no paramétricos responde a la naturaleza de los datos y a las características de la muestra analizada.

En primer lugar, la variable tamaño de la entidad presentaba una distribución altamente asimétrica, con diferencias muy pronunciadas entre aseguradoras de gran dimensión y entidades de menor escala. Para evitar que un solo caso condicionara el análisis, se aplicó la transformación logarítmica natural. Este procedimiento “comprime” las diferencias, estabiliza la varianza y facilita la comparación entre entidades. Así, una compañía diez veces más grande no aparece desproporcionadamente sobrerrepresentada, sino que su peso relativo se reduce a una magnitud más manejable y comparable (Hair et al., 2019).


En segundo lugar, se optó por coeficientes de correlación no paramétricos — Spearman (r_s) y Kendall (τ)— debido a tres razones principales:

- El tamaño de la muestra ($N = 16$) es reducido, lo que limita la validez de técnicas paramétricas más exigentes.
- El nivel de madurez corresponde a una escala ordinal (1–5), que refleja posiciones relativas más que distancias métricas exactas.
- Los datos de tamaño, incluso tras la transformación logarítmica, no presentan una distribución normal.

El coeficiente de Spearman permite verificar si los rankings de las entidades por tamaño y madurez son consistentes, mientras que el coeficiente de Kendall compara cada par de entidades para determinar si, en la mayoría de los casos, la organización de mayor tamaño es también la más madura en IA. El uso complementario de ambos índices aporta robustez y triangulación metodológica, aumentando la fiabilidad de las conclusiones (Gibbons & Chakraborti, 2011). Los resultados de este análisis estadístico confirma de manera robusta la existencia de una relación positiva y significativa entre el tamaño de la entidad y su nivel de madurez en inteligencia artificial. Los coeficientes no paramétricos muestran asociaciones consistentes: Spearman $r_s = 0,74$ ($p = 0,0011$) y Kendall $\tau = 0,62$ ($p = 0,0024$), lo que refleja una correlación alta y estadísticamente significativa.

La Figura 16 representa gráficamente la relación entre el tamaño de las entidades (medido como logaritmo natural del volumen de negocio anual) y su nivel de madurez en inteligencia artificial según el modelo AIMM. Cada punto corresponde a una entidad, diferenciada además por categoría de tamaño (micro, pequeña, mediana, grande y mega). La línea de tendencia confirma la asociación positiva detectada en el análisis estadístico: a mayor volumen de negocio, mayor nivel de madurez en la adopción de IA. Esta visualización permite apreciar de forma clara cómo las entidades de mayor escala tienden a situarse en niveles superiores de madurez, mientras que las de menor tamaño se concentran en los niveles iniciales o intermedios.

Figura 16: Relación entre tamaño de las entidades y nivel de madurez en IA (AIMM)



Fuente: Elaboración propia

Con el objetivo de reducir la heterogeneidad extrema de la muestra con órdenes de magnitud distintos en volumen de negocio y permitir comparaciones significativas entre entidades en el presente estudio se han establecido cinco tramos de volumen (expresado en millones de euros de negocio anual) definidos de la siguiente forma:

- **Micro (<50 M€):** Entidades muy pequeñas, fundamentalmente mutualidades profesionales o compañías de nicho, cuya capacidad inversora es limitada. En este grupo se sitúan organizaciones donde la IA apenas se explora mediante pilotos y PoCs aislados.
- **Pequeña (50–300 M€):** Aseguradoras con cierta escala pero aún restringida, capaces de sostener inversiones selectivas en tecnología, pero con fuerte dependencia de la eficiencia en costes y prudencia en sus decisiones estratégicas.
- **Mediana (300–1.000 M€):** Entidades de tamaño intermedio, a menudo especializadas en determinados ramos (salud, autos, multirriesgo), con recursos suficientes para desplegar proyectos estructurados de IA, aunque sin la diversificación y músculo financiero de los grandes grupos.
- **Grande (1.000–5.000 M€):** Aseguradoras nacionales de gran tamaño o filiales de grupos internacionales con un peso significativo en el mercado español. Suelen contar con infraestructuras de datos más avanzadas,


gobernanza corporativa formalizada y capacidad para desplegar iniciativas de IA a escala transversal.

- **Mega (>5.000 M€):** Compañías líderes por volumen en el mercado español, incluyendo tanto grandes multinacionales como aseguradoras con fuerte integración en la banca. Su tamaño les permite contar con centros de competencia en IA, inversión continuada en infraestructura y colaboración estrecha con proveedores globales.

La clasificación micro–pequeña–mediana–grande–mega no pretende replicar exactamente las categorías regulatorias o contables (p. ej. Solvencia II), sino construir un marco operativo adaptado a la realidad de la muestra, que facilite la interpretación comparativa del grado de madurez en inteligencia artificial.

La Figura 17 presenta la madurez media en inteligencia artificial (según el modelo AIMM) para cada categoría de tamaño de entidad.

Figura 17: Madurez promedio AIMM por categoría de tamaño de entidad



Fuente: Elaboración propia

Tal y como se observa en el gráfico, la distribución de la madurez promedio por categorías de tamaño refuerza la conclusión sobre la relación positiva entre tamaño y madurez en la adopción de IA. Las entidades micro (< 50 M€) apenas alcanzan un nivel medio de 1,5, mientras que las pequeñas (50–300 M€) y medianas (300–1.000 M€) se sitúan en torno a 2,5. En el caso de las grandes (1.000–5.000 M€), la madurez

media asciende a 3,4, y las entidades mega (> 5.000 M€) alcanzan un promedio de 3,7, próximo al nivel Managed. El patrón evidencia, por tanto, una relación ascendente clara, que confirma que las aseguradoras de mayor escala tienden a situarse en fases más avanzadas de adopción de IA.

No obstante, este efecto no es determinista. El análisis cualitativo revela excepciones relevantes: algunas entidades pequeñas y medianas logran avanzar hasta niveles intermedios gracias a estrategias ágiles y un enfoque en casos de uso específicos, mientras que ciertas entidades grandes todavía no han consolidado plenamente estructuras de gobernanza y cultura de IA, lo que limita su progreso hacia etapas superiores.

4.1.3.5. Modelo Operativo (por producto, transversal, etc.)

El análisis de las entrevistas revela que la adopción de la inteligencia artificial no se despliega sobre una única lógica organizativa, sino que se combinan enfoques tradicionales con otros por producto y con estructuras más transversales y ágiles. La elección de un modelo responde a factores como el tamaño y grado de madurez tecnológica y cultural de cada entidad.

Metodologías Ágiles

Varios directivos subrayan que la única manera de reducir significativamente los plazos de entrega de proyectos es abrazar metodologías ágiles. En palabras de un entrevistado:

“al final la forma de disminuir el time to market. Solo hay una forma que es que ya está inventada, que se llama Agile” (E01).

Esta visión sitúa la agilidad no como una moda, sino como condición estructural para poder absorber tecnologías disruptivas como la IA.

De estructuras funcionales a equipos transversales

El paso de modelos en cascada hacia esquemas de colaboración interdisciplinar es un patrón recurrente. Un directivo reconoce que

“si yo voy a implementar inteligencia artificial, no tiene mucho sentido que nos reunamos los típicos grupos en cascada... lo lógico es que los equipos que están implantando inteligencia artificial trabajen en Agile” (E05).

Este tránsito implica, en la práctica, reorganizar espacios y dinámicas:

“tenemos a los de tecnología, los de negocio que se sientan físicamente juntos y cada vez más trabajamos en proyectos en los cuales hay una ubicación única” (E03).

Trabajo por producto frente a proyectos acotados

Algunas aseguradoras están reemplazando la lógica de proyectos aislados por estructuras permanentes en torno a productos o líneas de negocio. Según un directivo:

“trabajar por proyecto... cuesta un dineral montar un equipo de ocho personas... y si cada proyecto lo matas, siempre estás creando equipos nuevos. Entonces trabajas por producto” (E12).

Este modelo se apoya en la co-ubicación continua de equipos de datos y negocio, lo que evita el desfase entre requerimientos iniciales y resultados entregados:

“estamos permanentemente pegados a ellos... como tenemos mucha interacción, las pérdidas de tiempo son de dos semanas, no de seis meses” (E12).

Comités de innovación y fórmulas híbridas

Otros entrevistados destacan la creación de espacios transversales como los comités de innovación, que actúan como foros para canalizar demandas diversas:

“ahora mismo, tal y como está organizada la empresa, también están Marketing, Recursos Humanos... y otras áreas que participan... y creo que tiene mucho sentido, porque todo esto también impacta en estrategia y en cliente” (E07).

Esta lógica híbrida se combina con roles de “embajadores de datos/IA” que permiten traducir las necesidades de negocio en casos de uso concretos (E03).

Retos de coordinación y tensiones prácticas

Si bien la transversalidad permite integrar perspectivas, también introduce complejidad en la toma de decisiones. Un entrevistado lo ilustra con franqueza:

“cuando metes a colaborar en estos proyectos transversales a 15 que opinen, joder, no hay forma de que salga un consenso rápido” (E14).

Estas tensiones reflejan que el cambio hacia modelos transversales exige no solo nuevas metodologías, sino también una redefinición de los procesos de decisión.

Adaptaciones al tamaño y modelo de negocio

El modelo operativo adoptado está condicionado por la escala de la entidad y su lógica de distribución. Compañías más pequeñas tienden a mantener estructuras internas reducidas, como destaca un directivo:

“en una entidad pequeña, 25 personas en el área tecnológica son mucha gente para pensarlo un poco” (E16).

Por otro lado, aseguradoras con fuerte peso en canales mediados reconocen que el grado de aplicabilidad de modelos como el pricing dinámico depende de la idiosincrasia del canal y del producto:

“en mi modelo de negocio no tiene sentido un pricing dinámico... en los mundos digitales de seguros por internet de coches sí que tiene mucha implicación” (E09).

Evolución de los modelos operativos según el nivel de madurez en IA

La evidencia recogida en las entrevistas muestra que la adopción de la inteligencia artificial se despliega sobre modelos operativos diferenciados, cuya configuración varía en función del nivel de madurez alcanzado por cada organización. Desde estructuras funcionales dependientes y poco sistematizadas en estadios iniciales, hasta esquemas transversales por producto en niveles más avanzados, se observa una progresión que combina lógicas tradicionales con fórmulas híbridas y, finalmente, con estructuras ágiles consolidadas. Esta evolución refleja cómo la complejidad organizativa y el grado de institucionalización de la IA determinan no solo la velocidad de despliegue, sino también la forma de coordinar recursos, integrar negocio y tecnología, y priorizar casos de uso. La tabla 19 sintetiza los modelos operativos predominantes identificados en cada nivel de madurez AIMM.

Tabla 19: Evolución de los modelos operativos según el nivel de madurez

Nivel AIMM	Modelos operativos predominantes
1 – Initial	Modelo funcional dependiente → Estructuras clásicas basadas en funciones, con fuerte dependencia de proveedores externos. Los procesos carecen de metodologías formales, presentan baja sistematización y elevada fragmentación, lo que ralentiza la ejecución de proyectos.
2 – Assessing	Modelo híbrido incipiente → Persistencia de silos funcionales, pero con primeras experiencias en dinámicas ágiles y transversales. Se introducen mecanismos de automatización parcial en procesos clave (p. ej., motores de decisión), mientras que los casos complejos se derivan a expertos. Se registran intentos de transversalidad, aunque las dificultades para alcanzar consensos ralentizan los avances.
3 – Determined	Modelo híbrido estructurado → Configuraciones intermedias que combinan prácticas ágiles con estructuras tradicionales. Algunas organizaciones implementan marcos adaptados (p. ej., versiones simplificadas de SAFe) y otras promueven una colaboración más estrecha entre negocio y tecnología. Conviven procesos digitalizados con prácticas manuales, reflejando un estadio de transición organizativa.
4 – Managed	Modelo transversal por producto → Predominan estructuras avanzadas que organizan equipos estables alrededor de productos o líneas de negocio. Estos equipos integran datos y negocio en ciclos de retroalimentación continua, apoyados en esquemas de tribus o squads multidisciplinares. El <i>backlog</i>

Nivel AIMM	Modelos operativos predominantes
	dinámico facilita la priorización flexible. Este enfoque se aplica especialmente a proyectos transformacionales, aunque su alto consumo de recursos obliga a focalizarlo en iniciativas estratégicas.

Fuente: Elaboración propia

4.1.3.6. Complejidad organizativa

El análisis de las entrevistas revela que la complejidad estructural y operativa constituye un factor determinante en el ritmo y la forma de adopción de la inteligencia artificial en el sector asegurador español.

Coordinación en grupos multinacionales y estructuras híbridas

Las compañías integradas en grupos con estructuras corporativas complejas —por ejemplo, alianzas banco-aseguradora o filiales multinacionales— enfrentan un reto adicional de coordinación. Las decisiones estratégicas, las arquitecturas tecnológicas y los tiempos de despliegue quedan sujetos a dinámicas compartidas que pueden ralentizar la innovación. Como se señalaba en una entrevista:

“Es extraordinariamente difícil, extremadamente difícil, conseguir disminuir el time to market. [...] en algunas cosas tu socio es infinitamente más rápido y en otras cosas, tú eres infinitamente más rápido” (E01).

Esta dependencia genera tensiones que limitan la agilidad y obligan a un delicado equilibrio entre prioridades locales y corporativas. La cuestión de la relación entre la matriz y las filiales como factor que condiciona el ritmo y el alcance de la adopción de IA será abordada con mayor detalle en el apartado siguiente.

Complejidad de la cadena de valor aseguradora

La cadena de valor del negocio asegurador es larga, fragmentada y muchas veces, compleja. Esto dificulta la adopción de soluciones *end to end* basadas en IA. Mientras que en el sector financiero han surgido *FinTech* capaces de disrumpir áreas completas, en seguros la especialización de las *InsurTech* se limita a eslabones concretos:

“Yo todavía no he sido capaz de identificar una InsurTech [...] que cubra la totalidad de la cadena de valor del negocio asegurador” (E02).

Esta amplitud y heterogeneidad obliga a priorizar ámbitos de alto volumen y menor complejidad —como siniestros o *Back-office*—, mientras que los procesos especializados avanzan más lentamente.

Sistemas heredados y rigidez organizativa

La presencia de sistemas *legacy* y estructuras organizativas tradicionales refuerza la complejidad interna y eleva las barreras a la adopción. En algunos casos, la existencia de múltiples silos de datos y la rigidez en los modelos de gestión frenan la capacidad de transformación:

“Es una empresa con mucho legacy, muchísimos datos en silos y cuesta mucho poner orden a los datos” (E11).

Frente a ello, algunas entidades han optado por reorganizar sus equipos “por producto” o trabajar con metodologías ágiles adaptadas, intentando compensar la lentitud de los procesos en cascada:

“Intentamos huir del concepto de proyecto [...]. Siempre estás creando equipos nuevos. [...] Nosotros trabajamos por producto” (E11).

Gestión de recursos y frentes simultáneos

La complejidad también se traduce en sobrecarga de proyectos y dispersión de esfuerzos. Cuando las organizaciones abren múltiples frentes simultáneos, la capacidad de dedicación plena a la IA se reduce de manera significativa:

“Si tú abres muchos frentes, todos avanzan despacio [...]. Cuando concentras recursos en un proyecto, el proyecto sale como un cohete” (E09).

Impacto de la complejidad en la velocidad de adopción

Los directivos reconocen que la complejidad inherente al sector y a sus propias estructuras ralentiza el proceso de adopción de IA, alejándolo de las visiones disruptivas a corto plazo:

“Tenemos tal complejidad de procesos que hay que revisarlos [...]. Es un trabajo de trimestres y en algunos casos de años [...]. Yo pondría el horizonte en 2030, no en 2025” (E15).

No obstante, se reconoce que esta misma complejidad también genera oportunidades de escala, especialmente en procesos masivos como siniestros, donde la adopción de IA puede multiplicar su impacto.

4.1.3.7. Relaciones Grupo-Filial

Tal y como se ha apuntado anteriormente, el análisis de las entrevistas indica que la relación entre la matriz y las filiales es un factor que condiciona el ritmo y el alcance del proceso de adopción de IA. También tiene implicaciones en la definición del marco de gobernanza, el acceso a recursos y la propia cultura innovadora de las subsidiarias.

Los directivos de entidades que forman parte de grupos coinciden en que el impulso inicial para la adopción de IA emana directamente de la cúpula directiva del grupo. Este mandato corporativo genera una sensación de urgencia en toda la organización. Este enfoque top-down asegura el alineamiento y la asignación de recursos. Sin embargo, también introduce tensión sobre las filiales aseguradoras, que deben adaptar presupuestos y planes estratégicos para cumplir con las expectativas corporativas:

"Esto es un top down. Del propio CEO del grupo. [...] Se ha montado una organización a nivel grupo. Mensualmente nos dicen dónde estamos, en qué estamos invirtiendo, qué va a escalar, qué no va a escalar, cómo ajustan los modelos. Esto nos obliga a nosotros, nos obliga. Entonces no lo teníamos en el plan estratégico [...] y ahora resulta que tenemos que identificar inversiones adicionales". (E12)

La pertenencia a un grupo proporciona acceso a economías de escala, facilitando el acceso a recursos que serían inaccesibles para una filial de forma aislada. Esto incluye infraestructuras tecnológicas, talento especializado y poder de negociación. Por ejemplo, en varios casos, la creación de plataformas seguras de IA generativa es una inversión que ha sido asumida por la matriz:

"El grupo decidió con bastante buen criterio. Esto es una oportunidad, pero hay que hacerlo de manera segura. Creamos un GPT en un entorno seguro para el Grupo. Ya está, se acabó. Es una inversión que ha hecho el grupo importante". (E12)

"Nuestra matriz, que tiene muchísimos más recursos de los que podamos tener nosotros, ellos están desarrollando un caso de uso que en el momento en el que lo escale vamos a poder escalarlo el resto de entidades, por ejemplo". (E12)

El Grupo funciona como un laboratorio distribuido. Los casos de uso exitosos desarrollados en una filial pueden ser transferidos y escalados al resto del grupo, reduciendo significativamente los costes y la curva de aprendizaje. Incluso las filiales pequeñas pueden actuar como abanderados para el grupo:

"Hablamos con grupo y decidimos hacer una prueba de concepto a nivel de grupo. La prueba de concepto nos toca hacerla a nosotros, por fortuna. Y entonces estaban buscando casos de uso". (E09)

La capacidad de negociación con los gigantes tecnológicos (*Big Tech*) se ve reforzada gracias a la pertenencia al Grupo. Una filial, por sí sola, difícilmente tiene poder de negociación, pero como parte de un conglomerado, su posición cambia substancialmente:

"La posibilidad de entrar en acuerdos o con Google, como te decía antes, o con Microsoft [...] el grupo sí tiene peso. [...] ir nosotros solos somos es una pulga. Para ellos es una auténtica pulga. [...] eso nos da muchísima potencia". (E03)

Si bien la pertenencia a un grupo aporta acceso a economías de escala, también conlleva fricciones operativas. La heterogeneidad de los sistemas heredados entre países y la necesidad de alinear diferentes ritmos y prioridades actúan como frenos a la adopción:

"El problema es que... que es extraordinariamente, extraordinariamente difícil, conseguir disminuir el time to market. ¿Por qué? Porque en algunas cosas tu socio es infinitamente más rápido y en otras cosas, tú eres infinitamente más rápido". (E01)


4.1.4. Implementación y gestión del cambio

La adopción de inteligencia artificial depende, en gran medida, de cómo las organizaciones planifican, gobiernan y acompañan el proceso de cambio que conlleva su implementación. Las entrevistas realizadas ponen de manifiesto que la IA se introduce en un entramado organizativo complejo, donde conviven tensiones entre urgencia tecnológica y prudencia inversora, resistencias culturales y la necesidad de asegurar retornos tangibles.

En este sentido, los directivos coinciden en que la implementación de IA debe gestionarse para avanzar lo suficientemente rápido para no quedar rezagados, pero con la cautela necesaria para garantizar control, legitimidad y alineamiento con el modelo de negocio.

La Figura 18 muestra la distribución de entrevistas y referencias por subcategorías, lo que permite identificar los ejes con mayor presencia en el discurso directivo. Destacan especialmente la planificación y gobernanza del cambio y el enfoque incremental de despliegue (piloto-escalado), seguidos de la relación con proveedores y consultoras y de los métodos de priorización y evaluación de casos. En menor medida, los entrevistados hicieron referencia al acompañamiento a empleados y a la gobernanza de modelos, aunque ambos apartados resultan relevantes para asegurar la sostenibilidad del proceso de transformación.

Figura 18: Distribución de entrevistas y referencias por subcategorías de implementación y gestión del cambio



Fuente: Elaboración propia

4.1.4.1. Planificación y gobierno del cambio

Las entrevistas evidencian un patrón común: las compañías no conciben la IA como una disrupción inmediata que requiera una transformación radical, sino como una

tecnología que debe integrarse de forma ordenada en el marco de planificación corporativa, con tensiones entre la urgencia percibida y la prudencia inversora.

Un primer aspecto destacado es la importancia de la agilidad organizativa como ventaja competitiva. Como señaló un directivo, la clave no es tanto ser el primero en implantar la IA, sino preparar la organización para reaccionar rápidamente:

“Yo creo que es tener tu organización preparada para ser los más ágiles, para que cuando realmente veas: “oye, esto se está produciendo o tenemos este ideal”, hacer una adopción muy rápida, casi frictionless. [...] No sé si lo más importante es ser el primero, sino ser capaz de copiar eso o de adoptar eso con mucha velocidad, porque esa ventaja competitiva de ser muy adaptable y muy rápido en poder hacer uso de esas tecnologías [...] es mucho más difícil de copiar” (E1).

En paralelo, varias entidades reconocen que la sensación de urgencia no viene de la propia existencia de la tecnología, sino de problemas de negocio concretos que la IA podría resolver. En palabras de un entrevistado:

“Yo no creo que la sensación de urgencia venga por la existencia de la tecnología. Yo creo que la sensación de urgencia viene porque tienes un problema que necesitas resolver y eso te sirve para resolverlo” (E1).

No obstante, otros subrayan la urgencia cultural de preparar a la organización para la transversalidad de la IA:

“Yo creo que es una revolución que nos va a afectar a todo lo que hacemos. [...] Es urgente en el sentido de que es necesario que culturalmente en la organización se genere esa sensibilidad, esa curiosidad que requiere una comprensión previa de dónde están las oportunidades” (E3).

El segundo elemento central es la planificación estructurada de la adopción. En los niveles más avanzados de madurez (Managed), esta planificación se traduce en metodologías formales de priorización, hojas de ruta dinámicas y centros de excelencia que canalizan las iniciativas. Así lo describía un directivo de una gran aseguradora:

“Lo que hemos puesto es una metodología que en función de determinados parámetros te dice: oye, deberías de priorizar este caso de uso. [...] Lo que hemos hecho es ordenar el tráfico y la priorización. [...] Y ahí es donde van a salir las políticas de inteligencia artificial de la compañía” (E5).

Incluso en entidades más pequeñas, la planificación aparece como un elemento clave, si bien con recursos más limitados. Un entrevistado destacaba la importancia de concentrar esfuerzos:

“Si tú abres muchos frentes, todos avanzan despacio porque cada persona tiene que atender siete cosas. Cuando tú abres un proyecto y concentras recursos en ese proyecto, va como un cohete. [...] Si yo tengo a la gente haciendo 50 cosas,

avanzamos como los ejércitos de Napoleón en el invierno ruso, a paso de tortuga” (E13).

En este marco, la gobernanza del cambio emerge como disciplina crítica. Varias aseguradoras han creado comités de innovación o centros de competencia donde se definen prioridades y se ordenan las iniciativas. En palabras de un directivo:

“Soy el encargado de intentar implementar la inteligencia artificial. Pensé en varios casos de uso, los pasé a mi responsable de estrategia y organización, que se ocupa del tema, y lo compararon con otros casos. [...] Luego los discutimos en el comité de innovación” (E9).

El modelo de gobernanza también se ha sofisticado en las grandes entidades, que combinan órganos formales de decisión con marcos metodológicos y roles definidos:

“Hemos hecho un tema conceptual, aclarar quién hace qué. [...] Tenemos todo un diccionario muy estándar para que todo el mundo, cuando uno habla de redes neuronales o de machine learning, esté hablando de lo mismo. [...] El gobierno está ya caminando y está muy, muy determinado” (E5).

Finalmente, los entrevistados subrayan que la gobernanza del cambio debe integrar no solo la dimensión operativa y económica, sino también las implicaciones regulatorias y éticas. La preocupación por la trazabilidad de las decisiones algorítmicas se refleja en varios testimonios:

“Lo que nos preocupa es ser capaces de explicar por qué la caja negra ha generado un resultado. [...] Ese es uno de los grandes retos de toda la inteligencia artificial” (E11).

4.1.4.2. Enfoque Incremental

El análisis de las entrevistas muestra que la implementación de la inteligencia artificial en el sector asegurador español sigue de forma recurrente un enfoque incremental. La secuencia prueba de concepto (PoC) → piloto → despliegue a escala aparece como patrón transversal, especialmente en un contexto en el que persisten dudas sobre el retorno, la gobernanza de datos y la capacidad organizativa. Este enfoque permite gestionar el riesgo de inversión, validar hipótesis y ajustar la tecnología antes de institucionalizarla.

Pruebas de concepto (PoC): aprendizaje y experimentación

Las PoC se conciben como ejercicios exploratorios cuyo objetivo no es tanto el retorno inmediato como el aprendizaje organizativo. Un directivo lo expresó con claridad:

“Hay que empezar a entender que los modelos de negocio evolucionan y por lo tanto como evolucionan. Hay que probar cosas nuevas y no todo lo que pruebes

va a tener un retorno positivo [...] el objetivo es aprender, no el retorno económico” (E09).

Estas pruebas suelen realizarse en entornos controlados, evitando la exposición directa a clientes y limitando el uso de datos sensibles. Así lo describe otro entrevistado:

“No queríamos subir datos de cliente de ningún tipo. [...] Vamos a meterle mucho contenido y vamos a preguntar para ver qué tipo de respuestas da y ver si esto luego en un futuro lo podemos hacer para consulta del equipo de tramitación, no para el cliente final” (E09).

La filosofía de “probar con gaseosa” es recurrente:

“No somos de grandes disrupciones, somos más bien de evoluciones. [...] Hacemos siempre experimentos con gaseosa, vale. Así que probamos mucho las cosas con pilotos” (E02).

Pilotos: validación y ajuste

Superada la fase inicial, los pilotos permiten comprobar la viabilidad técnica y, sobre todo, el grado de ajuste de los modelos a la práctica de negocio. La validación suele hacerse en paralelo con la operativa humana para verificar consistencia:

“El piloto se hace básicamente por dos motivos. Primero, para ver cómo el modelo ajusta. [...] Durante la fase de piloto hay una persona que lo está haciendo con el modelo para asegurar que eso tiene sentido” (E08).

La función de los pilotos no es solo tecnológica, sino también organizativa: facilitan la aceptación interna y preparan el terreno para el cambio cultural. Como ilustró un directivo, esta etapa implica comunicar de forma explícita a la plantilla que se trata de proyectos exploratorios y no de sustitución inmediata:

“Nosotros cada mes tenemos una video, explicamos cómo ha ido el cierre del mes [...] y decimos: estamos haciendo una prueba de concepto con inteligencia artificial. Esto no es para quitar puestos, es para entender cómo funciona” (E09).

Escalado: institucionalización y despliegue

El escalado marca la transición de la experimentación al impacto operativo. Solo se produce cuando los pilotos han demostrado resultados tangibles en eficiencia o experiencia del cliente:

“Tú no lo escalas hasta que no ves cuáles son los beneficios que tienes en el piloto” (E08).

Ejemplos de despliegue exitoso incluyen la automatización de procesos de siniestros o el uso de IA en canales de atención masiva. Como señaló un entrevistado:

“Toda la parte de voz y de consultas [...] en diez meses 1.200.000 chats gestionados por inteligencia artificial. [...] Eso tiene un potencial enorme, pero no puede quedar simplemente como una prueba de concepto; tiene que ser escalable” (E13).

En compañías más avanzadas, la IA ya ha dejado de ser un experimento para convertirse en parte estructural de la operativa, con decenas o incluso centenares de modelos desplegados en producción:

“No son solo pruebas de concepto [...] tenemos más de 100 modelos puestos en producción” (E11).

La adopción incremental responde a la necesidad de conciliar ambición y prudencia. Permite incorporar aprendizajes, gestionar resistencias internas y garantizar que cada avance se alinea con las capacidades de datos, la infraestructura tecnológica y el plan estratégico. En palabras de un directivo:

“En IA, no se hacen megaproyectos, sino que se comienza a focalizar en un punto concreto y se le da mucha intensidad en algo muy específico” (E07).

La Tabla 20 sintetiza las características principales de cada fase, sus funciones específicas, los riesgos o limitaciones asociados y ejemplos de citas representativas de los directivos entrevistados.

Tabla 20: Fases de adopción de la IA en aseguradoras españolas: PoC, piloto y escalado

Fase	Funciones principales	Riesgos / limitaciones	Ejemplos de citas (ID)
Prueba de Concepto (PoC)	<ul style="list-style-type: none"> - Explorar viabilidad técnica en entornos controlados. - Aprender sobre capacidades y límites de la IA. - Identificar potenciales casos de uso sin comprometer la operativa. 	<ul style="list-style-type: none"> - Falta de retorno económico directo. - Riesgo de proyectos “en cajón” sin continuidad. - Uso restringido de datos para evitar riesgos legales o reputacionales. 	<p>“El objetivo es aprender, no el retorno económico” (E09).” No queríamos subir datos de cliente de ningún tipo [...] buscamos casos que tuvieran sentido” (E09).” Esto va de probar” (E09).</p>
Piloto	<ul style="list-style-type: none"> - Validar resultados en entornos limitados. - Medir ajuste de modelos frente a operativa real. - Generar 	<ul style="list-style-type: none"> - Costes elevados de pruebas sin escalabilidad. - Expectativas frustradas si los modelos no alcanzan precisión suficiente. - Posible 	<p>“El piloto se hace [...] para ver cómo el modelo ajusta. [...] Hay una persona que lo está haciendo con el modelo para asegurar que eso tiene sentido” (E08).” Estamos haciendo una prueba de concepto [...] Esto no</p>

Fase	Funciones principales	Riesgos / limitaciones	Ejemplos de citas (ID)
	aceptación interna y preparar el cambio cultural.	resistencia interna por miedo a sustitución.	es para quitar puestos, es para entender cómo funciona” (E09).
Escalado	<ul style="list-style-type: none"> - Integrar casos de uso validados en procesos de negocio. - Estandarizar y controlar resultados a gran escala. - Transformar la IA en capacidad estructural de la organización. 	<ul style="list-style-type: none"> - Riesgo de complejidad en integración con sistemas <i>legacy</i>. - Necesidad de infraestructura y gobierno de datos sólidos. - Exigencia de métricas homogéneas para justificar inversión. 	<p>“Tú no lo escalas hasta que no ves cuáles son los beneficios que tienes en el piloto” (E08).” En diez meses, 1.200.000 chats gestionados por inteligencia artificial” (E13).”</p> <p>Tenemos más de 100 modelos puestos en producción” (E11).</p>

Fuente: Elaboración propia

4.1.4.3. Métodos de Priorización y Evaluación de Casos

El análisis de las entrevistas muestra que las aseguradoras españolas no abordan la adopción de la inteligencia artificial como un proceso indiscriminado de incorporación tecnológica, sino que desarrollan mecanismos explícitos de priorización y evaluación de casos de uso. Estos métodos combinan criterios de madurez tecnológica, coste-beneficio, impacto esperado en el negocio, y alineamiento estratégico con las prioridades corporativas. La diversidad de aproximaciones refleja distintos niveles de institucionalización: desde comités estructurados con metodologías formales hasta procesos más pragmáticos y basados en la experiencia.

Madurez tecnológica y momento de adopción

Un criterio recurrente es el análisis del grado de madurez de la tecnología. La experiencia previa con innovaciones que no llegaron a consolidarse (como *Blockchain*) ha llevado a los directivos a evaluar cuidadosamente el “timing” de cada tecnología antes de decidir su implantación:

“¿Cuál es el grado en el que se encuentra cada una de esas tecnologías? [...] hay algunas que aparecen de manera novedosa y luego desaparecen para siempre o no alcanzan el grado de brillantez que parecía que tenían. Ese es uno de los elementos: ¿en qué momento de madurez se encuentra esa tecnología?” (E01).

En este sentido, varios entrevistados destacan la importancia de esperar a que las soluciones alcancen una solidez suficiente, evitando inversiones prematuras que no generen retorno:

“Estaremos atentos a estos paquetes cuando veamos que están maduros y a unos precios económicos, y entonces los implantaremos” (E02).

Evaluación coste-beneficio y retorno esperado

El análisis económico constituye un filtro central. Muchas entidades descartan proyectos de IA si no se justifica un retorno tangible, incluso cuando la tecnología es prometedora:

“En el ámbito del fraude vimos algunas soluciones [...]. Hicimos el caso de negocio y la rentabilidad que se suponía que tenía la solución por la inversión que hacíamos no nos salía. Lo evaluamos y lo dejamos en suspenso” (E02).

Este pragmatismo se extiende también a la escala del impacto esperado:

“Los primeros casos de uso nos dan un cierto margen, pero no nos cambian la cuenta de resultados. [...] Yo les exijo impacto. Les devolví todas las iniciativas y les hice recomenzar el proceso porque quería más potencia” (E15).

Otras entidades, sin embargo, reconocen que incluso proyectos con retornos modestos pueden ser valiosos si contribuyen al aprendizaje organizativo y a preparar a la compañía para una futura adopción más amplia:

“Sabemos que independientemente de que te dé o no un retorno o un payback determinado, hay un intangible: formar a la organización alrededor de una tecnología que sí estamos convencidos de que formará parte de nuestro negocio en el medio plazo” (E03).

Metodologías de filtrado y comités de decisión

En varias aseguradoras se han creado mecanismos formales para comparar, filtrar y priorizar casos de uso. Estos incluyen tanto metodologías de *scoring* como comités de innovación:

“Pensé en varios casos de uso, los pasé a mi responsable de estrategia y organización, que los comparó con otros, y les pedí que añadieran un análisis de coste-beneficio. [...] En el comité, cada uno evalúa y luego quizá se descarta. Por ejemplo, el Blockchain lo analizamos y lo descartamos” (E06).

En los grupos multinacionales, esta priorización se refuerza con sistemas de clasificación corporativa que segmentan los proyectos en función de su riesgo o encaje regulatorio:

“En función de la regulación existente, cómo se clasifican, si es rojo, amarillo o verde [...]. Esta parte de supervisión está llegando incluso antes que el caso de uso con impacto real” (E01).

Impacto en negocio y alineamiento estratégico

Otro criterio clave es el impacto esperado en las áreas críticas del negocio. Los directivos subrayan que la IA se prioriza en procesos de gran escala o en ámbitos directamente vinculados a la eficiencia y la competitividad:

“Hay una parte de gastos donde la IA tendrá un gran impacto, sobre todo en áreas transaccionales o de procesos masivos. Y luego está la otra parte, que es la siniestralidad [...]. Aquí veo mucho recorrido en detección de fraude y en la capacidad de identificar proporcionalidad y equidad” (E06).

Asimismo, la selección de casos de uso no se limita a la eficiencia, sino que busca alinear la IA con los objetivos estratégicos de producto e innovación:

“Las hemos integrado porque creíamos que eran críticas para el futuro de la compañía [...]. Ha habido seis o siete grupos dentro de la organización que han priorizado iniciativas para los próximos 12–18 meses” (E15).

Alocación selectiva de recursos

Finalmente, la disponibilidad limitada de recursos obliga a muchas aseguradoras a aplicar criterios de estricta selectividad. Este pragmatismo se traduce en descartar proyectos con retorno incierto o que saturen la capacidad organizativa:

“Los recursos no son ilimitados y no se puede ir a todo a la vez. [...] Me gusta que las cosas estén contrastadas. [...] Hacemos experimentos con gaseosa” (E09).

Otros directivos insisten en que la selección debe guiarse por problemas concretos del negocio, no por la promesa abstracta de la tecnología:

“¿Cuál es tu problema? ¿Qué es lo que quieres solucionar? [...] Si mi problema es que el equipo pasa demasiado tiempo buscando la información de la póliza, busquemos algo que lo agilice. Que tenga IA perfecto, que no la tenga, tampoco pasa nada” (E10).

La Tabla 21 sintetiza los principales factores identificados, sus subfactores asociados, el grado de consenso entre los entrevistados y citas representativas que ilustran cómo se articulan estos procesos en la práctica.

Tabla 21: Factores de priorización y evaluación de casos de uso de IA en aseguradoras españolas

Factor principal	Subfactor identificado	Nº de entrevistas	Nº de referencias	Cita representativa
Factores económicos y de impacto en negocio	Análisis coste–beneficio / ROI	6	9	“Podía ser un caso interesante, pero no era suficientemente interesante en términos de coste–beneficio” (E01)
	Impacto esperado en negocio	5	8	“Les devolví todas las iniciativas... quería más impacto, no este circo para 2 millones de euros” (E15)
Criterios operativos y estratégicos	Eficiencia operativa (procesos masivos)	4	6	“En siniestros con 50 o 60 personas, sí tiene sentido aplicar IA; en fraude no salía el retorno” (E02)
	Selección estratégica / alineamiento con prioridades	4	6	“Tenemos una lista tan larga que priorizamos proyectos <i>Tier 1</i> en comité de dirección” (E03)
	Disponibilidad y calidad de datos	3	5	“Tenemos árboles de decisión y modelos predictivos... pero necesitamos datos externos para afinar la prima” (E04)
	Madurez tecnológica de la solución	3	4	“¿En qué momento de madurez se encuentra esa tecnología? Algunas desaparecen y otras triunfan” (E01)
	Escalabilidad y aplicabilidad transversal	3	4	“Empezamos con speech analytics... pero muchos casos no se extendían porque no eran escalables” (E01)
	Viabilidad regulatoria y supervisión	2	3	“Según la regulación existente se clasifican rojo, amarillo o verde, y deben pasar supervisión” (E01)
	Metodologías estructuradas de priorización	2	3	“Cada uno de los 115 casos de uso tiene inversión y

Factor principal	Subfactor identificado	Nº de entrevistas	Nº de referencias	Cita representativa
				output medible en ahorro o conversión” (E05)
Criterios intangibles	Aprendizaje organizativo y cultura	2	3	“Aunque no dé un retorno inmediato, hay un intangible: formar a la organización en la tecnología” (E03)

Fuente: Elaboración propia

4.1.4.4. Gobernanza de los modelos de IA

La gobernanza de los modelos de inteligencia artificial se configura como un eje crítico en la estrategia de adopción de las aseguradoras. No se trata únicamente de implementar soluciones tecnológicas, sino de establecer mecanismos de control que permitan garantizar la transparencia, el cumplimiento normativo, la calidad de los datos y la alineación con las políticas corporativas. Las entrevistas revelan que, en este ámbito, las compañías están avanzando en tres frentes principales: (i) creación de estructuras de supervisión y comités específicos, (ii) desarrollo de metodologías de validación y control de modelos y (iii) establecimiento de límites éticos y contractuales en el uso de la IA.

Comités de gobernanza y supervisión previa

El contexto regulatorio, especialmente en Europa, ha llevado a que muchas aseguradoras prioricen la creación de comités de gobernanza antes incluso de definir el alcance operativo de los casos de uso. Como señaló un directivo:

“Todas las empresas, dada la altísima regulación que existe tanto en el entorno europeo como el entorno español, están ya diciendo: lo primero hay que montar una serie de comités de gobernanza [...] para poder clasificar estos potenciales algoritmos” (E01).

Estos comités clasifican los modelos según su nivel de riesgo y definen los requisitos de supervisión:

“En función de la regulación existente, cómo se clasifican, si es rojo, amarillo o verde, y entonces decir oye, esto tiene que pasar por una cierta supervisión” (E01).

En las entidades de mayor tamaño, esta supervisión se ha institucionalizado mediante órganos corporativos multinivel, en los que la gobernanza se articula tanto a escala local como global (E05).

Metodologías de validación y control de modelos

Otro elemento recurrente es la aplicación de metodologías sistemáticas para validar y monitorizar los modelos de IA. En una aseguradora, todos los algoritmos deben pasar por un proceso formal de auditoría interna:

“Hace mucho tiempo que estamos en todos los modelos pasando una especie de tests [...] con 70 u 80 preguntas para clasificar el modelo y determinar que no estamos incorporando sesgos” (E03).

Además, estas validaciones no son puntuales, sino que incluyen revisiones periódicas:

“Lo que hemos hecho, sobre todo, es cada X tiempo chequear que las decisiones que se han tomado tienen sentido” (E03).

El control también se extiende al grado de ajuste de los modelos y su monitorización antes del escalado:

“Una cosa es que sea viable tecnológicamente, sí. Pero luego hay que ver si el modelo ajusta. [...] Tú lo estás poniendo, pero hay una persona que revisa que eso tiene sentido. [...] Tenía un 87% de ajuste. Para mí no era suficiente, aunque otros decían que estaba muy bien” (E12).

Gobernanza frente a proveedores y “caja negra”

La creciente incorporación de inteligencia artificial embebida en sistemas de terceros introduce nuevas exigencias de control contractual y técnico. Como señaló un directivo:

“Cada vez lo que nos venden los proveedores viene con IA embebida. [...] Eso también hay que controlarlo, porque si controlas perfectamente lo que haces tú, luego viene SAP o un CRM y te cuela por ahí no se sabe qué” (E05).

Esta preocupación enlaza con la necesidad de evitar la dependencia de soluciones opacas, lo que lleva a algunas aseguradoras a marcar líneas rojas explícitas:

“Nosotros hemos marcado una línea roja: no usarla dándole datos sensibles que puedan tener un uso dañino para la compañía. [...] Eso tendrá que resolverse con contratos de proveedor donde la IA trabaje para ti y de manera exclusiva” (E06).

En casos incipientes, las PoC se desarrollan en entornos cerrados y controlados para reducir riesgos:

“Hemos empezado una PoC muy controlada en un entorno cerrado, con un equipo que sabe de qué va el tema. Ya veremos cómo acaba” (E10).

Dimensión ética y control humano

La dimensión ética ocupa también un lugar central en la gobernanza de los modelos. Varias entidades enfatizan que la IA debe funcionar como apoyo, no como sustituto, garantizando siempre la decisión humana final:

“Esto está para que la decisión final la tome un tío, está para herramientas” (E05).

Otros directivos vinculan la gobernanza con la prevención de sesgos y con la necesidad de mantener criterios de justicia organizativa:

“Lo que hemos hecho es ver que los modelos no estén incorporando sesgos. [...] Porque puedes estar sacando análisis que, si se aplican sin evaluar, no cumplan criterios de negocio o de justicia” (E09).

La prudencia aparece como elemento transversal. Ante la incertidumbre de los modelos generativos, una directiva advertía:

“Estamos siendo bastante precavidos. No lo usamos con clientes hasta que tengamos claro qué vamos a hacer y cómo lo vamos a controlar. [...] Hay que ver cómo aseguramos que el modelo no se desvíe” (E12).

El análisis comparado de las entrevistas evidencia que los mecanismos de gobernanza evolucionan en paralelo al grado de madurez tecnológica de las entidades. Mientras que en los niveles iniciales su adopción es muy limitada, en los niveles intermedios (Assessing y Determined) empieza a tomar forma a través de comités, protocolos y validaciones, y en las compañías con mayor madurez (Managed) la gobernanza alcanza un grado de formalización prácticamente pleno.

Nivel 1 – Initial

En entidades en fase inicial, la gobernanza es prácticamente inexistente o se limita a criterios básicos de prudencia. La preocupación se centra en no traspasar determinadas líneas rojas en el uso de datos sensibles, evitando exposiciones que puedan comprometer la seguridad o la confidencialidad:

“Nosotros hemos marcado una línea roja que es no usarla dándole datos que puedan tener sensibilidad o que puedan tener un uso por terceros dañino” (E06).

Se trata de una gobernanza defensiva y centrada en la contención de riesgos, sin estructuras formales.

Nivel 2 – Assessing

En la etapa de evaluación, aparecen señales incipientes de gobernanza, vinculadas sobre todo a la gestión ética y al control humano en la toma de decisiones. La presión regulatoria se percibe, pero los mecanismos todavía son dispersos y poco sistemáticos:

“El humano no puede desaparecer, [...] es importante que esa capacidad ética la aporte el análisis además de la máquina” (E10).

La gobernanza se concibe más como una precaución conceptual que como un sistema estructurado, y su papel es fundamentalmente reactivo.

Nivel 3 – Determined

En este nivel intermedio, los mecanismos de gobernanza se amplían y diversifican. Se incorporan comités de supervisión, sistemas de clasificación, procedimientos internos de validación, protocolos éticos y revisiones periódicas de modelos:

“Lo primero hay que montar una serie de comités de gobernanza [...] para poder clasificar estos potenciales algoritmos” (E01).

“En función de la regulación existente, cómo se clasifican, si es rojo, amarillo o verde y entonces decir oye, esto tiene que pasar por una cierta supervisión” (E01).

“Pasando una especie de tests en los cuales hay 70 u 80 preguntas para clasificar el modelo y determinar que no estamos incorporando sesgos” (E03).

“Lo que hemos hecho [...] es cada X tiempo chequear que las decisiones que se han tomado tienen sentido” (E03).

“Para que eso ocurra, el sistema necesita acceso a nuestras bases de datos, protocolos, plantillas y estilo de respuesta” (E04).

La preocupación por la calidad del dato, la adaptación contextual de los modelos y la respuesta a la presión regulatoria se convierten en las prioridades de la gobernanza en este estadio.

Nivel 4 – Managed

En las entidades más avanzadas, la gobernanza se consolida como un sistema integral y formalizado, respaldado por órganos estatutarios y metodologías de estandarización. El control se articula a través de:

1. Estructuras formales de gobierno multinivel (Comité de Transformación e Innovación, Consejos asesores externos).
2. Sistemas de medición homogénea de impacto y retorno de modelos.
3. Reflexión sobre IA embebida en sistemas de proveedores y contratos de supervisión.
4. Marcos éticos híbridos, donde la decisión final recae siempre en personas.

