

# EMPRENDER EN LA ERA DE LA INTELIGENCIA ARTIFICIAL: OPORTUNIDADES Y RETOS

HUMPHREY XAVIER RUBIO TOBAR  
LINDSAY KATHERINE RANGEL ANCHUNDIA  
CARMEN KATERINE ZAMBRANO VÉLEZ  
SANTOS ALCIBIADES ÁLAVA MACÍAS  
ROBERTO JONATHAN PICO MACÍAS  
HÉCTOR JUNIOR ESPINOZA ALCÍVAR  
PABLO HORACIO HIDROVO ALCÍVAR  
ÁNGEL FABIAN MOREIRA ROMERO  
WAGNER OSWALDO VILLAFUERTE MUÑOZ  
MARIUXI ELIZABETH ZAMBRANO CHAVARRÍA







**PREINCUBADORA  
DE EMPRESAS**

FACULTAD DE INGENIERÍA, INDUSTRIA Y ARQUITECTURA

**EMPRENDER EN LA ERA DE LA  
INTELIGENCIA ARTIFICIAL:  
OPORTUNIDADES Y RETOS**

HUMPHREY XAVIER RUBIO TOBAR  
LINDSAY KATHERINE RANGEL ANCHUNDIA  
CARMEN KATERINE ZAMBRANO VÉLEZ  
SANTOS ALCIBIADES ÁLAVA MACIAS  
ROBERTO JONATHAN PICO MACÍAS  
HÉCTOR JUNIOR ESPINOZA ALCÍVAR  
PABLO HORACIO HIDROVO ALCÍVAR  
ÁNGEL FABIAN MOREIRA ROMERO  
WAGNER OSWALDO VILLAFUERTE MUÑOZ  
MARIUXI ELIZABETH ZAMBRANO CHAVARRÍA

Colección Académica. Área Ingeniería  
Tomo 7

**CUERPO  
DEVOCES**

Este libro ha sido evaluado bajo el sistema de pares ciegos.

COMITÉ EDITORIAL:

Siomara España, PhD. Universidad de las Artes (Ecuador)  
Jeovanny Benavides, PhD. Universidad Técnica de Manabí (Ecuador)  
Pablo Romo, PhD. Universidad Central del Ecuador (Ecuador)  
Gonzalo Díaz Troya, PhD. Universidad Laica Eloy Alfaro de Manabí (Ecuador)  
Alejandro Recio Sastre, PhD. Universidad de Chile (Chile)  
Mario Madroñero, PhD. Universidad Nacional Abierta y a Distancia (Colombia)  
Mario Morenza, Mg. Universidad Central de Venezuela (Venezuela)

Contacto:

Email: [cuerpodevoces@gmail.com](mailto:cuerpodevoces@gmail.com)

Web: [www.cuerpodevoces.com](http://www.cuerpodevoces.com)

Teléfono: 0984172663. Manta

**Emprender en la era de la inteligencia artificial: oportunidades y retos**

©Humphrey Xavier Rubio Tobar  
©Lindsay Katherine Rangel Anchundia  
©Carmen Katerine Zambrano Vélez  
©Santos Alcibiades Álava Macías  
©Roberto Jonathan Pico Macías  
©Héctor Junior Espinoza Alcívar  
©Pablo Horacio Hidrovo Alcívar  
©Ángel Fabian Moreira Romero  
©Wagner Oswaldo Villafuerte Muñoz  
©Mariuxi Elizabeth Zambrano Chavarría

Diseño de portada: Isaac Vélez (Hidropixel Agencia)