“Hay que tener un sistema de medición homogéneo, que de eso se encarga el Centro de Inteligencia Artificial, de ponerlo en práctica” (E05).

“Cada vez lo que nos venden los proveedores viene con IA embebida [...] y eso también hay que controlarlo” (E05).

“Esto está para que la decisión final la tome un tío, está para herramientas” (E05).

En este estadio, la gobernanza deja de ser un mecanismo reactivo y se transforma en un instrumento proactivo de institucionalización de la IA, que combina control, estandarización y explotación estratégica.

Mientras que en el nivel Managed el 100% de las entidades mencionan mecanismos de gobernanza, en los niveles Assessing y Determined su presencia es parcial y heterogénea, con una adopción todavía incipiente y centrada en la respuesta regulatoria. Esto indica que la gobernanza aparece como un aspecto muy consolidado en fases maduras (estructuras formalizadas) pero todavía disperso en los niveles intermedios, donde la prioridad sigue siendo el cumplimiento y la experimentación controlada.

4.1.4.5. Acompañamiento a los empleados

Uno de los retos más señalados por los directivos entrevistados es la gestión del impacto que la inteligencia artificial genera en las personas. El acompañamiento a los empleados se revela como un eje crítico para evitar resistencias, reducir miedos y transformar la adopción tecnológica en una oportunidad de crecimiento organizativo. Lejos de presentarse como una amenaza directa al empleo, la mayoría de las aseguradoras intentan transmitir un mensaje de continuidad, reubicación y dotación de nuevas capacidades:

“Lo que más miedo nos da a nosotros no es eso, sino que se genere una resistencia a la IA como potencial exterminadora de puestos de trabajo”. (E05)

“La inteligencia artificial lo que permite es trabajar con... con muchos datos a la vez y, y como digo yo, dotar a los humanos de superpoderes”. (E09)

La estrategia de acompañamiento incluye formación específica y campañas internas de sensibilización. Algunas entidades plantean un proceso de *upskilling* gradual, con distintos niveles de capacitación que abarcan desde cursos básicos accesibles a toda la plantilla hasta programas avanzados orientados a colectivos especializados:

“Tenemos un curso de formación muy básico [...] disponible para todos. [...] Y luego tienes otro nivel que es un nivel más avanzado, que es el que te comento, que lo que yo quiero es ir engranando este segmento. No van a ser los 3000 empleados que tenemos porque tampoco es necesario, pero bueno, es que a lo mejor ahora no sé si tenemos 20 o 30 personas. Me gustaría que fueran 300. ¿Vale? Esto ya sí que mueve la aguja, porque... porque tienen que empezar a visualizar con esta tecnología qué casos de uso tenemos que empezar a meter en nuestro día a día y cómo nos puede ayudar”. (E12)

El acompañamiento también se apoya en estructuras de mediación interna, como embajadores de datos e IA o comités transversales que canalizan las inquietudes de las áreas de negocio hacia las áreas tecnológicas:

“Lo que intentamos es que cada una de las direcciones tenga como un embajador que antes era el embajador de datos, ahora es un embajador de datos, inteligencia artificial, algoritmos y que tenga un poco de sensibilidad. Realmente donde se puedan generar las oportunidades. Entonces, a través de este embajador un poco se hace esa recopilación de dónde hay”. (E03)

Pese a estos esfuerzos, persisten resistencias culturales y emocionales. Los temores de pérdida de empleo o de pérdida de identidad profesional emergen con fuerza, especialmente en organizaciones con plantillas de larga antigüedad:

“Ha habido una cierta desconfianza en una entidad muy tradicional, muy hecha a sí misma, donde la media de antigüedad es de 20 años y de repente aparece ese sin, sin, sin ninguna experiencia en la entidad. [...] No es sencillo ganarte la confianza de la gente”. (E16)

Frente a esta realidad, las compañías recurren a mensajes reiterativos que subrayan la continuidad del valor humano y la posibilidad de reubicar perfiles:

“Probablemente sí que los tengamos que reubicar. [...] Pero lo que estamos intentando es que esos perfiles vean que su intervención va a ser no tanto en la parte más automática, que es lo que me puede hacer una máquina, sino en aportar el valor que ellos conocen porque lo han hecho durante años”. (E10)

El acompañamiento, además, trasciende los límites internos de la aseguradora para alcanzar a mediadores y corredores, cuya confianza resulta esencial en el modelo de negocio:

“Nosotros como compañía estamos obligados a ayudarles a ese proceso de transformación también. [...] Al final los mismos problemas que tenemos nosotros de ganar eficiencia y orientación al cliente, lo tienen ellos”. (E09)

Las aseguradoras asumen que la resistencia al cambio es inevitable, pero tratan de encauzarla a través de mensajes positivos y ejemplos prácticos:

“Como es un proceso de cambio tan importante, el acompañamiento en el cambio es crítico. No es algo que puedes dejar que vaya solo; tienes que estar encima de ello, tienes que empujarlo, animarlo, ver qué stoppers tiene y luego exigir”. (E15).

La Tabla 22 resume los principales mecanismos identificados, acompañados de descripciones y citas representativas que ilustran cómo las compañías tratan de encauzar los temores culturales y laborales mediante mensajes positivos, formación diferenciada, figuras de mediación interna, reubicación de perfiles y extensión del acompañamiento al ecosistema de mediadores y corredores.

Tabla 22: Mecanismos de acompañamiento a empleados en la adopción de IA

Mecanismo de acompañamiento	Descripción	Cita representativa (ID)
Comunicación clara y reiterada	Mensajes que subrayan que la IA no busca eliminar empleos, sino dotar de nuevas herramientas y mejorar procesos.	“Lo que más miedo nos da a nosotros no es eso, sino que se genere una resistencia a la IA como potencial exterminadora de puestos de trabajo” (E05).
Formación y upskilling	Programas de capacitación diferenciados: cursos básicos para toda la plantilla y entrenamientos avanzados para colectivos especializados.	“Tenemos un curso de formación muy básico [...] disponible para todos. [...] Y luego tienes otro nivel más avanzado [...] me gustaría que fueran 300, porque tienen que empezar a visualizar qué casos de uso tenemos que empezar a meter en nuestro día a día” (E12).
Embajadores y nodos de sensibilización	Figuras internas que actúan como referentes de datos/IA y difunden la cultura digital en cada área.	“Lo que intentamos es que cada una de las direcciones tenga como un embajador que antes era el embajador de datos, ahora es un embajador de datos, inteligencia artificial, algoritmos” (E03).
Reubicación y valorización de perfiles	Redistribución de tareas para liberar a empleados de funciones repetitivas y potenciar el valor añadido de su experiencia.	“Lo que estamos intentando es que esos perfiles vean que su intervención va a ser no tanto en la parte más automática [...], sino en aportar el valor que ellos conocen porque lo han hecho durante años” (E10).
Gestión de resistencias culturales	Reconocimiento de la desconfianza y las reticencias, especialmente en plantillas con antigüedad elevada.	“Ha habido una cierta desconfianza en una entidad muy tradicional, muy hecha a sí misma, donde la media de antigüedad es de 20 años [...]. No es sencillo ganarte la confianza de la gente” (E16).
Apoyo a mediadores y corredores	Extensión del acompañamiento al canal de distribución, considerado parte esencial del ecosistema asegurador.	“Nosotros como compañía estamos obligados a ayudarles a ese proceso de transformación también [...]. Al final los mismos problemas que tenemos nosotros de ganar eficiencia y orientación al cliente, lo tienen ellos” (E09).
Acompañamiento intensivo al cambio	Seguimiento cercano, animación y exigencia para que la organización complete la transición.	“Como es un proceso de cambio tan importante, el acompañamiento en el cambio es crítico. No es algo que puedes dejar que vaya solo; tienes que estar encima de ello, tienes que empujarlo,

Mecanismo de acompañamiento	Descripción	Cita representativa (ID)
		animarlo, ver qué stoppers tiene y luego exigir” (E15).

Fuente: Elaboración propia

4.1.4.6. Relación con proveedores y consultoras

La adopción de inteligencia artificial en el sector asegurador español está condicionada por la relación con proveedores tecnológicos y consultoras. Esta relación se caracteriza por la tensión entre la necesidad de acceder a capacidades externas y el riesgo de dependencia excesiva.

Un primer aspecto recurrente es la desconfianza hacia la profundidad técnica de las consultoras generalistas. Se cuestiona si su aportación va más allá del discurso comercial:

“¿Estamos preguntando a los consultores [...] pero saben algo? ¿Realmente tienen profundidad en la materia para decir si estratégicamente debes utilizarlo aquí o tal? La respuesta es no” (E01).

“He pinchado con [consultora internacional], he pinchado con un montón de gente [...] al final qué tienes que hacer, esto se basa todo en consultores, que esa es la jodienda” (E15).

En paralelo, se percibe un riesgo de dependencia contractual frente a grandes integradores como Indra o SAP, que tienden a encarecer y extender proyectos más allá del plan inicial:

“Cada vez que tengo que hacer esos proyectos sufro un montón, porque de lo que te piden por un proyecto inicial, el tiempo se acaba transformando en el doble o el triple y en el doble o el triple de dinero” (E10).

“Cuando entremos en algún proyecto de estos vas a estar totalmente en sus manos y al final no vas a poder salir en la vida” (E10).

La relación con las *Big Tech* (Microsoft, Google) aparece como inevitable, dado que concentran el desarrollo de las herramientas más avanzadas en IA. Algunas entidades reconocen la importancia estratégica de “estar cerca” de estos proveedores globales, aunque son conscientes de su posición marginal frente a ellos:

“Para mí es muy importante estar cerca de un proveedor grande [...] pero nosotros para estos monstruos somos canijos también. O sea, España es canijo” (E11).

“Estamos trabajando tanto a nivel de grupo como con Google y con Microsoft, que para mí este es el problema de fondo. [...] Para inteligencia artificial generativa como tal tienes que ir a las grandes” (E03).

En este punto, surge con fuerza la cuestión de la adecuación de las soluciones al modelo de negocio asegurador. Algunos entrevistados señalan que las propuestas de los gigantes tecnológicos no siempre se ajustan a la realidad operativa y distributiva del sector, generando tensiones en la negociación:

“Grandes discusiones, con los representantes de Microsoft aquí [...] sus soluciones no están adaptadas al modelo de negocio, como mínimo al modelo de distribución que tenemos nosotros. Una discusión muy dura hace tres o cuatro años. [...] No estábamos dispuestos a comprar 20.000 licencias y menos aún a estar sujetos a que año tras año nos fueran aplicando incrementos. Les costó muchísimo entenderlo” (E02).

La cuestión de la adecuación no es solo tecnológica, sino también contractual y económica. La percepción de quedar “atados” a modelos rígidos de licenciamiento impulsa a las aseguradoras a buscar alternativas de relación con proveedores. En este sentido, algunos directivos plantean fórmulas de colaboración más flexibles, basadas en compartir riesgos y beneficios. Frente a la venta tradicional de licencias o desarrollos cerrados, se sugieren esquemas de remuneración variable vinculados al impacto real obtenido:

“Solemos proponer modelos donde se comparta el éxito. Si tú vienes a venderme una cosa [...] y rasco dos puntos de ratio de gastos, pues esos dos puntos que voy a rasgar yo te pago una parte fija, y si realmente eso se produce, ya lo compartiremos en el futuro” (E02).

Este enfoque introduce un elemento de alineación de incentivos: el proveedor solo captura parte del valor en la medida en que el proyecto genera resultados tangibles para la aseguradora. Se trata de una lógica más cercana a la co-innovación que a la relación proveedor-cliente tradicional, y refleja la búsqueda de fórmulas contractuales que reduzcan la percepción de riesgo en inversiones en IA.

Sin embargo, no todas las compañías aceptan pasivamente esta dependencia. Varias han optado por internalizar conocimiento crítico para evitar la “caja negra” de soluciones opacas, o exigir mayor control sobre la IA embebida en sistemas adquiridos:

“Nuestro acercamiento ahí es que esto es tan crítico que preferimos internalizar el conocimiento. [...] No ir a las empresas de nicho porque te suelen dar su caja negra y entonces no podemos tener siete cajas negras por ahí” (E11).

“Cada vez lo que nos venden los proveedores viene con IA embebida [...] y eso también hay que controlarlo” (E05).

Las startups e *InsurTechs* también ocupan un espacio relevante, especialmente en pruebas de concepto rápidas y focalizadas. Estas colaboraciones se perciben como más flexibles y ajustadas a necesidades concretas:

“Nosotros entramos en una prueba de concepto de la mano de una empresa de Barcelona que toca bastante el tema este” (E09).

“Me gusta la gente que tiene soluciones hechas y que viene y te dice vamos a hacer una prueba de concepto, pásame no sé cuántas cosas y lo vemos en real. A esos es a los que me creo, porque tienen algo que funciona” (E09).

Finalmente, el criterio económico aparece como decisivo en la relación con proveedores. Muchas aseguradoras expresan que, incluso ante soluciones técnicamente maduras, la falta de rentabilidad esperada o los altos costes de entrada las llevan a postergar decisiones:

“Nos dijeron que con esta solución podíais tener una mejora de 300.000 € en fraude detectado, pero es que la solución cuesta 200.000. Entonces dijimos: cuando estéis más económicos podemos hablar” (E02).

“Invertir para tener una ganancia de 100.000 € [...] no hay un retorno. Entonces la solución es buena, pero aún quieren cobrar demasiado para el retorno que te va a dar” (E02).

Más allá de los aspectos contractuales, uno de los directivos entrevistados introduce una visión más estructural, advirtiendo que la adopción de IA puede estar desplazando la rentabilidad del sector hacia las tecnológicas:

“Si lo ves a altísima escala, pues muy posiblemente esté habiendo una transferencia de valor hacia las tecnológicas. [...] El dinero que está cobrando las tecnológicas, pues antes lo tenían las empresas” (E11).

Diferencias por nivel de madurez (AIMM)

El análisis permite observar una clara evolución en la forma en que las aseguradoras gestionan su relación con proveedores y consultoras según su grado de madurez en IA.

- Initial: relación altamente defensiva, centrada en evitar riesgos de datos sensibles.
- Assessing: aproximación exploratoria, basada en conversaciones y pilotos incipientes, pero con fuerte desconfianza hacia consultoras y cautela contractual.
- Determined: la relación se diversifica (consultoras, *Big Tech*, startups). Surgen tensiones por dependencia y adecuación al negocio, pero también fórmulas de *success fee* y colaboración ágil con *InsurTechs*.

- **Managed:** las entidades más avanzadas institucionalizan la relación a través de órganos formales, combinan colaboración con *Big Tech* e internalización de conocimiento y reconocen explícitamente la transferencia de valor hacia las tecnológicas.

La Tabla 23 sintetiza esta evolución, mostrando los porcentajes de entidades que mencionan la relación con proveedores en cada nivel AIMM, los patrones predominantes y citas representativas que ilustran las prácticas y tensiones identificadas.

Tabla 23: Evolución de la relación con proveedores y consultoras según niveles de madurez AIMM

Nivel AIMM	% que mencionan relación con proveedores*	Patrones principales	Citas representativas
1 – Initial	100% (1/1)	Enfoque defensivo y de contención del riesgo. Línea roja sobre datos sensibles. Apertura condicionada a contratos de proveedor que garanticen exclusividad y control; asumen <i>trade-off</i> de menor aprendizaje por menor exposición.	“Hemos marcado una línea roja [...] no usarla dándole datos [...] sensibles o que puedan tener un uso por terceros dañino [...] esto tendrá que ser superado por contratos de proveedor [...] uso exclusivo; el aprendizaje será más lento.” (E6)
2 – Assessing	50% (2/4)	Relación exploratoria y pragmática: pilotos acotados, ROI estricto y cautela ante “caja negra”. Dificultad para especialización sectorial en consultoras grandes; segmentación de <i>partners</i> y compras por tamaño/coste.	“Comenzamos a hacer evaluaciones [...] fraude/pricing; no apostamos por retorno insuficiente; monitorizamos y volveremos a llamar.” (E8) · “No nos hemos casado con uno; consultor para cada cosa [...]; el grande es más generalista, los pequeños especializados encajan mejor.” (E10)
3 – Determined	100% (7/7)	Relación sistemática y diversificada. Negociación dura con hipoteca de licencias y riesgo de lock-in (p. ej., Microsoft, Indra/SAP). Aparición de success fee y PoC con startups; <i>due-diligence</i> del equipo real del proveedor; combinación make-buy con <i>core in-house</i> .	“¿Estamos preguntando a los consultores [...] pero saben algo de verdad? [...] La respuesta es no.” (E1) · “Grandes discusiones con Microsoft; licencias no adaptadas a nuestro modelo [...]; proponemos modelos de success fee.” (E2) · “Trabajamos con Google y Microsoft; para generativa hay que ir con grandes.” (E3) · “Antes de contratar pedimos CVs del equipo

Nivel AIMM	% que mencionan relación con proveedores*	Patrones principales	Citas representativas
			que estará en el proyecto.” (E4) · “PoC con startup de Barcelona; primero verlo funcionando.” (E9) · “Hemos internalizado funciones que antes estaban en socios tecnológicos.” (E15)
4 – Managed	100% (4/4)	Relación estratégica y gobernada por órganos estatutarios. Internalización del conocimiento crítico; control de IA embebida; consciencia de transferencia de valor hacia <i>Big Tech</i> ; combinación estructurada comprar vs. desarrollar; uso táctico de <i>copilots</i> .	“Cada vez lo que nos venden los proveedores viene con IA embebida [...] hay que controlarlo.” (E5) · “Preferimos internalizar el conocimiento; evitamos cajas negras de nicho.” (E11) · “Nos apoyamos en Microsoft <i>Copilot</i> ; proveedor como palanca, sin perder criterio propio.” (E12) · “La consultoría aporta disciplina y velocidad, pero lo crítico debemos saber hacerlo nosotros.” (E13)

Fuente: Elaboración propia

4.1.5. Visión y Estrategia

El análisis de las entrevistas revela que la visión y la estrategia de las aseguradoras son factores determinantes en el ritmo y la profundidad de la adopción de la IA. La influencia de la alta dirección, la integración de la IA en los planes corporativos, la percepción de su potencial transformador y la priorización de recursos dibujan un panorama heterogéneo que oscila entre la proactividad inversora y una prudencia expectante.

4.1.5.1. Integración de la IA en el Plan Estratégico

La integración de la inteligencia artificial en los planes estratégicos de las aseguradoras españolas se presenta de manera desigual, reflejando distintos niveles de institucionalización y compromiso. Del análisis de las entrevistas emergen tres patrones principales: (i) integración prioritaria como eje del plan estratégico, (ii) incorporación transversal como herramienta para alcanzar objetivos ya definidos, y (iii) vigilancia estratégica con adopción condicionada a la madurez tecnológica y los costes.

a) Integración prioritaria en el plan estratégico

En las aseguradoras más grandes y avanzadas, la IA se formaliza como una línea prioritaria de los planes estratégicos, convirtiéndose en un elemento estructural del marco de transformación digital. Un directivo de una gran aseguradora nacional explica cómo la analítica avanzada surgió directamente de la planificación corporativa, evolucionando con cada ciclo estratégico:

“La inteligencia artificial o la analítica avanzada [...] nace [...] directamente un plan estratégico en el 15, 16, 17 [...] y esto viene directamente del plan estratégico de la compañía, o sea, sin el impulso del plan estratégico esto no sale y sale en el contexto de lo que en aquellas fechas se llamaba la transformación digital.” (E11)

En otros casos, el impulso proviene de la matriz multinacional, que exige la incorporación explícita de inversiones en IA y establece mecanismos de seguimiento estrecho:

“Esto es un top down. Del propio CEO del grupo. [...] Se ha montado una organización a nivel grupo. Mensualmente nos dicen dónde estamos, en qué estamos invirtiendo, qué va a escalar, qué no va a escalar, cómo ajustan los modelos. Esto nos obliga a nosotros, nos obliga. Entonces no lo teníamos en el plan estratégico [...] y ahora resulta que tenemos que identificar inversiones adicionales.” (E12)

Incluso cuando la IA no figura como un programa independiente, se integra en los planes estratégicos como una tendencia clave, con múltiples iniciativas desplegadas en producción:

“Es directamente un plan estratégico. Hace ahora mismo diez años más o menos [...] y está metido en toda la cadena de valor del seguro. En retención se hace una predicción de cuáles son la máximo que le puedes ofrecer a un cliente para retenerlo. [...] Así hasta 120 modelos. Imagínate.” (E11)

b) Integración transversal como herramienta de apoyo

Un segundo grupo de entidades no formula la IA como un objetivo estratégico autónomo, sino como una herramienta subordinada a los objetivos de eficiencia y experiencia de cliente definidos previamente. Desde esta perspectiva, la IA no constituye un eje disruptivo, sino un medio para acelerar procesos ya contemplados:

“Nosotros lo que entendemos es que hacemos un plan estratégico y dentro de ese plan estratégico hay dos puntos básicos que luego tiene un desarrollo. Uno es la eficiencia y otro es la experiencia cliente [...]. Claro, hasta la fecha, dentro de ese plan estratégico, las herramientas para desarrollar esos dos puntos eran unas y ahora con la inteligencia artificial tenemos otras.” (E10)

La misma lógica se observa en otras aseguradoras que integran la IA dentro de presupuestos globales de transformación, sin asignar un capítulo específico:

“Lo veo como parte del proceso de transformación de la compañía. Y más que como una inversión estrictamente en inteligencia artificial generativa que tiene que dar un retorno, dentro del presupuesto de transformación de la compañía [...] eso nos va a requerir también inversión. [...] No es que tenga un porcentaje determinado sobre el total ni mucho menos, pero sí que te puedo decir que estamos invirtiendo mucho.” (E03)

En este modelo, la IA aparece asociada a la superación de pilotos y pruebas de concepto, cuyo éxito determina su incorporación definitiva en el plan estratégico:

“Entonces, cuando acabemos la PoC miraremos esa parte, cómo impacta, porque eso sí que ya es más relacionado con el modelo de negocio. [...] Y lo otro es verlo como una herramienta, ganar productividad.” (E09)

c) Vigilancia estratégica y adopción condicionada

Finalmente, un tercer patrón se observa en entidades de tamaño medio o con estructuras mutuales, donde la IA figura en el plan estratégico como un ámbito a monitorizar, pero su adopción se pospone hasta que las soluciones externas maduren y sean económicamente asumibles. Un directivo lo expone de manera explícita:

“Nosotros en el plan estratégico [...] hemos hecho el análisis, ¿vale? Y entonces vemos que en estos cuatro ámbitos pues uno nos impacta el otro. Hay temas de productividad pero que no requieren prisa. [...] Estaremos atentos a estos

paquetes cuando veamos que están maduros y a unos precios económicos y entonces los implantaremos.” (E02)

En estos casos, la planificación reconoce el potencial de la IA, pero subordina su despliegue al equilibrio entre oportunidad tecnológica, retorno económico y capacidad organizativa:

“El problema que tenemos es que estamos metidos en tantas cosas, en tantos proyectos a la vez [...] Al final somos pocas personas. [...] ¿Entonces por qué no se ha hecho esto? ¿O por qué no hemos abordado esto? Pues quizá por falta de tiempo, por falta de recursos.” (E15)

La integración de la IA en los planes estratégicos de las aseguradoras españolas sigue un eje evolutivo claro. En un extremo, las grandes compañías la institucionalizan como línea prioritaria y destinan recursos específicos bajo impulso de la alta dirección o de la matriz. En un nivel intermedio, se concibe como una herramienta instrumental al servicio de objetivos de eficiencia y experiencia de cliente, integrada en presupuestos de transformación más amplios. Finalmente, en entidades medianas y mutuales, la IA se vigila estratégicamente, pero su implementación queda supeditada a la madurez tecnológica, los costes y la disponibilidad de recursos. Este gradiente refleja cómo la planificación estratégica no solo marca el ritmo de adopción, sino que también condiciona la profundidad de la transformación organizativa vinculada a la IA. La Tabla 24 sintetiza esta evolución, mostrando los patrones predominantes de integración estratégica por nivel AIMM, sus características y citas representativas de los directivos entrevistados.

Tabla 24: Integración de la IA en los planes estratégicos según niveles de madurez AIMM

Nivel AIMM	% de entidades en ese nivel que mencionan el patrón dominante	Patrón predominante	Características	Citas representativas (ID)
1 – Initial	100% (1/1)	Vigilancia estratégica	Relación defensiva. La IA no figura como objetivo estratégico, se limita a evitar riesgos y a condicionar su uso a contratos de proveedor.	“Nosotros hemos marcado una línea roja que es no usarla dándole datos que puedan tener sensibilidad o que puedan tener un uso por terceros dañino” (E06).
2 – Assessing	75% (3/4)	Vigilancia estratégica y	La IA se menciona en planes estratégicos, pero se pospone su despliegue. Se integra	“Nosotros en el plan estratégico [...] vemos que en estos cuatro ámbitos [...] hay temas de productividad

Nivel AIMM	% de entidades en ese nivel que mencionan el patrón dominante	Patrón predominante	Características	Citas representativas (ID)
		adopción condicionada	en análisis de impacto o como herramienta futura, condicionada a madurez tecnológica, precios y retorno.	pero que no requieren prisa. [...] Estaremos atentos a estos paquetes cuando veamos que están maduros y a unos precios económicos” (E08). · “Dentro de ese plan estratégico, los puntos básicos son eficiencia y experiencia cliente [...] y ahora con la inteligencia artificial tenemos otras [herramientas]” (E10).
3 – Determined	86% (6/7)	Integración transversal como herramienta de apoyo	La IA se integra como parte del plan de transformación digital, vinculada a objetivos de eficiencia, experiencia de cliente o innovación. Se gestiona en comités de innovación y presupuestos de transformación, sin constituir aún un programa autónomo.	“Lo veo como parte del proceso de transformación de la compañía. [...] Dentro del presupuesto de transformación [...] estamos invirtiendo mucho” (E03). · “En el Comité de Innovación [...] los grandes temas están muy relacionados con tecnología, porque es el mundo de la IA y la digitalización” (E04). · “Desde el top management hay que pensar en cómo la IA puede impactar en los modelos de negocio y hay que impulsar al comité de dirección a mirarlo” (E9).
4 – Managed	100% (4/4)	Integración prioritaria	La IA se formaliza como línea estratégica independiente, con objetivos, presupuestos dedicados y seguimiento al más alto nivel (Consejo, CEO, matriz). Se convierte en	“La inteligencia artificial o la analítica avanzada [...] nace [...] directamente de un plan estratégico [...] y esto viene directamente del plan estratégico de la compañía” (E11). · “Esto es un top down. Del propio CEO del grupo. [...] Mensualmente

Nivel AIMM	% de entidades en ese nivel que mencionan el patrón dominante	Patrón predominante	Características	Citas representativas (ID)
			un eje transversal de la transformación.	nos dicen dónde estamos, en qué estamos invirtiendo, qué va a escalar, qué no va a escalar” (E12). · “Tenemos un marco conceptual aprobado por Comité de Dirección y Consejo Asesor de Innovación [...] la IA forma parte de ese eje estratégico” (E5).

Fuente: Elaboración propia

4.1.5.2. Alineación con la Visión de la Alta Dirección

El impulso de dirección se considera mayoritariamente como el catalizador principal para la adopción de la IA. El compromiso del CEO y del Consejo de Administración se considera determinante:

“Esto es un es un top down. Del propio CEO del grupo. Esto nos va a ver. Y es que no es que tú no sabes, es que estamos sometidos a examen todos los CEOs todos los días. Porque él tiene muy claro. Y es que tiene razón. Si esto no emana del CEO, esto no va a suceder. Y como él está tan sumamente convencido, pues hemos tenido sesiones” (E12).

“Si un líder no cree en algo a los que están por debajo se van a tener que esforzar mucho para demostrar y para y para convencer. Si un líder cree en algo de lo que las cosas son mucho, mucho más fáciles” (E02).

No obstante, la alineación entre dirección y tecnología no siempre responde a un esquema exclusivamente vertical. Algunos directivos destacan un modelo iterativo en el que el liderazgo puede surgir tanto desde el negocio como desde el área tecnológica, dependiendo del origen de la necesidad:

“Era del negocio en donde le decía: ‘mira tengo estas necesidades y qué tecnologías habría para poder cubrir esto’. Entonces se trataba de un modelo iterativo [...]. Creo que la visión es distinta dependiendo de por dónde surja la necesidad” (E01).

Incluso en organizaciones que avanzan con un enfoque más prudente, la implicación de la dirección es explícita. Los comités de dirección y los consejos de

administración discuten estas materias de forma recurrente, integrándolas en la definición del plan estratégico y en procesos de formación de consejeros. Un entrevistado lo expresaba así:

“Hace cuatro meses hemos hecho una formación de ciberseguridad. [...] Todo esto que hemos hablado formó parte del plan estratégico, con lo cual se compartió estas reflexiones con el Consejo. Yo formo parte del Consejo también” (E02).

Finalmente, los testimonios revelan que el liderazgo, aunque decisivo, no elimina automáticamente las resistencias internas. En organizaciones con fuerte tradición y plantillas de larga antigüedad, los directivos reconocen dificultades culturales para asimilar el cambio impulsado desde arriba:

“Ha habido una cierta desconfianza en una entidad muy tradicional, muy hecha a sí misma, donde la media de antigüedad es de 20 años [...]. No es sencillo ganarte la confianza de la gente” (E16).

4.1.5.3. La IA como Eje Transformador

Existe un consenso generalizado entre los directivos entrevistados sobre el potencial de la IA para optimizar procesos y mejorar la eficiencia. Sin embargo, no hay unanimidad en considerarla una disrupción fundamental del modelo de negocio asegurador. Las percepciones recogidas permiten distinguir tres patrones principales: visión disruptiva, visión incremental y visión matizada.

En primer lugar, un grupo de grandes aseguradoras con mayor madurez tecnológica conciben la IA como un cambio integral que redefine la compañía en todas sus dimensiones. Como subrayó un directivo:

“La IA es toda la compañía la que tiene que cambiar. Es que esto. Esto cambia la compañía completa, cambia el talento, cambia el mindset de la gente, cambia la propia regulación que va a ir apretando, cambia los procesos de la tecnología, la forma de medir, es que lo cambia todo.” (E05)

De forma similar, otras entidades describen la IA generativa como un “cambio de era”, que obliga a revisar iniciativas estratégicas y acelerar la transformación digital. En las aseguradoras de modelo directo, este carácter disruptivo se vincula con la sostenibilidad del negocio, al permitir *“escalabilidad, eficiencia y servicio digital masivo”* (E13).

En segundo lugar, varias compañías presentan la IA principalmente como un motor de productividad y eficiencia en procesos específicos, sin percibir un impacto inmediato en su modelo de negocio. Esta visión incremental conecta la IA con la continuidad de la analítica de datos y la digitalización previa, situándola como una herramienta más dentro del arsenal tecnológico. Como apuntaba un directivo:

“Nosotros lo que entendemos es hacemos un plan estratégico y dentro de ese plan estratégico hay dos puntos básicos: uno es la eficiencia y otro es la experiencia cliente. Hasta la fecha, las herramientas para desarrollar esos dos puntos eran unas y ahora con la inteligencia artificial tenemos otras.” (E10)

Otro directivo incidía en la larga tradición del sector en analítica, lo que reduce el carácter rupturista de la IA:

“Somos organizaciones que estamos acostumbradas, es decir, tenemos en nuestro ADN lo que es la toma de decisiones en base a lo que observamos en analítica. [...] Considero que estamos muchísimo mejor posicionados que otro tipo de sectores, porque ya tenemos una costumbre, nuestra dinámica normal de negocio es en base al tratamiento masivo de datos.” (E02)

Finalmente, un tercer grupo adopta una posición intermedia y más matizada. Estas entidades reconocen el potencial transformador de la IA, pero subrayan que su efecto depende de factores contextuales como el modelo de distribución (directo vs. mediado), la madurez de las soluciones o los riesgos regulatorios. Un directivo de una aseguradora mediada lo expresaba en términos de continuidad del negocio:

“Lo que mira es primero, yo creo como CEO, es si tendrás una disrupción del tipo de si te va a cambiar el modelo de negocio, si tu modelo de negocio está en riesgo. [...] Tenemos un modelo de negocio, llegamos a los clientes a través de mediadores. Esto me puede suponer una disrupción en este ámbito y yo te diría que cuando comenzaste a ver inteligencia artificial, ves que no es el tema.” (E08)

En este sentido, otras entrevistas destacan que el impacto no es homogéneo, sino que varía en función del canal y del producto:

“El cliente digital [...] la inteligencia artificial sí que aportará mucho valor. [...] El mediador más tradicional, seguramente, la inteligencia artificial estará más orientada a ayudarle a ganar eficiencia.” (E09)

El análisis comparado muestra una clara correlación entre el grado de madurez en IA y la visión estratégica atribuida a esta tecnología. En las entidades clasificadas como Managed, predomina la percepción de la IA como motor disruptivo, capaz de transformar no solo la eficiencia operativa, sino también la cultura, la gobernanza y la lógica de negocio. En niveles Determined, los enfoques son diversos: algunas compañías consideran la IA predictiva como una continuidad con la analítica avanzada y ven su aporte como incremental a procesos ya establecidos, otras apuntan a un horizonte de disrupción, aunque no inmediato, y apalancado, sobre todo en la IA generativa. Las aseguradoras situadas en fases Assessing o Initial muestran una orientación más conservadora, donde la IA se interpreta mayoritariamente como un instrumento para mejorar la productividad y la eficiencia en ámbitos concretos y consideran que no ponen en riesgo sus modelos de negocio actuales.

La Tabla 25 sintetiza estos patrones dominantes, mostrando la correlación entre el nivel AIMM, el tipo de visión estratégica (disruptiva, incremental o matizada), el porcentaje de entidades que los comparten y citas representativas que ilustran dichas percepciones.

Tabla 25: Visiones estratégicas de la IA en el sector asegurador según niveles de madurez AIMM

Nivel AIMM	Patrón dominante	% entidades en el nivel	Caracterización	Citas representativas
Initial	Vigilancia defensiva	100% (1/1)	La IA se percibe relevante pero no prioritaria; el foco está en observar y proteger el modelo existente (p. ej., mediación), con cautelas.	“...hemos marcado una línea roja...” (E06).
Assessing	Incremental (continuidad)	75% (3/4)	La IA se interpreta como continuidad de analítica/digitalización. Se priorizan pilotos y mejoras operativas, esperando madurez/precio.	“...estaremos atentos a estos paquetes cuando... estén maduros y a precios económicos” (E08). · “...dentro del plan estratégico los puntos básicos son eficiencia y experiencia cliente; ahora con IA tenemos nuevas herramientas” (E10).
Determined	Matizada / instrumental	100% (7/7)	Reconocen potencial transformador, pero el alcance real se supedita a canal, madurez tecnológica y rentabilidad; se integra como herramienta en planes de eficiencia/cliente.	“...lo veo como parte del proceso de transformación... dentro del presupuesto de transformación...” (E03). · “...somos organizaciones acostumbradas al tratamiento masivo de datos...” (E02). · “...el cliente digital se beneficiará más; el mediador tradicional sobre todo en eficiencia” (E09).
Managed	Disruptiva / estratégica	100% (4/4)	La IA se concibe como cambio de era que obliga a repensar talento, procesos, regulación y estrategia; se institucionaliza con	“La IA es toda la compañía la que tiene que cambiar... lo cambia todo” (E05). · “Es un top down del CEO; <i>reporting</i> mensual de inversiones y escalado” (E12). · “IA como motor de

Nivel AIMM	Patrón dominante	% entidades en el nivel	Caracterización	Citas representativas
			objetivos y seguimiento top-down.	escalabilidad y servicio digital masivo” (E13).

Fuente: Elaboración propia

4.2. Dimensión Tecnología (T)

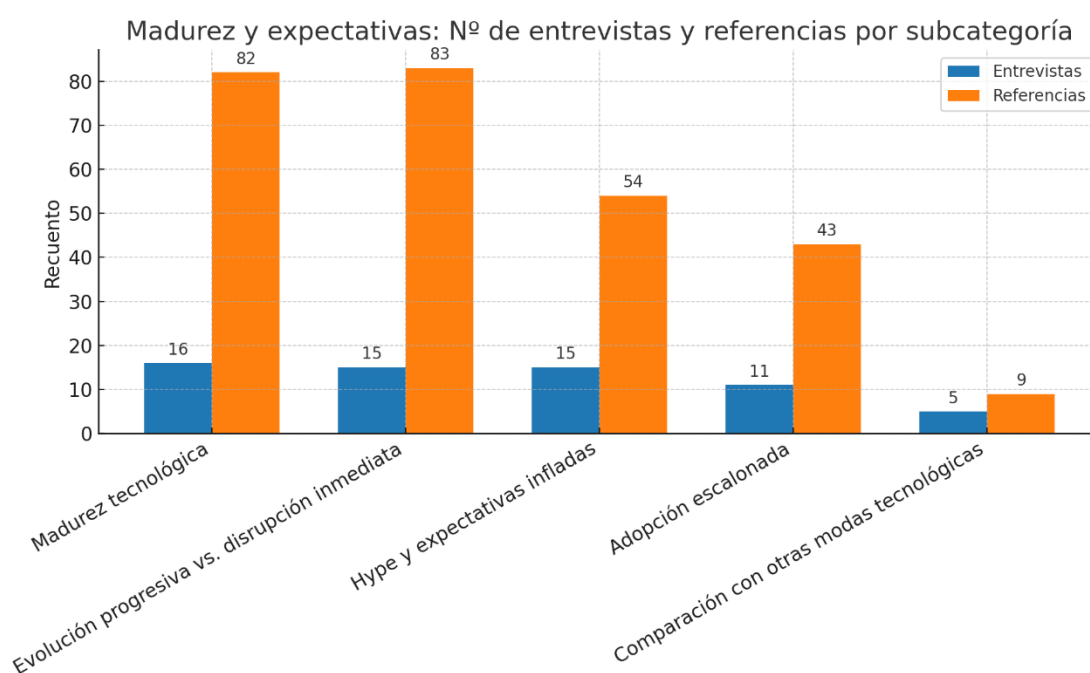
Aunque, como se ha visto anteriormente, los entrevistados han enfatizado la importancia de la gestión interna, la estrategia, las personas y la cultura organizativa, el análisis también revela claramente que los factores tecnológicos también juegan un papel importante en la adopción de la IA.

Comenzamos presentando la percepción que los entrevistados tienen sobre la madurez tecnológica y expectativas sobre la IA, que ha sido el código de esta dimensión con mayor número de párrafos codificados (271 referencias).

4.2.1. Madurez y Expectativas

La percepción sobre la madurez y las expectativas en torno a la inteligencia artificial es un tema recurrente en las entrevistas. La Figura 19 muestra la distribución de entrevistas y referencias por subcategoría.

Figura 19: Distribución de entrevistas y referencias en las subcategorías de madurez y expectativas sobre la IA



Fuente: Elaboración propia

4.2.1.1. Madurez de la Tecnológica

La percepción sobre el estado de madurez de la IA en el sector asegurador español por parte de los entrevistados es variada. Los directivos distinguen con claridad entre la IA tradicional —basada en analítica predictiva y modelos de machine learning— y la IA generativa, considerada aún incipiente y rodeada de incertidumbre sobre su fiabilidad y aplicabilidad. Como señalaba un entrevistado:

“La diferencia con la generativa es que tiene una capacidad, una visión un poco más holística, pero también está en un momento bastante incipiente. Es decir, que la imprecisión de los resultados hay que mirársela con un poco de detalle o como mínimo, lo que salga de esas cajas negras hay que mirarlo, hay que revisarlo, hay que revisarlo un poco, un poco manual” (E07).

La IA tradicional se percibe como consolidada y suficientemente madura para estar integrada en procesos de negocio. En palabras de otro directivo:

“Estamos en un nivel bastante maduro en tradicional y en los últimos años además nos ha permitido automatizar muchos procesos. [...] ¿Dónde estamos nosotros? En la utilización de IA generativa no con cliente. No directamente con cliente. ¿Por qué? Porque el grupo ha establecido que no la vamos a utilizar directamente con cliente hasta que no tengamos seguro qué es lo que vamos a hacer” (E12).

Esta diferencia explica que la IA generativa se limite, por el momento, a pilotos y entornos internos, mientras que la predictiva ya funciona a escala en ámbitos como fraude, pricing o tramitación de siniestros.

Algunos directivos reconocen, además, que el sector parte de una ventaja comparativa frente a otras industrias gracias a su larga experiencia en el tratamiento masivo de datos:

“Yo creo que la ventaja que tiene el sector asegurador en términos de adopción es que hace muchos años que vamos oyendo hablar de analítica de datos [...]. Somos organizaciones que estamos acostumbradas, tenemos en nuestro ADN la toma de decisiones en base al tratamiento masivo de datos” (E07).

Sin embargo, esta ventaja no elimina las dudas sobre el “timing” de la disrupción. Para unos, se trata de un cambio inminente:

“Yo creo que la inteligencia artificial va a ser disruptiva en general [...]. La gran incógnita es el timing de todo esto. Y seguramente el timing puede ser un poco más lento de lo que nos gustaría” (E03).

Para otros, en cambio, la tecnología sigue siendo demasiado inmadura para justificar una adopción acelerada:


“Yo creo que sí, yo creo que aún todo está con una tecnología muy, muy incipiente para tú ya crearte la herramienta” (E01).

La frustración con ciertas herramientas, como CoPilot, muestra este gap entre expectativas y realidad:

“Yo creo que la expectativa que tenía era muy alta [...]. Pensaba que íbamos a poder automatizar ciertas tareas, pero CoPilot no está lo desarrollado que se ha vendido” (E09).


La Figura 20 muestra la distribución absoluta de entidades por nivel de madurez, diferenciando entre quienes consideran que la tecnología es todavía inmadura, quienes reconocen madurez parcial en casos concretos y quienes la perciben ya lista para escalar. La Figura 21 presenta la misma información expresada en términos porcentuales, lo que permite comparar de manera más precisa el peso relativo de cada percepción en los distintos niveles AIMM. Se observa que a medida que aumenta la madurez, se incrementa el porcentaje de entidades que confían en el potencial de la IA para ser escalada, aunque persiste una base significativa de cautela en fases intermedias.

Figura 20: Percepción de la madurez tecnológica según nivel AIMM (número de entidades)



Fuente: Elaboración propia

Figura 21. Percepción de la madurez tecnológica según nivel AIMM (porcentaje de entidades)



Fuente: Elaboración propia

4.2.1.2. “Hype” y expectativas infladas

Expectativas infladas

Los testimonios de los directivos revelan que la inteligencia artificial, especialmente en su vertiente generativa, se percibe todavía envuelta en un ciclo de expectativas infladas. No se trata únicamente de una cuestión de madurez tecnológica —abordada en el apartado anterior—, sino de la manera en que el discurso mediático, los consultores y los grandes inversores contribuyen a generar un clima de sobreexpectativa. La noción de que la IA está “verde” es recurrente en las entrevistas:

“Es cierto que el sector habla mucho de inteligencia artificial, pero en realidad aún está muy verde, sobre todo en la parte de lenguaje, donde queda muchísimo por mejorar” (E04).

Algunos directivos califican incluso determinadas aplicaciones como inalcanzables en el corto plazo, llegando a considerarlas “ciencia ficción”:

“Hay otra cosa, que también te digo... que en principio parece atractivo, que es, para peritaciones, para video peritaciones [...] intentar, ¿me entiendes?, pues lo que sería la valoración de la peritación. Pero creo que esto aún es ciencia ficción [...] está muy poco maduro” (E08).

Estas percepciones se ven reforzadas por experiencias negativas en implementaciones iniciales, como los errores o “alucinaciones” en modelos de lenguaje, o el fracaso de pilotos en entornos operativos:

“Hemos testado que hay algunas inteligencias artificiales, que no te contestan que no saben una cosa, se la inventa. Directamente, entera, ¿eh? Que bastante curioso” (E07).

“En un momento determinado sacamos el Chatbot y no funciona, no funciona, no funciona porque no aprende lo suficiente [...] al final cuesta tanto que aprenda y que suelta auténticas tonterías” (E14).

En este contexto, varios entrevistados describen el momento actual como una “burbuja” tecnológica, análoga a ciclos anteriores de *Data Analytics* o *Blockchain*, donde la narrativa de consultores y medios acelera las expectativas más allá del ritmo real de adopción:

“Tengo sensación de burbuja tecnológica, es decir, de que está de moda. De eso es de lo que tengo la sensación, igual que Data Analytics estuvo en su momento” (E01).

“Hay gente que piensa que es “hype” [...] iba a decir frases del estilo de ‘esto es para que los proveedores ganen más dinero’. Y digo, hombre, es que han invertido 10 mil millones, 13 mil millones en esta compañía. Querrán rentabilizarlo, lógicamente” (E11).

Las comparaciones con otros fenómenos tecnológicos pasados sirven para contextualizar y relativizar las expectativas. El metaverso aparece como el ejemplo paradigmático de desilusión tras un boom mediático:

“Yo te digo que soy reactivo, porque cuando vino el multiverso o como se llame eso, parecía que nos iba a arrastrar y se ha quedado en nada. [...] Ya hay empresas que han invertido montones de dinero en estas cosas y luego se queda en nada” (E14).

En cambio, *Blockchain* se cita como un éxito parcial, acotado a determinados nichos, lo que permite contrastar la transversalidad de la IA con la especificidad de otras modas:

“Metaverso. ¿Dónde está el metaverso? No tengo ninguna duda de que la inteligencia artificial no será como el metaverso. La inteligencia artificial es una historia de éxito. [...] Blockchain, es historia de éxito. Pero de un éxito que tiene que ver con determinadas cosas” (E07).

“La inteligencia artificial nos va a pegar a todos, nos va a impactar a todos, igual que el Blockchain. [...] La IA sí que te impacta directamente en todos los sitios” (E09).

Brecha entre expectativas y realidad

La percepción de “hype” se traduce, en la práctica, en una creciente frustración entre los directivos por la distancia entre las promesas iniciales y los resultados obtenidos hasta la fecha. Varios entrevistados coinciden en que los plazos de

transformación anunciados son irreales y que el impacto de la IA se desplegará de forma mucho más progresiva. Como reconocía un directivo:

“Hay la ilusión de que de repente en 2026 la inteligencia artificial va a cambiar absolutamente todo [...]. Va a ser algo gradual, más lento y menos fulgurante de lo que parece. Yo pondría el horizonte del 2030, no el horizonte del 2025” (E15).

Esta brecha se observa con especial intensidad en relación con la IA generativa, cuya irrupción fue acompañada de expectativas desmesuradas sobre su capacidad inmediata para transformar la operativa aseguradora. Sin embargo, la realidad ha revelado limitaciones técnicas y una curva de aprendizaje más lenta de lo esperado:

“El problema es que nos hemos creído que tenía que ser desde ya. Para mí es el gran problema que el bombo que se le ha dado a la inteligencia artificial generativa parecía que ya estaba disponible para hacer todo aquello que tu mente ahora de repente se abría y decías lo puede hacer una máquina. Y el problema es que no es así. Entonces, nos estamos encontrando, o por lo menos a mi nivel, un poco de frustración porque intentas hacer cosas que creías que iban a ser posibles y no lo son” (E10).

La decepción se extiende también a herramientas concretas, presentadas como soluciones listas para mejorar la productividad, pero que aún no han alcanzado la madurez prometida. La experiencia con CoPilot es paradigmática:

“Co-Pilot va a venir y nos va a solucionar la vida en términos de análisis de lo que podamos hacer en nuestro ordenador. Y eso sí que ha sido una verdadera decepción. O sea, creo que hay dos cosas, CoPilot como tal para nosotros y hemos tenido reuniones con otros que lo están intentando implementar. No está lo desarrollado que se ha vendido” (E10).

Urgencia y potencial transformador

Aunque la mayoría de los entrevistados subraya la inmadurez actual de la IA generativa, un grupo minoritario adopta un discurso mucho más enfático y disruptivo. Para estos directivos, el riesgo no reside en la precipitación tecnológica, sino en la posibilidad de quedar rezagados frente a la competencia. Como afirmaba uno de ellos:

“Yo estoy leyendo artículos en los periódicos de directores de tecnología que dicen que todavía la tecnología no está lista para ser usada a escala. Eso no lo veo. Está más, desde mi punto de vista, más que disponible para ser utilizada a escala. Y el salto que hemos pegado es tan grande con respecto a lo que hacíamos antes, que me da igual que al final se quede aquí arriba o aquí, o aquí o aquí. Estábamos ahí abajo” (E11).

Este grupo de compañías no considera la IA en fase embrionaria, sino ya plenamente operativa en procesos críticos de negocio, como la tramitación masiva de siniestros o la atención digital:

“Lo tenemos en producción en cosas que de verdad pasan cientos de miles de transacciones por ahí, la apertura de cientos de miles de siniestros se gestiona por inteligencia artificial” (E13).

El lenguaje utilizado refleja un sentido de urgencia y una visión de “cambio de era”, que obliga a acelerar la adopción y maximizar los aprendizajes:

“Yo sí creo que tenemos que tener un punto de urgencia tremendo. [...] Me preocupa que otros vayan por delante. Pues sí, qué quieres que te diga, claramente hay una nueva [...]. Esto es un cambio de era desde mi punto de vista, y hay que pillarlo lo antes posible” (E11).

“Es tan brutal, tan brutal... que es, ¡madre mía de mi vida! [...]. En el caso de uso que tenemos, tenemos un ahorro de un 50% del tiempo, una tarea que se hace en un 50% del tiempo. No son 20, son 50. Y acabamos de empezar” (E12).


En contraste con la visión mayoritaria de cautela, este discurso minoritario acentúa la urgencia competitiva y sitúa la IA no como promesa futura, sino como un vector ya transformador que exige actuar de inmediato.

Existe una correlación clara entre las percepciones y los niveles de madurez tecnológica de las entidades analizadas. En los estadios más incipientes (Initial y Assessing) predomina la visión de la IA como un fenómeno de “hype”, percibido más como una moda impulsada por consultores y medios que como una capacidad consolidada, lo que explica la desconfianza ante su aplicación práctica. En un nivel intermedio (Determined), que agrupa a la mayoría de aseguradoras de la muestra, se observa un discurso de prudencia y gradualidad: se reconoce el potencial transformador, pero se insiste en que su despliegue debe ser escalonado y con horizontes temporales más largos, como ilustra la afirmación de que “*será algo gradual, más lento y menos fulgurante de lo que parece [...] pondría el horizonte del 2030, no el horizonte del 2025*” (E15). Finalmente, en las compañías con mayor madurez (Managed), el discurso cambia radicalmente: se describe la IA como un “cambio de era” ya operativo en procesos críticos, y se enfatiza la urgencia de no quedar rezagados en la competencia (“Lo tenemos en producción en cosas que de verdad pasan cientos de miles de transacciones por ahí, la apertura de cientos de miles de siniestros se gestiona por inteligencia artificial” E13).

La Figura 22 muestra como en los niveles iniciales predomina una visión crítica, en la que los directivos reconocen la existencia de expectativas infladas y alertan sobre el riesgo de sobredimensionar las capacidades de la tecnología. En cambio, a medida que las entidades avanzan en madurez AIMM, aumenta el número de

compañías que niegan la existencia de “hype” y consideran que la IA constituye un cambio estructural real y duradero, más allá de una moda pasajera.

Figura 22: Percepción de existencia de “hype” según nivel AIMM (número de entidades)



Fuente: Elaboración propia

4.2.1.3. Evolución Progresiva vs. Disrupción

La visión evolutiva es mayoritaria respecto a la visión disruptiva y conecta la IA con la trayectoria de otras innovaciones previas (ERP, *Business intelligence*, digitalización). Desde esta perspectiva, la IA representa una herramienta destinada a reforzar la eficiencia y la productividad, sin cuestionar los fundamentos del modelo de negocio. En palabras de un directivo:

“No acabo de ver que cualquier aplicación de la inteligencia artificial elimine, diríamos, al mediador de nuestra propuesta de valor [...]. Yo la veo más, pues como ha sido el Business intelligence, como han sido los ERP en su momento, [...] para que seamos más productivos” (E08).

Esta lógica incremental se expresa también en la cautela metodológica, donde los proyectos se abordan mediante pilotos y pruebas controladas:

“Nosotros no somos de grandes disrupciones, o sea, somos más bien de evoluciones. En el momento en el que hemos testeado que una tecnología puede ayudarnos a mejorar, pues oye, tiramos para adelante, pero hacemos siempre experimentos con gaseosa, ¿vale? Así que probamos mucho las cosas con pilotos” (E02).

Por el contrario, la visión disruptiva describe a la IA —especialmente en su vertiente generativa— como un “salto cuántico” o incluso un “cambio de era” que reconfigurará la organización en todas sus dimensiones. En este discurso aparecen metáforas de ruptura radical, asociadas a la urgencia de actuar y a la convicción de que la transformación será integral y transversal. Así lo expresa un directivo:

“La IA es toda la compañía la que tiene que cambiar. Es que esto. Esto cambia la compañía completa, cambia el talento, cambia el mindset de la gente, cambia la propia regulación que va a ir apretando, cambia los procesos de la tecnología, la forma de medir, es que lo cambia todo” (E05).

El contraste entre ambas visiones no es aleatorio: se relaciona con el modelo de negocio y el nivel de madurez organizativa. Entre las entidades *Assessing* o *Determined*, con estructuras mediadas y mayor prudencia inversora, predomina el relato de continuidad y mejora incremental. En cambio, las compañías *Managed* y de modelo directo son las que articulan un discurso disruptivo, apoyado en la escala de operaciones y en la presión competitiva de los canales digitales.

4.2.1.4. Adopción Gradual

El análisis de las entrevistas muestra que la gradualidad en la adopción de IA en el sector asegurador no responde únicamente a una estrategia culturalmente prudente, sino a condiciones técnicas y contractuales que facilitan un despliegue controlado y escalonado. Estos mecanismos permiten a las compañías reducir riesgos, validar retornos y optimizar la asignación de recursos en función de su nivel de madurez (especialmente en fases *Assessing* y *Determined*).

Disponibilidad de soluciones específicas “plug-and-play”. Una palanca clave es la existencia de soluciones empaquetadas y orientadas a procesos aseguradores concretos —fraude, siniestros o tarificación— que permiten una integración rápida, generalmente bajo licencias SaaS o modelos modulares, sin necesidad de desarrollos internos de gran escala:

“Nuestra estrategia va a ser más reactiva porque al final pues si en algún momento me viene cualquier consultor y me dice, oye, en siniestros tengo un paquete, ¿vale?, pues que lo desarrollen. [...] No me voy a gastar yo 7 millones de euros para desarrollar un paquete que no sé si triunfará” (E08).

Costes decrecientes y modelos “pay-per-use”. La reducción acelerada de precios de la tecnología refuerza estrategias de espera y adopción selectiva. Como señaló un directivo:

“La última innovación suele costar el doble de lo que costará seis meses después. Y eso en una compañía como la mía, que mira muy bien la escasez de recursos, también tiene su importancia” (E07).

En paralelo, los modelos de pago por uso y la escalabilidad de la nube permiten a entidades medianas adoptar IA de forma gradual, alineando costes con beneficios probados.

Herramientas de bajo umbral para experimentación. La proliferación de soluciones universales y embebidas en suites ofimáticas (p.ej., Microsoft *Copilot*) ha democratizado el acceso a la IA, facilitando pruebas rápidas en áreas diversas:

“Ya tenemos, en el Office, ya tenemos Copilot que te ayuda a ir más rápido. Pues lo mismo. Esto lo veremos en muchas líneas de negocio” (E09).

Infraestructura de datos como base habilitadora. En entidades más maduras, la adopción gradual se apoya en una infraestructura analítica consolidada que permite escalar con rapidez:

“Nosotros estamos en un nivel bastante maduro, en tradicional y en los últimos años además nos ha permitido automatizar muchos procesos [...] fundamentalmente aplicamos machine learning” (E12).

En este sentido, la IA aparece como la “fase dos” natural de una trayectoria iniciada con la analítica avanzada:

“Esa analítica avanzada de datos [...] es la fase uno. ¿Qué pasa? Que ahora viene la dos [...] introducir herramientas de inteligencia artificial para explotar mejor esos patrones” (E16).

Soluciones on-premise para seguridad y privacidad. Las compañías mitigan riesgos de confidencialidad mediante entornos controlados y cerrados, lo que permite extender gradualmente el uso de IA a ámbitos sensibles:

“Vi que alguien del sector [...] mencionaba que tenían una red interna instalada en su empresa. Nosotros también la tenemos. La gran novedad es que ya está instalada en casa y es funcional, aunque en pruebas internas” (E04).

Pruebas de concepto y pilotos como norma de entrada. La gradualidad se articula operativamente a través de PoC y pilotos que limitan riesgos antes de pasar a producción:

“Una prueba de concepto que estamos haciendo, que parece así, sencillita y que no tiene mucha implicación. Pero si la cosa funciona bien, pues el alcance puede ser enorme” (E09).

Vigilancia continua y actualización permanente. La rápida evolución tecnológica obliga a las aseguradoras a mantener un monitoreo constante para no perder competitividad:

“Cambia tan rápido que no te da tiempo a que aprenda otro antes. [...] En cuanto te paras seis meses, ya está” (E11).

Esta vigilancia se traduce en dinámicas recurrentes con proveedores para evaluar el momento oportuno de adopción:

“Nosotros a estos proveedores, y los que vayamos viendo, los iremos llamando cada verano: ‘Oye, ¿cómo estáis?’” (E08).

La adopción gradual de la IA en el sector asegurador no debe interpretarse solo como cautela, sino como un modelo estructural de despliegue, sustentado en soluciones modulares, costes decrecientes, PoC escalonadas y controles de seguridad. Mientras que en niveles iniciales (Assessing) esta gradualidad refleja limitaciones de recursos y dependencia de proveedores, en fases más avanzadas (Determined y Managed) se convierte en una estrategia consciente para balancear velocidad, retorno y control organizativo.


4.2.2. Datos e Infraestructura

El bloque *Datos e Infraestructura* concentra 265 referencias en las 16 entrevistas, lo que confirma que se trata de uno de los pilares más críticos para la adopción de inteligencia artificial en el sector asegurador. Destacan especialmente Gobernanza del dato (56 referencias en 15 entrevistas) y Calidad del dato (46 referencias en 15 entrevistas), señaladas como prerequisites indispensables: sin marcos de gobierno sólidos, diccionarios corporativos ni datos fiables y consistentes, la analítica avanzada carece de valor operativo y estratégico.

Un segundo conjunto temático agrupa los retos de modernización tecnológica — sistemas *legacy*, arquitectura tecnológica, repositorios de datos y complejidad asociada—, con 87 referencias en total. Los testimonios apuntan al *legacy* como la principal barrera estructural, lo que obliga a costosos procesos de reingeniería y refuerza la necesidad de avanzar hacia arquitecturas modulares y *API-first*. En paralelo, la construcción de repositorios centralizados se percibe como inversión estratégica para unificar datos estructurados y no estructurados, aunque esta transición incrementa la complejidad tecnológica al coexistir múltiples generaciones de sistemas y la obligación de mantener la trazabilidad del dato.

Por último, aparecen dos categorías transversales: Plataformas tecnológicas (36 referencias en 10 entrevistas), que evidencian la creciente estrategia de consumir IA embebida en soluciones de terceros como *CoPilot* o Salesforce, y Dependencia tecnológica/lock-in (22 referencias en 10 entrevistas), que refleja las tensiones derivadas de la escalada de costes de licencia y la pérdida de autonomía frente a grandes proveedores. La Figura 23 sintetiza la distribución de entrevistas y referencias codificadas en torno al bloque Datos e Infraestructura, que emerge como uno de los pilares más críticos para la adopción de inteligencia artificial en el sector asegurador.

Figura 23: Distribución de entrevistas y referencias en las subcategorías de datos e infraestructura



Fuente: Elaboración propia

4.2.2.1. Sistemas Legacy

El principal obstáculo tecnológico para la adopción de la IA identificado de forma recurrente por los entrevistados es la persistencia de sistemas *core* heredados (*legacy*). Décadas de desarrollos internos y de crecimiento por acumulación han configurado arquitecturas fragmentadas y entrelazadas que limitan la implementación transversal de soluciones de IA. Un directivo lo describe con crudeza como una “configuración de aplicaciones en espagueti” que genera problemas en múltiples niveles:

“Al final tienes una mezcla de aplicaciones tan elevada, y los datos los tienes propietarios de esas diferentes aplicaciones. [...] Cuando tienes una arquitectura que está montada de esa manera, entonces tienes problemas en tres niveles: en la adquisición y presentación de datos, en las propias aplicaciones y en los datos mismos” (E01).

Esta situación se repite en entidades que conviven con múltiples generaciones tecnológicas, donde incluso los sistemas más recientes envejecen rápidamente:

“Tengo dos. El core antiguo, que está en proceso de extinción, pero no se acaba de extinguir nunca. Y el nuevo, que ya es viejo, que también es un desarrollo 100% interno” (E14).

No obstante, no todas las compañías sufren esta herencia de la misma manera. Algunas entidades destacan que decisiones tomadas en los años noventa — cuando se reconstruyó el sistema desde cero— les permiten hoy operar con datos únicos y de calidad:

“En un momento en los años 90, se optó por desarrollar un sistema nuevo. Ya permitió utilizar las técnicas de los años 90, donde la base de datos ya es una base de datos normalizada y granular, donde el dato está bien. [...] Nuestros

antecesores lo pasaron muy mal, pero nosotros lo disfrutamos, porque se hizo un sistema nuevo que nos da mucha productividad” (E08).

La deuda tecnológica asociada al *legacy* no solo ralentiza la integración de IA, sino que condiciona la estrategia de adopción. Mientras las entidades en fases más avanzadas de madurez AIMM (Managed) han invertido en planes de renovación de sistemas y despliegan *cores* modulares que facilitan la incorporación de algoritmos, aquellas situadas en estadios intermedios o iniciales (Assessing e Initial) reconocen que la complejidad de sus arquitecturas internas limita la capacidad de escalar proyectos más allá de pilotos.

Frente a estas limitaciones, las *InsurTechs* emergen como actores con mayor flexibilidad. Aunque ninguna cubre aún la totalidad de la cadena de valor, su ventaja reside en la ausencia de deuda tecnológica, lo que les permite especializarse en eslabones concretos con mayor agilidad y eficiencia:

“Yo, una InsurTech que cubra la totalidad de la cadena de valor del negocio asegurador todavía no he visto ninguna. Pero sí que es cierto que hay muchas InsurTech especializadas en determinados eslabones [...] probablemente por no tener que arrastrar legacy” (E02).

4.2.2.2. Arquitectura Tecnológica

Más allá de las limitaciones impuestas por los sistemas *legacy*, los directivos coinciden en que la plena explotación de la IA requiere evolucionar hacia arquitecturas modulares y conectables (*API-first*). El objetivo es disponer de un núcleo tecnológico flexible que permita un modelo *plug-and-play* con soluciones externas, reduciendo la dependencia de desarrollos internos y acelerando el *time-to-market*.

Un entrevistado describía así la lógica de esta transición:

“Estamos diseñando este core precisamente para que podamos ir adaptando módulos externos y que sean mucho más fáciles las adaptaciones. [...] La idea es que en el 27 tengamos un core al que podamos inyectar desde fuera todo lo que venga” (E14).

En paralelo, se percibe que la IA generativa exige un nivel aún mayor de sofisticación tecnológica y de datos. Para algunos directivos, constituye “el final de todo”, en el sentido de que su verdadero potencial solo puede desplegarse sobre infraestructuras preparadas:

“En los diferentes estadios hay muchísimo que hacer aún. [...] Es complicado hablar de inteligencia artificial generativa cuando aún tú no tienes [...] la tecnología o los datos suficientemente preparados para ello. Por tanto, creo que también tenemos que todos ir trabajando muchísimo en cómo estamos

evolucionando todas nuestras infraestructuras de datos y tecnológicas, para después poder utilizarla también al máximo” (E03).

La estrategia API-first y la construcción de *data pools* robustos emergen como ejes prioritarios de esta modernización. En contraste con la visión defensiva sobre el *legacy*, este discurso proyecta una hoja de ruta de futuro donde la flexibilidad, la interoperabilidad y la capacidad de conectar soluciones externas son condiciones indispensables para que la IA —y especialmente la generativa— pueda desplegar todo su potencial transformador.

4.2.2.3. Repositorios de datos centralizados

Para superar la fragmentación generada por el *legacy*, la mayoría de las aseguradoras han iniciado la construcción de repositorios de datos centralizados, como los *Data Lakes*. Estos proyectos son percibidos como estratégicos y fundamentales para habilitar la analítica avanzada y la explotación de la IA. Algunas entidades ya cuentan con plataformas consolidadas que consideran su “tesoro” (E03) o un “activo estratégico” que ha requerido años de inversión (E05), mientras que otras admiten encontrarse aún “en construcción”:

“Al punto de decir, oye, ¿tengo un Data Lake donde conservo de una ingesta completa de los datos de la compañía de manera completamente separada y donde yo aquí ya puedo operar de manera paralela a lo que sería el transaccional de la compañía? La respuesta es no, [...] estamos en construcción” (E01).

La necesidad de unificar datos estructurados y no estructurados es subrayada por varios directivos, al advertir que sin un modelo sólido el avance hacia IA generativa puede quedar bloqueado:

“Ahora mismo el dato es la clave, el estructurado, el conectado y el no estructurado. ¿Y la utilización de todos estos datos, ¿con qué tecnología? [...] como no tengan un modelo de datos que les permita realmente gestionar luego lo que les va a venir [...] se van a perder en el camino” (E12).

En paralelo, algunas compañías han optado por repositorios intermedios para esquivar las limitaciones del *core* y alimentar herramientas de visualización como Power BI:

“Hemos sabido encontrar la manera de generando unos [...] ficheros en otro sitio, y el Power BI bebe de ahí, no bebe de la fuente informacional, sale del repositorio. Y funciona bien” (E07).

El análisis comparado muestra que el avance en la construcción de repositorios centralizados está estrechamente ligado al nivel de madurez tecnológica (AIMM) alcanzado por cada entidad.

En el estadio Initial, no se registra ninguna referencia a *data lakes*. La única compañía situada en este nivel mantiene un enfoque esencialmente defensivo

sobre el uso del dato y carece de iniciativas estructurales orientadas a su explotación (E06).

En el nivel Assessing, comienzan a vislumbrarse los primeros movimientos. Dos entidades han dado pasos concretos, aunque todavía parciales: una ha optado por un repositorio intermedio para alimentar herramientas de visualización como Power BI (E07), mientras que otra se encuentra desplegando sistemas analíticos y CRM para reforzar la gestión del dato (E14). El resto mantiene una actitud de observación, centrada en ordenar gradualmente la información sin emprender aún proyectos de gran calado.

La situación cambia en el nivel Determined, donde más de la mitad de las compañías (4/7) reportan ya la existencia de *data pools* o bases transversales en diferentes grados de madurez. En este grupo destacan un *data lake* todavía “*en construcción*” (E01), un *datapool* robusto considerado “*el tesoro*” de la organización (E03), proyectos de catalogación e integración para superar redundancias (E04) o la creación de *data warehouses* y procesos ETL acompañados de un refuerzo de la gobernanza (E16). Sin embargo, aún persisten casos en los que predominan los silos o se prioriza la normalización y calidad del dato antes que la centralización (E02, E09, E15).

Finalmente, en el nivel Managed, los repositorios de datos centralizados se consolidan como una pieza clave de la infraestructura tecnológica. Tres entidades mencionan de forma explícita la existencia de *foundations* sólidos: desde un gran *data lake* corporativo desplegado a escala global (E05), hasta estructuras concebidas como requisito para escalar la IA (E12) o la reorganización integral de los datos por verticales de negocio (E11). La cuarta (E13) enfatiza la importancia de la ordenación intensiva del dato, con un foco claro en habilitar procesos de escalado operativo continuo.

4.2.2.4. Calidad del Dato

La calidad, fiabilidad y estructura de los datos emergen como un prerequisite ineludible para la adopción de IA en las aseguradoras españolas. Mientras que el apartado anterior abordaba la consolidación de repositorios centralizados (Data Lakes, Data Pools) como infraestructuras habilitadoras, aquí la atención se centra en el cómo: la depuración, la coherencia semántica y la gobernanza de los datos que alimentan a la IA.

Los primeros proyectos de analítica avanzada y de IA han servido para poner de relieve carencias en los datos, lo que ha convertido el saneamiento en una prioridad estratégica. En palabras de un directivo:

“La fiabilidad de las de los datos. O sea, yo creo que es clave para generar cualquier output que sea fiable” (E02).

Otro entrevistado reconocía que este proceso de depuración es un trabajo ingrato, pero indispensable:

“Cualquier proyecto de tecnología que comporte el uso o el análisis masivo de datos, ha habido una parte menos agradable, mucho más administrativa, que ha sido [...] toda la fase de depuración de esos datos” (E07).

La importancia de la calidad del dato trasciende lo técnico y alcanza la esfera organizativa. En algunas entidades, se ha institucionalizado como disciplina propia, vinculada incluso a incentivos de la alta dirección:

“La calidad del dato es un tema tremendo, tremendo. [...] recientemente hemos llevado la calidad del dato, a propuesta del presidente, al variable de la alta dirección” (E05).

Esta formalización contrasta con compañías donde aún predominan datos redundantes o mal segmentados, lo que ralentiza el aprovechamiento de modelos avanzados:

“Descubres, cuando lanzas estos modelos, que al final hay déficit de datos. [...] Llevamos un año y cuatro meses de experiencia. No hemos podido rehacer la base de datos histórica” (E16).

Los testimonios muestran disparidad significativa entre entidades. Algunas entidades capitalizan reingenierías previas y hoy disfrutan de “datos únicos y con calidad” (E08), mientras que otras reconocen que sus procesos se ven limitados por la inconsistencia y dispersión heredada de sistemas *legacy* (E03, E09). La clave radica en la gobernanza: integrar catálogos de datos, eliminar redundancias y estandarizar definiciones son pasos previos indispensables para que los modelos produzcan resultados fiables.

Desde la perspectiva de la madurez organizativa (AIMM), esta heterogeneidad se traduce en un patrón evolutivo:

- En fases **Assessing**, los problemas de calidad son todavía básicos, centrados en la inconsistencia histórica y la falta de estandarización.
- En niveles **Determined**, comienzan a desplegarse proyectos de catalogación y diccionarios de datos, aunque los silos persisten y ralentizan los avances.
- En compañías **Managed**, la calidad del dato se institucionaliza como disciplina estratégica, vinculada a la gobernanza corporativa y a incentivos directivos.

4.2.2.5. Gobernanza del Dato

La gobernanza del dato emerge como un ámbito en consolidación en las aseguradoras, concebido como el marco que permite asegurar la calidad, coherencia y disponibilidad de la información para su explotación analítica y para

el despliegue de iniciativas de inteligencia artificial. Lejos de ser un ejercicio puramente técnico, los entrevistados describen la gobernanza como un proceso organizativo que requiere de estructuras estables, roles específicos y políticas comunes.

En varios casos se han creado diccionarios de datos corporativos que homogeneizan definiciones y garantizan consistencia en los distintos dominios de negocio:

“No había un diccionario de datos. Ahora hemos creado un diccionario bastante completo con los términos. [...] Cada año vamos trabajando. Este año, un área, el siguiente otro, y así sucesivamente” (E04).

La institucionalización de la gobernanza se apoya también en la emergencia de figuras y órganos especializados, que articulan el proceso de forma transversal. Algunos directivos destacan la creación de centros de competencia en inteligencia artificial que incluyen áreas diversas —ciberseguridad, riesgos, talento, protección de datos o asesoría jurídica— con el fin de establecer políticas claras y mecanismos de control:

“Hemos creado lo que se llama un centro de competencia de inteligencia artificial, donde están representadas distintas funciones [...] y ahí es donde van a salir las políticas de la compañía” (E11).

Asimismo, se observa una evolución en el discurso: la gobernanza ya no se presenta únicamente como un esfuerzo de control y corrección técnica, sino como un habilitador del negocio. La lógica ha pasado de centrarse en indicadores abstractos de calidad a organizar la información de manera que resuelva problemas concretos en áreas clave:

“Ya no hablamos de gestión del dato de calidad del dato [...] ahora está ordenado por verticales de negocio. Y entonces resolvemos problemas concretos. Y todo lo demás de calidad y gobernanza lo vamos haciendo porque hay que hacerlo” (E11).

El análisis muestra un patrón consistente con los niveles de madurez tecnológica (AIMM). En etapas Assessing, la gobernanza se percibe aún como incipiente y se limita a ordenar catálogos básicos o corregir inconsistencias localizadas. En niveles Determined, se avanza hacia modelos más estructurados, con diccionarios, responsables designados y planes plurianuales, aunque todavía conviven con silos históricos. Finalmente, en las fases Managed, la gobernanza alcanza un grado de formalización mayor, con indicadores vinculados a la alta dirección y órganos transversales que integran datos, riesgos y estrategia.

4.2.2.6. Plataformas Tecnológicas (CoPilot, Salesforce, etc.)

Un rasgo distintivo en la adopción de IA en el sector asegurador es que, especialmente en entidades pequeñas y medianas, la estrategia predominante no consiste en desarrollar modelos propios, sino en consumir funcionalidades de IA embebidas en plataformas de terceros. Este enfoque incluye la incorporación de capacidades de IA en CRMs, herramientas ofimáticas, soluciones de ciberseguridad o plataformas de atención al cliente. La principal motivación es la rapidez en la obtención de valor, al permitir mejoras inmediatas en productividad sin necesidad de inversiones elevadas en talento o infraestructuras.

Como explicaba un directivo en relación con la formación y soporte en *contact centers*:

“Ahora no hay tanta necesidad de formación técnica de los productos [...] porque tienen la posibilidad de preguntar [...]. Entonces ahora eso es mucho más ágil, la llamada es mucho más corta y el cliente obtiene una respuesta mucho antes” (E02).

Este patrón se observa con fuerza en entidades situadas en fases *Assessing* y *Determined*, que aprovechan las soluciones SaaS como puerta de entrada a la IA. La lógica es clara: “nuestra estrategia va a ser más reactiva porque al final, si en algún momento me viene cualquier consultor y me dice, oye, en siniestros tengo un paquete, ¿vale?, pues que lo desarrollen. [...] No me voy a gastar yo 7 millones de euros para desarrollar un paquete que no sé si triunfará” (E08). La dependencia de proveedores se convierte así en un mecanismo de reducción de riesgos y costes, aunque a costa de ceder parte del control estratégico.

El uso de plataformas embebidas también obliga a replantear la arquitectura tecnológica y los modelos de datos. Varias compañías reconocen que estas herramientas exigen estructuras de datos adaptadas que no siempre están disponibles:

“Nos hemos dado cuenta de que la estructura de datos necesaria para que eso lo podamos explotar bien no es la misma que necesitábamos. [...] Estamos viendo si tenemos que cambiar ciertas estructuras de datos para que eso funcione a nivel usuario” (E10).

Las empresas con mayor madurez (nivel *Managed*) integran estas soluciones en arquitecturas más sofisticadas, combinando repositorios centralizados con el consumo de IA como servicio. En estos casos, las plataformas no sustituyen al desarrollo interno, sino que se convierten en un complemento estratégico que refuerza la capacidad analítica y operativa. Así lo ejemplifica la adopción de versiones privadas y cerradas de modelos generativos:

“Hemos comprado una caja, un Enterprise, por decir algo. Un ChatGPT cerrado en local y le hemos subido nuestros condicionados. Entonces estamos haciendo preguntas sobre nuestros condicionados [...] y la IA ha sabido interpretar el condicionado [...] y dar una respuesta coherente” (E09).

La seguridad emerge como condición indispensable, sobre todo cuando se manejan datos sensibles. Por ello, varias entidades optan por entornos controlados en local o en nubes privadas, conscientes del riesgo de transferir conocimiento estratégico a terceros sin garantías. La tensión entre dependencia de proveedores y necesidad de control interno aparece como una de las cuestiones más citadas en los testimonios.

Finalmente, los directivos expresan percepciones diversas sobre el verdadero alcance transformador de estas plataformas. Mientras algunos destacan ganancias inmediatas y califican su impacto de “brutal”:

“Es tan brutal, tan brutal... que es, ¡madre mía de mi vida! [...] En el caso de uso que tenemos, tenemos un ahorro de un 50% del tiempo [...] Y acabamos de empezar” (E12).

Otros muestran decepción con herramientas que no cumplen las expectativas generadas:

“CoPilot va a venir y nos va a solucionar la vida en términos de análisis [...]. Y eso sí que ha sido una verdadera decepción. [...] No está lo desarrollado que se ha vendido” (E10).

4.2.2.7. Dependencia Tecnológica / Lock-in

La adopción de soluciones externas de IA plantea un desafío recurrente: la dependencia tecnológica y el riesgo de *vendor lock-in*. Este fenómeno, ampliamente documentado en la literatura de gestión tecnológica bajo los conceptos de *path dependence* y *switching costs*, describe la dificultad —y en ocasiones la imposibilidad— de abandonar un proveedor una vez que la organización ha integrado sus soluciones en procesos críticos.

Los directivos entrevistados advierten de una escalada constante de los costes de licencias, que se perciben como una “renta vitalicia” inevitable:

“Cuando veo lo que me cuesta todos los años, las 96 o las 110 licencias, digo, esto es una renta vitalicia porque ya no te puedes salir y ahora te piden 400” (E14).

Las negociaciones con los grandes proveedores globales son complejas, en parte porque sus modelos de licenciamiento no siempre se adaptan a las especificidades del negocio asegurador:

“No estábamos dispuestos uno a comprar 20.000 licencias y menos aún a estar sujetos a que año tras año nos fueran aplicando incrementos. Pues les costó muchísimo, muchísimo entenderlo” (E02).

Una vez implantada una solución, el proceso de desvinculación se considera técnica y económicamente inviable. A ello se suma la pérdida de control sobre la información, que lleva a las aseguradoras a fijar “líneas rojas” para proteger los datos sensibles:

“Nosotros hemos marcado una línea roja que es no usarla dándole datos, que puedan tener sensibilidad o que puedan tener un uso por terceros dañino para nuestra propia compañía o, que transfieren inteligencia muy rápida y muy gratuita a terceros” (E07).

Las estrategias de mitigación adoptadas varían en función del nivel de madurez AIMM. En fases Assessing y Determined, la dependencia de proveedores externos es mayor debido a la falta de capacidades internas, lo que amplifica los riesgos de lock-in. En estas fases, la IA suele consumirse a través de soluciones empaquetadas, sin margen para personalización ni control. En cambio, en las entidades Managed, se observa un modelo híbrido, que combina la externalización con la preservación de talento y capas críticas de control interno:

“Nuestro modelo es como más... es un poco más in-house. O sea, sí que tenemos mucho externo [...] pero nos aseguramos, o sea que la primera capa y la segunda capa directiva sea gente interna de la casa que sobre todo conozca el negocio” (E02).

4.2.3. Riesgos


El bloque Riesgos concentra 113 referencias en 15 entrevistas, lo que confirma que constituye una de las principales preocupaciones de los directivos en relación con la adopción de la IA. Tal como se observa en la Figura 24, la subcategoría con mayor peso es Reputación y confianza (43 referencias en 15 entrevistas), lo que refleja que el impacto de la IA no se evalúa únicamente en términos técnicos, sino también en su capacidad para preservar la legitimidad social y la confianza de clientes, mediadores y reguladores. Por este motivo, la mayoría de entidades opta por restringir el uso de la IA a procesos internos o de apoyo supervisado, posponiendo su despliegue directo hacia el cliente hasta contar con garantías técnicas y regulatorias más sólidas.

En un segundo nivel destacan los riesgos éticos y de discriminación (26 referencias en 13 entrevistas), asociados al sesgo algorítmico y al riesgo de desmutualización del seguro. Los directivos advierten que la granularidad en la tarificación puede erosionar el principio de solidaridad y excluir a colectivos de mayor riesgo, poniendo en cuestión el propio modelo mutualista. Con un peso similar, la caja negra y la falta de explicabilidad (17 referencias en 8 entrevistas) y la pérdida de control sobre procesos (15 referencias en 8 entrevistas) señalan dos frentes complementarios: por un lado, la opacidad de los modelos —especialmente los de terceros— obliga a reforzar mecanismos de supervisión y auditoría; por otro, la dependencia de proveedores y la cesión de datos alimentan el temor a perder soberanía tecnológica, lo que impulsa la creación de entornos privados y estrictos controles internos.

Finalmente, los entrevistados subrayan los riesgos propios de la IA generativa, en particular las alucinaciones (12 referencias en 9 entrevistas), que ponen en cuestión la fiabilidad de los resultados y explican la cautela con la que se están aplicando. El consenso es claro: la IA generativa aún no ofrece garantías suficientes para interactuar directamente con los clientes, limitándose a usos internos bajo verificación humana y técnicas como el prompt engineering para reducir errores.

La Figura 24 recoge la distribución de entrevistas y referencias por subcategoría dentro del bloque Riesgos. El gráfico permite visualizar de forma clara el predominio de las preocupaciones asociadas a la reputación y la confianza, seguidas de los riesgos éticos y de discriminación, mientras que aspectos como la explicabilidad de los modelos, la pérdida de control sobre procesos o las alucinaciones en sistemas generativos presentan un peso algo menor, aunque igualmente significativo en el discurso de los directivos.

Figura 24: Distribución de entrevistas y referencias en las subcategorías de riesgos asociados a la adopción de IA



Fuente: Elaboración propia

4.2.3.1. Caja negra y explicabilidad de los modelos

La percepción de la IA como una “caja negra” constituye un denominador común en los discursos de los directivos aseguradores. La opacidad tanto de soluciones adquiridas a terceros como de modelos internos se cita reiteradamente como uno de los riesgos principales, al generar incertidumbre sobre la fiabilidad de los resultados y al plantear interrogantes regulatorios y éticos.

En el caso de soluciones externas, los entrevistados reconocen que el funcionamiento interno de las herramientas es desconocido para la compañía, lo que introduce una dependencia adicional respecto al proveedor:

“Para esta solución utilizamos un software que es un software de protección de máquinas y allí hay pues técnicas de inteligencia artificial que yo te diría que para nosotros es caja negra, es decir, nos viene el software y nosotros sabemos que los técnicos [...] acaban de decidir si aquello puede ser un comportamiento normal [...] o un posible ataque” (E01).

Más allá de la falta de visibilidad sobre algoritmos de terceros, la dificultad para trazar y justificar por qué un modelo de IA produce un determinado resultado se percibe como un reto transversal a toda la industria:

“Es imprescindible que tú seas capaz de explicar por qué estás tomando esas decisiones, es decir, que tú seas capaz de explicar por qué la caja negra ha generado [ese resultado]. Y yo creo que ese es uno de los grandes retos de toda la inteligencia artificial” (E02).

Las implicaciones de esta opacidad se consideran especialmente críticas cuando afectan a decisiones de tarificación o selección de riesgos que podrían derivar en sesgos o exclusiones colectivas:

“Me preocupa no saber exactamente qué es lo que está pasando dentro de esa caja negra [...] por ejemplo, que la prevalencia del fraude sea mayor en una determinada zona y esto nos lleve a subir la prima o incluso a excluir de la cobertura a determinados colectivos” (E02).

Como respuesta, las entidades adoptan salvaguardas que incluyen la intervención humana obligatoria (*human-in-the-loop*), auditorías periódicas y monitorización constante de outputs. En palabras de un directivo:

“Lo tengo claro: al menos en esta fase, la última decisión siempre será de una persona humana” (E04).

Otro entrevistado añadía:

“Yo no considero que la inteligencia artificial pueda hacer un proceso desde el principio hasta el final [...] todos los proyectos que estamos marcando necesitan una intervención humana en algún punto” (E10).

Finalmente, la falta de explicabilidad también impulsa estrategias organizativas de control interno. Algunas entidades priorizan internalizar conocimiento en lugar de depender de proveedores de nicho que entregan algoritmos opacos:

“Preferimos internalizar el conocimiento [...] no podemos tener siete cajas negras por ahí. Intentamos que quienes conocen bien el modelo estén dentro de la compañía” (E11).

Patrón según niveles de madurez (AIMM)

El análisis comparado muestra que la preocupación por la “caja negra” y la búsqueda de explicabilidad se modulan en función del nivel de madurez:

- **Initial y Assessing:** el discurso se centra en la desconfianza hacia herramientas externas percibidas como “cajas negras” y en la fijación de *líneas rojas* sobre los datos que se transfieren. La preocupación se vincula a la falta de capacidades internas para auditar o replicar los algoritmos.
- **Determined:** emerge con fuerza la preocupación por la trazabilidad y la explicabilidad de modelos predictivos y generativos. Se institucionalizan mecanismos de supervisión humana y se reconoce explícitamente el riesgo de sesgos y exclusiones derivadas de decisiones algorítmicas opacas.
- **Managed:** el foco se desplaza hacia la creación de estructuras de gobernanza (p. ej. centros de competencia en IA) y la internalización de capacidades técnicas. Aunque también consumen soluciones externas, estas entidades

buscan equilibrar eficiencia con soberanía tecnológica, integrando la explicabilidad en la gobernanza corporativa y la gestión del riesgo.

4.2.3.2. Alucinaciones en modelos generativos

Además de la falta de explicabilidad, el riesgo de "alucinaciones" (la generación de información plausible pero incorrecta o inventada por parte de los modelos generativos) constituye una preocupación crítica que condiciona adopción de la IA generativa. Las compañías perciben de forma unánime que estos modelos se encuentran en una fase de desarrollo temprana, insuficiente para garantizar la robustez que requieren los procesos del negocio asegurador.

Se considera necesaria una validación manual constante, ya que los resultados no son, de partida, confiables.

“la imprecisión ...los resultados hay que mirárselos con un poco de detalle o como mínimo, lo que salga de esas cajas negras. Hay que mirarlo, hay que revisarlo, hay que revisarlo un poco, un poco manual” (E02).

La incapacidad de eliminar o reducir las alucinaciones hasta un nivel aceptable ha llevado a la suspensión de iniciativas ya en marcha:

“El Chatbot... lo hemos retirado... decía auténticas tonterías [...] cuesta tanto que aprenda [...] es que tiene que estar muy perfeccionada la herramienta para que dé la información que tú quieres” (E14).

Debido a esta falta de fiabilidad, las entidades están limitando al máximo el ámbito de aplicación de la IA generativa a ámbitos internos, evitando deliberadamente la exposición directa al cliente final.

“No lo vamos a utilizar directamente con cliente hasta que no tengamos seguro qué es lo que vamos a hacer [...] por el tema de las alucinaciones, por el tema de donde puede derivar esto” (E12).

En los casos con exposición a cliente se implementan capas de control manual para contrastar la veracidad del contenido generado:

“Estamos utilizando ya la inteligencia artificial para que nos ayude en la parte de la generación del contenido, que luego es revisado por una persona del equipo para ver que no haya barbaridades” (E09).

Además, se exploran activamente mecanismos técnicos como el diseño de instrucciones (prompt engineering) para reducir la propensión de los modelos a alucinar.

“Basta con que le digas: “Si no lo sabes, no te lo inventes”, para reducir muchísimo las alucinaciones” (E11).

4.2.3.3. Riesgos éticos y discriminación

Riesgos éticos y discriminación

Los directivos entrevistados coinciden en señalar que la adopción IA plantea riesgos éticos de gran calado. Una de las preocupaciones más citadas es el sesgo algorítmico, entendido como la posibilidad de que los modelos reproduzcan o amplifiquen desigualdades sociales ya existentes. La aplicación de algoritmos a patrones históricos puede conducir a resultados discriminatorios, generando decisiones que penalicen a colectivos específicos y erosionen la confianza en el sector asegurador. Un directivo lo expresaba con claridad:

“Me preocupa desde el punto de vista de impacto empresarial o de implicaciones morales o éticas. Por ejemplo, que... la prevalencia del fraude es mayor en una determinada zona de España. Y esto nos lleve a subir la prima o incluso a excluir de la cobertura de aseguramiento a unos determinados colectivos” (E02).

Impacto en el principio mutualista

Más allá de los sesgos puntuales, el riesgo más profundo identificado por los entrevistados es la desnaturalización del principio mutualista, pilar sobre el que se asienta la actividad aseguradora. La mayor granularidad que aportan los modelos de IA facilita la tarificación individualizada, lo que amenaza con convertir el seguro en un instrumento de selección más que de protección colectiva. Así lo advertían distintos directivos:

“El seguro cada vez la prima será menos solidaria. [...] lo que tendrás es que habrá gente que no se podrá asegurar y entonces tendrá a actuar más el consorcio o veremos qué pasa” (E08).

“Si al final haces pólizas para cada tío en función de lo que tal... estamos jodiendo el seguro porque estamos rompiendo el carácter mutualista” (E14).

“Efectivamente, el principio de desmutualización es absoluto. Llevan al riesgo individualizado [...] El principio mutual se lo cargan” (E16).

Incluso quienes reconocen el valor analítico de la IA advierten que la sofisticación excesiva en la segmentación de riesgos puede conducir a escenarios indeseados de exclusión. Como señalaba otro entrevistado:

“Si le metemos una capa de inteligencia artificial que incrementa esas capacidades, al final estamos desnaturalizando el seguro, porque a cada uno le vamos a cobrar por el riesgo que tiene y usted está perdiendo la parte de [...] el concepto mutualista” (E02).

Respuestas organizativas

Ante estas tensiones éticas, algunas entidades buscan fórmulas de equilibrio que permitan aprovechar las capacidades predictivas de la IA sin romper la lógica mutual. Varios directivos apuntan a la necesidad de mantener productos estandarizados o “puntos intermedios” que aseguren el acceso a colectivos de mayor riesgo:

“La esencia del sector básicamente es el mutualismo y la solidaridad entre el conjunto. Claro, todo esto se desnaturaliza un poco. [...] Debemos encontrar un punto en el que haya una prima estándar básica con ciertos márgenes de maniobra según el perfil” (E04).

Asimismo, se introducen salvaguardas organizativas y regulatorias para evitar efectos indeseados. Algunas compañías ya realizan auditorías periódicas de sesgos en los modelos, mediante tests estructurados y revisiones sistemáticas de decisiones (E03), mientras que otras destacan la necesidad de mantener la intervención humana en los procesos de decisión críticos:

“Nuestro concepto todavía no es que la máquina ande sola. [...] Para mí todos los proyectos que estamos marcando necesitan una intervención humana en algún punto” (E10).

4.2.3.4. Pérdida de control sobre procesos

Otra de las preocupaciones manifestadas por los entrevistados es el riesgo de perder el control sobre los procesos de negocio al incorporar IA. Este temor se articula en tres planos interrelacionados: la dependencia de proveedores externos, la soberanía de los datos y la deriva del aprendizaje autónomo de los modelos.

Ceder datos a proveedores tecnológicos se percibe como una cesión de “inteligencia de negocio” y, en consecuencia, como un riesgo estratégico. Varios directivos advierten que el conocimiento extraído de los datos corporativos puede revertir más en el proveedor que en la aseguradora:

“Con todos los peligros que conlleva algo que escapa nuestro control [...] el volcado de datos y el volcado de documentos porque ahora mismo te hace cualquier cosa [...] pero se lo está quedando todo. De alguna manera, hay una transferencia de conocimiento, no a la máquina, sino a los dueños de la máquina” (E07).

El uso de herramientas públicas de IA generativa incrementa esa sensación de pérdida de control debido a la posibilidad de “contaminación cruzada” entre compañías:

“Ha habido casos donde, al preguntar sobre una entidad, la IA contesta en base a información que había metido otra compañía porque va todo al mismo sitio” (E06).