ISBN: 978-9942-631-38-1

Primera edición: junio de 2025

Manta, Ecuador

INTRODUCCIÓN.....	9
CAPÍTULO 1	
LA NUEVA REVOLUCIÓN INDUSTRIAL: EL IMPACTO DE LA INTELIGENCIA ARTIFICIAL.....	
1.1 Evolución histórica de las revoluciones tecnológicas.....	11
1.2 Principales tecnologías que componen la inteligencia artificial.....	14
1.3 Cambios estructurales en la economía global impulsados por IA.....	18
1.4 Modelos de negocio emergentes en la era algorítmica.....	22
1.5 Desplazamiento de industrias y creación de nuevos ecosistemas.....	25
CAPÍTULO 2	
EL ADN DEL NUEVO EMPRENDEDOR TECNOLÓGICO.....	
2.1 Perfil del emprendedor digital frente al tradicional.....	29
2.2 Competencias clave en tiempos de automatización.....	33
2.3 Pensamiento computacional y mentalidad algorítmica.....	36
2.4 Resiliencia y adaptabilidad en entornos volátiles.....	39
2.5 Aprendizaje continuo y alfabetización en datos.....	42
CAPÍTULO 3	
DESCUBRIENDO OPORTUNIDADES DE NEGOCIO CON INTELIGENCIA ARTIFICIAL.....	
3.1 Metodologías para la identificación de oportunidades tecnológicas.....	46
3.2 Análisis predictivo aplicado al estudio de mercados.....	49
3.2.1 Fundamentos del análisis predictivo en mercados.....	49
3.2.2 Aplicaciones prácticas en la investigación de mercados.....	54
3.2.3 Tecnologías y herramientas utilizadas en análisis predictivo.....	56
3.2.4 Limitaciones, riesgos y consideraciones éticas.....	59
3.3 Segmentos emergentes potenciados por IA.....	62
3.4 Detectar problemas reales susceptibles de automatización.....	65
3.5 Innovación basada en necesidades no satisfechas.....	67

## CAPÍTULO 4

### DISEÑO Y VALIDACIÓN DE PROPUESTAS DE VALOR

CON INTELIGENCIA ARTIFICIAL.....	70
4.1 Integración de IA en la identificación de necesidades del cliente.....	70
4.2 Herramientas algorítmicas para el diseño de prototipos.....	72
4.3 Validación automatizada de hipótesis de mercado.....	75
4.4 Medición en tiempo real del comportamiento del usuario.....	77
4.5 Optimización iterativa del producto basada en datos.....	80

## CAPÍTULO 5

### AUTOMATIZACIÓN INTELIGENTE EN STARTUPS DIGITALES.....

5.1 Procesos operativos susceptibles de automatización.....	83
5.2 Plataformas accesibles para startups sin infraestructura propia.....	87
5.3 Aplicación de RPA e IA en gestión interna.....	90
5.4 Escalabilidad sin incremento estructural gracias a IA.....	92
5.5 Uso de dashboards inteligentes para mejora continua.....	95

## CAPÍTULO 6

### ÉTICA, SESGOS Y GOBERNANZA ALGORÍTMICA

EN PROYECTOS EMPRENDEDORES.....	99
6.1 Sesgos en modelos utilizados por startups tecnológicas.....	99
6.2 Toma de decisiones automatizadas y responsabilidad ética.....	101
6.3 Privacidad de datos en plataformas emergentes.....	104
6.4 Transparencia algorítmica y validación ante terceros.....	107
6.5 Buenas prácticas de gobernanza digital en emprendimientos.....	110

## CAPÍTULO 7

### INTELIGENCIA ARTIFICIAL Y TRANSFORMACIÓN DEL TRABAJO.....

7.1 Nuevos perfiles híbridos en startups basadas en datos.....	113
7.2 IA como complemento de equipos humanos en proyectos ágiles.....	115
7.3 Automatización de tareas emprendedoras repetitivas.....	118
7.4 Reconversión de roles y adquisición de competencias clave.....	121
7.5 Plataformas de IA para organización del trabajo colaborativo.....	124

## CAPÍTULO 8

### ACCESIBILIDAD Y BRECHAS EN EL EMPRENDIMIENTO CON IA.....

8.1 Asimetrías en el acceso a infraestructura y datos.....	128
8.2 Formación técnica y barreras cognitivas.....	130
8.3 Costos reales de implementar IA en proyectos pequeños.....	133
8.4 Modelos open-source y recursos gratuitos disponibles.....	136
8.5 Estrategias de inclusión digital para emprendedores.....	139