Como respuesta, varias entidades han decidido implementar entornos controlados, desarrollando versiones privadas de los modelos que minimizan la exposición externa. Un directivo describía su estrategia como un *“chatGPT, pero dentro de un entorno privado”* (E01), subrayando la necesidad de mantener la soberanía de los datos y el control del conocimiento derivado de ellos.

A este riesgo se añade la preocupación por la *“deriva del modelo” (model drift)*, es decir, el deterioro progresivo de la precisión y fiabilidad de los modelos a medida que aprenden de sí mismos o de entornos cambiantes. Aunque todavía se trata de un fenómeno incipiente en las aseguradoras, algunos directivos reconocen su inquietud sobre cómo controlar esta evolución:

“Cuando lo escalemos, tendremos que establecer nuestros controles para realmente seguir asegurando que, como el modelo aprende de sí mismo, no se nos va. Eso es lo que tenemos que ver, cómo tenemos que hacer esa parte. Pero como es tan nuevo es que no sabemos” (E12).

Estos riesgos internos se ven amplificados por un contexto de creciente inseguridad digital, derivada de fenómenos como los *deepfakes* y la manipulación de evidencias digitales. La facilidad con que pueden fabricarse correos, audios o imágenes falsas introduce un nuevo nivel de incertidumbre en procesos críticos como la gestión de siniestros o los litigios, poniendo en jaque la confianza digital.

“En el ámbito de siniestros, es que ahora tú tienes un correo electrónico y lo presentas en un juicio o unos whatsapps y ¿vale todo esto? [...] Hay una herramienta a la cual tú le das un audio de una persona y te genera todo lo que sería después una posible entrevista de forma sintética” (E08).

Paradójicamente, los mismos riesgos que generan preocupación entre las entidades también abren la puerta a nuevas oportunidades de negocio. La creciente conciencia sobre amenazas como la ciberseguridad impulsa la demanda de productos aseguradores específicos. Las entidades más atentas al entorno podrán convertir estos desafíos en oportunidades de mercado:

“Ir viendo los cambios en la sociedad y a partir de allí ver si hay pues alguna solución que nosotros podamos entrar. Pues como ciberseguridad entramos hace cinco años”. (E08)

En este contexto, la supervisión humana se concibe como la principal salvaguarda frente a una pérdida de control. Existe un consenso generalizado en que la automatización total es prematura y arriesgada:

“La última decisión siempre será de una persona humana” (E02).

El enfoque mayoritario es el de un *“modelo híbrido, ético y responsable”* (E05), donde la IA actúa como herramienta de apoyo y no como sustituto del juicio humano. Así ocurre en áreas sensibles como la detección de fraude, donde, aunque

los casos se analicen inicialmente con algoritmos, *“todos esos outputs pasan a un departamento de personas” para aplicar “sentido común y, sobre todo, ética”* (E02).

4.2.3.5. Reputación y confianza

La reputación y la confianza de los clientes y de los mediadores se mencionan como uno de los factores más sensibles en la adopción de IA. De las dieciséis entrevistas realizadas, diez directivos (63%) mencionan explícitamente este riesgo, con un total de doce referencias codificadas.

Una de las preocupaciones más destacadas es la frustración que puede generar en los clientes el despliegue de tecnologías poco maduras, especialmente *Chatbots*:

“Francamente mal, muy mal. O sea, como que se queda entre enredado y encima es difícil, horrible. Yo no salgo del bucle” (E13).

Otro entrevistado corrobora esta visión, relatando sus dificultades como cliente de otra aseguradora al enfrentarse a sistemas de voz que no resuelven los problemas planteados (E15). Estas experiencias negativas confirman que la falta de fiabilidad tecnológica puede traducirse inmediatamente en pérdida de confianza.

El riesgo reputacional no se limita al contacto directo con clientes. También se asocia al manejo de datos y al cumplimiento normativo. Varios directivos expresan su inquietud ante la posibilidad de que la información corporativa termine en manos de terceros.

“Con todos los peligros que conlleva algo que escapa nuestro control [...] el volcado de datos y el volcado de documentos [...] hay una transferencia de conocimiento, no a la máquina, sino a los dueños de la máquina” (E07).

En esta línea, otro entrevistado alerta del riesgo de “contaminación cruzada” en el uso de modelos generativos abiertos:

“Ha habido casos donde, al preguntar sobre una entidad, la IA contesta en base a información que había metido otra compañía porque va todo al mismo sitio” (E06).

La incertidumbre regulatoria añade un elemento adicional de riesgo. En particular, la clasificación de ciertas actividades como “de alto riesgo” en el marco del AI Act de la UE despierta temores sobre posibles sanciones y, sobre todo, sobre el impacto reputacional de un incumplimiento:

“Nos tira para atrás, pero me preocupa mucho, no está nada claro. Todo el tema de la Artificial Intelligence Act que nos ha catalogado como actividades de alto riesgo [...] no tenemos mucha claridad” (E03).

La complejidad de la norma se percibe como un freno, que obliga a destinar recursos significativos a su interpretación antes de avanzar en proyectos (E11).

Ahora bien, la reputación no se asocia únicamente a riesgos, sino también a oportunidades. Algunos entrevistados destacan que la IA puede convertirse en una palanca decisiva para reforzar la confianza si se orienta hacia la mejora tangible de la experiencia de cliente:

“Mi filosofía sobre esto es que esto lo que va a redundar sobre todo es en una mejor experiencia de cliente, claramente. [...] Es la noche y el día” (E03).

4.3. Dimensión Entorno (E)

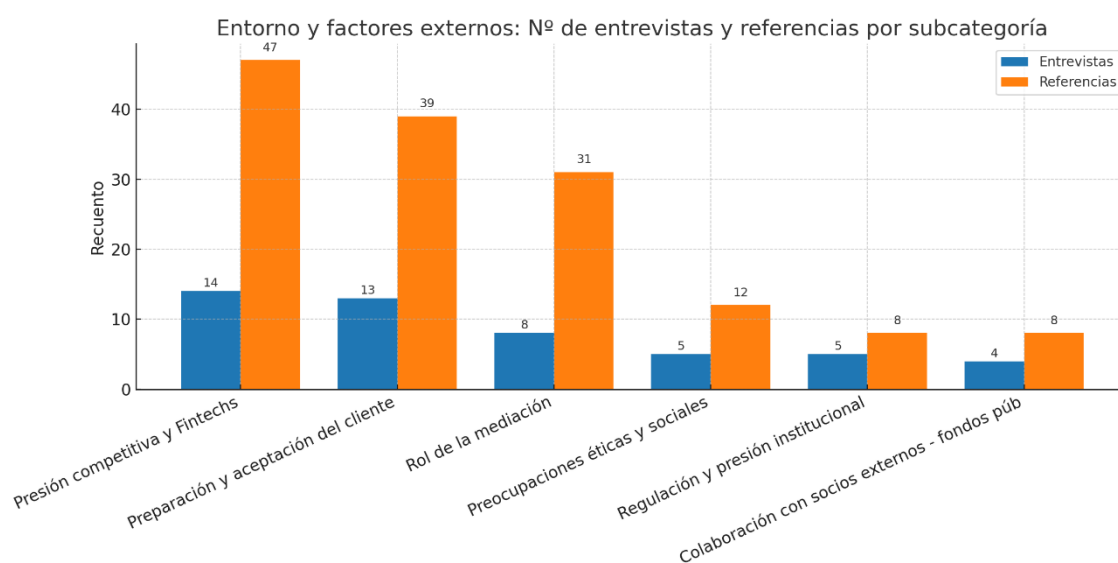
En este apartado analizamos la dimensión Entorno (E) y su influencia en la adopción de IA en las aseguradoras españolas. La sección aborda, primero, los factores externos que configuran el contexto competitivo (presión de grandes grupos y papel de *InsurTechs/Big Tech*), la preparación y aceptación del cliente, y el rol de la mediación en el ritmo y la forma del despliegue. En segundo lugar, examinamos la regulación —con especial atención al marco europeo y a la protección de datos— y cómo esta condiciona la priorización de casos de uso y la escala de las inversiones. Por último, revisamos las colaboraciones con socios externos como mecanismo de acceso a capacidades, aprendizaje y aceleración de pilotos, así como las tensiones que introducen (costes, *lock-in*, soberanía tecnológica).

4.3.1. Entorno y factores externos

El bloque “Entorno y factores externos” reúne 145 referencias en 15 entrevistas, confirmando que el contexto competitivo y regulatorio condiciona significativamente la adopción de IA en el sector asegurador. La Presión competitiva y *FinTechs* concentra la mayor parte (47 referencias en 14 entrevistas), destacando la tensión entre grandes grupos que marcan el ritmo y entidades medianas que optan por estrategias de *fast followers*. La Preparación y aceptación del cliente (39 referencias en 13 entrevistas) y el Rol de la mediación (31 referencias en 8 entrevistas) reflejan la importancia de mantener el contacto humano y de acompañar a la red de agentes en su transformación. A ello se suman las Preocupaciones éticas y sociales (12 referencias en 5 entrevistas), centradas en la desmutualización del seguro, y la influencia de la Regulación y la Colaboración con socios externos (8 referencias cada una).

La Figura 25 sintetiza la distribución de entrevistas y referencias dentro del bloque *Entorno y factores externos*.

Figura 25: Distribución de entrevistas y referencias en las subcategorías de Entorno y factores externos



Fuente: Elaboración propia

4.3.1.1. Presión Competitiva y Papel de las *InsurTech*

Presión Competitiva

Los directivos perciben que los grandes grupos aseguradores, sobre todo los de carácter multinacional, marcan el ritmo de la innovación gracias a su superior capacidad de inversión y a la escala de sus datos. Esta situación genera una presión

reactiva en el resto de competidores. Un directivo de una compañía de tamaño considerable destaca la asimetría de recursos de manera explícita:

“Claro, cuando tú te estás comparando con grupos que son diez veces lo que tú, pues su capacidad de inversión, pues es eventualmente como mínimo diez veces superior a la tuya. [...] a buen seguro se están desarrollando grandes proyectos tecnológicos a nivel corporativo de los que se van a beneficiar las sucursales y eso evidentemente es una ventaja competitiva con la que tienes que lidiar”. (E02).

Sin embargo, la mayoría de los entrevistados no percibe que, en la actualidad, la inteligencia artificial les esté generando una ventaja competitiva diferencial ni que exista un competidor que, gracias a un uso a gran escala de esta tecnología, esté obteniendo beneficios estratégicos significativos en el mercado español. Aun así, reconocen el potencial transformador de la IA y comparten una sensación de urgencia por mantenerse al día, de modo que, cuando la tecnología alcance un nivel suficiente de madurez, su organización no haya “perdido el tren” y pueda adoptarla con rapidez y eficacia.

Esta ventaja, en opinión de varios directivos, podría, a medio plazo, concentrar el mercado. Se anticipa una convergencia digital liderada por las grandes entidades, que podrían atraer a los clientes de competidores más pequeños si estos no logran igualar la experiencia ofrecida:

“Creo que lo que se producirá es, lentamente, una convergencia a la que llegarán primero las de las grandes compañías que tienen recursos. El 20 % del mercado que genera el 80 % de las primas y que ahí sí que está el riesgo de que las compañías medianas y pequeñas que no tienen esa capacidad de inversión [...] se queden, digamos, les cueste tanto llegar, que el cliente acabe discriminando y acabe yéndose a aquellas compañías que ofrecen una experiencia superior”. (E15).

Esta dinámica genera sensación de urgencia sobre todo en las entidades grandes que sienten la necesidad de acelerar para no “perder la carrera”, un impulso que a menudo es una directriz estratégica corporativa:

“Esto es un top down del propio CEO del grupo. [...] Se ha montado una organización a nivel grupo. Mensualmente nos dicen dónde estamos, qué estamos invirtiendo, qué vas a escalar, qué no vas a escalar [...]. Esto nos obliga a nosotros [...]. Teníamos en el plan estratégico [...] y ahora resulta que tenemos que identificar inversiones adicionales a las que teníamos con resultados adicionales sobre esas inversiones”. (E12).

Frente a la estrategia de liderazgo de los pioneros, varias entidades de tamaño mediano adoptan conscientemente un rol de *fast follower*. La ausencia de pruebas claras de que algún competidor esté logrando ventajas competitivas sostenibles

mediante la IA refuerza la idea de que no es necesario precipitarse, aunque sí es clave estar listos para reaccionar en cuanto la tecnología esté lista para escalarse. Esta estrategia no implica pasividad, sino una agilidad reactiva. Algunos directivos confían en su capacidad para absorber rápidamente el conocimiento generado por los primeros adoptantes, minimizando así el riesgo de la inversión inicial:

“¿La última innovación? Suele costar el doble de lo que costará 6 meses después. Y eso en una compañía como la mía, que mira muy bien la escasez de recursos también tiene su importancia. Si otros están un poco por delante no me preocupa porque luego yo también sabré”. (E07).

“Confío en mi capacidad de reacción [...]. Ellos lo hacen, o sea que también están pagando un sobreprecio por ser los primeros y meterse en todo esto y se están arriesgando a que esto no funcione”. (E02).

No obstante, algún entrevistado asume que esta posición de espera no está exenta de riesgos ya que, si bien la estrategia permite optimizar recursos, un retraso excesivo en la adopción podría hacer imposible recuperar la ventaja competitiva perdida.

Las entidades de menor tamaño contraponen a las ventajas de escala de las grandes su agilidad organizacional. Consideran que su estructura les permite decidir y ejecutar con una rapidez inalcanzable para las grandes corporaciones, lo que les facilita adaptarse velozmente cuando la IA alcance el punto de madurez que justifique su adopción a gran escala. La ventaja, por tanto, no radica en liderar la carrera ahora —cuando nadie parece obtener beneficios competitivos claros con IA—, sino en estar preparados para aprovechar la oportunidad en el momento adecuado.

“Nosotros somos una compañía pequeña y somos capaces, a nivel de máquina, de lanzar un producto a nivel de sistemas en cuatro semanas [...]. Yo hablo con una compañía grande y me dice cuatro meses [...]. Yo creo que en este caso yo creo que el tamaño es una ventaja para las pequeñas”. (E09).

Desde esta perspectiva, la IA no se considera una amenaza que ampliará la brecha con los líderes, sino como una oportunidad para nivelar el campo de juego y romper barreras de entrada tradicionales:

“Yo creo que la IA también hay una cosa relevante va a romper muchas barreras de entrada en muchos modelos de negocio y esto es algo que hay que explorar. [...] salía el concepto de El emprendedor único, es decir, que montas la startup tú solo y usas la IA como una herramienta”. (E09).

Papel de las *InsurTech* y de nuevos entrantes tecnológicos

En su momento, la irrupción de las *InsurTech* y de las *Big Tech* generó inquietud por su potencial disruptivo, pero, en opinión de los entrevistados, la realidad ha

mostrado que su impacto directo ha sido limitado y que actúan más como catalizadores que como competidores integrales.

Se reconoce que la irrupción de las *startups* fue clave para introducir nuevas metodologías de trabajo en las aseguradoras tradicionales:

“Una cosa que... que la empresa ha tenido a bien hacer y esto ha venido de la mano de las startups, InsurTech, etcétera, ha sido que, al menos en bancos y en compañías de seguros, se ha creado pues esta metodología del caso. Y esto se creó desde mi punto de vista, principalmente, con los casos de data Analytics”. (E01).

Sin embargo, la percepción general es que la competencia directa por parte de las *InsurTech* es muy limitada. La principal barrera identificada es su falta de acceso a grandes volúmenes de datos y a un "banco de pruebas" amplio, lo que dificulta la validación y el escalado de sus modelos.

“Yo creo en las InsurTech hoy en día han fracasado estrepitosamente. No un poco estrepitosamente. [...] Es muy difícil probarlo porque tienen muy pocos datos”. (E01).

Además, por el momento, ninguna *InsurTech* ha logrado cubrir la compleja cadena de valor del seguro “end to end”. Su aportación se concentra en nichos o eslabones muy concretos.

“Yo, una InsurTech que cubra la totalidad de la cadena de valor del negocio asegurador todavía, todavía, no he visto ninguna. Pero sí que es cierto que hay muchas InsurTech, o sea, que están especializadas en determinados eslabones de la cadena de valor”. (E02).

A pesar de estas limitaciones, los entrevistados consideran que la IA generativa podría cambiar drásticamente este panorama. Al proporcionar acceso a modelos entrenados con datos a escala mundial, la IA podría reducir una de las principales barreras de entrada que han experimentado las *InsurTechs*.

“Los grandes gigantes tecnológicos han tenido un banco de pruebas extensísimo, que ha sido todo el mundo. [...] el problema que tú tenías con las tecnológicas o con las startups o con las InsurTech [...] es que, claro, la base sobre la que podrían hacer esas pruebas para avanzar [...] era pequeña”. (E01).

En este contexto, actualmente la relación predominante entre aseguradoras e *InsurTech* no es de competencia, sino de colaboración. Las entidades incumbentes las ven como una fuente de *know-how* y proveedores de soluciones especializadas que permiten acelerar pilotos sin necesidad de desarrollo interno. Varios entrevistados relataron colaboraciones específicas en áreas como *call centers*, siniestros o ciberseguros.

“Nosotros tenemos ahora mismo abiertos dos proyectos de eficiencia que son en la parte del call center y en la parte de prestaciones, porque creemos que al final es donde nos puede aportar a valor”. (E10).

Expectativas importadas de otros sectores

Un factor que acelera la necesidad de implementar IA es la presión competitiva indirecta ejercida por empresas líderes en experiencia de cliente de otros sectores, como el *retail* o el comercio electrónico. Los estándares de rapidez, personalización y eficiencia que imponen gigantes tecnológicos se convierten en la nueva norma que los clientes esperan de todos sus proveedores de servicios, incluyendo las aseguradoras.

Este fenómeno es visto como un catalizador para la transformación del sector, ya que eleva las expectativas del consumidor de manera transversal y empuja a las aseguradoras a adoptar IA para no quedarse atrás en la calidad de la experiencia percibida:

“Esto no es un tema de seguros. O sea, esto está en todo el mundo. Entonces, en todo el mundo, el uso de estas nuevas tecnologías va a hacer un salto en cómo somos capaces de dar respuesta a lo que nos piden nuestros clientes. Y eso le va a pasar al cliente de Amazon, que, seguro que está mucho más avanzado que nosotros, como al de Google, como al de Inditex o al de Zara como nosotros” (E03).

4.3.1.2. Preparación y aceptación de los clientes

Preferencia por mantener el contacto humano

Un idea recurrentemente manifestada por los directivos es su convencimiento de que la mayoría de los clientes sigue valorando y, cuando no exigiendo, la interacción con su entidad de manera personal. La IA es bienvenida como herramienta de eficiencia, siempre que no elimine la posibilidad de contactar con una persona, especialmente en momentos críticos o emocionalmente sensibles como puede ser la gestión de un siniestro complejo o la comunicación de un deceso.

Unánimemente, se considera una necesidad mantener el componente humano como un pilar del servicio:

“La gente, cuando llama para comunicar que se ha muerto su madre, como le pongas con una máquina que le dice el “marque el uno, el dos, el tres el siete y el diez”, ¡te quiere matar!” (E07).

Esta visión es compartida por todas las entidades, independientemente de su grado de automatización. Todas establecen como principio irrenunciable la disponibilidad de un interlocutor humano. Se concibe la IA como un soporte para el empleado, no como un sustituto del valor emocional del servicio:

“El cliente siempre tendrá la posibilidad de hablar con una persona” (E02).

“No renunciaremos a la inteligencia emocional, la calidad de la persona” (E16).

A pesar de ello, los directivos también reconocen que los clientes esperan que las entidades ofrezcan una experiencia de servicio fluida a través de todos los canales disponibles (oficina, mediador, centro de llamadas, aplicación móvil, etc.), dándoles la capacidad de iniciar una gestión en un canal y continuarla en otro sin fricciones. En este contexto, la IA no se percibe tanto como un canal en sí mismo, sino como el motor tecnológico que unifica y dota de coherencia a la experiencia omnicanal:

“Aquí no se cierra nada. Aquí la gente que quiere un delegado se va a ver al delegado; el que quiera llamar al call center, el call center; y el que quiere la app se va a la app. Y aquí cada canal se busca la vida” (E05).

La IA se percibe, por tanto, como la herramienta que permite a la aseguradora responder al cliente con un nivel de servicio que este ya experimenta en sus interacciones con gigantes tecnológicos, siendo un “*enabler* para responder al cliente al nivel de experiencia que ya recibe de Amazon o Google” (E03).

Ritmos de adopción diferenciados

Los entrevistados distinguen claramente la existencia de diferentes velocidades en la adopción de tecnologías de IA según el segmento de cliente. Por un lado, un perfil de cliente más digitalizado, normalmente más joven, acostumbrado a operar con comparadores y modelos de autoservicio muestra una mayor predisposición a operar con IA. Por otro, los clientes menos digitalizados, que generalmente operan a través de mediadores presentan un ritmo de adopción más lento y una mayor dependencia de la interacción humana.

Esta heterogeneidad obliga a las compañías a diseñar estrategias de IA que se adapten a ambas realidades:

“Habrá clientes que con IA estarán súper contentos y habrá otros que no” (E09).

“Muchos ya están acostumbrados a hablar con máquinas o algoritmos. Si está bien hecho, puede ser positivo, pero si no, la experiencia no será agradable para el cliente” (E04).

El despliegue, por tanto, se plantea de forma progresiva, entendiendo que se necesita tiempo “hasta que el cliente también se acostumbre” (E10), en un proceso similar al que se vivió con la banca por internet.

Finalmente, la estrategia de implementación de la IA de cara al cliente se aborda de manera incremental y cautelosa. Las entidades introducen automatizaciones de forma gradual, monitorizando constantemente la experiencia del usuario. Ante la

mínima señal de fricción o insatisfacción, el proceso se revierte y se deriva al cliente a un operador humano.

Este enfoque de "prueba y error" controlado facilita una aceptación más suave por parte del cliente y permite a la organización aprender y ajustar sus modelos:

"Empezamos a meter inteligencia artificial muy poco a poco, de tal manera que en cuanto veíamos que [...] había una mínima fricción, lo pasábamos con la persona" (E13).

4.3.1.3. Papel de los Mediadores

El análisis de las entrevistas con altos directivos del sector asegurador español revela que el canal de mediación ejerce una influencia significativa en la estrategia y el ritmo de adopción de la IA. El mediador se tiene muy en cuenta a la hora de tomar decisiones de inversión y priorizar casos de uso, a la vez que supone una barrera para otros.

Baja Percepción de Amenaza de Desintermediación

A diferencia de la potencial disrupción que se vislumbraba ante la llegada de internet, los líderes del sector no perciben la IA como una amenaza existencial para el modelo de negocio basado en la mediación:

"Puedo tener algunos roles que se vean más impactados y tendré que gestionar cambios dentro de la organización, vale, pero no está poniendo en crisis mi modelo de negocio". (E08).

Esta percepción se ve reforzada por la resiliencia histórica del canal. Como señalan algunos directivos, las predicciones sobre la desaparición de la mediación no solo no se han cumplido, sino que este ha seguido fortaleciendo su posición en el mercado.

"Hace unos años nos decían que los mediadores iban a desaparecer, que había que eliminarlos y el mediador gana cuota de mercado". (E09).

Los entrevistados coinciden en que el principal valor que aporta el mediador está en su capacidad de asesoramiento personalizado y en la relación de confianza que establece con el cliente, especialmente en momentos críticos como la gestión de un siniestro. Se destaca la necesidad de un "vínculo" humano que la tecnología, por sí sola, no puede replicar. El trabajo de desarrollar agentes se describe como una labor casi artesanal.

"Al final es crear profesionales, formarlos, que sean autónomos. (...) este es un trabajo muy artesanal". (E08).

Incluso cuando se implanta IA para mejorar la eficiencia, como en los centros de contacto, se mantiene la clara voluntad de que el cliente siempre tenga la opción de interactuar con una persona.

"Por mucha inteligencia que incorporemos (...), en esta compañía el cliente siempre tendrá la posibilidad de hablar con una persona". (E02).

En consecuencia, las entidades abordan proyectos de IA que refuercen y no erosionen el valor relacional del mediador, lo que puede frenar la implementación de iniciativas resten protagonismo al agente en la relación con el cliente.

Omnicanalidad Competitiva

Las aseguradoras que combinan una fuerte presencia de canales tradicionales (agentes, oficinas) y digitales (apps, web) operan bajo un principio de omnicanalidad estricta para evitar conflictos internos. La estrategia no es forzar al cliente hacia un canal, sino hacer que todos compitan en igualdad de condiciones, obligando al canal digital a ser genuinamente superior en experiencia de usuario para ser elegido.

"Aquí no se cierra nada. Aquí la gente que quiere un delegado se va a ver al delegado. El que quiera llamar al call center, el call center y el que quiere la app se va a la app. Y aquí cada uno se busca la vida". (E05).

Adopción por parte del Mediador

Existe consenso sobre que la velocidad de adopción de la IA depende de la capacidad de la red externa de mediadores para integrar nuevas herramientas. Esto obliga a las compañías a invertir significativamente en formación, gestión del cambio y, sobre todo, en el diseño de interfaces de usuario simples e intuitivas.

"¿El corredor está preparado? No lo está. Pero vuelvo un poco a lo que te he dicho. No están nuestros empleados, no estamos, no estamos en general. (...) es un change management, porque hay gente que abraza los cambios y hay otros que tienen una resistencia al cambio brutal". (E12).

Los entrevistados señalan que para que un mediador adopte una tecnología nueva, debe percibir un beneficio claro, ya sea en forma de mayores ingresos (como herramientas para agilizar la emisión, la tramitación de siniestros o la identificación de oportunidades de venta cruzada (*cross-selling*)) o de una reducción de su carga administrativa. La IA se orienta, por tanto, facilitarle la vida al mediador más que a conseguir eficiencias para la compañía.

"Son herramientas que el distribuidor puede utilizar para captar clientes, captar satisfacción de clientes y por el medio haces eficiencias". (E12).

Cuando se consigue, la disponibilidad de soluciones de IA para mediadores se convierte en un argumento competitivo para atraerlo y retenerlo. Se apunta que

ofrecer a los agentes y corredores herramientas de IA de vanguardia se convertirá en el futuro en un diferenciador clave para que elijan trabajar con una entidad.

"El mensaje es trabajo con vosotros porque hay otro tío o hay otra compañía que a lo mejor incluso tiene más comisión (...) pero es que vosotros (...) que me pagáis menos comisión me simplificáis la vida. Quiero trabajar con vosotros". (E09).

"El agente ahora mismo, que es el olvidado (...), creo que puede ser el grandísimo beneficiado (...) si somos capaces de... de vincularlo". (E12).

En sentido contrario, los mediadores pueden actuar como freno en la adopción de modelos de IA valiosos para la entidad (como, por ejemplo, la tarificación dinámica en productos retail) si su uso complica el proceso de venta o es muy diferente a las prácticas habituales del mercado:

"¿Qué pasa? Que, en nuestro modelo de distribución, si yo tengo que explicarle al distribuidor (...) que tenemos que cambiarlo, que tiene que tener una serie de datos para dar precio. Me dice que naranjas de la China, el competidor no lo hace... y que no le complique la vida". (E09).

Las compañías de venta directa consideran que pueden permitirse una mayor libertad y agilidad a la hora de implementar soluciones de IA en el *front office* ya que no necesitan gestionar expectativas o posibles conflictos con la red.

"No tenemos esa barrera ya que yo no tengo que vivir con el cordón umbilical con un mediador. (...) digamos que no tenemos que contemporizar tanto. Más allá de servir lo que el cliente necesita. Nuestra ventaja competitiva es que no tenemos que digamos como que contentar a nadie más que a nuestro cliente ". (E13).

4.3.1.4. Preocupaciones Éticas y Sociales

Riesgo de exclusión

Los directivos muestran gran preocupación por las implicaciones éticas que puede acarrear la IA, en particular por el riesgo de discriminación hacia determinados colectivos. La capacidad de los algoritmos para identificar patrones en datos históricos puede traducirse en decisiones que penalicen a segmentos específicos de la población:

"Me preocupa, desde el punto de vista de impacto empresarial o de implicaciones morales o éticas, por ejemplo, que, si la prevalencia del fraude es mayor en una determinada zona de España, esto nos lleve a subir la prima o incluso a excluir de la cobertura de aseguramiento a unos determinados colectivos" (E02).

El avance hacia una tarificación cada vez más granular es percibido como un fenómeno que erosiona progresivamente el principio de solidaridad en el que se ha sustentado el seguro. Aunque no se trata de un efecto exclusivo de la IA, esta

tecnología puede acelerar dicha tendencia al permitir una segmentación mucho más precisa:

“En el seguro cada vez la prima será menos solidaria. [...] En definitiva, lo que tendrás es que habrá gente que no se podrá asegurar” (E08).

El temor expresado de forma reiterada es que esta dinámica conduzca a la desnaturalización del carácter mutualista del seguro:

“Si le metemos una capa de inteligencia artificial que incrementa esas capacidades, al final estamos desnaturalizando el seguro, porque a cada uno le vamos a cobrar por el riesgo que tiene y usted está perdiendo la parte de [...] el concepto mutualista” (E02).

“Si al final haces pólizas para cada tío en función de lo que tal... estamos jodiendo el seguro porque estamos rompiendo el carácter mutualista” (E14).

“Efectivamente, el principio de desmutualización es absoluto. Llevan al riesgo individualizado [...] El principio mutual se lo cargan” (E16).

Algunos directivos, no obstante, plantean posibles fórmulas de equilibrio que permitan aprovechar la capacidad analítica de la IA sin excluir a los colectivos más vulnerables. Entre ellas se mencionan primas estándar básicas con márgenes de ajuste o la introducción de factores correctores:

“Debemos encontrar un punto en el que haya, por así decirlo, una prima estándar básica con ciertos márgenes de maniobra según el perfil. Es un punto intermedio que puede tener sentido” (E04).

“A medida que hay más analítica, más tecnología, más capacidad de perfilar [...] entiendo que vendrán temas de regulación. Tendremos que ver cómo poner factores correctores a la prima que te sale, para intentar hacerla solidaria” (E08).

Impacto sociolaboral

Junto al riesgo de exclusión de clientes, los directivos subrayan la dimensión social que implica el impacto de la IA sobre el empleo. La preocupación no se limita al sector asegurador, sino que se extiende a la percepción de la sociedad en su conjunto sobre el futuro del trabajo:

“Yo ahora, por ejemplo, me preocuparía mucho tener un hijo o una hija que se dedicara al ámbito audiovisual, porque es que lo ves, es que se hacen maravillas” (E08).

Existe inquietud sobre la necesidad de tener que hacer reestructuraciones de personal como consecuencia de la adopción de IA:

“¿Entonces qué hago con las personas? Son redundantes. Todas. Fenomenal. Muy bien, pues tienes todos los costes de redundancia. Con lo cual ya el Business Case [...] seguramente no saldrá” (E01).

Otros riesgos éticos

Finalmente, los directivos admiten que el horizonte de riesgos éticos es en gran medida incierto. Reconocen que surgirán dilemas aún desconocidos, derivados de la capacidad transformadora de la IA y de su integración en ámbitos sensibles como la generación de pruebas digitales o la comunicación con clientes:

“No me atrevo ni casi a pensar todo lo que puede salir de todo aquí [...] no está escrito lo que va a salir de todo esto, ¿no? Porque vaya, es que puede haber muchas aplicaciones que yo creo que no somos capaces” (E08).

4.3.1.5. Colaboración con socios externos

Los directivos entrevistados también identifican la relación con el ecosistema tecnológico como un factor determinante en la adopción de IA en el sector asegurador. Las organizaciones no actúan de forma aislada, sino que recurren de manera sistemática a socios externos (como *InsurTechs*, *startups* especializadas, *Big Techs* y consultoras) para complementar capacidades internas, validar la viabilidad de nuevas tecnologías y acelerar su curva de aprendizaje.

Apertura a la innovación abierta e *InsurTech*

Se constata la disposición por parte de las entidades a la colaboración y co-desarrollo de soluciones con actores emergentes del ecosistema. En lugar de percibir a las *InsurTech* como competidores, se las integra en un modelo de innovación abierta para fomentar un aprendizaje bidireccional:

“Nosotros tenemos proyectos de innovación, de innovación abierta, ¿vale? O sea, con... con InsurTech; los hemos metido muchas veces en áreas de negocio para aprender cómo hacen las cosas ellos y que también ellos puedan aprender. Y en este sentido la verdad es que somos, somos muy abiertos.” (E02)

“Yo tengo relación con bastantes startups y una de las startups con las que tenía relación me dijo: “He aplicado inteligencia artificial utilizando GPT y donde tenía que tener 14 desarrolladores tengo diez”. Y le dije: “vente a la compañía y explica a todo el comité de dirección cómo lo has hecho”. Entonces vino la compañía y nos hizo una demo, una explicación muy sencilla.” (E09)

Los directivos destacan la necesidad de mantener una actitud proactiva y sistemática de observación del entorno, que a menudo se extiende más allá del sector seguros, para detectar oportunidades de innovación y casos de uso aplicables:

“Hay que estar cerca de los ecosistemas donde se está moviendo la inteligencia artificial para entender qué están haciendo y decir: “oye, esto que están haciendo aquí puede tener sentido para nosotros o no, y quizá donde puede tener sentido.” (E09)

“Yo creo que como directivos tenemos que salir mucho a la calle y ver lo que se hace fuera de las aseguradoras, pues nosotros vamos a una velocidad y el mercado se irá a otra. Entonces hay que entender toda esta nueva economía, toda esta economía circular, todas esas startups, cómo se están moviendo y cómo transforman las cosas.” (E09)

Relación con Consultoras

El mercado de proveedores de tecnología IA se percibe como dual. Por un lado, las grandes consultoras aportan robustez, escala y una sensación de control que genera tranquilidad. Por otro, consultoras de nicho y *startups* ofrecen innovación disruptiva y soluciones muy potentes, pero les falta capacidad de comercialización:

“Las grandes consultoras y tal me cuesta, me cuesta algunas cosas. Es verdad que según para qué cosas te dan una cierta tranquilidad de que van a tener todo controlado y demás, pero luego hay mucha subcontrata en el fondo. O sea, tienes algunas consultoras grandes que están trabajando con startups porque tienen cosas buenísimas. Lo que pasa es que la startup no tiene market.” (E09)

Los entrevistados manifiestan la existencia de una importante presión por parte de las consultoras para “vender” proyectos de IA, pero que existe un gap entre el discurso comercial y la disponibilidad real de soluciones maduras y aplicables en el mercado español:

“Si tú recorres por todas las consultoras de España y preguntas a todos: “¿Oye, me puedes decir tienes algo que podamos hacer?”. Las cosas en general son... todos dicen sí, pero la realidad es que es un tema lento, es un tema lento.” (E15).

Como se ha señalado también en el apartado de Riesgos, los directivos señalan que negociaciones con los grandes proveedores son complejas, ya que sus modelos de licenciamiento no siempre se adaptan a la realidad del negocio asegurador:

“no estábamos dispuestos uno a comprar 20.000 licencias y menos aún a estar sujetos a que año tras año nos fueran aplicando incrementos. Pues le costó, les costó muchísimo, muchísimo entenderlo” (E02).

La preocupación está, sobre todo, en el riesgo de vendor lock-in. Una vez que se implanta una solución externa, el proceso de desvinculación se considera técnica y económicamente muy compleja:

“Cuando veo lo que me cuesta todos los años, las 96 o las 110 licencias, digo, esto es una renta vitalicia porque ya no te puedes salir y ahora te piden 400” (E14).

A esto se suma la pérdida de control sobre los datos, lo que lleva a las empresas a establecer “líneas rojas” para evitar la transferencia de información sensible.

“Nosotros hemos marcado una línea roja que es no usarla dándole datos, que puedan tener sensibilidad o que puedan tener un uso por terceros dañino para nuestra propia compañía o, que transfieren inteligencia muy rápida y muy gratuita a terceros” (E07).

Como estrategia mitigadora de esta dependencia, las aseguradoras optan por modelos híbridos, combinando externalización con el mantenimiento de capacidades y talento interno clave para salvaguardar el conocimiento del negocio y evitar una dependencia total.

“Nuestro modelo es como más... es un poco más in-house. O sea, sí que tenemos mucho externo. [...] pero nos aseguramos, o sea que la primera capa y la segunda capa directiva sea gente interna de la casa que sobre todo conozca el negocio” (E02).

4.3.2. Regulación

El análisis de las entrevistas revela que los directivos consideran que el marco regulatorio y la presión institucional son factores que condicionan la adopción de la IA.

Marco Regulatorio Europeo

Una percepción generalizada entre los directivos es la de una "hiperregulación" procedente de las instituciones europeas, que supone un obstáculo para la innovación. En opinión de los directivos, el estricto marco normativo europeo limita la capacidad del sector para implementar tecnologías, en comparación con otros países fuera del continente donde el entorno es menos restrictivo. Un entrevistado describe esta situación como una "vorágine regulatoria" que obliga a contener el impulso innovador:

“Es porque en determinados ámbitos, como por ejemplo en el aterrizaje de la inteligencia artificial, ya empieza a sonar que Europa tira de regulaciones que ponen freno sobre todo a tecnologías que no han sido desarrolladas en Europa, porque en Europa no se da el contexto adecuado para el desarrollo de este tipo de tecnologías por la vorágine regulatoria que hay”. (E02)

Algunos entrevistados afirman que esta situación se traduce en una notable reticencia a desplegar casos de uso de IA y en una mayor cautela a la hora de dimensionar los presupuestos y recursos destinados a estos proyectos.

Para las aseguradoras con presencia internacional, la exposición a múltiples marcos regulatorios añade complejidad. La obligación de cumplir con normativas cambiantes y específicas de cada geografía obliga a un esfuerzo constante:

“[...] respeto de las normativas que son cambiantes y que además como estamos en muchas zonas geográficas, pues en cada zona tienes unos requerimientos legislativos diferentes”. (E05)

Este escenario incrementa los costes asociados al cumplimiento y exige el diseño de arquitecturas tecnológicas modulares y adaptables, permitiendo una configuración específica por territorio sin sacrificar la escalabilidad global.

La incertidumbre y la rigidez que genera el marco normativo agudiza la tradicional cultura de aversión al riesgo y hace al sector "menos dado a inventar muchas cosas" (E07), lo que puede desincentivar la inversión en determinados proyectos disruptivos:

“[...] si la regulación aquí te las acota, a lo que te va a llevar a ti es a ser mucho más prudente o probablemente a invertir menos, porque si no vas a poder aprovechar, pues, todo su todo su potencial...”. (E02)

Este es otro de los factores que lleva a las aseguradoras a priorizar iniciativas de IA con un retorno claro y defensivo (como la optimización de procesos, el ahorro de costes o la detección de fraude) frente a propuestas más ofensivas y de mayor riesgo, como el desarrollo de nuevos productos o modelos de negocio basados en datos.

Protección de Datos

Dentro del amplio marco regulatorio, los entrevistados destacan la normativa sobre protección de datos como el factor más influyente y restrictivo. Los entrevistados coinciden en que esta área *"ha cogido muchísimo ritmo"* (E02), afectando de manera significativa las posibilidades de aplicación de la IA, especialmente en la interacción con el cliente. La normativa impone límites al tratamiento de información personal, limitando la capacidad de las aseguradoras para sacar el máximo provecho a la IA.

"Pero claro, por otro lado, te van viniendo normativas y regulaciones en las que, pues oye, pues sí, pues a lo mejor tienes noción de tal y cual, pero tú no les puedes hacer ofertas, no puedes perfilar, no puedes, no puedes hacer mil cosas". (E02)

Como consecuencia directa, se observa una limitación en el desarrollo de modelos de hiperpersonalización y en la implementación de sistemas que requieren el uso de datos sensibles o de comportamiento del cliente para funcionar de manera óptima.

Apoyo e Inversión Pública

Las decisiones sobre adopción de IA también se ven influidas por señales exógenas del entorno macroeconómico y políticas públicas. Noticias sobre grandes planes de inversión públicos o movimientos estratégicos a nivel global actúan como catalizadores, generando una sensación de urgencia y validando la relevancia estratégica de la IA.

"Evidentemente algo está cambiando, porque solo viendo la noticia de hoy de que Trump apoya con 500 mil millones de dólares temas de inteligencia artificial y demás... Está habiendo es un posicionamiento, ¿no? de inversiones en aquellas industrias críticas para la producción de infraestructuras para generar inteligencia artificial." (E15)

4.4. Niveles de Adopción AIMM

Tal y como se ha señalado en el apartado 3.5.2, la asignación del nivel global de madurez se ha realizado a partir de la valoración de las cuatro dimensiones del modelo AIMM (Funciones, Datos, Personas y Organización), cada una de ellas puntuada en una escala de 1 a 5 en correspondencia con los niveles definidos por el marco. Para determinar el nivel global de cada organización se aplicó la regla del mínimo, también conocida como criterio del “cuello de botella”. Este procedimiento establece que el nivel alcanzado por la entidad queda condicionado por la dimensión con menor puntuación, reflejando así que el avance en la madurez depende del eslabón más débil.

Aplicando esta metodología, la distribución de las dieciséis entidades analizadas es la siguiente:

Tabla 26: Distribución de entidades aseguradoras por nivel de madurez en IA según el modelo AIMM

Nivel AIMM	Descripción	Nº de casos
1 – Initial	Ausencia de funciones de IA sistemáticas	1
2 – Assessing	Fase exploratoria, pilotos iniciales	4
3 – Determined	Proyectos avanzados con requisitos de escalabilidad	7
4 – Managed	Procesos definidos y desplegados transversalmente	4
5 – Optimized	Infraestructura y procesos estandarizados a gran escala	0


Fuente: Elaboración propia

La distribución evidencia una concentración en las fases intermedias del modelo. La moda corresponde al nivel 3 – Determined, que agrupa a casi la mitad de los casos (7/16). Le siguen el nivel 4 – Managed (4/16) y el nivel 2 – Assessing (4/16), mientras que únicamente se identificó un caso en el nivel 1 – Initial. Ninguna entidad alcanzó todavía el nivel 5 – Optimized.

El análisis de las entrevistas a través del *Artificial Intelligence Maturity Model* (AIMM) de Alsheiabni et al. (2019) muestra que ninguna entidad se encuentra en el nivel más avanzado (*Optimized*), mientras que solo una permanece en el nivel más incipiente (*Initial*). La mayoría de compañías se concentra en los niveles intermedios, con un predominio de organizaciones en el nivel *Determined* y un grupo reducido que ya ha alcanzado *Managed*. Esta distribución refleja que el sector ha superado, en gran medida, la fase exploratoria (*Assessing*), pero todavía no ha consolidado estándares organizativos y tecnológicos propios de la madurez plena.

El desglose porcentual de referencias por nivel AIMM y código temático (ver Figura 26) permite matizar cómo varía la importancia relativa de los factores a lo largo del proceso de madurez:

Figura 26: Mapa de calor de referencias por nivel de madurez AIMM y código temático:




Fuente: Elaboración propia

El análisis del mapa de calor (Figura 26) y del desglose de drivers y barreras por etapa de madurez permite observar una progresión clara en la forma en que las aseguradoras abordan la adopción de la inteligencia artificial.


En la fase Initial, el patrón aparece fragmentado y reactivo. El peso desproporcionado de las referencias a datos e infraestructura (23,3 %) y a coste-beneficio y ROI (18,6 %) refleja un estadio donde la IA se aborda desde proyectos aislados, con fuerte dependencia de *quick wins* y campeones individuales. En paralelo, emergen ya preocupaciones por justificar retornos económicos, aunque sin métricas sistemáticas ni modelos de gobernanza. Las barreras predominantes se centran en la falta de talento, la escasez presupuestaria y la inexistencia de un modelo operativo claro, mientras que los impulsores provienen de proveedores externos y del atractivo del *hype* tecnológico como palanca exploratoria.

Figura 27: drivers y barreras de adopción de IA en nivel Initial, clasificados en las dimensiones TOE

Drivers



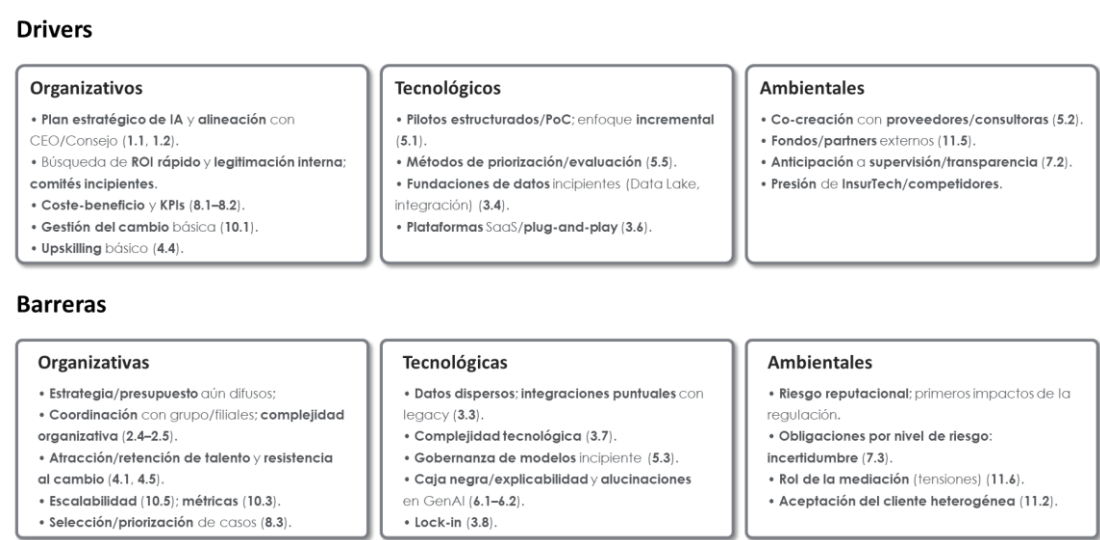
Barreras



Fuente: Elaboración propia

En la fase Assessing, el foco se desplaza hacia la búsqueda de legitimidad interna. El heatmap muestra un incremento de referencias a coste-beneficio y ROI (15,6 %) e implementación y gestión del cambio (11,9 %), lo que sugiere que los pilotos se utilizan como prueba de concepto para convencer a los órganos de gobierno y asegurar la continuidad de los proyectos. En este punto aparecen comités incipientes, planes estratégicos básicos y prácticas de *upskilling*, aunque las compañías siguen condicionadas por la falta de talento especializado, la fragmentación de la estrategia y la resistencia cultural. En el plano tecnológico, se intensifica el uso de PoCs y de plataformas *plug-and-play*, lo que facilita la experimentación pero limita la escalabilidad.