**CAPÍTULO 9**

MARCO LEGAL Y REQUISITOS REGULATORIOS PARA EMPRENDER CON IA.....	142
9.1 Normativas aplicables a startups con base algorítmica.....	142
9.2 Derechos del usuario y responsabilidad del creador de sistemas....	145
9.3 Gestión del consentimiento y trazabilidad en modelos predictivos.....	147
9.4 Propiedad intelectual en productos generados con IA.....	149
9.5 Buenas prácticas para la legalidad operativa de emprendimientos.....	151

**CAPÍTULO 10**

**ESCENARIOS FUTUROS PARA EL EMPRENDIMIENTO**

CON INTELIGENCIA ARTIFICIAL.....	154
10.1 Inteligencia generativa y nuevos formatos de negocio.....	154
10.2 Plataformas autónomas y modelos de decisión sin intervención humana.....	156
10.3 Convergencia con blockchain, IoT y realidad extendida.....	158
10.4 Tendencias de automatización total en microempresas.....	161
10.5 Proyecciones éticas, sociales y económicas del emprendimiento algorítmico.....	163
Glosario de términos.....	167
Bibliografía.....	178
Autores.....	203



## INTRODUCCIÓN

La inteligencia artificial es un eje funcional en la transformación de los sistemas económicos, organizativos y productivos actuales. Su integración en procesos de análisis, automatización y toma de decisiones permite redefinir funciones operativas, estructuras de costos y modelos de escalabilidad. Esta tecnología no opera como herramienta aislada, sino como una arquitectura técnica que reorganiza flujos de valor y condiciones de competencia en entornos dinámicos.

El presente libro, titulado *Emprender en la era de la inteligencia artificial: oportunidades y retos*, examina cómo la inteligencia artificial modifica los entornos técnicos y operativos necesarios para la estructuración y desarrollo de proyectos emprendedores. El enfoque está dirigido a identificar mecanismos mediante los cuales estas iniciativas pueden organizar procesos, validar propuestas de valor y operar con eficiencia en escenarios condicionados por automatización, procesamiento de datos y escalabilidad computacional. El alcance del análisis se orienta de forma precisa a las aplicaciones funcionales de la inteligencia artificial en la lógica operativa del emprendimiento digital.

La organización del contenido responde a un criterio de utilidad técnica. Cada capítulo identifica procesos críticos en los que la inteligencia artificial aporta valor concreto a proyectos en fase inicial o con aspiraciones de expansión. Se presentan herramientas que permiten detectar oportunidades,

mejorar validaciones, automatizar operaciones esenciales y estructurar modelos de crecimiento fundamentados en información procesable.

Cada sección parte de condiciones reales observables en la gestión y ejecución de iniciativas emprendedoras. Se describen configuraciones que optimizan la eficiencia organizativa, aumentan la precisión operativa y reducen la dependencia de recursos físicos mediante soluciones basadas en datos. La inteligencia artificial se analiza como infraestructura técnica que habilita decisiones estructuradas, interacción continua con entornos digitales y optimización de operaciones mediante lógica algorítmica.

El análisis incorpora criterios técnicos para evaluar la pertinencia de su implementación, la compatibilidad con arquitecturas operativas existentes y los puntos críticos de integración. Estas condiciones permiten formular decisiones fundamentadas, orientadas a resultados funcionales y coherentes con las limitaciones que enfrentan los proyectos productivos en procesos de consolidación.

La integración de inteligencia artificial en proyectos emprendedores requiere enfoques operativos que articulen capacidades tecnológicas, criterios funcionales y estructuras adaptativas. Este libro proporciona marcos analíticos y herramientas aplicables para abordar esa integración desde una perspectiva sistemática, orientada al diseño eficiente, la validación técnica y la escalabilidad controlada de nuevas iniciativas productivas. El contenido se dirige a personas responsables del diseño, operación y mejora continua de iniciativas que buscan integrar inteligencia artificial como parte estructural de su arquitectura organizativa y lógica de valor.

## CAPÍTULO 1

# LA NUEVA REVOLUCIÓN INDUSTRIAL: EL IMPACTO DE LA INTELIGENCIA ARTIFICIAL

### 1.1 EVOLUCIÓN HISTÓRICA DE LAS REVOLUCIONES TECNOLÓGICAS

A lo largo de la historia, las revoluciones tecnológicas han sido motores fundamentales de transformación estructural en las sociedades humanas. Cada una ha marcado un punto de inflexión, dando paso a nuevos modelos económicos, patrones laborales, estructuras sociales y configuraciones políticas. Estas revoluciones no han ocurrido de manera aislada, sino como procesos acumulativos y evolutivos que se alimentan de las condiciones históricas, científicas y culturales de cada época.

La Primera Revolución Industrial, que tuvo lugar entre finales del siglo XVIII y principios del XIX, supuso la transición de una economía basada en la agricultura y la manufactura artesanal hacia un modelo fabril mecanizado. La invención de la máquina de vapor, atribuida a James Watt, permitió sustituir la fuerza humana y animal por energía mecánica, lo que incrementó radicalmente la productividad (Stearns, 2021). Este periodo se caracterizó por el surgimiento de grandes centros urbanos industriales, la formación de una clase obrera asalariada y el establecimiento de mercados nacionales interconectados. Las industrias textil, minera y metalúrgica fueron pioneras en la adopción de estos nuevos procesos productivos.

La Segunda Revolución Industrial, a partir de 1870, incorporó avances más sofisticados como la electricidad, el motor de combustión interna, la química industrial y la producción en masa. A diferencia de la anterior, esta fase se caracterizó por la estandarización, la eficiencia organizacional y la expansión de infraestructuras como el ferrocarril y la red eléctrica. El modelo fordista, basado en la línea de ensamblaje y la división científica del trabajo, permitió reducir los costos unitarios y democratizar el acceso al consumo (Mokyr, 2016). Este periodo también impulsó una oleada de urbanización acelerada, acompañado de una expansión del sistema bancario, de seguros y del comercio internacional.

En la segunda mitad del siglo XX, la Tercera Revolución Industrial transformó los entornos industriales mediante la integración de la electrónica, la informática y las telecomunicaciones. Las innovaciones como el transistor, los circuitos integrados, los computadores personales y el internet sentaron las bases para una economía digital emergente (Hilbert, 2020). Las empresas comenzaron a utilizar sistemas de planificación de recursos empresariales (ERP) y redes de comunicación para automatizar procesos, reducir errores humanos y tomar decisiones basadas en datos. La digitalización no solo modificó el entorno empresarial, sino también las formas de interacción social, la educación, el comercio minorista y la gestión gubernamental.

En las primeras décadas del siglo XXI, la Cuarta Revolución Industrial ha consolidado un nuevo paradigma basado en la inteligencia artificial, la robótica, el internet de las cosas, la biotecnología, la computación cuántica y el blockchain. Lo distintivo de esta revolución no es solo la aparición de tecnologías nuevas, sino la fusión de las dimensiones física, digital y biológica en un mismo sistema (Schwab, 2016). A diferencia de revoluciones anteriores que afectaban sectores puntuales,

esta transformación abarca todas las industrias y territorios, reconfigurando simultáneamente cadenas de valor, sistemas laborales, relaciones de consumo y estructuras de poder.