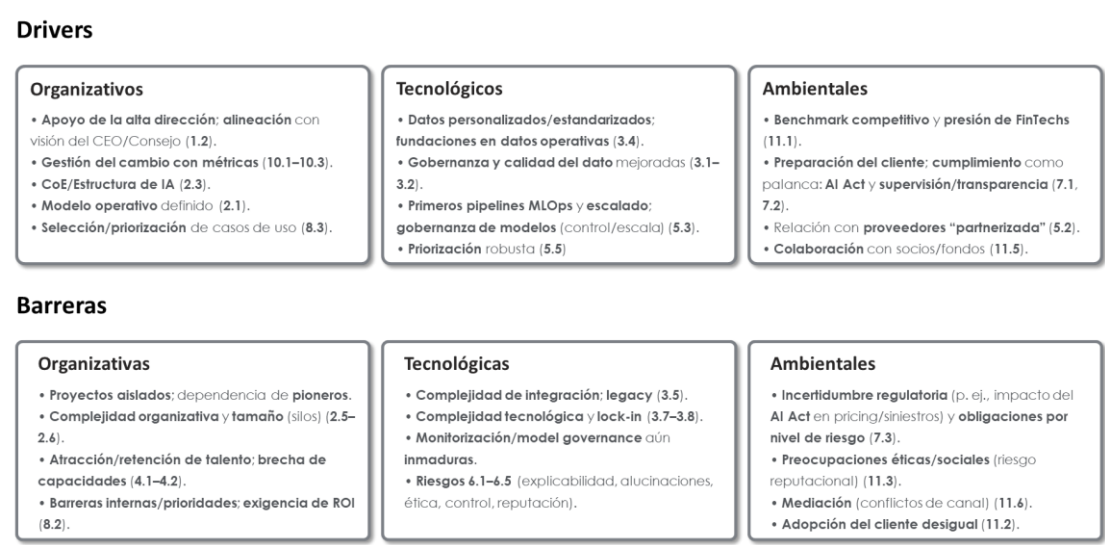
Figura 28: drivers y barreras de adopción de IA en nivel Assessing, clasificados en las dimensiones TOE



Fuente: Elaboración propia

La fase Determined muestra un desplazamiento hacia la consolidación tecnológica y la gobernanza de datos. Aquí se incrementan las referencias a implementación de IA (13,2 %), datos e infraestructura (10,9 %) y organización y gobierno (11,6 %). Ello indica que las entidades en este nivel ya cuentan con proyectos en producción, comienzan a desplegar arquitecturas de datos más robustas (data lakes, MLOps) y establecen mecanismos de gobernanza incipientes. Sin embargo, las barreras se trasladan a la complejidad de integración, la dependencia de plataformas heredadas y los dilemas de explicabilidad y riesgos éticos asociados a la IA generativa. Es decir, los retos dejan de ser conceptuales y pasan a estar relacionados con la escala y la gestión del riesgo.

Figura 29: drivers y barreras de adopción de IA en nivel Determined, clasificados en las dimensiones TOE



Fuente: Elaboración propia

Finalmente, en la fase Managed la atención vuelve a los factores organizativos y culturales. Destacan las referencias a organización y gobierno (13,3 %) y talento y cultura (14,1 %), junto con la persistencia de coste-beneficio y ROI (13,5 %). En este nivel, la tecnología se percibe ya como un pilar estabilizado y el énfasis recae en la institucionalización transversal de la IA, el patrocinio de la alta dirección, la formación masiva y la alineación con los planes estratégicos corporativos. La presión competitiva, la supervisión regulatoria y las preocupaciones éticas aparecen internalizadas, lo que permite a las compañías integrar la IA de forma madura y sostenible. No obstante, persisten barreras asociadas a la complejidad organizativa, la fatiga del cambio y la escasez de perfiles críticos, que se convierten en los principales cuellos de botella de la consolidación.

Figura 30: drivers y barreras de adopción de IA en nivel Managed, clasificados en las dimensiones TOE

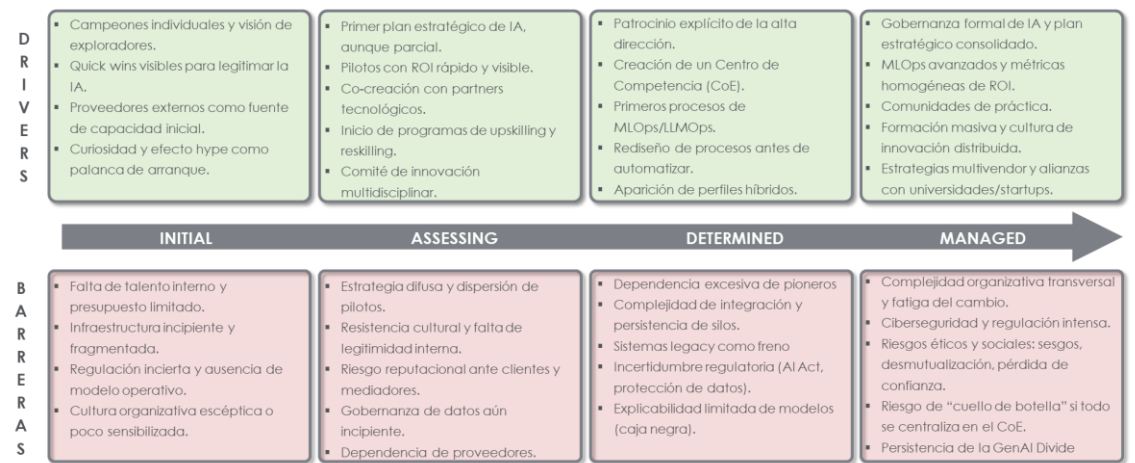


Fuente: Elaboración propia

Cabe señalar que, si bien se trata de un estudio cualitativo, la muestra de 16 entrevistas en profundidad aporta una alta representatividad: las entidades incluidas en el análisis en conjunto concentran aproximadamente el 60 % del volumen de primas del mercado asegurador español. Esta cobertura refuerza la validez de los hallazgos y permite interpretar los resultados no solo como casos individuales, sino como una aproximación robusta al grado de madurez en IA del sector en su conjunto.

La Figura 31 sintetiza los principales drivers y barreras identificados en las entrevistas según las distintas etapas de madurez en la adopción de inteligencia artificial, siguiendo el modelo evolutivo propuesto por Alsheiabni et al. (2019).

Figura 31: evolución de drivers y barreras en el ciclo de madurez organizativa



Fuente: Elaboración propia

4.5. Casos de uso

El análisis de las entrevistas evidencia que la inteligencia artificial se concibe, en la práctica, más como una herramienta de optimización de procesos que como un elemento disruptivo capaz de transformar el modelo de negocio en su conjunto. Esta percepción es coherente con la literatura reciente: los estudios de Eling y Lehmann (2018) y de Eling, Nuesse y Staubli (2022) destacan que la aplicación de la IA en el seguro se concentra en la cadena de valor existente —operaciones, siniestros, fraude, marketing y tarificación— con impacto principal en eficiencia y reducción de asimetrías de información, más que en cambios radicales del modelo de negocio.

No obstante, la irrupción de la IA generativa introduce un nuevo abanico de casos de uso que amplían las aplicaciones tradicionales. Owen, Sheehan y Mullins (2025) identifican 37 casos de uso de GenAI a lo largo de la cadena de valor aseguradora, desde la clasificación y resumen de documentos hasta la automatización avanzada de siniestros y el pricing en salud y vida, muchos de los cuales ya han alcanzado fases de producción en algunas entidades. Bhattacharya, Castignani, Masello y Sheehan (2025), en una revisión sistemática, constatan que la práctica empresarial se orienta hacia aplicaciones equilibradas en claims, fraude, personalización de clientes y explicabilidad (XAI), mientras que la investigación académica todavía se concentra en pricing y riesgo.

En el caso español, los testimonios analizados muestran una convergencia con estas tendencias internacionales. La Tabla 27 recoge los principales casos de uso de IA mencionados espontáneamente en las entrevistas, clasificados por área funcional, estado de adopción y entidad de referencia. Conviene realizar dos precisiones metodológicas. En primer lugar, esta es una investigación cualitativa basada en entrevistas en profundidad a directivos, en las que no se planteó un cuestionario cerrado sobre casos de uso. Los ejemplos recogidos corresponden únicamente a aquellos que los participantes mencionaron en su discurso, por lo que es posible que existan otros casos relevantes en el sector que no aparezcan en este análisis. En segundo lugar, el inventario de aplicaciones no pretende ofrecer una imagen exhaustiva, sino más bien una aproximación interpretativa que permite observar en qué áreas funcionales se concentran los esfuerzos y qué tendencias emergen de manera más consistente.

En comparación con la literatura académica, destacan tres elementos:

Predominio de la IA operacional: la mayoría de casos mencionados por directivos españoles se concentran en siniestros, fraude y operaciones, en línea con lo identificado por Eling et al. (2022).

Adopción gradual de GenAI: se observan pilotos y pruebas de copilotos, asistentes de RRHH y ChatGPTs internos, que coinciden con los casos de uso descritos por Owen et al. (2025), aunque en fases iniciales y con foco en productividad interna.

Tensión entre eficiencia y confianza: mientras que los proyectos de fraude, pricing o análisis de llamadas generan valor tangible, persisten reservas regulatorias y culturales, coherentes con las barreras de confianza y riesgo regulatorio documentadas en Owen et al. (2025) y Bhattacharya et al. (2025).

Tabla 27: Casos de uso de inteligencia artificial en aseguradoras españolas por área funcional y estado de adopción

Área funcional	Caso de uso	ID entrevista	Estado de adopción
Operaciones, Siniestros y Fraude	Clasificación y gestión de siniestros	E13	Producción
	Pago de siniestros en tiempo real	E3	Producción
	Detección de fraude	E5, E11	Producción
	Detección de fraude (descartado)	E8	Descartado
	Análisis de coberturas de pólizas	E9	Piloto
	Reconocimiento de daños por imagen	E11	Escalado
	Procesos robotizados con IA	E9	Producción inicial
	Videoperitación	E8	Exploración
	Transcripción y resumen de actas	E6	Producción
	Automatización masiva de operaciones	E12	Producción
Servicio al Cliente y Marketing	Asistente de IA para empleados (<i>CoPilot</i>)	E13	Escalado
	Asistencia por voz y transcripción	E12	Producción inicial

Área funcional	Caso de uso	ID entrevista	Estado de adopción
	Asistentes híbridos (<i>Chatbots</i> y <i>voicebots</i>)	E13	Producción
	Análisis de llamadas	E13	Piloto
	Captura automática de datos en llamadas	E16	Producción inicial
	Gestión de leads	E7	Producción
	Generación de contenido	E9	Producción inicial
Suscripción, Tarificación y Desarrollo de Producto	Modelos de predicción y segmentación	E11	Producción
	Suscripción PyME	E15	Piloto
	Modelos de riesgo y pricing	E16	Exploración
	Producto de ciberseguridad	E8	Producción inicial
	Diagnóstico digital en salud	E16	Piloto avanzado
Desarrollo Interno y Productividad de TI	Asistentes de programación	E3, E9	Producción inicial
	Desarrollo de páginas web	E7	Piloto
	ChatGPTs internos y seguros	E1, E5, E12, E15	Escalado
	Asistente de RRHH	E13	Piloto inicial
	Fraude (solución externa)	E8	Evaluado/Descartado

Fuente: Elaboración propia

4.5.1. Casos de uso y niveles de adopción AIMM

El análisis de los casos de uso permite observar una clara correspondencia entre el tipo de iniciativas desplegadas y el nivel de madurez AIMM de las organizaciones entrevistadas. En el extremo inferior, la entidad clasificada en el nivel *Initial* (E06) apenas registra experiencias relevantes: la IA se percibe más como una posibilidad futura que como una herramienta actualmente aplicable. Este escenario confirma que, en ausencia de capacidades organizativas y tecnológicas mínimas, los casos de uso tienden a no materializarse más allá de la exploración conceptual.

En el **nivel Assessing** (E07, E08, E09, E14) se concentran iniciativas incipientes. Predominan las pruebas piloto, los ensayos de tecnologías externas y los primeros experimentos con IA generativa. Un ejemplo representativo es la adopción de *Chatbots* que, tras una fase de prueba, fueron descartados por ofrecer resultados insatisfactorios. En otros casos, como en la videoperitación o la detección de fraude con soluciones de mercado, la falta de retorno económico llevó a abandonar los proyectos. Estas experiencias ponen de relieve que, en este estadio, la IA funciona principalmente como un espacio de aprendizaje organizativo y cultural más que como una fuente de valor económico consolidado.

El **nivel Determined** agrupa a la mayor parte de las entidades (E01, E02, E03, E04, E10, E15, E16). Aquí se observa un salto cualitativo: los casos de uso dejan de ser simples pilotos para integrarse en procesos de negocio estratégicos. Surgen ejemplos como el pago de prestaciones en tiempo real, el uso de copilotos de programación en los departamentos de TI o la suscripción automatizada de riesgos en el segmento de pymes. No obstante, a pesar de este avance, los despliegues todavía carecen de estandarización transversal: los proyectos suelen estar aislados en determinadas áreas y dependen en gran medida de equipos pioneros o de líderes concretos que los impulsan.

En el **nivel Managed** (E05, E11, E12, E13) se sitúan las organizaciones más avanzadas de la muestra. En estos casos, la IA se ha incorporado de manera sistemática a las operaciones centrales de la aseguradora. Se habla de decenas e incluso centenares de modelos desplegados simultáneamente, de cuadros de mando corporativos que miden el retorno de cada caso de uso y de programas de formación masiva que han logrado extender el conocimiento en IA a toda la plantilla. El escalado de casos como la apertura automatizada de siniestros, la segmentación avanzada de clientes o la omnicanalidad con soporte de IA ilustra cómo estas entidades han pasado de experimentar a institucionalizar la IA como parte de su modelo operativo.

Finalmente, el nivel *Optimized* permanece vacío en la muestra. Ninguna de las entidades alcanza todavía ese grado de madurez en el que la IA se convierte en un sistema estandarizado, soportado por infraestructuras unificadas, datos en tiempo

real y una cultura plenamente integrada en todas las decisiones de negocio. Este vacío no resulta sorprendente si se tiene en cuenta que incluso los grupos líderes reconocen barreras importantes en materia de calidad de datos, estandarización tecnológica y atracción de talento.

4.5.2. Casos de uso en la cadena de valor aseguradora

Cuando se contrastan los resultados empíricos con la matriz de Eling et al. (2022), se observa que las aseguradoras españolas han desarrollado aplicaciones de IA en prácticamente todas las etapas de la cadena de valor, aunque con una clara concentración en aquellas más vinculadas a la eficiencia operativa.

En el ámbito del **marketing**, se identifican experiencias en segmentación de clientes, predicción de valor futuro y gestión de leads a través de algoritmos de machine learning. También aparecen iniciativas de generación automática de contenidos corporativos. No se han identificado, sin embargo, técnicas más avanzadas como la detección de sentimientos o los motores de recomendación personalizados, que sí son citados en la literatura. Esta ausencia sugiere que, en España, la IA aplicada al front office aún se encuentra en fases exploratorias.

En **desarrollo de producto** emergen casos de innovación, como el lanzamiento de servicios de prevención de ciberataques ligados a seguros de empresa, basados en IA o el uso de visión artificial para diagnóstico digital en salud. También se mencionan modelos predictivos para diseñar coberturas más ajustadas. Sin embargo, las entrevistas no reflejan iniciativas que utilicen la IA para expandirse hacia nuevos mercados o ecosistemas, una de las aplicaciones apuntadas en la literatura.

El área de **ventas y distribución** se ha recogido evidencia mixta. Por un lado, se ha identificado el uso de *Chatbots* que gestionan cientos de miles de interacciones con asegurados. Por otro, algunos *Chatbot* han sido retirado al no alcanzar la calidad esperada. A diferencia de lo descrito en la literatura, no se identifican motores de recomendación que guíen al cliente hacia productos adicionales de forma automatizada.

En **suscripción y tarificación** se observa una adopción más avanzada. Varias aseguradoras trabajan ya con modelos predictivos de riesgo y pricing, aplicando machine learning para ajustar primas o identificar patrones de comportamiento. También se detectan proyectos de underwriting automatizado en segmentos específicos como las pymes, donde la entrada de solicitudes en formatos no estructurados plantea un terreno fértil para la IA. Estos hallazgos coinciden con lo planteado en la literatura y muestran que la suscripción y el pricing son áreas prioritarias en la estrategia de digitalización del sector.

En **servicio al cliente** la IA se aplica en diferentes frentes: copilotos que apoyan al operador del *call center* con información en tiempo real, herramientas de captura automática de datos durante las llamadas y entornos internos de IA generativa (ChatGPTs privados) diseñados para preservar la seguridad y confidencialidad. Estas experiencias reflejan el tránsito desde un uso meramente experimental hacia

una integración más profunda en la interacción con clientes y empleados, alineándose con la categoría de “gestión proactiva de la relación” descrita por Eling et al. (2022).

La **gestión de siniestros** constituye el ámbito con mayor densidad de aplicaciones. Aquí se concentran casos de clasificación automática de siniestros mediante lenguaje natural, pagos en tiempo real, reconocimiento de daños por imagen, videoperitación aún en exploración y sofisticados modelos de detección de fraude. En esta etapa, la coincidencia con la literatura es plena: las aseguradoras han priorizado aquellos procesos de gran volumen y alto impacto en costes, donde la IA ofrece retornos inmediatos en eficiencia y rapidez de servicio.

Finalmente, en **gestión de activos y riesgos**, el panorama es más incipiente. Se registran casos de *business intelligence* aplicada al seguimiento del ROI tecnológico y de analítica predictiva para segmentar carteras. Sin embargo, no aparecen ejemplos de *robo-advisors* ni de *reporting* automatizado de riesgos, dos de las aplicaciones más destacadas en la literatura internacional. Este vacío refleja que, en España, la IA aún no ha penetrado con fuerza en la vertiente financiera del negocio asegurador.

La Tabla 28 compara los usos identificados en las entrevistas la matriz de aplicaciones de IA en seguros identificadas en la revisión de la literatura.

Tabla 28: Casos de uso de IA en la cadena de valor aseguradora: contraste entre las aplicaciones según la literatura y la evidencia empírica

Etapa de la cadena de valor	Aplicaciones según la literatura	Evidencia empírica entrevistas (España)	No observadas en la muestra
Marketing	Segmentación avanzada con <i>big data</i> , <i>sentiment analysis</i> básico, motores de recomendación (Eling et al., 2022). Generación de contenidos y microsegmentación hipercontextual (Bhattacharya et al., 2025; Owen et al., 2025). Riesgos de diferenciación injusta al usar datos conductuales sin control de sesgos (van Bekkum, 2025). HIL en comunicación sensible para reforzar confianza (Yang et al., 2025).	Segmentación (E11), gestión de leads (E7), generación de contenidos (E9).	<i>Sentiment detection</i> avanzado, recomendadores personalizados.
Desarrollo de producto	Telemática en autos y salud, <i>wearables</i> en vida, ciberseguros (Eling & Lehmann, 2018). Innovación en nuevos productos	Producto de ciberseguridad (E8), diagnóstico digital en	Expansión de ecosistemas digitales, seguros paramétricos.

Etapa de la cadena de valor	Aplicaciones según la literatura	Evidencia empírica entrevistas (España)	No observadas en la muestra
	digitales y on-demand (Eling et al., 2022). Fairness y solidaridad en el uso de datos sensibles (van Bekkum, 2025). Detección de oportunidades con datos no estructurados y diseño asistido de coberturas emergentes (Owen et al., 2025; Bhattacharya et al., 2025). Revisión HIL en productos sensibles (Yang et al., 2025).	salud (E16), analítica predictiva (E4).	
Ventas y distribución	<i>Chatbots</i> de primera generación; plataformas digitales y agregadores (Eling & Lehmann, 2018; Eling et al., 2022). Copilotos de venta y asistentes virtuales avanzados (Owen et al., 2025). HIL incrementa la disposición del cliente a aceptar recomendaciones (Yang et al., 2025).	Chatbots híbridos (E13), piloto fallido de asistente virtual (E14).	Recomendadores personalizados para <i>cross/up-selling</i> .
Suscripción y pricing	<i>Underwriting</i> automatizado, fijación dinámica de primas (Eling et al., 2022). IoT y telemática para riesgos dinámicos (Eling & Lehmann, 2018). Pricing en vida/salud con GenAI (alto riesgo, Owen et al., 2025). Responsible AI en salud: modelos predictivos (XGBoost/RF) con explicabilidad, privacidad y mitigación de sesgos (Alam et al., 2024). Controles de fairness en diferenciación de riesgos (van Bekkum, 2025). HIL recomendado en decisiones de alto impacto (Yang et al., 2025).	Suscripción PyME (E15), modelos de riesgo y pricing (E11, E16), primas con datos externos (E4).	Pricing dinámico en tiempo real, uso intensivo de GenAI en salud/vida.
Servicio al cliente	<i>Text analytics</i> , automatización, gestión proactiva de clientes (Eling et al., 2022). Copilotos de atención y chatbots multimodales (Owen et al., 2025). HIL en reclamaciones/disputas	Copilotos en <i>call center</i> (E13), captura automática de datos (E16), ChatGPT internos (E1, E5, E12, E15).	No se observan <i>voicebots</i> multimodales ni copilotos desplegados al cliente final.

Etapa de la cadena de valor	Aplicaciones según la literatura	Evidencia empírica entrevistas (España)	No observadas en la muestra
	sensibles mejora la percepción de justicia (Yang et al., 2025).		
Siniestros	Reconocimiento por imagen y vídeo, detección de fraude, automatización integral (Eling et al., 2022). Responsible AI: trazabilidad y explicabilidad en procesos automatizados (Alam et al., 2024). <i>Claims automation end-to-end</i> y análisis de emociones en llamadas (alto riesgo, Owen et al., 2025). HIL reduce fricción y mejora la experiencia del cliente (Yang et al., 2025).	Clasificación de siniestros (E13), pago inmediato (E3), reconocimiento por imagen (E11), videoperitación (E8), detección de fraude (E5, E11).	Automatización integral <i>end-to-end</i> , análisis de emociones en llamadas.
Gestión de activos y riesgos	<i>Robo-advisors</i> en inversión, reporting analítico, simulación de escenarios (Eling & Lehmann, 2018; Eling et al., 2022). Modelización climática y reputacional con GenAI (Bhattacharya et al., 2025). Controles de sesgo en señales de riesgo y transparencia en modelos (van Bekkum, 2025).	BI de ROI tecnológico (E5), segmentación de carteras (E16).	<i>Robo-advisors</i> activos, reporting automatizado con IA, modelización ESG con GenAI.
Funciones de soporte (IT, RRHH, Legal, PR)	Reclutamiento y formación digital, automatización de reporting, <i>cloud</i> y <i>blockchain</i> en contratos (Eling & Lehmann, 2018; Eling et al., 2022).	Generación de informes regulatorios, asistentes de <i>upskilling</i> , análisis automático de cambios normativos (Owen et al., 2025; Bhattacharya et al., 2025). Gobernanza de IA: auditorías de sesgo, privacidad y explicabilidad; <i>human-in-the-loop</i> en sistemas de alto riesgo (Alam et al., 2024; Yang et al., 2025; van Bekkum, 2025).	Asistentes de programación (E3, E9), desarrollo web (E7), asistentes de RRHH (E13), despliegue de ChatGPT internos (E1, E5, E12, E15).

Fuente: Elaboración propia a partir de Eling et al. (2022)

5. Discusión

5.1. Dimensión Organización

Predominio de los factores organizativos

Los resultados obtenidos en las entrevistas confirman que los factores organizativos constituyen el núcleo explicativo de la adopción de IA en el sector asegurador español. Esta conclusión no es trivial: pese a la centralidad que habitualmente se concede a la disponibilidad tecnológica y al marco regulatorio, los directivos sitúan la capacidad organizativa —liderazgo, talento, cultura y estructuras de gobernanza— como el verdadero diferencial entre proyectos aislados y adopciones a escala. Este hallazgo enlaza directamente con el marco TOE de Tornatzky & Fleischer (1990), que reconoce que la innovación no depende exclusivamente del entorno o de la infraestructura técnica, sino de la preparación y disposición organizativa para absorber y escalar la tecnología.

La literatura previa sobre adopción de IA en servicios financieros (Gupta et al., 2022; Kruse et al., 2019) ya había subrayado el peso del factor humano y de la dirección estratégica, pero el análisis de este estudio lo confirma con una densidad notable: los fragmentos codificados bajo la dimensión organizativa superan en frecuencia a los tecnológicos y ambientales, lo que sugiere una especificidad cultural del seguro español. De hecho, los testimonios apuntan a que, en ausencia de liderazgo comprometido y talento especializado, incluso las inversiones en tecnologías avanzadas terminan confinadas a pruebas piloto sin impacto transformador, un fenómeno coincidente con la GenAI Divide descrita por MIT NANDA (2025) y corroborada en entrevistas de Owen, Sheehan & Mullins (2024), donde la aversión al riesgo y la ambigüedad regulatoria ralentizan el escalado.

Coste-beneficio, ROI y ventaja relativa como filtros

El discurso directivo sitúa el análisis coste–beneficio como el primer filtro de viabilidad. Ningún proyecto de IA avanza sin un *business case* sólido que demuestre un retorno claro, cuantificable y sostenible. Esta práctica confirma lo planteado por Rogers (2003), para quien la ventaja relativa es el factor más influyente en la difusión tecnológica. Los resultados empíricos refuerzan esta tesis: el subcódigo “coste-beneficio y ROI” acumula 389 referencias, lo que lo convierte en la categoría organizativa más citada.

Sin embargo, los hallazgos revelan una tensión dual. Por un lado, la IA predictiva —percibida como “tradicional”— se evalúa bajo una lógica incremental y financiera estricta, donde solo se aprueban proyectos cuyo beneficio marginal supera claramente el coste. Por otro, la IA generativa se interpreta como un salto

cualitativo, legitimado no tanto por retornos inmediatos como por su potencial estratégico a medio plazo. Esta distinción coincide con Xu, Ramayah & Shi (2025), que demuestran empíricamente que la ventaja relativa y el apoyo de la alta dirección son los predictores más influyentes en la adopción de GenAI, por encima de la compatibilidad tecnológica.

Rentabilidad tangible e intangible

El examen detallado de los testimonios revela que la contribución de la IA trasciende la medición económica. Los directivos reconocen retornos intangibles en capital humano (liberación de tiempo, upskilling), en innovación organizativa (capacidad de experimentación, aprendizaje iterativo), en reputación (imagen de modernidad y atracción de talento) y en capital relacional (refuerzo de la confianza con mediadores y clientes). Estos hallazgos se alinean con Hamm & Klesel (2021) y con Bhattacharya et al. (2025), que reclaman incorporar la gobernanza de datos, la explicabilidad y marcos ESG como parte de la evaluación del valor generado.

La noción de coste de la inacción (Pumplun et al., 2019) aparece de forma recurrente: no invertir en IA supone perder inercia tecnológica en un sector donde FinTech e InsurTech avanzan con mayor rapidez. Este argumento conecta también con Eling & Lehmann (2018), que advierten de los riesgos de fragmentación de la cadena de valor y pérdida de insurabilidad de ciertos riesgos si no se integran tecnologías emergentes.

Talento, cultura y resistencia al cambio

La escasez de perfiles híbridos y especializados, junto con la dificultad para retenerlos, constituye una de las barreras críticas. Este hallazgo coincide con Gupta et al. (2022) y Lopez-García & Manrique Rojas (2024), quienes subrayan la brecha de competencias como freno a la adopción, vinculada a una resistencia organizacional que convive en tensión con la motivación tecnológica.

Además, los directivos señalan resistencias culturales derivadas del temor a la sustitución laboral, del escepticismo frente a modas tecnológicas y de la fatiga por transformaciones previas fallidas. Sin embargo, también se identifican palancas de mitigación: comunicación transparente, narrativa de la IA como *copilot*, obtención de *quick wins* y la configuración de equipos transversales con metodologías ágiles. Estas estrategias se alinean con Rogers (2003) sobre la compatibilidad cultural y la trialability, y con Matsepe & Van der Lingen (2022), que destacan la importancia del *upskilling* y la gestión del cambio.

Gobernanza, liderazgo y modelos operativos

La evidencia confirma que el liderazgo constituye un vector decisivo. En aseguradoras grandes y maduras predomina un modelo *top-down*, donde el CEO y

el consejo marcan la agenda, mientras que en organizaciones con madurez intermedia se aprecia un modelo mixto de interacción entre negocio y tecnología. En entidades en etapas iniciales, el liderazgo es reactivo y dependiente de individuos concretos.

El desarrollo de Centros de Excelencia (CoE) refuerza esta institucionalización, actuando como mecanismos de priorización y mediación entre negocio y tecnología, en línea con Pumplun et al. (2019). Además, la transición de modelos en cascada hacia metodologías ágiles confirma lo señalado por Oliveira & Martins (2011): las innovaciones disruptivas requieren rediseñar estructuras y procesos, no solo incorporar herramientas.

El papel del tamaño y la complejidad organizativa

Los resultados estadísticos obtenidos ($r_s = 0,74$; $\tau = 0,62$) confirman una correlación positiva entre tamaño y madurez, en línea con Jeyaraj et al. (2006). Las grandes aseguradoras disponen de más recursos y capacidad de negociación, pero arrastran rigideces que ralentizan la adopción, mientras que las pequeñas, con menos músculo financiero, pueden competir en agilidad. Esta tensión reproduce lo señalado por Kruse et al. (2019) y Alsheiabni et al. (2020), y se conecta con Eling & Lehmann (2018), que advierten sobre el riesgo de que grandes players externos capten partes de la cadena de valor si los incumbentes no se adaptan.

Prudencia, trialability y enfoque fast follower

El patrón incremental PoC → piloto → escalado identificado transversalmente en las entrevistas confirma la noción de trialability de Rogers (1995). Este enfoque prudente refleja la aversión al riesgo propia del sector y coincide con Owen, Sheehan & Mullins (2024), quienes documentan que la mayoría de proyectos de GenAI en seguros permanecen en usos internos o de bajo riesgo, evitando despliegues críticos hasta que exista claridad regulatoria y confianza tecnológica.

Tabla 29: Hallazgos empíricos y correspondencia con la literatura en la dimensión organizativa de la adopción de IA

Eje analítico	Hallazgos empíricos (entrevistas)	Correspondencia con la literatura
Predominio de los factores organizativos	El éxito en la adopción depende más de liderazgo, talento, cultura y gobernanza que de la tecnología o el entorno regulatorio. Sin estas bases, incluso proyectos técnicamente sólidos quedan en pilotos.	TOE (Tornatzky & Fleischer, 1990): centralidad organizativa. Gupta et al. (2022); Kruse et al. (2019): peso del factor humano. Xu, Ramayah & Shi (2025): apoyo directivo media entre presión competitiva y adopción de GenAI. Owen et al. (2024): mentalidad de riesgo y confianza como freno. MIT NANDA (2025): <i>GenAI Divide</i> .

Eje analítico	Hallazgos empíricos (entrevistas)	Correspondencia con la literatura
Coste–beneficio, ROI y ventaja relativa	El ROI positivo es condición indispensable. IA predictiva: lógica incremental y financiera estricta. IA generativa: legitimada por su potencial estratégico a medio plazo, aun sin ROI inmediato.	Rogers (2003): ventaja relativa como factor más influyente. Alsheibani et al. (2018): ROI como requisito clave. Xu, Ramayah & Shi (2025): ventaja relativa, predictor más influyente en GenAI. Dwivedi et al. (2023); Eloundou et al. (2023): GenAI como horizonte cualitativo distinto.
Rentabilidad tangible e intangible	Reconocimiento de beneficios intangibles: capital humano (tiempo, competencias), innovación, reputación, confianza con clientes y mediadores. La IA también se valora como inversión para evitar el “coste de la inacción”.	Hamm & Klesel (2021): factores culturales y organizativos. Pumplun et al. (2019): aprendizaje como retorno estratégico. Bhattacharya et al. (2025): gobernanza de datos, explicabilidad y marcos ESG. MIT NANDA (2025): superar la <i>GenAI Divide</i> exige aprendizaje organizativo.
Talento, cultura y resistencias	Escasez de perfiles híbridos y especializados, dificultades de retención y resistencias culturales (miedo a sustitución, escepticismo, fatiga). Palancas: comunicación, narrativa de <i>copilot</i> , <i>quick wins</i> y equipos ágiles.	Gupta et al. (2022): brecha de competencias. Rogers (2003): compatibilidad cultural y trialability reducen resistencias. Matsepe & Van der Lingen (2022): gestión del cambio y <i>upskilling</i> . Lopez-García & Manrique Rojas (2024): tensión entre resistencia organizacional y motivación tecnológica.
Gobernanza, liderazgo y modelos operativos	Liderazgo <i>top-down</i> en grandes/maduras; modelo mixto en intermedias; liderazgos reactivos en pequeñas. Los CoE institucionalizan la innovación y median entre negocio y tecnología. Transición de cascada a Agile y equipos transversales.	Jeyaraj et al. (2006); Alsheibani et al. (2020): apoyo directivo como predictor clave. Pumplun et al. (2019): CoE y laboratorios de innovación como facilitadores. Oliveira & Martins (2011): rediseño organizativo. Owen et al. (2024): confianza y liderazgo como factores diferenciales en GenAI.
Tamaño y complejidad	Correlación positiva entre tamaño y madurez ($r_s=0,74$; $\tau=0,62$). Grandes: más recursos y datos, pero riesgo de rigidez y burocracia. Pequeñas: más agilidad, pero limitaciones financieras y de escala.	Jeyaraj et al. (2006): tamaño condiciona adopción. Alsheibani et al. (2020): grandes con más recursos, pequeñas con agilidad. Kruse et al. (2019): rigidez de grandes estructuras. Eling & Lehmann (2018): digitalización puede fragmentar la cadena de valor si los incumbentes no se adaptan.
Prudencia, trialability y fast follower	Patrón incremental PoC → piloto → escalado. Estrategia fast follower y prudente para reducir riesgos, aunque se renuncie a ventajas de primer movimiento.	Rogers (1995): trialability como clave. Kruse et al. (2019): aversión al riesgo en seguros. Owen et al. (2024): preferencia por casos internos de bajo riesgo en

Eje analítico	Hallazgos empíricos (entrevistas)	Correspondencia con la literatura
		GenAI. MIT NANDA (2025): proliferación de pilotos no escalados (<i>GenAI Divide</i>).

Fuente: Elaboración propia

5.2. Dimensión Tecnología

Madurez tecnológica dual: predictiva consolidada vs. generativa incipiente

Los resultados muestran que los directivos perciben una clara dualidad en la madurez tecnológica de la IA. La analítica predictiva y el *machine learning* se consideran consolidados e integrados en procesos clave como fraude, *pricing* o siniestros, mientras que la IA generativa se percibe aún inmadura, rodeada de incertidumbre y limitada a pilotos internos. Esta diferenciación refuerza lo planteado por Eling et al. (2022), que destacan la penetración de la IA predictiva en *underwriting* y gestión de siniestros, pero apenas citan aplicaciones generativas. Asimismo, confirma la literatura sobre madurez (Alsheiabni et al., 2019), donde las compañías solo avanzan hacia integración plena cuando los modelos alcanzan fiabilidad y escalabilidad. El contraste entre entusiasmo y escepticismo frente a la IA generativa conecta con Dwivedi et al. (2023) y Eloundou et al. (2023), que la describen como un cambio cualitativo con gran potencial, pero aún lejos de un despliegue a escala.

“Hype” y expectativas infladas

El discurso de los directivos sitúa a la IA —sobre todo la generativa— en un ciclo de expectativas infladas, amplificado por medios, consultores y proveedores. Experiencias frustrantes con *chatbots* o con herramientas como Copilot alimentan la percepción de brecha entre promesas y resultados. Esta lógica coincide con el *hype cycle* descrito en la literatura de innovación (Rogers, 1995; Vagnani et al., 2019), donde la sobreexpectativa inicial genera desilusión antes de que emerja una adopción sostenible. El fenómeno de la GenAI Divide (MIT NANDA, 2025) refuerza esta visión al mostrar que el 95% de los pilotos generativos no alcanzan producción, reproduciendo el patrón superficial identificado también en las entrevistas. Owen, Sheehan & Mullins (2024) confirman que la aversión al riesgo y la ambigüedad regulatoria explican por qué la mayoría de aseguradoras restringe los usos de GenAI a casos internos o de bajo riesgo. Aun así, los entrevistados reconocen que, a diferencia de modas pasajeras como el *metaverso* o *blockchain*, la IA generativa será estructural, aunque su despliegue será más lento y gradual de lo anunciado.

Evolución progresiva vs. disrupción

Se observan dos marcos narrativos contrapuestos: uno incremental, que sitúa la IA en continuidad con otras innovaciones (ERP, BI) y la entiende como herramienta de eficiencia, y otro disruptivo, que la describe como un “cambio de era” capaz de transformar talento, procesos y cultura. Esta dicotomía se vincula al nivel de madurez (AIMM) y al modelo de negocio: en fases *Assessing* o *Determined* predomina la lógica incremental, mientras que en entidades *Managed* y de distribución directa emerge la narrativa de disrupción. Este hallazgo enlaza con

Rogers (2003), para quien la percepción de ventaja relativa varía según el contexto, y con Neumann et al. (2022), que muestran cómo los factores tecnológicos ganan centralidad conforme avanza la madurez. A ello se suma lo señalado por Lopez-García & Manrique Rojas (2024): la adopción depende de la tensión entre resistencia organizacional y motivación tecnológica.

Adopción gradual y *trialability*

El despliegue tecnológico sigue un patrón incremental: PoC → piloto → escalado, apoyado en soluciones empaquetadas, modelos *pay-per-use* y plataformas SaaS (Copilot, Salesforce). Este enfoque confirma la relevancia de la *trialability* en la DOI de Rogers (1995) y las observaciones de Matsepe & Van der Lingen (2022) sobre la reducción de riesgos mediante pilotos. Además, la disponibilidad de herramientas de bajo umbral democratiza el acceso, especialmente en entidades medianas, mientras que las más maduras combinan gradualidad con infraestructuras sólidas (Data Lakes, API-first). La literatura respalda esta lógica: Pumplun et al. (2019) destacan que la experimentación incremental es crítica en proyectos de IA. En el sector asegurador, esta gradualidad se confirma como estrategia estructural: prudente culturalmente, pero también funcional ante costes, seguridad y dependencia de proveedores.

Datos, infraestructuras y plataformas como habilitadores críticos

La evidencia empírica confirma que la calidad del dato, la gobernanza y la modernización de arquitecturas son condiciones sine qua non para la IA. El *legacy* divide al sector en tres perfiles: entidades atrapadas en arquitecturas obsoletas, compañías que se benefician de reingenierías pasadas e InsurTechs libres de deuda tecnológica. Este hallazgo dialoga con Kruse et al. (2019) y Alsheiabni et al. (2020), que identifican la compatibilidad tecnológica como determinante. La transición hacia arquitecturas modulares y API-first refuerza lo planteado por Bauer et al. (2020) sobre interfaces estandarizadas. La institucionalización de la gobernanza del dato y la construcción de *Data Lakes* en entidades *Managed* confirman la evolución prevista en el AIMM: desde silos en fases iniciales hasta infraestructuras centralizadas en niveles avanzados. Además, el consumo de IA embebida en plataformas externas (Microsoft, Salesforce) reproduce lo señalado por Premkumar & Roberts (1999): el soporte fiable de proveedores como catalizador inicial, aunque con riesgos de dependencia.

Riesgos tecnológicos, éticos y reputacionales

Los riesgos asociados a la IA van más allá de lo técnico: opacidad de modelos (*caja negra*), alucinaciones de modelos generativos, sesgos, riesgo de desmutualización, pérdida de control de datos y daño reputacional. Estos hallazgos coinciden con Kruse et al. (2019) y Hamm & Klesel (2021), que identifican la explicabilidad y

gobernanza ética como factores críticos. Bhattacharya et al. (2025) subrayan que la integración de criterios ESG y marcos regulatorios robustos es esencial para legitimar la innovación en seguros. Por su parte, Eling & Lehmann (2018) advierten que la digitalización cambia la insurabilidad de riesgos y puede generar dilemas éticos cuando la transparencia erosiona la solidaridad en los sistemas mutualistas. Finalmente, la insistencia en mantener la supervisión humana (*human-in-the-loop*) confirma que, en sectores regulados, la adopción de IA exige combinar eficiencia con legitimidad.

La Tabla 30 sintetiza los principales hallazgos relativos a la dimensión tecnológica y su correspondencia con la literatura especializada.

Tabla 30: Hallazgos empíricos y correspondencia con la literatura en la dimensión tecnológica de la adopción de IA

Eje analítico	Hallazgos empíricos (entrevistas)	Correspondencia con la literatura
Madurez tecnológica dual	IA predictiva consolidada en procesos críticos (fraude, pricing, siniestros). IA generativa percibida como inmadura, limitada a pilotos internos, con entusiasmo y escepticismo en paralelo.	Eling et al. (2022): consolidación de IA predictiva en la cadena de valor aseguradora. Alsheiabni et al. (2019): madurez progresiva según niveles AIMM. Dwivedi et al. (2023); Eloundou et al. (2023): GenAI como salto cualitativo. Owen et al. (2024): uso prudente de GenAI, restringido a casos internos de bajo riesgo.
“Hype” y expectativas infladas	Directivos perciben sobreexpectación mediática y comercial en torno a GenAI. Frustraciones con <i>chatbots</i> y Copilot refuerzan la brecha entre promesas y resultados.	Rogers (1995): ciclos de sobreexpectativa y adopción gradual. Vagnani et al. (2019): contradicciones empíricas por “hype”. MIT NANDA (2025): <i>GenAI Divide</i> (95% de pilotos sin valor). Owen et al. (2024): aversión al riesgo y ambigüedad regulatoria alimentan la cautela.
Evolución progresiva vs. disrupción	Dos narrativas: (i) incremental (IA como continuidad de ERP, BI, digitalización); (ii) disruptiva (IA como “cambio de era”). La visión depende del nivel de madurez (AIMM) y modelo de negocio.	Rogers (2003): ventaja relativa depende del contexto. Neumann et al. (2022): factores tecnológicos ganan peso en fases avanzadas. Eling et al. (2022): IA impacta transversalmente. Lopez-García & Manrique Rojas (2024): tensión entre resistencia organizacional y motivación tecnológica.
Adopción gradual y trialability	Patrón PoC → piloto → escalado. Uso de SaaS y <i>pay-per-use</i> . Herramientas “plug-and-play” democratizan la IA en fases	Rogers (1995): <i>trialability</i> como factor clave. Matsepe & Van der Lingen (2022): pilotos reducen riesgos. Pumplun et al. (2019): metodologías ágiles y

Eje analítico	Hallazgos empíricos (entrevistas)	Correspondencia con la literatura
	iniciales. Gradualidad estructural, no solo prudencial.	experimentación incremental. Owen et al. (2024): preferencia por despliegues internos de bajo riesgo en GenAI.
Datos, infraestructuras y plataformas	Sistemas <i>legacy</i> como principal barrera estructural. <i>Data Lakes</i> y gobernanza del dato como habilitadores. Arquitecturas API-first facilitan escalabilidad. Dependencia creciente de IA embebida en plataformas externas (Copilot, Salesforce).	Kruse et al. (2019): deuda <i>legacy</i> como freno. Alsheibani et al. (2020): compatibilidad e infraestructura como facilitadores. Bauer et al. (2020): interfaces estandarizadas. Premkumar & Roberts (1999): proveedores como catalizadores iniciales. Bhattacharya et al. (2025): gobernanza de datos y explicabilidad como pilares.
Riesgos tecnológicos, éticos y reputacionales	Preocupación por la “caja negra” y falta de explicabilidad, alucinaciones en GenAI, sesgos algorítmicos y riesgo de desmutualización. Temor a pérdida de control de datos y daño reputacional. Supervisión humana como salvaguarda.	Kruse et al. (2019): seguridad y transparencia como factores críticos. Hamm & Klesel (2021): dilemas éticos y explicabilidad. Pumplun et al. (2019): gobernanza y legitimidad. MIT NANDA (2025): riesgos de pilotos no escalados. Eling & Lehmann (2018): digitalización impacta en insurabilidad y justicia mutualista. Bhattacharya et al. (2025): ESG y marcos regulatorios como condiciones de legitimación.

Fuente: Elaboración propia

5.3. Dimensión Entorno

Presión competitiva y papel de las InsurTech

Los resultados muestran que la presión competitiva constituye un factor determinante en la adopción de IA en el sector asegurador español, aunque con matices. Los grandes grupos multinacionales fijan el ritmo de la innovación gracias a su escala financiera y de datos, generando una presión reactiva sobre entidades medianas y pequeñas. No obstante, ningún directivo identifica aún a un competidor que esté obteniendo ventajas estratégicas sostenibles a partir de la IA, lo que alimenta una estrategia de espera vigilante y un posicionamiento de *fast follower*. Esta dinámica se corresponde con la literatura sobre factores ambientales del marco TOE, que destaca la presión competitiva como motor clave de adopción (Jeyaraj et al., 2006; Gatignon & Robertson, 1989). En línea con Premkumar & Ramamurthy (1995) y Eitle & Buxmann (2020), los entrevistados reconocen que el riesgo de “perder el tren” justifica mantenerse atentos y preparados, aunque todavía no se perciba una ventaja diferencial tangible. Estudios recientes confirman que la presión competitiva impulsa la adopción de GenAI de forma mediada por el apoyo de la alta dirección (Xu, Ramayah & Shi, 2025).

El papel de las *InsurTech* y de las *Big Tech* se describe como más catalizador que disruptivo: aportan metodologías ágiles y soluciones especializadas, pero carecen de datos y capacidad de escalar en la cadena de valor completa. Este hallazgo coincide con Kruse et al. (2019) y Matsepe & Van der Lingen (2022), que señalan que las FinTech e InsurTech presionan a los incumbentes a modernizarse, aunque rara vez logran sustituirlos. En la práctica, las aseguradoras tienden a integrarlas en dinámicas de innovación abierta, usándolas como socios tecnológicos más que como competidores. Esto confirma lo señalado por Bauer et al. (2020) y por Eling & Lehmann (2018), quienes destacan que la digitalización reconfigura la cadena de valor y que el verdadero riesgo de disrupción procede de actores con acceso directo al cliente y a los datos.

Preparación y aceptación de los clientes

Los testimonios reflejan que la preparación del cliente constituye una condición esencial para la adopción de IA. Si bien existe un segmento más digitalizado, dispuesto a interactuar con algoritmos y procesos automatizados, la mayoría de clientes —especialmente en contextos sensibles como siniestros o decesos— exige preservar la interacción humana. Esta evidencia se alinea con Matsepe & Van der Lingen (2022), quienes destacan la disposición del cliente como factor ambiental crítico.

En línea con la DOI (Rogers, 1995), la compatibilidad cultural y la confianza son decisivas: la IA se acepta cuando complementa la experiencia omnicanal, pero no

cuando sustituye el vínculo humano. La literatura reciente subraya este punto: de Andrés-Sánchez & Gené-Albesa (2024) demuestran que la confianza explica más que la utilidad o la facilidad de uso en la adopción de chatbots en seguros.

El papel de los mediadores

El canal de mediación emerge como un factor externo decisivo que condiciona el ritmo de adopción. A diferencia de predicciones sobre su desaparición, los mediadores mantienen un rol central, lo que obliga a las compañías a diseñar proyectos que refuercen —y no sustituyan— el vínculo relacional que estos ofrecen. La evidencia muestra que los mediadores solo adoptan la IA si perciben beneficios claros (más ventas, menos carga administrativa). De lo contrario, actúan como freno, rechazando herramientas que compliquen su labor. Esto enlaza con la *trialability* de Rogers (1995): el mediador solo integra la innovación si puede probarla en un entorno de bajo riesgo y comprobar beneficios tangibles. Además, se confirma el papel estratégico de la omnicanalidad en la literatura (Eling et al., 2022), donde la coexistencia de canales humanos y digitales se convierte en ventaja competitiva cuando el cliente elige libremente.

Preocupaciones éticas y sociales

Una preocupación compartida por la mayoría de entrevistados son los riesgos éticos de la IA, en particular la erosión del principio mutualista y la exclusión de colectivos vulnerables. La granularidad de la tarificación, habilitada por la IA, amenaza la solidaridad del seguro, un dilema señalado en la literatura sobre digitalización e insurabilidad (Hamm & Klesel, 2021; Eling & Lehmann, 2018). Los hallazgos coinciden también con la literatura sobre sesgos algorítmicos (Kruse et al., 2019), que alerta sobre el refuerzo de desigualdades sociales.

En paralelo, los directivos mencionan impactos sociolaborales y dilemas emergentes, confirmando la advertencia de Wirtz et al. (2019) sobre la imprevisibilidad de la IA como tecnología multipropósito. Owen, Sheehan & Mullins (2024) añaden que la desconfianza organizativa y la ambigüedad regulatoria explican la cautela en la adopción de GenAI. A ello se suma la demanda de mecanismos correctores regulatorios, reforzando la perspectiva de que la legitimidad del seguro depende de preservar equidad y empleo como variables estratégicas.

Colaboración con socios externos y riesgo de lock-in

Las entrevistas muestran una dependencia creciente de socios externos — InsurTechs, consultoras, Big Tech— para acelerar pilotos y validar soluciones, lo que confirma el papel de la innovación abierta en la literatura (Hamm & Klesel, 2021; Bauer et al., 2020). Sin embargo, esta colaboración genera un dilema: mientras las grandes consultoras aportan robustez y escala, las startups ofrecen

innovación pero carecen de mercado. La dependencia tecnológica y el riesgo de *vendor lock-in* coinciden con Demlehner & Laumer (2020). La estrategia híbrida observada en entidades más maduras —externalizar capacidades periféricas y preservar conocimiento clave internamente— se alinea con Alsheiabni et al. (2019). Bhattacharya et al. (2025) añaden que la gobernanza de datos, la explicabilidad y la integración ESG se han convertido en condiciones necesarias para legitimar estas colaboraciones.

Regulación y políticas públicas

El entorno regulatorio europeo aparece en las entrevistas como una fuerza ambivalente: frena la innovación mediante una hiperregulación percibida como rígida, pero también legitima la adopción e impulsa inversiones defensivas (fraude, eficiencia). Esta dualidad coincide con Pumplun et al. (2019) y Matsepe & Van der Lingen (2022). La percepción de “vorágine regulatoria” descrita por los directivos se corresponde con lo señalado por Kruse et al. (2019). Al mismo tiempo, la referencia a fondos públicos internacionales como incentivo confirma el rol catalizador de la política pública (Schäfer et al., 2021).

La literatura reciente (Bhattacharya et al., 2025) confirma que la regulación debe combinar control con legitimación, integrando requisitos de explicabilidad y sostenibilidad para que la IA gane aceptación social

La Tabla 31 sintetiza los principales hallazgos relativos a la dimensión Entorno y su correspondencia con la literatura académica.

Tabla 31: Hallazgos empíricos y correspondencia con la literatura en la dimensión entorno de la adopción de IA

Eje analítico	Hallazgos empíricos (entrevistas)	Correspondencia con la literatura
Presión competitiva e InsurTechs	Grandes grupos multinacionales marcan el ritmo; entidades medianas y pequeñas adoptan estrategias de <i>fast follower</i> . InsurTechs y Big Techs actúan como catalizadores, aportando metodologías ágiles pero sin escalar toda la cadena de valor.	TOE: presión competitiva como motor (Jeyaraj et al., 2006; Gatignon & Robertson, 1989). Riesgo de “perder el tren” (Premkumar & Ramamurthy, 1995; Eitle & Buxmann, 2020). Rol catalizador de FinTech/InsurTech (Kruse et al., 2019; Matsepe & Van der Lingen, 2022). La presión competitiva impulsa la adopción de GenAI mediada por el apoyo de la alta dirección (Xu, Ramayah & Shi, 2025). Riesgo de disrupción bajo y cooperación con InsurTechs (Eling & Lehmann, 2018).
Preparación y aceptación de clientes	Segmento digitalizado abierto a la IA, pero la mayoría exige interacción humana en	Factores ambientales críticos (Matsepe & Van der Lingen, 2022). Compatibilidad cultural y confianza (Rogers, 1995, DOI).

Eje analítico	Hallazgos empíricos (entrevistas)	Correspondencia con la literatura
	contextos sensibles. La IA se acepta solo como complemento en la experiencia omnicanal.	Baja aceptación de <i>chatbots</i> y centralidad de la confianza (TAM+Trust) (de Andrés-Sánchez & Gené-Albesa, 2024). Cautela por desconfianza y ambigüedad regulatoria en GenAI (Owen, Sheehan & Mullins, 2024). Gobernanza de datos/explicabilidad como base de legitimidad (Bhattacharya et al., 2025).
Papel de los mediadores	Los mediadores mantienen rol central; los proyectos de IA deben reforzar el vínculo humano. Solo adoptan IA si perciben beneficios claros (más ventas, menos carga administrativa).	Rogers (2003): intermediarios como transmisores de confianza. <i>Trialability</i> (Rogers, 1995). Omnicanalidad y coexistencia de canales humanos/digitales como ventaja (Eling & Lehmann, 2018).
Preocupaciones éticas y sociales	Riesgo de desmutualización del seguro, exclusión de colectivos de riesgo, impacto sociolaboral y dilemas aún desconocidos.	Dilema mutualista / erosión de solidaridad (Hamm & Klesel, 2021). Sesgos algorítmicos (Kruse et al., 2019). Digitalización y cambios en la insurabilidad; tensión solidaridad–tarificación granular (Eling & Lehmann, 2018). Necesidad de marcos ESG y explicabilidad para legitimación (Bhattacharya et al., 2025).
Colaboración con socios externos y lock-in	Dependencia creciente de consultoras, Big Tech y <i>startups</i> . Estrategia híbrida: externalizar capacidades periféricas y preservar conocimiento interno. Riesgo de dependencia y pérdida de soberanía tecnológica.	Innovación abierta (Bauer et al., 2020; Hamm & Klesel, 2021). Riesgos de <i>vendor lock-in</i> (Demlehner & Laumer, 2020). Equilibrio externalización–soberanía (Alsheiabni et al., 2019). La gobernanza del dato, la explicabilidad y la alineación ESG condicionan estas colaboraciones (Bhattacharya et al., 2025).
Regulación y políticas públicas	Regulación europea percibida como freno (hiperregulación), pero también como legitimadora y catalizadora de inversiones defensivas. Fondos públicos vistos como incentivos estratégicos.	Restricciones regulatorias (Kruse et al., 2019). RGPD y AI Act como frenos y marco de riesgo (Pumplun et al., 2019; Matsepe & Van der Lingen, 2022). Ambigüedad regulatoria y enfoque “wait-and-see” en GenAI (Owen, Sheehan & Mullins, 2024). AI Act y exigencias de transparencia/gestión de riesgos (Bhattacharya et al., 2025). Señales de inversión pública como motor (Schäfer et al., 2021).

Fuente: Elaboración propia

5.4. Niveles de Adopción AIMM

La aplicación del modelo AIMM (Alsheibani et al., 2019) a las dieciséis entidades analizadas muestra que ninguna ha alcanzado todavía el nivel 5 – *Optimized*, mientras que solo una permanece en el nivel 1 – *Initial*. La mayor parte de los casos se concentra en los niveles intermedios, con un predominio del nivel 3 – *Determined* (7/16), seguido por *Assessing* (4/16) y *Managed* (4/16). Esta distribución indica que el sector asegurador español ha superado en gran medida la fase exploratoria (*Assessing*), pero aún no ha consolidado estándares organizativos y tecnológicos propios de la madurez plena (*Optimized*).

Los hallazgos son consistentes con lo planteado en la literatura sobre adopción tecnológica. Hameed et al. (2012) destacan que la adopción de innovaciones suele ser secuencial y acumulativa; el AIMM permite constatar qué nivel estructural se ha alcanzado tras esas decisiones. En este sentido, los resultados del presente estudio confirman que las aseguradoras españolas se encuentran mayoritariamente en un estadio intermedio, con proyectos avanzados y estructuras de gobernanza incipientes, pero lejos aún de la integración transversal y estandarizada.

La comparación con el marco propuesto por Alsheibani et al. (2019) revela una correspondencia clara entre la caracterización teórica de cada nivel y las evidencias empíricas. Así, en el nivel *Initial* se observan patrones fragmentados y dependientes de campeones individuales, con fuerte peso de los problemas de talento, presupuesto y ausencia de modelo operativo. En *Assessing*, se identifican pilotos que buscan legitimidad interna y demuestran ROI, aunque persisten la falta de talento y la resistencia cultural, en línea con lo descrito en el modelo. En *Determined*, las entidades ya despliegan arquitecturas de datos (data lakes, MLOps iniciales) y mecanismos de gobernanza, lo que coincide con la literatura que señala la importancia creciente de los factores tecnológicos en este estadio (Neumann et al., 2022). Finalmente, en *Managed* los factores organizativos y culturales recuperan protagonismo: la formación masiva, el patrocinio de la alta dirección y la institucionalización transversal se convierten en impulsores clave, en consonancia con la literatura que enfatiza la centralidad de los factores organizativos en las fases más avanzadas (Neumann et al., 2022).

En cuanto a las **barreras percibidas**, el análisis comparado de los termómetros de ICEA (2023, 2024) confirma las tendencias descritas en la literatura y aporta matices específicos al sector asegurador español. En línea con Alsheibani et al. (2019), los factores de talento y datos aparecen como los principales cuellos de botella en todas las etapas, pero con una evolución significativa: en 2023 el talento era el obstáculo más citado, mientras que en 2024 los **problemas con los datos** pasan a ocupar la primera posición. Este desplazamiento sugiere, como señala

Neumann et al. (2022), que a medida que las organizaciones avanzan en la madurez, las dificultades dejan de ser conceptuales y se trasladan a la **integración, calidad y gobernanza de la información**.

Entre las aseguradoras que ya trabajan con IA, las barreras predominantes en 2024 se relacionan con la ejecución y el escalado (talento, datos, presupuesto, alineamiento TI–negocio), lo que coincide con la caracterización de los niveles *Determined* y *Managed*. En cambio, entre las entidades que aún no han iniciado proyectos, las limitaciones son principalmente de carácter estratégico (“no es prioritario”, ausencia de backlog de casos), lo que concuerda con lo planteado en el nivel *Assessing*. Esta divergencia confirma que los factores limitantes no son estáticos, sino que evolucionan con el grado de madurez, en línea con la literatura sobre TOE y AIMM.

Asimismo, la aparición de nuevas categorías en 2024 (seguridad y regulación) refleja una convergencia con las preocupaciones descritas en los marcos teóricos más recientes: la adaptación al AI Act y los riesgos de ciberseguridad pasan a formar parte de la agenda de barreras, sugiriendo un tránsito hacia retos más sistémicos y menos tácticos. Esto coincide con lo planteado por Neumann et al. (2022), que identifican que los factores ambientales adquieren relevancia en los niveles avanzados, especialmente en torno a la preparación del cliente y la presión regulatoria.

Este análisis permite concluir que el sector asegurador español se encuentra en una fase de consolidación intermedia, donde los proyectos de IA avanzan hacia estructuras de gobernanza y despliegues transversales, pero donde las barreras vinculadas a talento, datos y regulación siguen condicionando la transición hacia niveles de madurez plena.

La Tabla 32 sintetiza las principales coincidencias entre la evidencia empírica obtenida en las entrevistas y la literatura académica previa, así como los hallazgos o matices emergentes específicos del sector asegurador español. La estructura sigue el marco Tecnología–Organización–Entorno (TOE), lo que permite visualizar de forma integrada cómo los factores se distribuyen en cada dimensión. La última fila recoge la progresión evolutiva de la adopción (AIMM), que actúa como conclusión transversal y dinámica al mostrar cómo cambian las prioridades, los impulsores y las barreras a medida que las entidades avanzan en su madurez.

Tabla 32: Coincidencias con la literatura académica y matices emergentes de la adopción de IA en aseguradoras españolas según el marco TOE y la progresión AIMM

Dimensión TOE	Coincidencias con la literatura (APA)	Aportaciones empíricas / matices emergentes
O	El análisis coste–beneficio y el ROI son factores	Se aceptan inversiones controladas sin ROI inmediato en IA generativa, como apuestas de aprendizaje y

Dimensión TOE	Coincidencias con la literatura (APA)	Aportaciones empíricas / matices emergentes
	decisivos (Rogers, 2003; Alsheiabni et al., 2019).	<i>capability building</i> . Uso de BI específico para medir retornos de IA con cuadros de mando mensuales.
O	La escasez de talento y la brecha de capacidades son barreras críticas (Gupta et al., 2022; Lopez-García & Manrique Rojas, 2024).	Problema agudo en perfiles híbridos negocio–dato. Tensiones salariales frente a equidad interna. Estrategias de retención basadas en proyectos estimulantes, orgullo de contribución y formación incluso al Consejo.
O	La resistencia cultural frena la adopción de IA (Rogers, 2003; Matsepe & Van der Lingen, 2022).	Narrativa de la IA como “superpoder” aliado, obtención de <i>quick wins</i> visibles, coexistencia de microculturas generacionales, y liderazgo distribuido insuficiente como freno.
O	La gobernanza y la explicabilidad son imprescindibles (Kruse et al., 2019; Hamm & Klesel, 2021).	Innovaciones como la clasificación semafórica de riesgos, <i>checklists</i> de 70–80 preguntas, medición homogénea del ROI desde CoE, control de IA embebida en terceros y principio de “decisión humana final”.
O	La ventaja competitiva depende de datos y talento más que de la tecnología en sí (Eling et al., 2022).	IA predictiva = <i>commodity</i> . En generativa, la ventaja es la velocidad de adopción, no la sostenibilidad. La diferenciación se logra en cómo se usan datos, talento y gobierno.
O	La automatización aumenta la productividad (Dwivedi et al., 2023).	Ahorros del 30–50 % en productividad, pero sin reducción directa de plantilla: se reasignan FTE a mayor valor. Se emplean métricas financieras clásicas (payback, TIR) y dashboards mensuales.
T	La IA predictiva está consolidada en fraude, pricing y siniestros (Eling & Lehmann, 2018; Eling, Nuessle & Staubli, 2022).	Se perciben ahorros del 30–50 % en tareas de texto/código con IA generativa, pero limitada a usos internos para evitar alucinaciones. La ventaja competitiva se considera temporal, ya que pronto se convertirá en <i>commodity</i> .
T	La adopción tecnológica suele seguir un patrón incremental PoC–piloto–escala (Rogers, 1995; Matsepe & Van der Lingen, 2022).	Estrategia explícita de <i>fast follower</i> para reducir riesgos y costes. Filosofía de “experimentar con gaseosa”: escalado solo tras beneficios probados en pilotos.
T	La calidad y gobernanza del dato son prerequisites	Se institucionalizan data lakes y diccionarios de datos, incluso vinculados a bonus directivos. Arquitectura API-

Dimensión TOE	Coincidencias con la literatura (APA)	Aportaciones empíricas / matices emergentes
	clave (Oliveira & Martins, 2011; Bauer et al., 2020).	first y repositorios intermedios para BI. Se perciben como “tesoro corporativo”.
T	La dependencia de proveedores y riesgo de lock-in es recurrente (Demlehner & Laumer, 2020).	Licencias percibidas como “renta vitalicia”. Estrategias emergentes: modelos <i>success-fee</i> , internalización de conocimiento crítico y uso de LLMs privados/seguros.
T	Las innovaciones pasan por ciclos de hype y expectativas infladas (Rogers, 1995; Vagnani et al., 2019; MIT NANDA, 2025).	Percepción de “burbuja” tecnológica en IA generativa: frustraciones con chatbots y Copilot; cautela generalizada (<i>GenAI Divide</i> : 95 % de pilotos sin valor medible). Solo una minoría ve un cambio de era ya operativo, mientras la mayoría sitúa el impacto profundo en un horizonte más largo (\approx 2030).
T	La reingeniería de procesos es condición previa a automatizar (Hammer & Champy, 1993; Oliveira & Martins, 2011).	Principio compartido: “no automatizar procesos obsoletos”. Mayor impacto en procesos de alto volumen (ej. siniestros). Aparición de squads y modelos por producto.
E	La omnicanalidad es clave en la relación cliente (Eling & Lehmann, 2018).	Se preserva el rol del mediador y del trato humano. La IA se concibe como soporte al agente (menor formación requerida, respuestas más ágiles) más que como sustituto.
E	La presión competitiva impulsa la adopción (Gatignon & Robertson, 1989; Xu, Ramayah & Shi, 2025).	Estrategia de <i>wait-and-see</i> para no precipitarse. Visión de “cambio de era” solo en una minoría. Horizonte realista de disrupción: 2030 más que 2025.
E	La IA plantea riesgos éticos y de sesgo (Kruse et al., 2019; Hamm & Klesel, 2021).	Preocupación por la desmutualización del seguro: tarificación algorítmica puede erosionar solidaridad y equidad. Restricciones deliberadas: prohibición de IVR/chatbots deshumanizadores en algunas entidades.
AIMM	Los factores cambian por etapas de madurez (Alsheiabni et al., 2019; Hameed et al., 2012; Neumann et al., 2022).	Progresión Evolutiva de la Adopción (AIMM): <i>Initial</i> → foco en datos/infra y ROI de <i>quick wins</i> ; <i>Assessing</i> → legitimidad interna, pilotos y gestión del cambio; <i>Determined</i> → gobernanza del dato, escalado y control de riesgos/explicabilidad; <i>Managed</i> → institucionalización (CoE, métricas homogéneas), talento/cultura y liderazgo <i>top-down</i> . Barreras se desplazan de talento/datos → complejidad organizativa/fatiga del cambio; horizonte de impacto

Dimensión TOE	Coincidencias con la literatura (APA)	Aportaciones empíricas / matices emergentes
		profundo ≈ 2030 ; correlación tamaño–madurez significativa ($\rho=0,74$; $\tau=0,62$).

Fuente: Elaboración propia

6. Conclusiones

El propósito central de esta tesis doctoral ha sido examinar de manera integral el proceso de adopción de la inteligencia artificial (IA) en el sector asegurador español, poniendo especial atención en las dinámicas que explican cómo las organizaciones evolucionan desde fases exploratorias iniciales hasta una integración más institucionalizada en su estrategia corporativa y en su operativa diaria. Para ello se ha recurrido a un marco teórico compuesto por tres pilares complementarios: el enfoque TOE (Tecnología–Organización–Entorno), la teoría de la Difusión de Innovaciones (DOI) y el Artificial Intelligence Maturity Model (AIMM).

La articulación de estos marcos ha permitido no solo identificar qué factores impulsan o frenan la adopción, sino también comprender cómo la importancia relativa de dichos factores se transforma en función del nivel de madurez alcanzado por cada entidad. Este enfoque dinámico constituye una de las principales aportaciones de la investigación.

El análisis empírico, basado en 16 entrevistas en profundidad con directivos de compañías que representan alrededor del 60% del mercado asegurador español, confirma que los factores tecnológicos, organizativos y ambientales no tienen un peso constante, sino que evolucionan con el tiempo. En fases iniciales prevalece la experimentación, la búsqueda de casos de uso y el aprendizaje organizativo; en fases intermedias cobran fuerza la gobernanza del dato, el retorno de la inversión (ROI) y la compatibilidad tecnológica; y, en niveles más avanzados, destacan los dilemas éticos, la gestión reputacional y la necesidad de integrar la IA de forma transversal en la estrategia empresarial.

De este modo, la investigación propone un modelo TOE–AIMM integrado, que entiende la adopción de IA no como un estado fijo, sino como un proceso evolutivo en el que barreras y facilitadores se reconfiguran a medida que las organizaciones avanzan. Se supera así la visión estática y fragmentada de parte de la literatura previa, ofreciendo un marco explicativo más ajustado a la realidad de sectores complejos, intensivos en datos y fuertemente regulados como el asegurador.

6.1. Conclusiones fundamentales

De la investigación se derivan varias conclusiones clave que enriquecen tanto el debate académico como la práctica empresarial:

1. Percepción dual de la IA.

La IA predictiva está consolidada en áreas como fraude, pricing o siniestros, donde ya genera retornos tangibles y medibles. La IA generativa, en cambio, se percibe como una tecnología con gran potencial transformador, aunque todavía inmadura

para aportar un ROI inmediato. Esta doble visión se traduce en carteras bimodales que combinan proyectos de eficiencia con proyectos de exploración.

2. El ROI como condición de escalado.

Ningún proyecto avanza hacia la producción sin demostrar retornos claros o métricas equivalentes. Incluso en el caso de la IA generativa, las inversiones se justifican como apuestas de *capability building*, siempre dentro de márgenes de riesgo definidos y con objetivos explícitos de aprendizaje.

3. Predominio de factores organizativos y culturales.

Más que las limitaciones técnicas o de datos, el éxito depende de la capacidad de liderazgo de los equipos directivos, de la cultura organizativa y de la disponibilidad de talento híbrido. Los proyectos rápidos y visibles (*quick wins*) actúan como catalizadores que legitiman la IA y ayudan a superar resistencias internas.

4. La gobernanza del dato como prerequisite.

La calidad y la gobernanza de los datos constituyen condiciones indispensables para escalar proyectos de IA. En ausencia de repositorios centralizados o de diccionarios de datos, la IA tiende a quedar confinada a pilotos locales sin continuidad estratégica.

5. Los sistemas heredados como freno estructural.

Más allá de la calidad de los datos, los sistemas *legacy* se configuran como la principal barrera tecnológica. Los directivos describen arquitecturas fragmentadas o “en espagueti” que dificultan la escalabilidad, condicionan la gobernanza y complican la modernización de procesos. Este “pecado original” tecnológico aparece como un obstáculo estructural cuya resolución es condición previa para aspirar a una adopción avanzada de IA.

6. Ventaja competitiva efímera.

La IA predictiva se percibe ya como un estándar del sector. La IA generativa ofrece un margen de diferenciación, pero este se considera temporal y estrechamente vinculado a la rapidez con la que cada entidad logre integrarla en procesos críticos.

7. Riesgos percibidos más sociales que técnicos.

Las principales preocupaciones no se centran en los fallos algorítmicos, sino en los riesgos de erosión de la confianza de clientes y mediadores, en la aparición de sesgos y en la posible desmutualización del seguro. Esta cautela social se alimenta, no obstante, de limitaciones técnicas muy concretas: la opacidad de los modelos (“caja negra”) y la fiabilidad reducida de la IA generativa debido a las

“alucinaciones”. Por ello se mantienen salvaguardas, supervisión humana y mecanismos de control ético.

8. El entorno como modulador, no determinante.

La competencia de grandes grupos internacionales, las expectativas de los clientes, el rol de los mediadores y la regulación europea ejercen presión sobre las aseguradoras, pero no determinan de manera uniforme la transformación. En este sentido, los mediadores emergen como *guardianes* de la innovación, capaces de frenar directamente la adopción de tecnologías que perciben como complejas o poco beneficiosas para su labor. Este hallazgo revela que el ecosistema puede condicionar la viabilidad de la innovación tecnológica más allá de las decisiones internas de cada compañía.

9. Evolución dinámica de drivers y barreras.

- *Initial*: predominan drivers exploratorios (campeones individuales, hype, proveedores externos) y barreras conceptuales (falta de talento, presupuesto).
- *Assessing*: se priorizan pilotos y métricas de ROI, con barreras vinculadas a legitimidad interna y gobernanza incipiente.
- *Determined*: cobran fuerza la calidad de datos y el control de riesgos/explicabilidad, mientras persisten dependencias de *legacy* y dilemas éticos.
- *Managed*: destacan la institucionalización (CoE, métricas homogéneas, patrocinio de la alta dirección, formación masiva), con barreras asociadas a la complejidad organizativa, la fatiga del cambio y la escasez de perfiles críticos.

Aunque los resultados confirman una correlación positiva entre tamaño y madurez, las aseguradoras pequeñas y medianas reivindican su agilidad como una ventaja competitiva diferenciadora. Esto introduce una contra-narrativa relevante: la relación tamaño–madurez no es lineal ni determinista, sino que refleja estrategias distintas de liderazgo por escala frente a liderazgo por agilidad.

6.2. Contribuciones teóricas principales

A De estas conclusiones se desprenden varias aportaciones teóricas relevantes:

- La formulación de un **marco TOE–DOI–AIMM integrado**, que permite analizar la adopción de IA como un proceso evolutivo y contextualizado, en el que la importancia de los factores varía según la madurez.
- La generación de **evidencia empírica inédita para el caso español**, en un sector de gran peso económico y social pero hasta ahora escasamente estudiado desde una perspectiva académica.
- La propuesta conceptual de una **gestión bimodal de carteras de IA**, en la que conviven proyectos de eficiencia con ROI inmediato junto a iniciativas exploratorias de IA generativa, conectando teoría y práctica.
- La incorporación del concepto emergente de la **GenAI Divide** (MIT NANDA, 2025), que describe la dificultad de pasar de pilotos a producción en proyectos de IA generativa, y que complementa los marcos clásicos de la difusión de innovaciones.
- El **reconocimiento del carácter dinámico de drivers y barreras**, demostrando que no son estáticos, sino que se transforman en cada etapa de madurez, lo que aporta una visión procesual frente a enfoques más estáticos.

6.3. Recomendaciones prácticas

Esta tesis doctoral ha permitido identificar los principales factores que condicionan la adopción de la IA en el sector asegurador español, aportando un marco comprensivo para entender su despliegue en distintos niveles de madurez tecnológica y organizativa. De los hallazgos empíricos se derivan una serie de recomendaciones orientadas tanto a las empresas del sector como a otros actores clave —reguladores, universidades y socios tecnológicos— que pueden contribuir a una incorporación más eficaz, sostenible y legítima de la IA.

Recomendaciones Prácticas para las aseguradoras

A Las recomendaciones se estructuran en función del nivel de madurez definido por el modelo AIMM. Es importante señalar que no todas las entidades deben seguir la misma hoja de ruta: mientras las grandes aseguradoras pueden capitalizar su escala en datos y recursos, las pequeñas y medianas pueden explotar su agilidad y foco como ventaja competitiva, posicionándose como *early movers* en nichos concretos.

Nivel 1: Initial (Fase de Concienciación y Exploración)

- **Liderazgo y Estrategia:** Formar al Consejo y al Comité de Dirección en el potencial estratégico de la IA. Identificar un único caso de uso de bajo riesgo y alto impacto visible (*quick win*) para demostrar valor tangible.
- **Talento y Cultura:** Realizar un diagnóstico inicial de capacidades internas y de brechas críticas de talento. Anticipar perfiles futuros y diseñar programas formativos básicos.
- **Datos e Infraestructura:** Evaluar la calidad y disponibilidad de los datos en el área elegida para el primer piloto.
- **A evitar:** dispersarse en múltiples pilotos sin dueño claro ni métrica de éxito.
- **Guardarraíles GenAI:** prohibir el uso de datos sensibles; plantillas de prompts seguras; registro obligatorio de usos para evitar *shadow AI*.

Nivel 2: Assessing (Fase de Experimentación y Legitimación)

- **Estrategia y ROI:** Concentrar recursos en pilotos con ROI claro y a corto plazo.
- **Gobernanza del Dato:** Limpiar y estandarizar las bases de datos (diccionario corporativo, *data owners*).
- **Talento y Cultura:** Lanzar programas iniciales de *upskilling* y *reskilling*; identificar empleados con potencial de especialización.

- **Organización y Gobierno:** Establecer un comité de innovación multidisciplinar (negocio, tecnología, legal, ética).
- **A evitar:** pasar de piloto a producción sin monitorización ni mecanismos de *rollback*.
- **Guardarrailes GenAI:** pruebas acotadas con *red teaming*; exclusión de datos personales; *model cards* simplificadas por piloto.

Nivel 3: Determined (Fase de Estandarización y Escalado)

- **Organización y Gobierno:** Formalizar un Centro de Competencia (CoE) en IA con mandato claro.
- **Tecnología e Infraestructura:** Invertir en arquitecturas escalables (Data Lake/Lakehouse) y en MLOps/LLMOps (registro de modelos, CI/CD, monitorización de deriva).
- **Talento y Cultura:** Diseñar itinerarios diferenciados de formación técnica y de negocio. Reforzar perfiles híbridos (“traductores”).
- **Procesos:** Rediseñar flujos de trabajo antes de automatizar.
- **A evitar:** escalar PoCs sin estandarizar, replicando ineficiencias.
- **Legacy:** abordar la modernización del *core* como prioridad estratégica, pues los sistemas heredados son el gran freno estructural a la escalabilidad.

Nivel 4: Managed (Fase de Optimización e Integración Cultural)

- **Cultura y Liderazgo:** Extender la cultura de innovación más allá del CoE, empoderando mandos intermedios como *champions*.
- **Riesgos y Ética:** Gestión avanzada de sesgos y explicabilidad; mecanismos de supervisión como *human-in-the-loop* en procesos sensibles.
- **Estrategia y Medición:** Medir el valor estratégico de la IA como capacidad transversal; integrar KPIs de IA en los cuadros de mando.
- **Ecosistema Externo:** Reforzar alianzas con proveedores, startups y centros de investigación, evitando dependencia excesiva mediante estrategias *multivendor*.
- **A evitar:** centralizar toda la IA en el CoE hasta convertirlo en cuello de botella.
- **GenAI Divide:** reconocer la dificultad de escalar pilotos generativos; superarla exige vincular proyectos a métricas de negocio claras y procesos de gobernanza robustos.

Recomendaciones para reguladores y administraciones públicas

- Equilibrar regulación y fomento de la innovación: acompañar el AI Act y el RGPD con *sandboxes* sectoriales.
- Definir estándares sobre ética y mutualidad: preservar el principio mutualista en la tarificación mediante factores correctores.
- Promover interoperabilidad tecnológica: arquitecturas abiertas, estándares comunes y compatibilidad *multi-cloud* para reducir dependencias y reforzar la soberanía tecnológica europea.

Recomendaciones para universidades y centros de formación

- Diseñar programas especializados en IA aplicada al seguro, combinando ciencia de datos, ética y regulación.
- Fomentar investigación aplicada en colaboración con aseguradoras (ROI, riesgos de desmutualización, gobernanza).
- Medir resultados formativos por inserción laboral, desarrollo de perfiles híbridos y satisfacción empresarial.

Recomendaciones para socios tecnológicos (InsurTechs, startups, consultoras)

- Pasar de *proof of concept* a *proof of value* con KPIs de negocio claros (ahorro, NPS, *time to quote*).
- Establecer modelos de colaboración equilibrados: contratos con *success fees*, cláusulas *anti lock-in*, portabilidad de datos y modelos.
- Ofrecer innovación responsable: *model cards*, métricas de equidad, auditorías de sesgo, control de alucinaciones en GenAI, explicabilidad y seguridad como valor diferencial.

Recomendaciones para empleados y profesionales del sector

- Participar en itinerarios de formación continua (alfabetización digital → analítica aplicada → ética de la IA).
- Desarrollar perfiles híbridos que combinen negocio y datos.
- Adoptar la IA como copiloto que amplía capacidades.
- Contribuir a una cultura de innovación responsable mediante feedback y detección temprana de riesgos.
- Proteger la empleabilidad a largo plazo manteniéndose actualizado en IA.

Recomendaciones para mediadores (agentes y corredores)

- Incorporar herramientas de IA que refuercen su rol: asistentes de cotización, *next best action*, tramitación de siniestros.
- Priorizar simplicidad y beneficios tangibles: reducción de carga administrativa, agilidad en procesos, incremento de ventas.
- Participar en programas de formación y acompañamiento.
- Mantener el valor relacional como diferencial: la IA debe reforzar la confianza y no sustituir la interacción humana en momentos críticos.
- Aportar retroalimentación continua a las aseguradoras mediante métricas de uso, satisfacción e impacto en ventas.
- Advertencia: los mediadores también pueden actuar como *gatekeepers* y frenar la adopción de innovaciones que perciban como perjudiciales. Su inclusión activa en el diseño y despliegue de herramientas es, por tanto, indispensable.

6.4. Limitaciones de la investigación

En primer lugar, si bien la muestra de entidades otorga al estudio un alto grado de representatividad del sector asegurador español, futuras investigaciones podrían ampliar el alcance incluyendo, *InsurTechs* con modelos de negocio asegurador alternativos, así como entidades de otros países europeos para poder hacer análisis comparativos.

En segundo lugar, aunque la metodología empleada en esta investigación ha permitido captar narrativas organizativas, percepciones y tensiones culturales, no permite establecer relaciones causales ni cuantificar el impacto económico de la adopción de IA. Sería conveniente en el futuro complementar este enfoque con estudios cuantitativos —encuestas sectoriales, análisis de series temporales o métricas de madurez—.

Una tercera limitación está relacionada con el alcance temporal. La investigación se ha llevado a cabo en un momento de rápida evolución tecnológica, marcado por la irrupción reciente de la IA generativa. Ello implica que algunas percepciones recogidas pueden cambiar con rapidez a medida que la tecnología madure, los marcos regulatorios se concreten y se disponga de casos de uso más estables. Este carácter dinámico aconseja realizar estudios longitudinales que permitan observar cómo evoluciona en el tiempo.

En cuarto lugar, la investigación ha recogido los discursos de directivos por lo que el diseño de la investigación no permite capturar en detalle los desafíos de implementación en el día a día con los que se encuentran los mandos intermedios, ni la percepción de los empleados. Incluir estas perspectivas enriquecería el análisis y permitiría observar cómo las decisiones estratégicas de los directivos se traducen —o no— en prácticas cotidianas. Tampoco incorpora la visión de otros actores, como mediadores, clientes o reguladores. Integrar estas perspectivas en futuros trabajos ofrecería una visión más completa.

6.5. Líneas futuras de investigación

Los resultados de esta investigación, junto con las limitaciones reconocidas, permiten apuntar futuras líneas futuras de investigación que pueden agruparse en seis ejes principales:

1. Ampliación metodológica

El enfoque cualitativo e interpretativo ha permitido captar significados, percepciones y narrativas organizativas. No obstante, futuras investigaciones deberían complementar este diseño con métodos mixtos, incluyendo encuestas sectoriales de amplio alcance, experimentos controlados o análisis econométricos. Ello permitiría validar estadísticamente los patrones identificados y contrastar las hipótesis emergentes sobre factores facilitadores y barreras de la adopción de IA.

2. Comparación internacional y regulación

Este estudio se circunscribe al contexto español, marcado por un marco regulatorio europeo prudente y por la inminente entrada en vigor del AI Act. Futuras investigaciones podrían desarrollar estudios comparativos internacionales que analicen cómo la regulación, la presión competitiva y la cultura empresarial modulan la adopción de IA en distintos mercados aseguradores.

3. Inclusión de actores múltiples

La muestra de entrevistas se ha centrado en la visión de altos directivos, lo que puede explicar la preponderancia de factores estratégicos y organizativos en su discurso. Futuras investigaciones deberían incorporar la perspectiva de otros actores clave: empleados de primera línea, equipos técnicos, mediadores, reguladores y clientes. Este abordaje multiactor contribuiría a comprender mejor la legitimidad social de la IA en el seguro y sus implicaciones sobre confianza, equidad y función mutualista.

4. Perspectiva longitudinal y sostenibilidad del valor

La rápida evolución tecnológica y regulatoria hace que este estudio capture una “fotografía” de un momento concreto. Son necesarios estudios longitudinales que sigan a las mismas entidades a lo largo del tiempo, permitiendo observar trayectorias de madurez, aprendizajes acumulativos y cambios en la percepción de riesgos y beneficios. Asimismo, futuras investigaciones podrían evaluar la sostenibilidad del valor creado por la IA en producción, analizando fenómenos como el model drift, la gestión de riesgos éticos y el equilibrio entre precisión algorítmica y equidad en la tarificación.

5. Temas emergentes

Sería interesante profundizar en futuros trabajos en dimensiones emergentes como el riesgo de desmutualización del seguro (el *trade-off* entre precisión e individualización excesiva) o la cuantificación de intangibles (aprendizaje organizativo, legitimidad social, reputación).

6. *Shadow AI* y prácticas informales de adopción

Un hallazgo reciente en la literatura (MIT NANDA, 2025) es la proliferación de un *shadow AI*, en la que los empleados utilizan herramientas de IA generativa a título personal (ChatGPT, Claude, *Copilot*, etc.) sin el aval ni el control de la organización. En el caso del sector asegurador, donde los datos que se manejan son muy sensibles y están muy regulados, el fenómeno del *Shadow AI* merece especial atención.

Referencias

- Ajzen, I. (1991). The theory of planned behaviour. *Organizational Behavior and Human Decision Processes*, 50(2), 179–211.
- Alam, S., Al-Amri, J. F., Al-Amri, H. F., Al-Besher, A., Al-Shehri, D., Al-Aqeel, M. K., Rahman, M. M., & Masud, M. (2024). Health insurance claim prediction using explainable artificial intelligence. *Healthcare Analytics*, 5, 100311.
- Alsheiabni, S., Cheung, Y., & Messom, C. (2018). Artificial intelligence adoption: AI-readiness at firm level. *PACIS 2018 Proceedings*, 4.
- Alsheiabni, S., Cheung, Y., & Messom, C. (2019). Towards an artificial intelligence maturity model: From science fiction to business. *PACIS 2019 Proceedings*, 46.
<https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1045&context=pacis2019>
- Alsheiabni, S., Cheung, Y., Messom, C., & Alhosni, M. (2020). Winning AI strategy: Six-steps to create value from artificial intelligence. *AMCIS 2020 Proceedings*.
- Alsheiabni, S., Messom, C., & Cheung, Y. (2020). Re-thinking the competitive landscape of artificial intelligence. *Proceedings of the Annual Hawaii International Conference on System Sciences*.
<https://doi.org/10.24251/HICSS.2020.718>
- Baker, J. (2012). The technology–organization–environment framework. En Y. K. Dwivedi, M. D. Williams, M. R. Wade, & S. L. Schneberger (Eds.), *Information systems theory: Explaining and predicting our digital society* (Vol. 1, pp. 231–245). Springer.
- Balasubramanian, R., Libarikian, A., & McElhaney, D. (2018, April 30). Insurance 2030—The impact of AI on the future of insurance. McKinsey & Company.
<https://www.mckinsey.com/industries/financial-services/our-insights/insurance-2030-the-impact-of-ai-on-the-future-of-insurance>
- Barney, J. (1991). Firm resources and sustained competitive advantage. *Journal of Management*, 17(1), 99–120.
- Bauer, M., van Dinther, C., & van de Klundert, D. (2020). Machine learning in SME: An empirical study on enablers and success factors. *AMCIS Proceedings*.

- Berger, R. (2015). Now I see it, now I don't: Researcher's position and reflexivity in qualitative research. *Qualitative Research*, 15(2), 219–234. <https://doi.org/10.1177/1468794112468475>
- Berliner, B. (1982). *Limits of insurability of risks*. Prentice-Hall.
- Bhattacharya, P., Castignani, G., Masello, I., & Sheehan, B. (2025). Artificial intelligence in the insurance industry: A PRISMA-based systematic review. *International Journal of Information Management*. [Advance online publication].
- Brinkmann, S. (2018). Qualitative interviewing. En N. K. Denzin & Y. S. Lincoln (Eds.), *The SAGE handbook of qualitative research* (5.^a ed., pp. 546–568). SAGE Publications.
- Bughin, J., Seong, J., Manyika, J., Chui, M., & Joshi, R. (2018). *Notes from the AI frontier: Modeling the impact of AI on the world economy*. McKinsey Global Institute.
- Ceylan, E. I. (2022). The effects of artificial intelligence on the insurance sector: Emergence, applications, challenges, and opportunities. En *The impact of artificial intelligence on governance, economics and finance* (Vol. 2, pp. 225–241). Springer Nature Singapore. https://doi.org/10.1007/978-981-16-8997-0_13
- Chakraborty, A., & Kar, A. K. (2017). Swarm intelligence: A review of algorithms. En *Nature-inspired computing and optimization: Theory and applications* (pp. 475–494). Springer.
- Chui, M., Hazan, E., Roberts, R., Singla, A., Smaje, K., Sukharevsky, A., Yee, L., & Zemmel, R. (2023). *The economic potential of generative AI: The next productivity frontier*. McKinsey & Company.
- Corbin, J., & Strauss, A. (2008). *Basics of qualitative research: Techniques and procedures for developing grounded theory* (3.^a ed.). Sage Publications.
- Czaja, S. J., & Sharit, J. (1998). Age differences in attitudes toward computers. *The Journals of Gerontology Series B: Psychological Sciences and Social Sciences*, 53B(5), P329–P340. <https://doi.org/10.1093/geronb/53B.5.P329>
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319–340.
- de Andrés-Sánchez, J., & Gené-Albesa, J. (2024). Trust takes the driver's seat: A TAM-based model for conversational AI adoption in insurance. *Kybernetes*. [Advance online publication].