### Figura 1

*Las cuatro revoluciones industriales desde el siglo XVIII.*



*Nota.* Tomado de <https://ellisalicante.org/book/inteligencia-artificial-hoy-en-dia>

Los impactos de esta revolución son múltiples. En el plano económico, las empresas que adoptan tecnologías disruptivas tienden a capturar ventajas competitivas significativas, mientras que aquellas que no logran adaptarse enfrentan obsolescencia acelerada. En el plano laboral, la automatización ha desplazado tareas rutinarias, demandando nuevas competencias relacionadas con pensamiento crítico, alfabetización digital y creatividad (UNESCO, 2021b). En el ámbito social, las brechas digitales refuerzan desigualdades estructurales y plantean interrogantes sobre el acceso equitativo a las oportunidades tecnológicas (UNCTAD, 2021).

El fenómeno actual también ha dado lugar a una creciente concentración del poder económico en grandes corporaciones tecnológicas, capaces de controlar ecosistemas digitales

completos. Estas plataformas no solo intermedian servicios, sino que recolectan, analizan y monetizan datos masivos, generando nuevas formas de capital: el capital informacional y el capital de vigilancia (Zuboff, 2019b). Frente a este escenario, los gobiernos y organizaciones internacionales enfrentan el desafío de desarrollar marcos regulatorios que garanticen la ética, la privacidad y la transparencia en el uso de tecnologías emergentes.

Comprender la evolución histórica de las revoluciones tecnológicas permite identificar patrones comunes de cambio y anticipar sus consecuencias futuras. Cada revolución ha venido acompañada de una fase de disrupción, seguida de una fase de estabilización en la que se redefinen las instituciones sociales. En este sentido, el emprendimiento desempeña un rol central como catalizador de la adaptación estructural. Los emprendedores tecnológicos deben asumir la tarea de diseñar soluciones innovadoras que integren no solo eficiencia económica, sino también impacto social positivo y sostenibilidad ambiental.

Hoy más que nunca, el conocimiento de estas transformaciones no puede limitarse al estudio del pasado. Es necesario vincular la comprensión histórica con una visión prospectiva que permita actuar con responsabilidad en un entorno tecnológico en constante evolución. La formación en historia de la tecnología, economía digital, gobernanza algorítmica y ética computacional se vuelve indispensable para todos los actores involucrados en la construcción del futuro.

## **1.2 PRINCIPALES TECNOLOGÍAS QUE COMPONEN LA INTELIGENCIA ARTIFICIAL**

La inteligencia artificial (IA) integra un conjunto avanzado de tecnologías diseñadas para simular procesos cognitivos humanos, optimizar la toma de decisiones y ejecutar tareas

con grados crecientes de autonomía. Su desarrollo reciente ha sido impulsado por la maduración de modelos algorítmicos, la expansión del acceso a datos masivos y la mejora constante del hardware computacional. En los últimos años, el campo ha evolucionado hacia sistemas más robustos, adaptativos y escalables, donde convergen múltiples disciplinas como la estadística, la neurociencia computacional, la lingüística computacional y la ingeniería del conocimiento.

El aprendizaje automático (machine learning) continúa siendo uno de los núcleos más activos de la IA. Los modelos de clasificación, regresión y clustering han sido optimizados mediante nuevas arquitecturas que permiten el procesamiento eficiente de grandes volúmenes de datos, incluso en tiempo real. En particular, las técnicas de aprendizaje por refuerzo profundo (deep reinforcement learning) han tenido un notable avance en aplicaciones como la robótica de control fino, el entrenamiento de agentes virtuales y el desarrollo de videojuegos interactivos. En años recientes, modelos como AlphaZero y MuZero han demostrado que estos sistemas pueden aprender estrategias complejas sin conocimientos previos codificados (Terven, 2025).

El aprendizaje profundo (deep learning), basado en redes neuronales de múltiples capas, ha permitido mejorar tareas como la detección de anomalías en sistemas críticos, la predicción de fallas en procesos industriales y la segmentación automática de imágenes médicas. A partir de 2020, se ha intensificado el entrenamiento de modelos de gran escala, lo que ha llevado al surgimiento de arquitecturas multimodales capaces de interpretar simultáneamente texto, imagen y audio. Modelos como CLIP y Flamingo han ampliado la capacidad de generalización de las redes neuronales y su aplicabilidad en entornos abiertos (Alayrac et al., 2022; Radford et al., 2021).

En el campo del procesamiento del lenguaje natural (PLN), se han consolidado modelos fundacionales (foundation models) como GPT-4, PaLM y LLaMA, entrenados con billones de parámetros y con capacidad de adaptación a múltiples tareas sin necesidad de ajustes finos extensivos. Estas arquitecturas han permitido avanzar en herramientas de productividad asistida, generación de código, síntesis de documentos legales y atención automatizada en múltiples idiomas. Desde 2021, la tendencia ha sido desarrollar modelos alineados éticamente y capaces de ofrecer explicaciones sobre sus respuestas, en un intento por mejorar la confiabilidad y transparencia de los sistemas (Bommasani et al., 2023).

La visión por computadora también ha experimentado una expansión significativa, especialmente en entornos industriales y de seguridad. Con el uso de aprendizaje auto-supervisado y transformadores visuales (Vision Transformers), las soluciones actuales pueden identificar patrones visuales sin necesidad de grandes bases de datos etiquetadas. En aplicaciones urbanas, las cámaras conectadas con IA son capaces de monitorear flujos vehiculares, detectar comportamientos sospechosos y generar alertas automáticas en plataformas de vigilancia inteligente (Caron et al., 2021).

Otra línea de desarrollo reciente son los sistemas de IA generativa. Los modelos de generación de imágenes, video y sonido como DALL·E, Midjourney y MusicLM han facilitado procesos creativos en diseño, producción audiovisual y simulación. Su despliegue en contextos educativos, publicitarios y científicos ha evidenciado su capacidad de expandir los límites de la creatividad humana, aunque también ha suscitado debates éticos sobre autenticidad, derechos de autor y manipulación (Tan & Luhrs, 2024).

En cuanto a los sistemas de recomendación, el foco se ha desplazado hacia la personalización responsable y la reduc-

ción de sesgos algorítmicos. En plataformas de contenido y comercio electrónico se han integrado técnicas de aprendizaje federado, que permiten el entrenamiento de modelos personalizados directamente en el dispositivo del usuario sin comprometer su privacidad. Esto ha mejorado la calidad de las sugerencias, preservando la confidencialidad de los datos personales (Yang et al., 2020).

Los avances en robótica inteligente han consolidado la interacción fluida entre humanos y máquinas, especialmente en entornos colaborativos. Desde 2020, se ha incrementado el uso de robots móviles autónomos en centros logísticos, almacenes automatizados y espacios hospitalarios. Equipados con sensores LIDAR, visión estéreo y algoritmos de mapeo dinámico, estos dispositivos realizan tareas con autonomía parcial o total, adaptándose a condiciones cambiantes y a la presencia humana sin comprometer la seguridad (Huang & Lin, 2023).

Paralelamente, los sistemas multiagente y la inteligencia artificial distribuida han evolucionado para dar soporte a ecosistemas descentralizados, donde diferentes unidades inteligentes interactúan para alcanzar objetivos comunes. Esto se observa en flotas de drones, redes eléctricas inteligentes y sistemas de transporte multimodal que optimizan rutas y recursos en tiempo real. Estas arquitecturas permiten escalar la inteligencia artificial más allá de un solo nodo de procesamiento, promoviendo la toma de decisiones compartida (Han et al., 2024).

El futuro inmediato apunta hacia una integración aún más estrecha entre tecnologías de IA y sistemas ciberfísicos, donde la IA no solo analiza datos, sino que también interviene directamente en la gestión y el control de procesos físicos. Esta tendencia ya se manifiesta en sectores como la fabricación aditiva, en la cual algoritmos de IA optimizan en tiempo real

las condiciones de impresión y los parámetros de materiales para mejorar el rendimiento estructural de los productos (Razvi et al., 2019). Asimismo, en los sistemas energéticos inteligentes, la inteligencia artificial permite predecir patrones de consumo, ajustar la distribución de recursos y reducir pérdidas energéticas, contribuyendo a la eficiencia y sostenibilidad del sector (Alsaigh et al., 2023). En el ámbito de la salud digital, dispositivos médicos conectados incorporan IA para realizar monitoreo continuo de signos vitales, alertar en tiempo real sobre situaciones anómalas y sugerir intervenciones clínicas automatizadas, lo que mejora la respuesta ante eventos críticos y reduce tiempos de atención (Topol, 2019). Estas aplicaciones evidencian que la convergencia entre IA, sensores inteligentes y automatización está transformando profundamente los procesos industriales, sanitarios y energéticos.