- DeLone, W. H., & McLean, E. R. (1992). Information systems success: The quest for the dependent variable. *Information Systems Research*, 3(1), 60–95.
- DeLone, W. H., & McLean, E. R. (2003). The DeLone and McLean model of information systems success: A ten-year update. *Journal of Management Information Systems*, 19(4), 9–30.
- Demlehner, Q., & Laumer, S. (2020). Shall we use it or not? Explaining the adoption of artificial intelligence for car manufacturing purposes. *ECIS Proceedings*.
- DiMaggio, P. J., & Powell, W. W. (1983). The iron cage revisited: Institutional isomorphism and collective rationality in organizational fields. *American Sociological Review*, 48(2), 147–160.
- Dutt, R. (2020). The impact of artificial intelligence on healthcare insurances. En A. Bohr & K. Memarzadeh (Eds.), *Artificial intelligence in healthcare* (pp. 271–293). Academic Press. <https://doi.org/10.1016/B978-0-12-818438-7.00011-3>
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2021). Artificial intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- Dwivedi, Y. K., Kshetri, N., Hughes, L., Slade, E. L., Jeyaraj, A., Kar, A. K., ... Wright, R. (2023). “So what if ChatGPT wrote it?” Multidisciplinary perspectives on opportunities, challenges and implications of generative conversational AI for research, practice and policy. *International Journal of Information Management*, 71, 102642. <https://doi.org/10.1016/j.ijinfomgt.2023.102642>
- Eitle, V., & Buxmann, P. (2020). Cultural differences in machine learning adoption: An international comparison between Germany and the United States. *ECIS Proceedings*.
- Eling, M., & Lehmann, M. (2018). The impact of digitalization on the insurance value chain and the insurability of risks. *The Geneva Papers on Risk and Insurance – Issues and Practice*, 43(3), 359–396. <https://doi.org/10.1057/s41288-017-0073-0>
- Eling, M., Nuessle, D., & Staubli, J. (2022). The impact of artificial intelligence along the insurance value chain and on the insurability of risks. *The Geneva Papers on Risk and Insurance – Issues and Practice*, 47(2), 205–241. <https://doi.org/10.1057/s41288-020-00201-7>

- Eloundou, T., Manning, S., Mishkin, P., & Rock, D. (2023). GPTs are GPTs: An early look at the labor market impact potential of large language models. *arXiv*. <https://doi.org/10.48550/arXiv.2303.10130>
- Fereday, J., & Muir-Cochrane, E. (2006). Demonstrating rigor using thematic analysis: A hybrid approach of inductive and deductive coding and theme development. *International Journal of Qualitative Methods*, 5(1), 80–92. <https://doi.org/10.1177/160940690600500107>
- Fink, D. (1998). Guidelines for the successful adoption of information technology in small and medium enterprises. *International Journal of Information Management*, 18(4), 243–253. [https://doi.org/10.1016/S0268-4012\(98\)00013-9](https://doi.org/10.1016/S0268-4012(98)00013-9)
- Fishbein, M., & Ajzen, I. (1975). *Belief, attitude, intention and behavior: An introduction to theory and research*. Addison-Wesley.
- Fonseka, K., Jaharadak, A. A., Raman, M., & Dharmaratne, I. R. (2020). Literature review of technology adoption models at firm level; special reference to e-commerce adoption. *Global Journal of Management and Business Research*, 20(B6), 1–9. <https://doi.org/10.34257/gjmbrbvol20is6pg1>
- Gatignon, H., & Robertson, T. S. (1989). Technology diffusion: An empirical test of competitive effects. *Journal of Marketing*, 53(1), 35–49. <https://doi.org/10.1177/002224298905300103>
- Geertz, C. (1973). *The interpretation of cultures: Selected essays*. Basic Books.
- Gibbons, J. D., & Chakraborti, S. (2011). *Nonparametric statistical inference* (5.^a ed.). CRC Press.
- Goldman Sachs Research. (2023). *Generative AI could raise global GDP by 7%*. <https://www.goldmansachs.com/intelligence/pages/generative-ai-could-raise-global-gdp-by-7-percent.html>
- Goodhue, D. L., & Thompson, R. L. (1995). Task-technology fit and individual performance. *MIS Quarterly*, 19(2), 213–236.
- Grover, V., & Goslar, M. D. (1993). The initiation, adoption, and implementation of telecommunications technologies in U.S. organizations. *Journal of Management Information Systems*, 10(1), 141–164. <https://doi.org/10.1080/07421222.1993.11517994>
- Gupta, S., Ghardallou, W., Pandey, D. K., & Sahu, G. P. (2022). Artificial intelligence adoption in the insurance industry: Evidence using the technology–organization–environment framework. *Research in International Business and Finance*, 63, 101757. <https://doi.org/10.1016/j.ribaf.2022.101757>

- Haenlein, M., & Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (8.^a ed.). Cengage.
- Hameed, M. A., Counsell, S., & Swift, S. (2012). A conceptual model for the process of IT innovation adoption in organizations. *Journal of Engineering and Technology Management*, 29(3), 358–390. <https://doi.org/10.1016/j.jengtecman.2012.03.007>
- Hamm, P., & Klesel, M. (2021). Success factors for the adoption of artificial intelligence in organizations: A literature review. *AIS Electronic Library (AISeL)*.
- Hammer, M., & Champy, J. (1993). *Reengineering the corporation: A manifesto for business revolution*. Harper Business.
- Hudson, L. A., & Ozanne, J. L. (1988). Alternative paradigms for consumer research. *Journal of Consumer Research*, 14(4), 548–557. <https://doi.org/10.1086/209129>
- Iacovou, C. L., Benbasat, I., & Dexter, A. S. (1995). Electronic data interchange and small organizations: Adoption and impact of technology. *MIS Quarterly*, 19(4), 465–485.
- ICEA. (2023). *VIII termómetro de inteligencia artificial y big data en el sector asegurador español*.
- ICEA. (2024). *IX termómetro de inteligencia artificial y data en el sector asegurador español*.
- Jeyaraj, A., Rottman, J. W., & Lacity, M. C. (2006). A review of the predictors, linkages, and biases in IT innovation adoption research. *Journal of Information Technology*, 21(1), 1–23. <https://doi.org/10.1057/palgrave.jit.2000056>
- Kar, A. K. (2016). Bio-inspired computing: A review of algorithms and scope of applications. *Expert Systems with Applications*, 59, 20–32. <https://doi.org/10.1016/j.eswa.2016.04.018>
- Kelley, K. H., Fontanetta, L. M., Heintzman, M., & Pereira, N. (2018). Artificial intelligence: Implications for social inflation and insurance. *Risk Management and Insurance Review*, 21(3), 373–387. <https://doi.org/10.1111/rmir.12111>

- Kinkel, S., Baumgartner, M., & Cherubini, E. (2022). Prerequisites for the adoption of AI technologies in manufacturing: Evidence from a worldwide sample of manufacturing companies. *Technovation*, 110, 102375. <https://doi.org/10.1016/j.technovation.2021.102375>
- Kordon, A. (2020). Applied artificial intelligence-based systems as competitive advantage. *IEEE International Conference on Intelligence and Safety for Robotics (IS)*, 6–18. <https://doi.org/10.1109/IS48319.2020.9200097>
- Kruse, L., Wunderlich, N., & Beck, R. (2019). Artificial intelligence for the financial services industry: What challenges organizations to succeed. *Proceedings of the 52nd Annual Hawaii International Conference on System Sciences*, 6408–6417.
- Kshetri, N., & Dholakia, N. (2002). Determinants of the global diffusion of B2B e-commerce. *Electronic Markets*, 12(2), 120–129. <https://doi.org/10.1080/10196780252844562>
- Kuan, K. K. Y., & Chau, P. Y. K. (2001). A perception-based model for EDI adoption in small businesses using a technology–organization–environment framework. *Information & Management*, 38(8), 507–521. [https://doi.org/10.1016/S0378-7206\(01\)00073-8](https://doi.org/10.1016/S0378-7206(01)00073-8)
- Kvale, S. (1996). *InterViews: An introduction to qualitative research interviewing*. Sage Publications.
- Lee, J. (2004). Discriminant analysis of technology adoption behavior: A case of internet technologies in small businesses. *Journal of Computer Information Systems*, 44(4), 57–66. <https://doi.org/10.1080/08874417.2004.11647596>
- Levenburg, N., Magal, S., & Kosalge, P. (2006). An exploratory investigation of organizational factors and e-business motivations among SMFOEs in the US. *Electronic Markets*, 16(1), 70–84. <https://doi.org/10.1080/10196780500491402>
- Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry*. Sage Publications.
- Lopez-García, J. J., & Manrique-Rojas, C. A. (2024). Adoption of artificial intelligence in the manufacturing and insurance sectors: An analysis from the TOE framework. *Journal of Open Innovation: Technology, Market, and Complexity*, 10(1), 100192.
- Maslej, N., Fattorini, L., Brynjolfsson, E., Etchemendy, J., Ligett, K., Lyons, T., Manyika, J., Ngo, H., Niebles, J. C., Parli, V., Shoham, Y., Wald, R., Clark, J., & Perrault, R. (2023). *The AI Index 2023 annual report*. Stanford University.

- Matsepe, N. T., & van der Lingen, E. (2022). Determinants of emerging technologies adoption in the South African financial sector. *South African Journal of Business Management*, 53(1), a2493.
<https://doi.org/10.4102/sajbm.v53i1.2493>
- MIT NANDA. (2025). *The GenAI divide: State of AI in business 2025*. MIT Project NANDA.
https://mlq.ai/media/quarterly_decks/v0.1_State_of_AI_in_Business_2025_Report.pdf
- MIT Technology Review Insights. (2023). *The great acceleration: CIO perspectives on generative AI*.
- Mullins, M., Holland, C. P., & Cunneen, M. (2021). Creating ethics guidelines for artificial intelligence (AI) and big data analytics customers: The case of the consumer European insurance market. *SSRN Electronic Journal*.
<https://doi.org/10.2139/ssrn.3858056>
- Neumann, O., Guirguis, K., & Steiner, R. (2022). Exploring artificial intelligence adoption in public organizations: A comparative case study. *Public Management Review*, 25(9), 1779–1804.
<https://doi.org/10.1080/14719037.2022.2048685>
- Nortje, M. A., & Grobbelaar, S. S. (2020). A framework for the implementation of artificial intelligence in business enterprises: A readiness model. *IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC)*, 1–10. <https://doi.org/10.1109/ICE/ITMC49519.2020.9198436>
- Oliveira, T., & Martins, M. F. (2011). Literature review of information technology adoption models at firm level. *The Electronic Journal of Information Systems Evaluation*, 14(1), 110–121.
- Opdenakker, R. (2006). Advantages and disadvantages of four interview techniques in qualitative research. *Forum: Qualitative Social Research*, 7(4).
<https://doi.org/10.17169/fqs-7.4.175>
- Owen, R., Sheehan, B., & Mullins, M. (2025). Generative AI in insurance: Use cases, risks, and controls. *The Geneva Papers on Risk and Insurance – Issues and Practice*. [Advance online publication].
- Owens, J., Haughton, O., & Ashton, J. (2022). Trustworthy artificial intelligence in finance: A review of the latest progress. *Journal of Finance and Data Science*, 8, 203–222.

- Parasuraman, A. (2000). Technology readiness index (TRI): A multiple-item scale to measure readiness to embrace new technologies. *Journal of Service Research*, 2(4), 307–320.
- Porter, M. E. (1985). *Competitive advantage: Creating and sustaining superior performance*. Free Press.
- Premkumar, G., & Ramamurthy, K. (1995). The role of interorganizational and organizational factors on the decision mode for adoption of interorganizational systems. *Decision Sciences*, 26(3), 303–336.
<https://doi.org/10.1111/j.1540-5915.1995.tb01431.x>
- Premkumar, G., & Roberts, M. (1999). Adoption of new information technologies in rural small businesses. *Omega*, 27(4), 467–484.
[https://doi.org/10.1016/S0305-0483\(98\)00071-1](https://doi.org/10.1016/S0305-0483(98)00071-1)
- Pumplun, L., Tauchert, C., & Heidt, M. (2019). A new organizational chassis for artificial intelligence: Exploring organizational readiness factors. *Federal Reserve Bank of St. Louis*.
- Radhakrishnan, J., & Chattopadhyay, M. (2020). Determinants and barriers of artificial intelligence adoption: A literature review. En *IFIP advances in information and communication technology* (pp. 89–99). Springer.
https://doi.org/10.1007/978-3-030-64849-7_9
- Rahlf, C. (2007). *Wertschöpfung und Wertschöpfungsarchitekturen in der Assekuranz*. Gabler.
- Ram, S., & Sheth, J. N. (1989). Consumer resistance to innovations: The marketing problem and its solutions. *Journal of Consumer Marketing*, 6(2), 5–14.
- Rangwala, A., Starrs, A., Viale, E., Presutti, D., Bramblet, J., Saldanha, K., & Shibata, N. (2020). *Technology vision for insurance 2020: We, the post-digital people. Can your enterprise survive the “techclash”?* Accenture.
- Rao, A. S., & Verweij, G. (2017). *Sizing the prize: What’s the real value of AI for your business and how can you capitalise*. PwC.
- Raymond, L. (2001). Determinants of website implementation in small businesses. *Internet Research*, 11(5), 411–424.
<https://doi.org/10.1108/10662240110410363>
- Reillon, V. (2018). *Understanding artificial intelligence*. European Parliament.
- Rogers, E. M. (1995). *Diffusion of innovations* (4.^a ed.). Free Press.
- Rogers, E. M. (2003). *Diffusion of innovations* (5.^a ed.). Free Press.

- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4.^a ed.). Pearson.
- Rzepka, C., & Berger, B. (2018). User interaction with AI-enabled systems: A systematic review of IS research. *ICIS Proceedings*.
- Salahshour Rad, M., Nilashi, M., & Mohamed Dahlan, H. (2018). Information technology adoption: A review of the literature and classification. *Universal Access in the Information Society*, 17(2), 361–390.
<https://doi.org/10.1007/s10209-017-0534-z>
- Schaefer, C., Lemmer, K., Samy, K., Ylinen, M., Mikalef, P., & Niehaves, B. (2021). Truth or dare? How can we influence the adoption of artificial intelligence in municipalities? *Proceedings of the Annual Hawaii International Conference on System Sciences*. <https://doi.org/10.24251/HICSS.2021.286>
- Teece, D. J. (2007). Explicating dynamic capabilities: The nature and microfoundations of (sustainable) enterprise performance. *Strategic Management Journal*, 28(13), 1319–1350.
- Thong, J. Y. L. (1999). An integrated model of information systems adoption in small businesses. *Journal of Management Information Systems*, 15(4), 187–214.
<https://doi.org/10.1080/07421222.1999.11518227>
- Tornatzky, L. G., & Fleischer, M. (1990). *The processes of technological innovation*. Lexington Books.
- Vagnani, G., Gatti, C., & Proietti, L. (2019). A conceptual framework of the adoption of innovations in organizations: A meta-analytical review of the literature. *Journal of Management and Governance*, 23(4), 1023–1062.
<https://doi.org/10.1007/s10997-019-09452-6>
- Valles, M. S. (2002). Entrevistas cualitativas. En M. García Ferrando, F. Alvira, L. E. Alonso, & M. S. Valles (Eds.), *El análisis de la realidad social: Métodos y técnicas de investigación* (pp. 251–282). Alianza Editorial.
- van Bekkum, S. (2025). AI in insurance: Fairness, discrimination, and the role of regulation. *Journal of Business Ethics*. [In press].
- van den Berg, J., & van der Lingen, E. (2019). An empirical study of the factors affecting the adoption of mobile enterprise applications. *South African Journal of Industrial Engineering*, 30(1), 124–146. <https://doi.org/10.7166/30-1-1992>
- Venkatesh, V., & Bala, H. (2008). Technology acceptance model 3 and a research agenda on interventions. *Decision Sciences*, 39(2), 273–315.

- Venkatesh, V., & Davis, F. D. (2000). A theoretical extension of the technology acceptance model: Four longitudinal field studies. *Management Science*, 46(2), 186–204.
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425–478.
- Venkatesh, V., Thong, J. Y. L., & Xu, X. (2012). Consumer acceptance and use of information technology: Extending the unified theory of acceptance and use of technology. *MIS Quarterly*, 36(1), 157–178.
- Wengraf, T. (2001). *Qualitative research interviewing: Biographic narrative and semi-structured methods*. Sage Publications.
- Wirtz, B. W., Weyerer, J. C., & Geyer, C. (2019). Artificial intelligence and the public sector: Applications and challenges. *International Journal of Public Administration*, 42(7), 596–615.
<https://doi.org/10.1080/01900692.2018.1498103>
- World Intellectual Property Organization. (2019). *World intellectual property report 2019: The geography of innovation—Local hotspots, global networks*. WIPO.
- Xu, X., & Zweifel, P. (2020). A framework for the evaluation of insurtech. *Risk Management and Insurance Review*, 23(4), 305–329.
<https://doi.org/10.1111/rmir.12161>
- Xu, Y., Ramayah, T., & Shi, G. (2025). Top management support as a mediator of organizational readiness, competitive pressure and generative AI adoption in the insurance industry. *Technological Forecasting and Social Change*. [Advance online publication].
- Yang, Y., Glikson, E., & Woolley, A. W. (2025). Human involvement as a signal of trustworthiness in AI-mediated services. *Journal of Marketing*. [Advance online publication].
- Zhu, K., Kraemer, K. L., & Xu, S. (2006). The process of innovation assimilation by firms in different countries: A technology diffusion perspective on e-business. *Management Science*, 52(10), 1557–1576.
<https://doi.org/10.1287/mnsc.1050.0487>

Anexos

Anexo 1: Manual de códigos

El presente anexo incorpora el **manual de códigos empleado en el análisis cualitativo de las entrevistas** realizadas a directivos del sector asegurador español sobre la adopción de IA. Su construcción responde a una estrategia metodológica de carácter **híbrido inductivo-deductivo**, que se alinea con la propuesta de Fereday y Muir-Cochrane (2006) para garantizar rigor y transparencia en la investigación cualitativa.

Este procedimiento metodológico asegura la **coherencia entre teoría y evidencia empírica**, al tiempo que preserva la apertura analítica característica de la investigación cualitativa interpretativa. En línea con Fereday y Muir-Cochrane (2006), el uso combinado de categorías teóricas predefinidas y categorías emergentes refuerza la **credibilidad, trazabilidad y validez interpretativa** del proceso, constituyendo una garantía de rigor en el análisis cualitativo desarrollado.

A continuación, se describen todos los códigos, incluyendo citas significativas en cada uno.

1. Estrategia y Visión

Descripción general: Engloba cómo las aseguradoras integran la IA en su visión corporativa, planes estratégicos y dirección general.

1.1 Plan estratégico

- **Descripción:** Inclusión explícita de la IA como línea de acción en el plan estratégico de la compañía.
- **Preguntas Clave:**
 - ¿Cuál es su visión a largo plazo para la integración de IA en su empresa?
 - ¿Puede compartir algún ejemplo de un proyecto de IA exitoso en su empresa y los factores que contribuyeron a su éxito?
- **Citas Representativas:**
 - “Nosotros en el plan estratégico [...] hemos hecho el análisis, ¿vale?” (E02)
 - “La inteligencia artificial o la analítica avanzada [...] nace [...] directamente un plan estratégico”. (E11)

1.2 Alineación con visión del CEO / Consejo

- **Descripción:** Impulso de la IA desde la alta dirección, vinculada a la visión del CEO o Consejo.
- **Preguntas Clave:**
 - ¿Qué rol juega la alta dirección en la adopción de IA en su empresa?
 - ¿Qué estrategias ha implementado para fomentar la adopción de IA?
- **Citas Representativas:**
 - *“El impulso viene de la altísima dirección, o sea, del Consejo, que es el que al final aprueba el plan”. (E11)*
 - *“Si un líder no cree en algo a los que están por debajo se van a tener que esforzar mucho para demostrar y para y para convencer.” (E02)*

1.3 Inteligencia artificial como eje transformador

- **Descripción:** Percepción de la IA como elemento central de transformación organizativa.
- **Preguntas Clave:**
 - ¿Cuál es su visión a largo plazo para la integración de IA en su empresa?
- **Citas Representativas:**
 - *“Esto cambia la compañía completa...”. (E05)*
 - *“La IA es toda la compañía la que tiene que cambiar. [...] cambia el talento, cambia el mindset de la gente, [...] es que lo cambia todo.” (E05)*

1.4 Priorización estratégica de la IA

- **Descripción:** Priorización específica de la IA como foco de inversión y desarrollo dentro de la estrategia.
- **Preguntas Clave:**
 - ¿Qué estrategias ha implementado la alta dirección para fomentar la adopción de IA?
 - ¿Qué recursos son esenciales para la implementación de proyectos de IA?
- **Citas Representativas:**
 - *“Hemos tenido que añadir inversiones adicionales...”. (E12)*
 - *“Esto es un top down que emana del propio CEO del grupo. [...] Si esto no emana del CEO, esto no va a suceder”. (E12)*

1.5 Cultura de innovación

- **Descripción:** Referencias explícitas a una cultura empresarial que fomenta la innovación, la experimentación, el aprendizaje y la asunción de riesgos.
 - **Preguntas Clave:**
 - ¿Cómo describiría la cultura organizacional de su empresa en términos de innovación?
 - ¿Qué medidas ha tomado para asegurar que la cultura de la empresa sea compatible con la implementación de IA?
 - **Citas Representativas:**
 - *“También te puedo contar muchas que han salido mal, muchas, porque la cosa de acertar está en equivocarse menos.” (E07)*
 - *“Nosotros tenemos proyectos de innovación, de innovación abierta, ¿vale?” (E02)*
-

2. Organización y Gobierno

Descripción general: Aborda la forma en que se estructura la adopción de IA internamente: liderazgo, modelos operativos, colaboración interna y barreras estructurales.

2.1 Modelo operativo (por producto, transversal, etc.)

- **Descripción:** Estructura organizativa adoptada para gestionar iniciativas de IA, combinando enfoques por producto con estructuras transversales y ágiles.
- **Preguntas Clave:**
 - ¿Cómo influye el tamaño y la estructura de su organización en la adopción de IA?
 - ¿Ha considerado la creación de laboratorios de innovación o *hubs* internos? ¿Cómo han funcionado?
- **Citas Representativas:**
 - *“trabajar por proyecto... cuesta un dineral [...] Entonces trabajas por producto”. (E12)*
 - *“si yo voy a implementar inteligencia artificial, no tiene mucho sentido que nos reunamos los típicos grupos en cascada... lo lógico es que [...] trabajen en Agile”. (E05)*

2.2 Comité de dirección / estructura de liderazgo

- **Descripción:** Papel del comité ejecutivo y la alta dirección en la conducción de la estrategia de IA, identificando modelos top-down, mixtos y reactivos.
- **Preguntas Clave:**
 - ¿Qué rol juega la alta dirección en la adopción de IA en su empresa?
- **Citas Representativas:**
 - *“Esto tiene que emanar del CEO...”. (E12)*
 - *“Hay un órgano máximo que lo llamamos Comité de Transformación e Innovación, que lo presido yo y ese es un comité delegado del Comité Ejecutivo”. (E05)*

2.3 Centro de competencia / estructura de IA

- **Descripción:** Existencia de unidades, equipos dedicados o Centros de Excelencia (CoE) para gobernar y desplegar la IA de forma transversal.
- **Preguntas Clave:**
 - ¿Ha considerado la creación de laboratorios de innovación o *hubs* internos? ¿Cómo han funcionado?
- **Citas Representativas:**
 - *“Hemos creado lo que se llama el Centro de competencia Inteligencia Artificial...”. (E11)*
 - *“Sí que tenemos un área en concreto de analítica de datos, la llamamos analítica de datos, donde ya tenemos a 20 personas.” (E02)*

2.4 Coordinación con grupo o filiales

- **Descripción:** Colaboración interorganizativa con la matriz o empresas del grupo, que condiciona el ritmo, los recursos y la gobernanza de la IA.
- **Preguntas Clave:**
 - ¿Cómo se coordinan las iniciativas de IA con la casa matriz u otras filiales del grupo? ¿Existen sinergias o transferencia de conocimiento?
- **Citas Representativas:**
 - *“Nuestra matriz, que tiene muchísimos más recursos de los que podamos tener nosotros, ellos están desarrollando un caso de uso que en el momento en el que lo escale vamos a poder escalarlo el resto de entidades”. (E12)*

- *“La posibilidad de entrar en acuerdos o con Google [...] el grupo sí tiene peso”. (E03)*

2.5 Complejidad y tamaño de la organización

- **Descripción:** Influencia del tamaño, la escala y las barreras internas (silos, jerarquía) en la capacidad para adoptar IA, afectando la inversión, agilidad y volumen de datos.
- **Preguntas Clave:**
 - ¿Cómo influye el tamaño de su organización en la adopción de IA?
- **Citas Representativas:**
 - *“Es evidente que una compañía diez veces mayor tiene mucha más capacidad de invertir en tecnología...”. (E02)*
 - *“Yo creo que en este caso el tamaño es una ventaja para las pequeñas.” (E09)*

2.6 Reingeniería de procesos

- **Descripción:** Necesidad de rediseñar procesos internos y flujos de trabajo para que la IA transforme la operativa tradicional y no solo automatice ineficiencias.
- **Preguntas Clave:**
 - ¿Cómo ha adaptado su empresa los procesos de trabajo para cumplir con los requisitos tecnológicos de la IA?
- **Citas Representativas:**
 - *“lo lógico es que la inteligencia artificial... en el fondo lo que te permite es replantear el proceso de otra manera.” (E05)*
 - *“No puedes enchufar IA encima del proceso antiguo, hay que repensarlo entero.” (E16)*

3. Datos e Infraestructura

Descripción general: Aspectos técnicos, estructurales y organizativos vinculados a los datos y sistemas tecnológicos para implementar IA.

3.1 Gobernanza y calidad del dato

- **Descripción:** Políticas, roles, estructuras (diccionarios de datos) y grado de fiabilidad y consistencia de los datos como prerrequisito para proyectos de IA.

- **Preguntas Clave:**

- ¿Qué tan crucial es la disponibilidad y calidad de los datos para el éxito de los proyectos de IA?

- **Citas Representativas:**

- *“La fiabilidad de las de los datos. O sea, yo creo que es clave para generar cualquier output que sea fiable”. (E02)*
- *“La calidad del dato está en el variable de la alta dirección.” (E05)*

3.2 Arquitectura tecnológica y sistemas *legacy*

- **Descripción:** Diseño de sistemas tecnológicos y la dependencia de sistemas antiguos (*legacy*) que dificultan la implementación ágil de IA y exigen una evolución hacia modelos *API-first*.

- **Preguntas Clave:**

- ¿Cómo evalúa la compatibilidad de las tecnologías de IA con la infraestructura IT existente?
- ¿Qué estrategias ha implementado para asegurar que las infraestructuras de TI sean adecuadas para soportar la IA?

- **Citas Representativas:**

- *“Nuestra arquitectura tiene mucho legacy...”. (E01)*
- *“Estamos diseñando este core precisamente para que podamos ir adaptando módulos externos y que sean mucho más fáciles las adaptaciones.” (E14)*

3.3 Fundaciones en datos (*Data Lake*, integración)

- **Descripción:** Infraestructuras centralizadas como *Data Lakes* para almacenamiento, análisis y acceso unificado a datos estructurados y no estructurados.

- **Preguntas Clave:**

- ¿Qué estrategias ha implementado para asegurar que las infraestructuras de TI sean adecuadas para soportar la IA?

- **Citas Representativas:**

- *“Tenemos un Data Lake que sirve de base para todo.” (E05)*
- *“como no tengan un modelo de datos que les permita realmente gestionar luego lo que les va a venir [...] se van a perder en el camino”. (E12)*

3.4 Complejidad y dependencia tecnológica

- **Descripción:** Dificultades derivadas de la sofisticación técnica de la IA y la limitación por un proveedor o arquitectura existente (lock-in).
- **Preguntas Clave:**
 - ¿Qué tan complejas han sido las implementaciones de IA y cómo han manejado esa complejidad?
- **Citas Representativas:**
 - *“Es complicado hablar de inteligencia artificial generativa cuando aún tú no tienes [...] la tecnología o los datos suficientemente preparados para ello.” (E03)*
 - *“Estamos atados a este proveedor y cambiar es muy costoso.” (E03)*

3.5 Sistemas *legacy*

- **Descripción:** Persistencia de sistemas core heredados y arquitecturas fragmentadas como principal obstáculo para la adopción transversal de la IA.
- **Preguntas Clave:**
 - ¿Cómo impactan los sistemas heredados en su capacidad para implementar nuevas tecnologías de IA?
- **Citas Representativas:**
 - *“Al final tienes una mezcla de aplicaciones tan elevada, y los datos los tienes propietarios de esas diferentes aplicaciones.” (E01)*
 - *“Tengo dos. El core antiguo, que está en proceso de extinción [...] Y el nuevo, que ya es viejo.” (E14)*

3.6 Plataformas tecnológicas (*CoPilot*, etc.)

- **Descripción:** Consumo de funcionalidades de IA embebidas en plataformas de terceros (CRMs, ofimática) como estrategia para obtener valor rápido sin grandes desarrollos internos.
- **Preguntas Clave:**
 - ¿Qué rol juegan las plataformas de *software* como servicio (SaaS) en su estrategia de IA?
- **Citas Representativas:**
 - *“CoPilot va a venir y nos va a solucionar la vida [...]. Y eso sí que ha sido una verdadera decepción.” (E10)*

- *“Hemos comprado un [...] ChatGPT cerrado en local y le hemos subido nuestros condicionados.” (E09)*

3.7 Complejidad tecnológica

- **Descripción:** Dificultades derivadas de la sofisticación técnica de la IA, su integración y la necesidad de adaptar la infraestructura de datos para explotarla.
- **Preguntas Clave:**
 - ¿Qué tan complejas han sido las implementaciones de IA y cómo han manejado esa complejidad?
- **Citas Representativas:**
 - *“Es complicado hablar de inteligencia artificial generativa cuando aún tú no tienes [...] la tecnología o los datos suficientemente preparados para ello.” (E03)*
 - *“Es una empresa con mucho legacy, muchísimos datos en silos y cuesta mucho poner orden a los datos”. (E11)*

3.8 Dependencia tecnológica - lock-in

- **Descripción:** Riesgo de quedar atado a un proveedor tecnológico, enfrentando escaladas de costes de licencia y pérdida de autonomía estratégica.
- **Preguntas Clave:**
 - ¿Cómo gestionan el riesgo de dependencia de un único proveedor tecnológico?
- **Citas Representativas:**
 - *“Cuando veo lo que me cuesta todos los años, las [...] licencias, digo, esto es una renta vitalicia porque ya no te puedes salir.” (E14)*
 - *“No estábamos dispuestos [...] a estar sujetos a que año tras año nos fueran aplicando incrementos.” (E02)*

4. Talento y Cultura

Descripción general: Gestión del talento, perfiles técnicos, formación y elementos culturales que influyen en la adopción de IA.

4.1 Atracción y retención de talento

- **Descripción:** Dificultades para captar y mantener profesionales con competencias en IA en un mercado competitivo.
- **Preguntas Clave:**
 - ¿Cuáles son los principales desafíos para atraer y retener talento especializado en IA?
- **Citas Representativas:**
 - *“Hay mucha pelea por el talento y no es fácil retenerlos.” (E11)*
 - *“El sector asegurador en general tampoco se ha vendido nunca demasiado bien.” (E02)*

4.2 Brecha de capacidades

- **Descripción:** Carencias estructurales de competencias en la plantilla, como la falta de perfiles híbridos (negocio y tecnología) y la indefinición de nuevos roles.
- **Preguntas Clave:**
 - ¿Cuáles son las competencias técnicas necesarias para la implementación efectiva de IA?
- **Citas Representativas:**
 - *“Hay un gap entre lo que la empresa pide y lo que produce la universidad con la formación.” (E15)*
 - *“Si no entrenas estos algoritmos en función de tu entidad, solo tienes un ‘bicho’ genérico.” (E04)*

4.3 Perfiles escasos y rotación

- **Descripción:** Escasez estructural de perfiles especializados y la alta tasa de rotación en roles digitales.
- **Preguntas Clave:**
 - ¿Cuáles son los principales desafíos para encontrar perfiles de IA?
- **Citas Representativas:**
 - *“El problema es que quienes realmente conocen esta tecnología están en San Francisco, donde están muy bien remunerados. Aquí, en cambio, falta conocimiento.” (E04)*
 - *“Nuestras tasas de abandono, puede ser el doble o triple de las que tenemos, que son muy muy bajas, pero a nosotros nos preocupa.” (E05)*

4.4 Formación interna y upskilling

- **Descripción:** Esfuerzo sistemático de capacitación que abarca a toda la organización (consejo, TI, negocio) a través de programas estructurados, talleres y aprendizaje experiencial.
- **Preguntas Clave:**
 - ¿Qué programas de capacitación ha implementado para preparar a su equipo para la IA?
- **Citas Representativas:**
 - *“Nosotros creamos hace dos años o cosa así un máster [...] tanto gente interna como externa, dándolo.” (E10)*
 - *“La inteligencia artificial lo que permite es [...] dotar a los humanos de superpoderes.” (E09)*

4.5 Cultura organizativa y resistencia

- **Descripción:** Rasgos culturales del sector (pragmatismo, aversión al riesgo) y fuentes de resistencia al cambio (miedo a la sustitución, escepticismo, fatiga de iniciativas).
- **Preguntas Clave:**
 - ¿Qué medidas ha tomado para asegurar que la cultura de la empresa sea compatible con la implementación de IA?
- **Citas Representativas:**
 - *“El freno es más freno cultural y freno regulatorio. Sobre todo, miedo a incumplir determinadas regulaciones.” (E11)*
 - *“una de las barreras [...] es el temor de la gente a perder sus trabajos.” (E10)*

4.6 Clima y sentido de pertenencia

- **Descripción:** Factores intangibles como la cohesión interna, el orgullo de contribución, la confianza interpersonal y la gestión de la diversidad cultural y generacional.
- **Preguntas Clave:**
 - ¿Cómo describiría el clima de su organización para afrontar el cambio tecnológico?
- **Citas Representativas:**
 - *“Lo que sí que nos encanta es explicarles bien a todas las áreas operativas cómo están contribuyendo al valor del negocio.” (E02)*

- *“Nunca hemos echado a nadie porque hayamos metido una cosa que antes era parte de lo que hacían las personas y ahora lo hacen las máquinas.” (E13)*

4.7 Cultura de innovación (vívda)

- **Descripción:** Prácticas y valores que fomentan la innovación, como la tradición analítica, la curiosidad, la tolerancia al error y el liderazgo basado en la confianza y la apertura externa.
- **Preguntas Clave:**
 - ¿Cómo describiría la cultura organizacional de su empresa en términos de innovación?
- **Citas Representativas:**
 - *“La ventaja que tiene el sector asegurador [...] es que tenemos en nuestro ADN lo que es el tratamiento [...] de datos.” (E02)*
 - *“También te puedo contar muchas que han salido mal, muchas, porque la cosa de acertar está en equivocarse menos.” (E07)*

5. Implementación de IA

Descripción general: Trata sobre cómo se operacionalizan los proyectos de IA, desde pilotos hasta producción, incluyendo aspectos metodológicos y relaciones externas.

5.1 Enfoque incremental / piloto / escalado

- **Descripción:** Estrategia de implementación progresiva, desde pruebas de concepto (PoC) para aprender, pasando por pilotos para validar, hasta el despliegue a gran escala.
- **Preguntas Clave:**
 - ¿Qué importancia le da su empresa a la capacidad de probar nuevas tecnologías de IA antes de una adopción completa? (Trialability)
 - ¿Utiliza metodologías ágiles para la gestión de proyectos de IA?
- **Citas Representativas:**
 - *“Empezamos a meter inteligencia artificial muy poco a poco, de tal manera que en cuanto veíamos que [...] había una mínima fricción, lo pasábamos con la persona”. (E13)*

- *“Tú no lo escalas hasta que no ves cuáles son los beneficios que tienes en el piloto.” (E12)*

5.2 Relación con proveedores y consultoras

- **Descripción:** Colaboraciones con expertos externos (consultoras, *Big Tech*, startups) para el desarrollo e implantación de soluciones de IA, gestionando la tensión entre la necesidad de sus capacidades y el riesgo de dependencia.
- **Preguntas Clave:**
 - ¿Qué papel juegan los colaboradores externos y los proveedores en la adopción de IA en su empresa?
- **Citas Representativas:**
 - *“Nosotros entramos en una prueba de concepto de la mano de una empresa de... de Barcelona que toca bastante el tema este”. (E09)*
 - *“Nuestro acercamiento ahí es que esto es tan crítico que preferimos internalizar el conocimiento.” (E11)*

5.3 Gobernanza de los modelos (control, escalado, caja negra)

- **Descripción:** Procesos y estructuras (comités, auditorías) para asegurar la calidad, control, transparencia, cumplimiento y escalabilidad de los modelos de IA.
- **Preguntas Clave:**
 - ¿Qué preocupaciones de seguridad ha tenido su empresa en relación con la adopción de IA?
- **Citas Representativas:**
 - *“Estamos definiendo cómo aseguramos que el modelo no se nos va...”. (E12)*
 - *“Lo primero hay que montar una serie de comités de gobernanza [...] para poder clasificar estos potenciales algoritmos.” (E01)*

5.4 Evaluación de costes y retorno (ROI)

- **Descripción:** Valoración económica de los proyectos para decidir su continuidad, siendo un requisito indispensable para el escalado.
- **Preguntas Clave:**
 - ¿Cuáles han sido los principales desafíos financieros que ha enfrentado al implementar IA y cómo los ha superado?

- ¿Cómo percibe su empresa la ventaja relativa de la IA en comparación con las tecnologías existentes?
- **Citas Representativas:**
 - “¿Cuál es el coste-beneficio? Eso nos permite decidir.” (E10)
 - “En el ámbito del fraude vimos algunas soluciones [...]. Hicimos el caso de negocio y la rentabilidad [...] no nos salía.” (E02)

5.5 Métodos de priorización y evaluación de casos

- **Descripción:** Mecanismos explícitos para filtrar y seleccionar casos de uso, combinando criterios de impacto, viabilidad y alineamiento estratégico.
- **Preguntas Clave:**
 - ¿Cómo priorizan los casos de uso de IA en su organización?
- **Citas Representativas:**
 - “hemos puesto es una metodología que en función de determinados parámetros te dice oye, deberías de priorizar este caso de uso.” (E05)
 - “En el comité, cada uno evalúa y luego quizá se descarta. Por ejemplo, el Blockchain lo analizamos y lo descartamos.” (E06)

6. Riesgos

Descripción general: Percepciones sobre los riesgos inherentes a la adopción de IA, tanto técnicos como éticos o reputacionales.

6.1 Caja negra, explicabilidad y pérdida de control

- **Descripción:** Dificultad para interpretar cómo toman decisiones los modelos (opacidad) y la sensación de delegar decisiones clave a sistemas no comprendidos, perdiendo soberanía sobre los datos y procesos.
- **Preguntas Clave:**
 - ¿Qué preocupaciones morales y éticas tiene su empresa respecto a la adopción de IA?
- **Citas Representativas:**
 - “Ser capaces de explicar por qué la caja negra ha generado esa decisión...” (E02)
 - “Hay una transferencia de conocimiento, no a la máquina, sino a los dueños de la máquina.” (E07)

6.2 Alucinaciones y riesgos éticos (discriminación)

- **Descripción:** Generación de información incorrecta por modelos generativos (alucinaciones) y posibles sesgos o impactos discriminatorios que erosionan el principio mutualista.
- **Preguntas Clave:**
 - ¿Qué preocupaciones morales y éticas tiene su empresa respecto a la adopción de IA?
- **Citas Representativas:**
 - “Hay alucinaciones. Por eso no lo usamos con cliente aún.” (E12)
 - “Si le metemos una capa de inteligencia artificial [...] al final estamos desnaturalizando el seguro”. (E02)

6.3 Riesgos éticos y reputación

- **Descripción:** Posible impacto negativo de la IA sobre la imagen pública o la relación con los clientes, así como los dilemas éticos asociados (sesgo, desmutualización).
- **Preguntas Clave:**
 - ¿Qué riesgos reputacionales y éticos identifican al implementar soluciones de IA y cómo planean mitigarlos?
- **Citas Representativas:**
 - “Si al final haces pólizas para cada tío en función de lo que tal... estamos jodiendo el seguro porque estamos rompiendo el carácter mutualista.” (E14)
 - “Francamente mal, muy mal. O sea, como que se queda entre enredado y encima es difícil, horrible. Yo no salgo del bucle.” (E13)

6.4 Pérdida de control sobre procesos

- **Descripción:** Temor a perder el control del negocio por la dependencia de proveedores, la cesión de datos o la deriva autónoma de los modelos de IA.
- **Preguntas Clave:**
 - ¿Cómo gestionan el riesgo de una excesiva automatización o dependencia de la IA?
- **Citas Representativas:**

- *“Cuando lo escalemos, tendremos que establecer nuestros controles para realmente seguir asegurando que, como el modelo aprende de sí mismo, no se nos va.” (E12)*
- *“La última decisión siempre será de una persona humana.” (E02)*

6.5 Reputación y confianza

- **Descripción:** Posible impacto negativo de la IA sobre la imagen pública o la relación con los clientes, derivado de fallos tecnológicos, mal uso de datos o experiencias de usuario deficientes.
- **Preguntas Clave:**
 - ¿Qué riesgos reputacionales identifican al implementar soluciones de IA de cara al cliente y cómo planean mitigarlos?
- **Citas Representativas:**
 - *“Con todos los peligros que conlleva algo que escapa nuestro control [...] hay una transferencia de conocimiento [...] a los dueños de la máquina.” (E07)*
 - *“Francamente mal, muy mal. O sea, como que se queda entre enredado y encima es difícil, horrible. Yo no salgo del bucle.” (E13)*

7. Regulación

Descripción general: Cumplimiento normativo, supervisión institucional y marcos legales aplicables a la IA.

7.1 Marco regulatorio (AI Act) y presión institucional

- **Descripción:** Impacto del Reglamento Europeo de IA y la influencia de decisiones políticas, percibido como un entorno de hiperregulación que frena la innovación.
- **Preguntas Clave:**
 - ¿Qué impacto tienen las regulaciones gubernamentales en la adopción de IA en su empresa?
 - ¿Qué papel juegan las decisiones políticas en la adopción de IA en su sector?
- **Citas Representativas:**
 - *“Todo el tema de la Artificial Intelligence Act que nos ha catalogado como actividades de alto riesgo [...] no tenemos mucha claridad”. (E03)*

- *“En Europa no se da el contexto adecuado para el desarrollo de este tipo de tecnologías por la vorágine regulatoria que hay.” (E02)*

7.2 Supervisión, transparencia y protección de datos

- **Descripción:** Exigencia de informar sobre el uso de IA, garantizar la trazabilidad de las decisiones y la participación de las áreas de privacidad y protección de datos.
- **Preguntas Clave:**
 - ¿Cómo equilibra su empresa la necesidad de cumplir con regulaciones mientras impulsa la adopción de IA?
- **Citas Representativas:**
 - *“Debes informar si estás hablando con una máquina.” (E11)*
 - *“Tenemos revisiones permanentes con protección de datos.” (E11)*

7.3 Obligaciones específicas por nivel de riesgo

- **Descripción:** Requerimientos normativos asociados a la clasificación de los casos de uso de IA según su nivel de riesgo, como exige el AI Act.
- **Preguntas Clave:**
 - ¿Cómo clasifican los proyectos de IA según su nivel de riesgo regulatorio?
- **Citas Representativas:**
 - *“En función de la regulación existente, cómo se clasifican, si es rojo, amarillo o verde, y entonces decir oye, esto tiene que pasar por una cierta supervisión.” (E01)*
 - *“en el reglamento hay una serie de temas que están claramente prohibidos y cuando nos hemos leído hemos dicho lógico que estén prohibidos.” (E11)*

7.4 Rol de protección de datos

- **Descripción:** Influencia de la normativa de protección de datos (RGPD) como factor restrictivo en el uso de información personal para modelos de IA.
- **Preguntas Clave:**
 - ¿Cómo afecta la normativa de protección de datos a sus proyectos de IA?
- **Citas Representativas:**

- *“Pero claro, por otro lado, te van viniendo normativas [...] no puedes perfilar, no puedes, no puedes hacer mil cosas.” (E02)*
- *“Hemos ido muy tarde en la adopción de CoPilot [...] porque ha generado un miedo interno. La primera reacción fue vamos a cerrar todo esto para que no se filtren los datos.” (E11)*

8. Coste-beneficio y ROI

Descripción general: Evaluación económica y justificación financiera de los proyectos de IA como factor organizativo determinante.

8.1 Análisis de coste-beneficio

- **Descripción:** Proceso de evaluación riguroso donde se ponderan los beneficios esperados (reducción de costes, aumento de ingresos) frente a la inversión requerida.
- **Preguntas Clave:**
 - ¿Cómo se evalúa la viabilidad económica de un proyecto de IA antes de su aprobación?
- **Citas Representativas:**
 - *“Todas las iniciativas que tenemos tienen su propio plan de negocio detrás. [...] si con dudas vemos que no sale, pues no.” (E11)*
 - *“Nos dijeron: ‘oye, con esta solución [...] podéis tener una mejora de 300.000 € en fraude detectado, pero es que la solución cuesta 200.000’.” (E08)*

8.2 Indicadores (KPIs, TIR, retorno)

- **Descripción:** Uso de métricas financieras clásicas (ahorro en FTE, pay-back, TIR) y operativas (reducción de tiempos, productividad) para medir el retorno de la IA.
- **Preguntas Clave:**
 - ¿Qué indicadores clave de rendimiento (KPI) utilizan para medir el éxito de los proyectos de IA?
- **Citas Representativas:**
 - *“hemos montado un BI de inteligencia artificial. Entonces distinguimos cada mes los retornos, las inversiones...” (E05)*
 - *“utilizamos métricas tradicionales. Las mismas, el mismo KPI que podrías estar utilizando con cualquier otro tipo de aplicación.” (E01)*

8.3 Selección y priorización de casos de uso

- **Descripción:** Proceso de selección de iniciativas de IA basado en el impacto económico, las capacidades internas y el modelo de negocio.
- **Preguntas Clave:**
 - ¿Qué criterios utilizan para seleccionar y priorizar los casos de uso de IA?
- **Citas Representativas:**
 - *“hemos puesto es una metodología que en función de determinados parámetros te dice oye, deberías de priorizar este caso de uso.” (E05)*
 - *“El objetivo es aprender. Si el objetivo es aprender, no el retorno económico.” (E09)*

8.4 Rentabilidad tangible e intangible

- **Descripción:** Reconocimiento de que el valor de la IA trasciende lo financiero, generando activos intangibles como la mejora del capital humano, la innovación y la reputación.
- **Preguntas Clave:**
 - Además del ROI, ¿qué otros beneficios no financieros han observado con la implementación de la IA?
- **Citas Representativas:**
 - *“Sabemos que independientemente de que te dé o no te dé un retorno [...] hay un intangible que es [...] formar a la organización.” (E03)*
 - *“vamos a ganar un 30% de eficiencia, vamos a poder dedicar más tiempo a lo que aporte valor hacia el cliente”. (E09)*

8.5 Ventaja relativa

- **Descripción:** Percepción dual sobre el valor de la IA: la predictiva como mejora incremental y la generativa como un salto cualitativo con potencial disruptivo.
- **Preguntas Clave:**
 - ¿Cómo percibe su empresa la ventaja relativa de la IA en comparación con las tecnologías existentes?
- **Citas Representativas:**

- *“Al final todos estos van a ser una commodity, como tenemos hoy bases de datos y lo que importará es lo que has construido sobre esa commodity.” (E09)*
- *“Sí que hay eficiencias importantes en el caso de uso que tenemos. Tenemos un ahorro de un 50% del tiempo.” (E12)*

9. Madurez y Expectativas

Descripción general: Nivel de desarrollo real de la IA en las aseguradoras y la percepción frente al discurso mediático.