### **1.3 CAMBIOS ESTRUCTURALES EN LA ECONOMÍA GLOBAL IMPULSADOS POR IA**

La integración de la inteligencia artificial en los sistemas productivos y organizacionales está provocando transformaciones estructurales profundas en la economía global. A diferencia de innovaciones tecnológicas previas, la IA no solo introduce eficiencia o automatización en procesos existentes, sino que altera los fundamentos sobre los cuales se estructuran las cadenas de valor, se asignan los recursos y se compite en los mercados. Esta transformación es impulsada por la capacidad de la IA para procesar datos a gran escala, generar conocimiento accionable y aprender de forma autónoma, lo que le permite modificar dinámicas económicas tradicionales y reconfigurar sectores completos.

Uno de los principales impactos se observa en la reasignación del capital hacia activos intangibles. Las empresas líderes en adopción de IA invierten crecientemente en algo-

ritmos, plataformas digitales, infraestructura en la nube y talento especializado, relegando el peso relativo del capital físico tradicional. Esta transición hacia una economía basada en conocimiento y datos ha generado una concentración de valor en empresas intensivas en propiedad intelectual y capacidades algorítmicas, especialmente en sectores como tecnología, servicios financieros, telecomunicaciones y comercio electrónico (Corrado et al., 2021).

La IA también ha modificado la estructura de costos de producción y el modelo de escalabilidad. Gracias a los sistemas inteligentes, las empresas pueden ofrecer productos y servicios personalizados a gran escala sin incurrir en costos marginales significativos. Este fenómeno ha permitido la aparición de plataformas digitales con rendimientos crecientes a escala, lo que ha derivado en economías de red altamente concentradas. Empresas como Google, Amazon, Tencent y Alibaba han logrado posicionarse como infraestructuras globales sobre las cuales operan miles de servicios terciarios, generando dependencia estructural en los ecosistemas empresariales (Jorzik et al., 2024).

Otro cambio estructural se relaciona con la redefinición del trabajo y las competencias laborales. La automatización inteligente ha desplazado ciertas tareas rutinarias, tanto manuales como cognitivas, dando lugar a una nueva división del trabajo entre humanos y máquinas. Las ocupaciones con mayor crecimiento corresponden a roles que integran habilidades técnicas con capacidades sociales, pensamiento crítico y adaptabilidad. A la par, se ha incrementado la polarización laboral, con una demanda creciente de talento altamente calificado y una reducción progresiva de empleos intermedios, lo que plantea implicaciones distributivas importantes.

La inteligencia artificial también ha inducido transformaciones en las cadenas globales de suministro. Gracias al aná-

lisis predictivo, los sistemas de IA pueden anticipar fluctuaciones en la demanda, identificar interrupciones logísticas y reconfigurar rutas en tiempo real. Esto ha incrementado la resiliencia operativa en sectores como manufactura avanzada, logística, comercio internacional y alimentación. Asimismo, permite el diseño de cadenas de suministro más descentralizadas, localizadas y personalizadas, reduciendo los costos de transporte y mitigando los riesgos asociados a shocks globales (Wang et al., 2024).