9.1 “Hype”, expectativas y madurez tecnológica

- **Descripción:** Exceso de expectativas (“hype”), necesidad de una visión realista y percepción de que la tecnología (especialmente la generativa) aún no está lista para producción.
- **Preguntas Clave:**
 - Frente a las altas expectativas del mercado sobre la IA, ¿cuál es su percepción sobre la madurez real de estas tecnologías y cómo gestionan internamente esas expectativas?
- **Citas Representativas:**
 - *“Tengo sensación de burbuja tecnológica, es decir, de que está de moda.” (E01)*
 - *“El bombo que se le ha dado a la inteligencia artificial generativa parecía que ya estaba disponible para hacer todo [...] Y el problema es que no es así.” (E10)*

9.2 Evolución progresiva vs. disrupción inmediata

- **Descripción:** Debate entre concebir la IA como un cambio paulatino (evolución) en continuidad con innovaciones previas, y la visión de una transformación radical e inminente (disrupción).
- **Preguntas Clave:**
 - ¿Considera que la adopción de la IA será una transformación disruptiva e inmediata o una evolución más progresiva y a largo plazo? ¿Por qué?
- **Citas Representativas:**
 - *“Va a ser algo gradual, más lento y menos fulgurante de lo que parece. Yo pondría el horizonte del 2030, no el horizonte del 2025”. (E15)*

- *“No será de un día para otro. Pero cambiará el sector.” (E11)*

9.3 Comparación con otras modas tecnológicas

- **Descripción:** Uso de analogías con ciclos tecnológicos previos (metaverso, Blockchain) para contextualizar y relativizar las expectativas sobre la IA.
- **Preguntas Clave:**
 - ¿Cómo compara el fenómeno de la IA con otras "modas" tecnológicas del pasado?
- **Citas Representativas:**
 - *“Yo te digo que soy reactivo, porque cuando vino el multiverso o como se llame eso, parecía que nos iba a arrastrar y se ha quedado en nada.” (E14)*
 - *“No tengo ninguna duda de que la inteligencia artificial no será como el metaverso. La inteligencia artificial es una historia de éxito.” (E07)*

9.4 Adopción escalonada

- **Descripción:** Despliegue controlado y por fases de la IA, apoyado en soluciones modulares, costes decrecientes y pruebas piloto.
- **Preguntas Clave:**
 - ¿Qué factores facilitan una adopción gradual de la IA en su empresa?
- **Citas Representativas:**
 - *“Nuestra estrategia va a ser más reactiva porque al final pues si en algún momento me viene cualquier consultor y me dice, oye, en siniestros tengo un paquete, ¿vale?, pues que lo desarrollen.” (E08)*
 - *“La última innovación suele costar el doble de lo que costará seis meses después.” (E07)*

9.5 Madurez tecnológica

- **Descripción:** Percepción sobre el estado de desarrollo de la tecnología, distinguiendo entre una IA tradicional consolidada y una IA generativa aún incipiente y con incertidumbre.
- **Preguntas Clave:**
 - ¿Cuál es su percepción sobre la madurez real de estas tecnologías?
- **Citas Representativas:**
 - *“Estamos en un nivel bastante maduro en tradicional y en los últimos años además nos ha permitido automatizar muchos procesos.” (E12)*

- *“Es cierto que el sector habla mucho de inteligencia artificial, pero en realidad aún está muy verde.” (E04)*
-

10. Implementación y Gestión del Cambio

Descripción general: Procesos y estrategias para acompañar la introducción de la IA, gestionando las resistencias y asegurando la alineación organizativa.

10.1 Planificación y gobernanza del cambio

- **Descripción:** Integración de la IA en la planificación corporativa de forma estructurada, gestionando la tensión entre la urgencia tecnológica y la prudencia inversora.
- **Preguntas Clave:**
 - ¿Cómo se planifica y gobierna el proceso de cambio asociado a la implementación de IA?
- **Citas Representativas:**
 - *“Lo que hemos puesto es una metodología que en función de determinados parámetros te dice: oye, deberías de priorizar este caso de uso.” (E05)*
 - *“Como es un proceso de cambio tan importante, el acompañamiento en el cambio es crítico.” (E15)*

10.2 Acompañamiento a empleados

- **Descripción:** Estrategias para mitigar miedos, reducir resistencias y transformar la adopción en una oportunidad de crecimiento, mediante formación, comunicación y reubicación.
- **Preguntas Clave:**
 - ¿Qué medidas se han tomado para acompañar a los empleados durante la adopción de IA?
- **Citas Representativas:**
 - *“Lo que más miedo nos da a nosotros no es eso, sino que se genere una resistencia a la IA como potencial exterminadora de puestos de trabajo.” (E05)*
 - *“La inteligencia artificial lo que permite es [...] dotar a los humanos de superpoderes.” (E09)*

10.3 Métricas de seguimiento

- **Descripción:** Uso de indicadores para monitorizar el avance y el impacto de la implementación de la IA.
- **Preguntas Clave:**
 - ¿Cómo miden el progreso de los proyectos de IA?
- **Citas Representativas:**
 - *“Tenemos un sistema ya, y las cosas se miden allí.” (E05)*
 - *“Hicimos 111 recuento y unas reglas de juego para medir cuál es el impacto de la inteligencia artificial”. (E05)*

10.4 Barreras internas

- **Descripción:** Resistencias y obstáculos organizativos, culturales o procesales que dificultan la implementación de la IA.
- **Preguntas Clave:**
 - ¿Cuáles han sido las principales barreras internas para la adopción de IA?
- **Citas Representativas:**
 - *“una de las barreras [...] es el temor de la gente a perder sus trabajos.” (E10)*
 - *“Cuando metes a colaborar en estos proyectos transversales a 15 que opinen, joder, no hay forma de que salga un consenso rápido.” (E14)*

10.5 Escalabilidad de pilotos

- **Descripción:** Desafíos y estrategias para pasar de pruebas de concepto y pilotos a un despliegue a gran escala en toda la organización.
- **Preguntas Clave:**
 - ¿Qué factores determinan que un piloto de IA se escale a producción?
- **Citas Representativas:**
 - *“Tú no lo escalas hasta que no ves cuáles son los beneficios que tienes en el piloto.” (E12)*
 - *“Eso tiene un potencial enorme, pero no puede quedar simplemente como una prueba de concepto; tiene que ser escalable.” (E13)*

11. Entorno y Factores Externos

Descripción general: Influencia del entorno competitivo, regulador y social sobre la adopción de IA.

11.1 Presión competitiva y *FinTechs*

- **Descripción:** Cómo la competencia de grandes grupos, *InsurTechs* y nuevos actores tecnológicos impulsa a adoptar IA, generando estrategias reactivas o de *fast follower*.
- **Preguntas Clave:**
 - ¿Cómo influye la competencia (incluyendo *InsurTechs* y *FinTechs*) en la adopción de IA en su empresa?
- **Citas Representativas:**
 - “Creo que lo que se producirá es, lentamente, una convergencia a la que llegarán primero las de las grandes compañías que tienen recursos.” (E15)
 - “Si otros están un poco por delante no me preocupa porque luego yo también sabré.” (E07)

11.2 Preparación y aceptación del cliente

- **Descripción:** Grado en que los clientes están dispuestos a interactuar con soluciones basadas en IA, y la preferencia mayoritaria por mantener el contacto humano.
- **Preguntas Clave:**
 - ¿Qué tan preparados percibe que están sus clientes para adoptar servicios basados en IA?
- **Citas Representativas:**
 - “La gente, cuando llama para comunicar que se ha muerto su madre, como le pongas con una máquina [...], ¡te quiere matar!”. (E16)
 - “El cliente siempre tendrá la posibilidad de hablar con una persona”. (E02)

11.3 Preocupaciones éticas y sociales

- **Descripción:** Riesgos de exclusión, impacto en el empleo y erosión del principio mutualista del seguro como consecuencia de la IA.
- **Preguntas Clave:**
 - ¿Qué implicaciones éticas y sociales consideran al implementar IA?
- **Citas Representativas:**

- *“Si le metemos una capa de inteligencia artificial [...] al final estamos desnaturalizando el seguro.” (E02)*
- *“En definitiva, lo que tendrás es que habrá gente que no se podrá asegurar.” (E08)*

11.4 Regulación y presión institucional

- **Descripción:** Influencia de decisiones políticas, programas de inversión pública y marcos normativos en la estrategia de adopción.
- **Preguntas Clave:**
 - ¿Qué papel juegan las decisiones políticas en la adopción de IA en su sector?
- **Citas Representativas:**
 - *“Está habiendo es un posicionamiento, ¿no? de inversiones en aquellas industrias críticas para la producción de infraestructuras para generar inteligencia artificial.” (E15)*
 - *“En Europa no se da el contexto adecuado para el desarrollo de este tipo de tecnologías por la vorágine regulatoria que hay.” (E02)*

11.5 Colaboración con socios externos

- **Descripción:** Alianzas con universidades, proveedores, startups y consultoras como facilitadores de la innovación y el acceso a capacidades.
- **Preguntas Clave:**
 - ¿Qué papel juegan los colaboradores externos en la adopción de IA en su empresa?
- **Citas Representativas:**
 - *“Nosotros tenemos proyectos de innovación, de innovación abierta, ¿vale? O sea, con InsurTech; los hemos metido muchas veces en áreas de negocio para aprender.” (E02)*
 - *“Hay que estar cerca de los ecosistemas donde se está moviendo la inteligencia artificial para entender qué están haciendo.” (E09)*

11.6 Rol de la mediación

- **Descripción:** Influencia del canal de mediadores (agentes y corredores) en el ritmo y la estrategia de adopción de IA, actuando tanto de facilitador como de freno.
- **Preguntas Clave:**

- ¿Cómo afecta el canal de mediación a sus planes de implementación de IA?
- **Citas Representativas:**
 - *“Hace unos años nos decían que los mediadores iban a desaparecer [...] y el mediador gana cuota de mercado.” (E09)*
 - *“El mensaje es trabajo con vosotros porque [...] me simplificáis la vida.” (E09)*

El presente manual de códigos no solo constituye una herramienta metodológica para organizar y sistematizar la codificación de los datos cualitativos, sino que representa en sí mismo un **resultado relevante de la investigación**. Su elaboración ha permitido visibilizar la correspondencia entre los marcos teóricos empleados y la evidencia empírica obtenida, al tiempo que ha facilitado la identificación de categorías emergentes de especial valor analítico.

De este modo, el manual aporta una contribución doble: por un lado, asegura la **transparencia y trazabilidad del proceso de análisis**; por otro, ofrece una **estructura conceptual consolidada** que sintetiza los principales factores que inciden en la adopción de inteligencia artificial en el sector asegurador español.

Anexo 2: Libro de códigos de NVivo: Descripciones, número de entrevistas y número de referencias

Código	Nombre	Descripción	Entrevistas	Referencias
1	Estrategia y Visión	Engloba cómo las aseguradoras integran la IA en su visión corporativa, planes estratégicos y dirección general.	15	183
1.1	Plan estratégico	Inclusión explícita de la IA como línea de acción en el plan estratégico de la compañía.	10	39
1.2	Alineación con visión del CEO / Consejo	Impulso de la IA desde la alta dirección, vinculada a la visión del CEO o Consejo.	14	40
1.3	Inteligencia artificial como eje transformador	Percepción de la IA como elemento central de transformación organizativa.	12	49
1.4	Priorización estratégica de la IA	Priorización específica de la IA como foco de inversión y desarrollo dentro de la estrategia.	12	33
1.5	Cultura de innovación	Referencias explícitas a una cultura empresarial que fomenta la innovación, la experimentación, el aprendizaje y la asunción de riesgos.	11	22
2	Organización y Gobierno	Aborda la forma en que se estructura la adopción de IA internamente: liderazgo, modelos operativos, colaboración interna y barreras estructurales.	16	278
2.1	Modelo operativo (por producto, transversal, etc.)	Estructura organizativa adoptada para gestionar iniciativas de IA, combinando enfoques por producto con estructuras transversales y ágiles.	14	31
2.2	Comité de dirección / estructura de liderazgo	Papel del comité ejecutivo y la alta dirección en la conducción de la estrategia de IA, identificando modelos top-down, mixtos y reactivos.	15	57
2.3	Centro de competencia / estructura de IA	Existencia de unidades, equipos dedicados o Centros de Excelencia	11	45

Código	Nombre	Descripción	Entrevistas	Referencias
		(CoE) para gobernar y desplegar la IA de forma transversal.		
2.4	Coordinación con grupo o filiales	Colaboración interorganizativa con la matriz o empresas del grupo, que condiciona el ritmo, los recursos y la gobernanza de la IA.	6	31
2.5	Complejidad y tamaño de la organización	Influencia del tamaño, la escala y las barreras internas (silos, jerarquía) en la capacidad para adoptar IA, afectando la inversión, agilidad y volumen de datos.	14	46
2.6	Reingeniería de procesos	Necesidad de rediseñar procesos internos y flujos de trabajo para que la IA transforme la operativa tradicional y no solo automatice ineficiencias.	7	21
3	Datos e Infraestructura	Aspectos técnicos, estructurales y organizativos vinculados a los datos y sistemas tecnológicos para implementar IA.	16	265
3.1	Gobernanza y calidad del dato	Políticas, roles, estructuras (diccionarios de datos) y grado de fiabilidad y consistencia de los datos como prerequisite para proyectos de IA.	15	56
3.2	Arquitectura tecnológica y sistemas <i>legacy</i>	Diseño de sistemas tecnológicos y la dependencia de sistemas antiguos (<i>legacy</i>) que dificultan la implementación ágil de IA y exigen una evolución hacia modelos <i>API-first</i> .	12	29
3.3	Fundaciones en datos (<i>Data Lake</i> , integración)	Infraestructuras centralizadas como <i>Data Lakes</i> para almacenamiento, análisis y acceso unificado a datos estructurados y no estructurados.	10	28
3.4	Complejidad y dependencia tecnológica	Dificultades derivadas de la sofisticación técnica de la IA y la limitación por un proveedor o arquitectura existente (lock-in).	13	33
3.5	Sistemas <i>legacy</i>	Persistencia de sistemas <i>core</i> heredados y arquitecturas fragmentadas como principal obstáculo para la adopción transversal de la IA [cite: 2836-2838].	8	15

Código	Nombre	Descripción	Entrevistas	Referencias
3.6	Plataformas tecnológicas (<i>CoPilot</i> , etc.)	Consumo de funcionalidades de IA embebidas en plataformas de terceros (CRMs, ofimática) como estrategia para obtener valor rápido sin grandes desarrollos internos.	10	36
3.7	Complejidad tecnológica	Dificultades derivadas de la sofisticación técnica de la IA, su integración y la necesidad de adaptar la infraestructura de datos para explotarla.	13	33
3.8	Dependencia tecnológica - lock-in	Riesgo de quedar atado a un proveedor tecnológico, enfrentando escaladas de costes de licencia y pérdida de autonomía estratégica.	10	22
4	Talento y Cultura	Gestión del talento, perfiles técnicos, formación y elementos culturales que influyen en la adopción de IA.	16	296
4.1	Atracción y retención de talento	Dificultades para captar y mantener profesionales con competencias en IA en un mercado competitivo.	15	52
4.2	Brecha de capacidades	Carencias estructurales de competencias en la plantilla, como la falta de perfiles híbridos (negocio y tecnología) y la indefinición de nuevos roles.	14	58
4.3	Perfiles escasos y rotación	Escasez estructural de perfiles especializados y la alta tasa de rotación en roles digitales.	11	22
4.4	Formación interna y upskilling	Esfuerzo sistemático de capacitación que abarca a toda la organización (consejo, TI, negocio) a través de programas estructurados, talleres y aprendizaje experiencial.	10	43
4.5	Cultura organizativa y resistencia	Rasgos culturales del sector (pragmatismo, aversión al riesgo) y fuentes de resistencia al cambio (miedo a la sustitución, escepticismo, fatiga de iniciativas).	13	72
4.6	Clima y sentido de pertenencia	Factores intangibles como la cohesión interna, el orgullo de contribución, la	9	21

Código	Nombre	Descripción	Entrevistas	Referencias
		confianza interpersonal y la gestión de la diversidad cultural y generacional.		
4.7	Cultura de innovación (vívida)	Prácticas y valores que fomentan la innovación, como la tradición analítica, la curiosidad, la tolerancia al error y el liderazgo basado en la confianza y la apertura externa.	5	28
5	Implementación de IA	Trata sobre cómo se operacionalizan los proyectos de IA, desde pilotos hasta producción, incluyendo aspectos metodológicos y relaciones externas.	16	333
5.1	Enfoque incremental / piloto / escalado	Estrategia de implementación progresiva, desde pruebas de concepto (PoC) para aprender, pasando por pilotos para validar, hasta el despliegue a gran escala.	16	125
5.2	Relación con proveedores y consultoras	Colaboraciones con expertos externos (consultoras, <i>Big Tech</i> , startups) para el desarrollo e implantación de soluciones de IA, gestionando la tensión entre la necesidad de sus capacidades y el riesgo de dependencia.	16	79
5.3	Gobernanza de los modelos (control, escalado, caja negra)	Procesos y estructuras (comités, auditorías) para asegurar la calidad, control, transparencia, cumplimiento y escalabilidad de los modelos de IA.	11	30
5.4	Evaluación de costes y retorno (ROI)	Valoración económica de los proyectos para decidir su continuidad, siendo un requisito indispensable para el escalado.	6	11
5.5	Métodos de priorización y evaluación de casos	Mecanismos explícitos para filtrar y seleccionar casos de uso, combinando criterios de impacto, viabilidad y alineamiento estratégico.	13	88
6	Riesgos	Percepciones sobre los riesgos inherentes a la adopción de IA, tanto técnicos como éticos o reputacionales.	15	113

Código	Nombre	Descripción	Entrevistas	Referencias
6.1	Caja negra, explicabilidad y pérdida de control	Dificultad para interpretar cómo toman decisiones los modelos (opacidad) y la sensación de delegar decisiones clave a sistemas no comprendidos, perdiendo soberanía sobre los datos y procesos.	8	17
6.2	Alucinaciones y riesgos éticos (discriminación)	Generación de información incorrecta por modelos generativos (alucinaciones) y posibles sesgos o impactos discriminatorios que erosionan el principio mutualista.	9	12
6.3	Riesgos éticos y reputación	Posible impacto negativo de la IA sobre la imagen pública o la relación con los clientes, así como los dilemas éticos asociados (sesgo, desmutualización).	13	26
6.4	Pérdida de control sobre procesos	Temor a perder el control del negocio por la dependencia de proveedores, la cesión de datos o la deriva autónoma de los modelos de IA.	8	15
6.5	Reputación y confianza	Posible impacto negativo de la IA sobre la imagen pública o la relación con los clientes, derivado de fallos tecnológicos, mal uso de datos o experiencias de usuario deficientes.	15	43
7	Regulación	Cumplimiento normativo, supervisión institucional y marcos legales aplicables a la IA.	12	58
7.1	Marco regulatorio (AI Act) y presión institucional	Impacto del Reglamento Europeo de IA y la influencia de decisiones políticas, percibido como un entorno de hiperregulación que frena la innovación.	10	29
7.2	Supervisión, transparencia y protección de datos	Exigencia de informar sobre el uso de IA, garantizar la trazabilidad de las decisiones y la participación de las áreas de privacidad y protección de datos.	6	9
7.3	Obligaciones específicas por nivel de riesgo	Requerimientos normativos asociados a la clasificación de los casos de uso de IA según su nivel de riesgo, como exige el AI Act.	3	3

Código	Nombre	Descripción	Entrevistas	Referencias
7.4	Rol de protección de datos	Influencia de la normativa de protección de datos (RGPD) como factor restrictivo en el uso de información personal para modelos de IA.	8	17
8	Coste-beneficio y ROI	Evaluación económica y justificación financiera de los proyectos de IA como factor organizativo determinante.	16	389
8.1	Análisis de coste-beneficio	Proceso de evaluación riguroso donde se ponderan los beneficios esperados (reducción de costes, aumento de ingresos) frente a la inversión requerida.	16	147
8.2	Indicadores (KPIs, TIR, retorno)	Uso de métricas financieras clásicas (ahorro en FTE, pay-back, TIR) y operativas (reducción de tiempos, productividad) para medir el retorno de la IA.	10	26
8.3	Selección y priorización de casos de uso	Proceso de selección de iniciativas de IA basado en el impacto económico, las capacidades internas y el modelo de negocio.	8	11
8.4	Rentabilidad tangible e intangible	Reconocimiento de que el valor de la IA trasciende lo financiero, generando activos intangibles como la mejora del capital humano, la innovación y la reputación.	11	33
8.5	Ventaja relativa	Percepción dual sobre el valor de la IA: la predictiva como mejora incremental y la generativa como un salto cualitativo con potencial disruptivo.	16	172
9	Madurez y Expectativas	Nivel de desarrollo real de la IA en las aseguradoras y la percepción frente al discurso mediático.	16	271
9.1	“Hype”, expectativas y madurez tecnológica	Exceso de expectativas (“hype”), necesidad de una visión realista y percepción de que la tecnología (especialmente la generativa) aún no está lista para producción.	15	54

Código	Nombre	Descripción	Entrevistas	Referencias
9.2	Evolución progresiva vs. disrupción inmediata	Debate entre concebir la IA como un cambio paulatino (evolución) en continuidad con innovaciones previas, y la visión de una transformación radical e inminente (disrupción).	15	83
9.3	Comparación con otras modas tecnológicas	Uso de analogías con ciclos tecnológicos previos (metaverso, <i>Blockchain</i>) para contextualizar y relativizar las expectativas sobre la IA.	5	9
9.4	Adopción escalonada	Despliegue controlado y por fases de la IA, apoyado en soluciones modulares, costes decrecientes y pruebas piloto.	11	43
9.5	Madurez tecnológica	Percepción sobre el estado de desarrollo de la tecnología, distinguiendo entre una IA tradicional consolidada y una IA generativa aún incipiente y con incertidumbre.	16	82
10	Implementación y Gestión del Cambio	Procesos y estrategias para acompañar la introducción de la IA, gestionando las resistencias y asegurando la alineación organizativa.	16	266
10.1	Planificación y gobernanza del cambio	Integración de la IA en la planificación corporativa de forma estructurada, gestionando la tensión entre la urgencia tecnológica y la prudencia inversora.	15	180
10.2	Acompañamiento a empleados	Estrategias para mitigar miedos, reducir resistencias y transformar la adopción en una oportunidad de crecimiento, mediante formación, comunicación y reubicación.	11	45
10.3	Métricas de seguimiento	Uso de indicadores para monitorizar el avance y el impacto de la implementación de la IA.	2	2
10.4	Barreras internas	Resistencias y obstáculos organizativos, culturales o procesales que dificultan la implementación de la IA.	10	34
10.5	Escalabilidad de pilotos	Desafíos y estrategias para pasar de pruebas de concepto y pilotos a un	4	5

Código	Nombre	Descripción	Entrevistas	Referencias
		despliegue a gran escala en toda la organización.		
11	Entorno y Factores Externos	Influencia del entorno competitivo, regulador y social sobre la adopción de IA.	15	145
11.1	Presión competitiva y <i>FinTechs</i>	Cómo la competencia de grandes grupos, <i>InsurTechs</i> y nuevos actores tecnológicos impulsa a adoptar IA, generando estrategias reactivas o de <i>fast follower</i> .	14	47
11.2	Preparación y aceptación del cliente	Grado en que los clientes están dispuestos a interactuar con soluciones basadas en IA, y la preferencia mayoritaria por mantener el contacto humano.	13	39
11.3	Preocupaciones éticas y sociales	Riesgos de exclusión, impacto en el empleo y erosión del principio mutualista del seguro como consecuencia de la IA.	5	12
11.4	Regulación y presión institucional	Influencia de decisiones políticas, programas de inversión pública y marcos normativos en la estrategia de adopción.	5	8
11.5	Colaboración con socios externos	Alianzas con universidades, proveedores, startups y consultoras como facilitadores de la innovación y el acceso a capacidades.	4	8
11.6	Rol de la mediación	Influencia del canal de mediadores (agentes y corredores) en el ritmo y la estrategia de adopción de IA, actuando tanto de facilitador como de freno.	8	31

Anexo 3: Matriz de codificación de entrevistas: distribución de referencias por categorías temáticas y entrevistas

ID	Categorías temáticas Nvivo										
	Estrategia y visión	Organización y gobierno	Datos e infraestructura	Talento y cultura	Implementación de IA	Riesgos	Regulación	Coste-beneficio y ROI	Madurez y expectativas	Implementación y gestión del cambio	Entorno y factores externos
E1	5	16	20	1	22	2	2	23	17	12	5
E2	6	16	10	38	13	15	11	36	14	42	11
E3	8	20	15	16	15	5	3	20	12	19	4
E4	7	14	19	17	24	4	2	17	20	6	6
E5	19	35	26	26	26	6	5	26	9	21	12
E6	–	1	10	1	8	5	2	8	5	3	–
E7	5	16	21	21	10	15	4	22	22	13	5
E8	20	16	7	13	23	5	1	37	31	13	21
E9	25	16	21	33	49	12	3	42	31	47	21
E10	9	17	10	21	28	12	2	24	21	16	9

ID	Categorías temáticas Nvivo										
	Estrategia y visión	Organización y gobierno	Datos e infraestructura	Talento y cultura	Implementación de IA	Riesgos	Regulación	Coste-beneficio y ROI	Madurez y expectativas	Implementación y gestión del cambio	Entorno y factores externos
E11	23	26	15	20	28	9	15	26	16	14	4
E12	11	20	11	21	22	7	8	24	17	10	9
E13	15	11	13	23	12	2	–	17	8	13	11
E14	5	7	19	11	7	9	–	13	17	10	3
E15	8	20	10	11	12	–	–	12	25	10	7
E16	17	27	38	23	34	5	–	42	6	17	17

Extended Summary

Abstract

In this thesis, I study how Spanish insurance companies adopt Artificial Intelligence (AI) and how this process evolves over time. I conducted sixteen in-depth interviews with CEOs and one CTO whose companies represent approximately 60% of the national market. The corpus amounts to more than 135K words and 17 hours of recorded conversations. Using the Technology–Organization–Environment (TOE) framework, the Diffusion of Innovations (DOI) theory, and the Artificial Intelligence Maturity Model (AIMM), I coded the transcripts in NVivo and assigned maturity levels conservatively using the minimum-rule.

The results show that the story of AI adoption in Spanish insurance is not primarily about algorithms, but about leadership, culture, and governance. Organizational factors dominated (54.8% of coded references), ahead of technology (34.3%) and environment (10.9%). Insurers rarely move directly into large deployments. Instead, they test ideas through proofs of concept, run pilots, and then decide whether to scale them. Predictive AI is trusted in areas such as fraud detection, pricing, and claims management, while generative AI remains exploratory, often limited to internal pilots.

By integrating insights from the field with theory, I developed an integrated TOE–DOI–AIMM model that shows how adoption drivers and barriers evolve dynamically as companies progress through maturity stages. The findings align with prior literature on ROI discipline, data governance, and cultural resistance, while adding sector-specific nuances: the centrality of hybrid business–data talent, legacy architectures as a structural brake, fast-follower logics, guardrails for GenAI (human-in-the-loop, explicability), the risk of “desmutualization,” and the prevalence of shadow AI and a GenAI Divide between pilots and production. This work provides both a map of where Spanish insurers stand today and guidance for managers, regulators, and technology providers aiming to advance AI responsibly.

Introduction

Artificial Intelligence has become a defining force of digital transformation across industries. In banking, healthcare, and retail, we already see AI used to predict risks, personalize services, and automate decisions (Haenlein & Kaplan, 2019; Russell & Norvig, 2021). Insurance is also a data-intensive industry, with vast amounts of historical records on clients, claims, and risks, making it a fertile ground for AI. However, in Spain, adoption has been cautious. Recent market surveys indicate that while most insurers experiment with AI, only a small fraction have scaled projects to production and integrated them systematically (Eling & Lehmann, 2018; Wirtz et al., 2019).

This gap between potential and reality motivated my research. As one executive put it: “The technology exists, but we don’t put it into practice. The question is: why?” (E01). This paradox encapsulates the central puzzle of AI adoption: if the technology is available and the benefits are clear, what prevents insurers from implementing it at scale?

I wanted to understand not only why some insurers move faster than others, but also how the drivers and barriers of adoption change as companies progress through different stages of maturity. Previous academic work often focused on single adoption factors such as data quality, perceived benefits, or leadership support (Dwivedi et al., 2021). But fewer studies examined how these elements interact dynamically across maturity stages, or how sector-specific characteristics like risk aversion, legacy systems, and mutuality shape the trajectory of AI adoption. Moreover, very little empirical research has focused specifically on the Spanish insurance market, despite its economic weight and unique structure dominated by both multinational groups and domestic mutuals.

To address these gaps, I combined three complementary theoretical lenses:

- **TOE framework** (Tornatzky & Fleischer, 1990), which considers how technological, organizational, and environmental contexts influence adoption.
- **DOI theory** (Rogers, 1995), which describes how innovations spread in stages from awareness to widespread integration.
- **AIMM model** (Alsheiabni et al., 2019), which classifies organizations into five maturity levels: Initial, Assessing, Determined, Managed, and Optimized.

These lenses guided my main research questions:

1. What helps or hinders the adoption of AI in Spanish insurance companies?
2. How do these adoption factors change as companies progress through different stages of maturity?

By answering these questions, I aim to contribute both theoretically—by linking maturity and adoption drivers—and practically—by offering insurers and policymakers a map of where the sector stands and what levers matter most at each stage.

Research Methodology

a) Approach

To answer my questions, I chose a qualitative and interpretive approach (Hudson & Ozanne, 1988). My goal was not to test a predefined hypothesis but to understand

how executives themselves perceive AI and what role it plays in their companies. This perspective is particularly suitable for a phenomenon that is still emergent, context-dependent, and shaped by organizational and cultural factors.

b) Data Collection

I conducted 16 semi-structured interviews with CEOs and one CTO of insurance companies operating in Spain. Together, these firms account for approximately 60% of the national market, covering a diverse spectrum: large multinational subsidiaries, mid-sized national players, and smaller mutuals. The interviews lasted between 30 and 90 minutes, producing more than 17 hours of recordings and 135,186 words of transcripts.

The interviewees were selected because they are the ultimate decision-makers on strategy and resources. Their perspective offers a unique window into how AI is framed and acted upon at the highest level of governance.

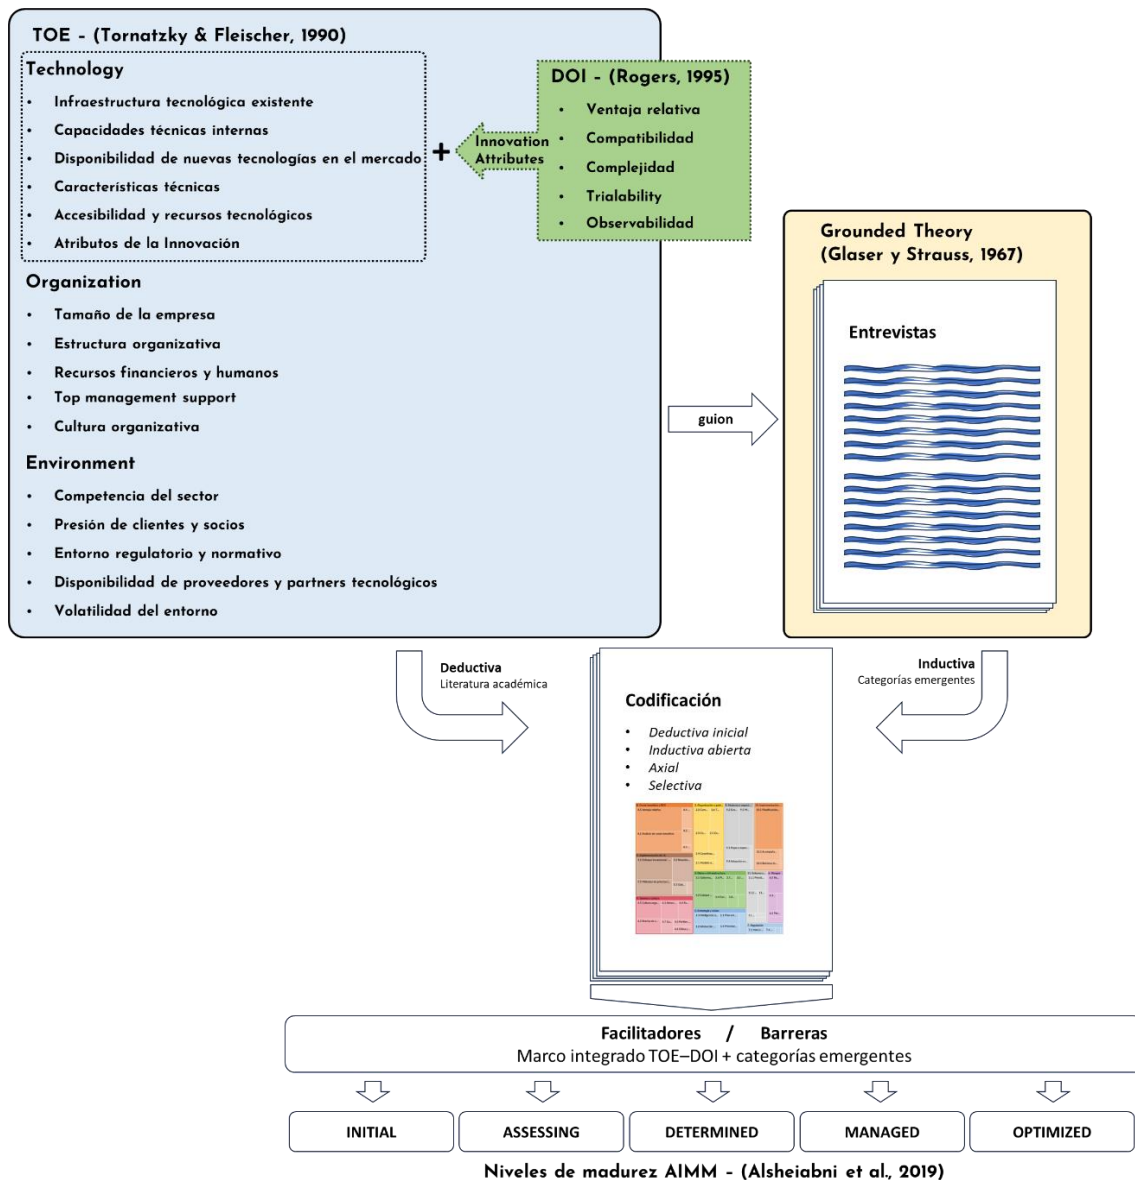
c) Analysis

I used NVivo software to code the transcripts. I started with a coding scheme derived from TOE, DOI, and AIMM, but also incorporated emergent categories such as hybrid talent scarcity, legacy constraints, the risk of desmutualization, and ecosystem effects (including mediator gatekeeping). This allowed me to capture both theory-driven and data-driven insights.

For maturity assessment, I applied the minimum-rule: if a company was advanced in one dimension (e.g., data) but weak in another (e.g., governance), I classified it at the lower stage. This conservative approach reduced the risk of overestimating maturity.

d) Ensuring Rigor

To strengthen credibility, I adopted several complementary strategies: cross-case comparison, analytical memos, iterative coding, and checks for thematic saturation. I anonymized participants and their companies to ensure confidentiality and candor. Triangulation across frameworks (TOE, DOI, AIMM) further reinforced the robustness of the findings.




Results

a) Distribution of Maturity


Placing the sixteen insurers on the AIMM maturity scale revealed a very uneven picture:

- 1 company at the Initial stage.
- 4 at the Assessing stage.
- 7 at the Determined stage.
- 4 at the Managed stage.
- 0 at the Optimized stage.



This distribution (1/4/7/4/0) shows that Spanish insurers are moving along the maturity path, but none have reached the highest level of full integration. Most are “in the middle”—advanced enough to recognize infrastructure and governance needs, but not yet fully scaled.

From a coding perspective, organizational factors dominated (54.8% of references), ahead of technological (34.3%) and environmental (10.9%). This underlines that AI adoption is less about algorithms and more about leadership, governance, and culture.



b) Technology Factors

Early-stage constraints centered on data quality and governance—fragmentation, inconsistency, and the absence of corporate dictionaries. Larger insurers invested in data lakes/lakehouses, API-first architectures, and standardized repositories treated as “corporate treasure,” sometimes tying data stewardship to executive bonuses. Predictive AI deployments in fraud, pricing, claims, and retention delivered measurable impact. For GenAI, firms reported 30–50% productivity gains in text/code tasks but kept use internal to mitigate hallucinations and compliance risk; differentiation is viewed as temporary as capabilities commoditize. Vendors were approached cautiously given license lock-in concerns; emergent strategies included success-fee models, internalization of critical know-how, and private/secured LLMs. Technology adoption followed an incremental PoC→pilot→scale pathway, often under an explicit fast-follower philosophy—“experiment with soft drinks,” scaling only after proven benefits. Legacy “spaghetti” architectures were the most persistent structural brake.

c) Organizational Factors

Three themes dominated: ROI discipline, hybrid talent, and culture/change. No initiative advanced to production without a demonstrable business case; in GenAI, investments were allowed as capability-building bets with clear learning objectives and risk bounds, supported by monthly BI dashboards (payback/IRR). Talent gaps were acute for hybrid business–data profiles, with salary tensions against internal equity; retention relied on stimulating projects, purpose/pride, and training up to Board level. Cultural resistance persisted, addressed via a narrative of AI as an ally “superpower,” quick-win legitimization, and emergent distributed leadership (still insufficient in some cases). Governance innovations included traffic-light risk classification, 70–80 item checklists, homogeneous ROI measurement from the CoE, third-party embedded-AI controls, and the “human final decision” principle.

d) Environmental Factors

External pressures acted as modulators rather than determiners. Competitive dynamics and customer expectations pushed adoption, but many firms pursued wait-and-see timing. Mediators (agents/brokers) emerged as gatekeepers, preserving human interaction and supporting AI that augments rather than substitutes their role (faster responses, lower training burden). Ethical and regulatory debates focused on bias/explicability and the risk of desmutualization from hyper-personalized pricing; some entities restricted IVR/chatbots to avoid dehumanization. The realistic horizon for deeper disruption was framed closer to 2030 than 2025.

e) Predictive vs. Generative AI

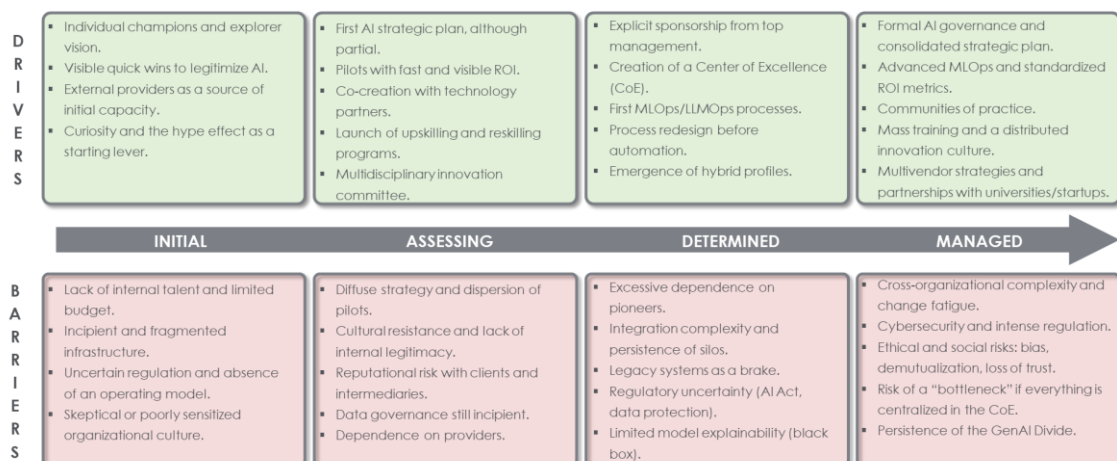
The contrast was clear. Predictive AI is a sector standard with measurable, reliable impact. Generative AI is seen as transformative but immature, with a visible GenAI Divide between numerous pilots and the small subset yielding measurable business value; shadow AI is widespread, offering bottom-up learning but raising data-governance risks.

f) Patterns of Adoption

Adoption followed a cautious sequence—proof of concept → pilot → scaling → production—consistent with DOI. Priorities and barriers shift across AIMM:

- **Initial:** exploratory champions, hype, external providers; barriers in talent/budget.
- **Assessing:** ROI-focused pilots, legitimacy building, nascent governance/change management.
- **Determined:** data governance, scaling, risk/explicability controls; legacy and ethical dilemmas persist.
- **Managed:** institutionalization (CoE, homogeneous metrics, top-down sponsorship), widespread training; new barriers in organizational complexity and change fatigue.

While size correlates positively with maturity ($\rho = 0.74$; $\tau = 0.62$), smaller/mid-size insurers leverage agility as an alternative path to leadership.



Conclusion

The main lesson is that AI adoption in Spanish insurance is less about technical algorithms and more about organizational and cultural readiness. Technology and environment set the stage, but leadership, governance, and talent determine outcomes.

Several conclusions stand out: predictive AI is consolidated and ROI-positive; generative AI remains exploratory, with temporary differentiation; ROI acts as gatekeeper to production; data governance is a prerequisite; legacy systems are a structural brake; risks are as much social/ethical (trust, bias, desmutualization) as technical; and drivers/barriers evolve by maturity stage, with agility enabling smaller players to offset scale advantages. By combining TOE, DOI, and AIMM, this thesis conceptualizes adoption as a dynamic, stage-dependent process, adding the notions of bimodal portfolios, shadow AI/GenAI Divide, and mediator gatekeeping to the insurance adoption discourse.

Theoretical contributions

The thesis develops an integrated TOE–DOI–AIMM framework that captures adoption as an evolutionary, context-dependent process, where the salience of factors shifts across maturity levels. It generates novel empirical evidence for the Spanish insurance market, a sector economically and socially significant but academically underexplored. It proposes the concept of bimodal AI portfolio management, where efficiency-oriented projects with immediate ROI coexist with exploratory generative AI initiatives, bridging theory and practice. It introduces the emerging idea of the GenAI Divide—the difficulty of moving from pilots to production in generative AI—which complements classic innovation diffusion models. Finally, it demonstrates the dynamic nature of drivers and barriers, showing that they transform with each maturity stage, thereby advancing a processual view of adoption over static perspectives.

Practical recommendations

Building on these findings, the thesis also proposes practical recommendations. For insurers, they are structured by maturity level: at the Initial stage, boards should focus on awareness, quick wins, and basic data readiness; at Assessing, concentrate on ROI-driven pilots, data governance, and multidisciplinary innovation committees; at Determined, invest in scalable data/ML infrastructures, formalize AI Centers of Excellence, and redesign processes before automation; and at Managed, embed AI into culture, ethics, and metrics, while avoiding centralization bottlenecks and addressing the GenAI Divide. Beyond insurers, regulators should balance the AI Act with sandboxes and preserve mutuality; universities should train hybrid profiles and foster applied research; technology partners should move from PoC to proof of value with transparent contracts; employees should embrace continuous up/reskilling; and mediators should be included as active co-designers, acting as both adopters and potential gatekeepers of innovation.

Limitations and Strengths

This research has limitations. It is qualitative and based on 16 executive interviews, so it is not statistically generalizable. It focuses on Spain, meaning results may differ in other markets. It privileges the voice of top executives, leaving aside employees, customers, and mediators. The timing—amid the emergence of generative AI—means perceptions may evolve as technology and regulation mature. Future work should include InsurTechs and comparative international analyses, incorporate multi-actor perspectives, and adopt longitudinal/mixed-methods designs to validate and quantify the dynamics observed (including shadow AI, legacy modernization, and social legitimacy).

Yet the study also has important strengths. It offers the first comprehensive mapping of AI maturity in Spanish insurance, covering over three-quarters of the market. It triangulates three theoretical lenses and connects them with rich empirical data. And by aligning with the literature on ROI, governance, and organizational factors—while adding sector-specific nuances such as hybrid talent constraints, fast-follower strategies, explicability guardrails, desmutualization risk, and the GenAI Divide—it contributes insights of both academic significance and practical relevance.

References (selected)

- Alsheiabni, S., Cheung, Y., & Messom, C. (2019). Towards an artificial intelligence maturity model: From science fiction to business. *PACIS 2019 Proceedings*, 46.
- Chui, M., Hazan, E., Roberts, R., Singla, A., Smaje, K., Sukharevsky, A., Yee, L., & Zemmel, R. (2023). *The economic potential of generative AI: The next productivity frontier*. McKinsey & Company.
- de Andrés-Sánchez, J., & Gené-Albesa, J. (2024). Trust takes the driver's seat: A TAM-based model for conversational AI adoption in insurance. *Kybernetes*. [Advance online publication].
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2021). Artificial intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- Eling, M., & Lehmann, M. (2018). The impact of digitalization on the insurance value chain and the insurability of risks. *The Geneva Papers on Risk and Insurance – Issues and Practice*, 43(3), 359–396. <https://doi.org/10.1057/s41288-017-0073-0>

- Eloundou, T., Manning, S., Mishkin, P., & Rock, D. (2023). GPTs are GPTs: An early look at the labor market impact potential of large language models. *arXiv*. <https://doi.org/10.48550/arXiv.2303.10130>
- Haenlein, M., & Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Hudson, L. A., & Ozanne, J. L. (1988). Alternative paradigms for consumer research. *Journal of Consumer Research*, 14(4), 548–557. <https://doi.org/10.1086/209129>
- ICEA. (2023). *VIII termómetro de inteligencia artificial y big data en el sector asegurador español*.
- ICEA & Minsait. (2024). *IX termómetro de IA y datos en el sector asegurador español*.
- MIT NANDA. (2025). *The GenAI divide: State of AI in business 2025*. MIT Project NANDA. https://mlq.ai/media/quarterly_decks/v0.1_State_of_AI_in_Business_2025_Report.pdf
- Rogers, E. M. (1995). *Diffusion of innovations* (4th ed.). Free Press.
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Tornatzky, L. G., & Fleischer, M. (1990). *The processes of technological innovation*. Lexington Books.
- Wirtz, B. W., Weyerer, J. C., & Geyer, C. (2019). Artificial intelligence and the public sector: Applications and challenges. *International Journal of Public Administration*, 42(7), 596–615. <https://doi.org/10.1080/01900692.2018.1498103>
- .