En el plano financiero, los sistemas algorítmicos han cambiado las reglas de inversión, gestión de riesgos y asignación de crédito. La banca y los seguros emplean modelos de IA para evaluar perfiles de clientes, detectar fraudes, ofrecer servicios personalizados y prever escenarios de riesgo sistémico. Las fintech han ganado terreno mediante soluciones que automatizan la toma de decisiones financieras, permitiendo modelos de negocio más ágiles, segmentados y de bajo costo operativo. Este entorno ha impulsado una transformación estructural del sistema financiero tradicional, que ahora compete con actores tecnológicos en la provisión de servicios críticos (Almansour, 2023).

La dinámica de innovación también ha sido impactada por la IA, al permitir ciclos de desarrollo más rápidos y experimentación continua. A través de simulaciones digitales, modelos generativos y análisis automatizado, las organizaciones pueden reducir los tiempos de validación, prototipado y despliegue de nuevos productos. Esto es particularmente visible en la industria farmacéutica, donde la IA ha acelerado procesos de descubrimiento de moléculas, pruebas clínicas y adaptación de tratamientos personalizados, modificando el marco competitivo global en biotecnología (Y. H. Li et al., 2024).

En paralelo, la integración de IA en sectores públicos está transformando la gobernanza económica. Gobiernos adoptan

herramientas algorítmicas para monitorear mercados, predecir recaudación fiscal, gestionar subsidios, distribuir recursos y planificar infraestructura. Esta tendencia apunta hacia una administración pública basada en evidencia y en datos masivos, aunque plantea también tensiones en torno a la equidad algorítmica, la protección de datos personales y la transparencia en la toma de decisiones automatizada.

Desde una perspectiva geoeconómica, la adopción diferencial de la IA está reconfigurando las posiciones relativas de los países. Aquellos con capacidades tecnológicas más avanzadas y ecosistemas digitales robustos están capturando una mayor proporción del valor económico generado por estas tecnologías. China, Estados Unidos, la Unión Europea, Corea del Sur e Israel lideran el desarrollo de infraestructura, patentes y talento en IA, lo que genera ventajas competitivas difíciles de replicar a corto plazo. Esto alimenta nuevas dinámicas de competencia estratégica y riesgo de fragmentación tecnológica, particularmente en dominios como defensa, semiconductores y telecomunicaciones (Thoenig, 2024).

Las implicaciones estructurales de la inteligencia artificial se extienden también al diseño institucional de los mercados. Nuevos actores entran a competir en sectores previamente regulados, lo que desafía las normativas tradicionales. Se requiere una adaptación de los marcos legales para regular plataformas, proteger derechos digitales, establecer estándares éticos y evitar posiciones dominantes que afecten la libre competencia. En este sentido, la gobernanza de la IA se convierte en un componente esencial del nuevo orden económico global, con implicaciones para la justicia distributiva, la sostenibilidad y la inclusión digital (Alalawi et al., 2024).

## **1.4 MODELOS DE NEGOCIO EMERGENTES EN LA ERA ALGORÍTMICA**

El avance de la inteligencia artificial ha propiciado el surgimiento de nuevos modelos de negocio caracterizados por la automatización de decisiones, la hiperpersonalización de servicios y la creación de valor a partir de datos. En la era algorítmica, la ventaja competitiva ya no radica exclusivamente en el acceso a recursos tangibles o en economías de escala tradicionales, sino en la capacidad de diseñar sistemas inteligentes que aprenden, se adaptan y escalan de manera autónoma. Esta transición ha redefinido las estrategias empresariales, provocando un giro desde estructuras lineales hacia plataformas abiertas, colaborativas y basadas en inteligencia computacional.

Uno de los modelos más destacados es el negocio basado en plataformas, donde las empresas no venden directamente un producto, sino que intermedian transacciones entre múltiples actores utilizando algoritmos para facilitar coincidencias, predecir comportamientos y optimizar resultados. Plataformas como Uber, Airbnb, Alibaba o MercadoLibre utilizan IA para ajustar dinámicamente precios, clasificar oferentes, detectar fraudes y mejorar la experiencia del usuario. Estas organizaciones operan bajo esquemas de rendimientos crecientes a escala de datos: mientras más usuarios participan, más datos se generan y más precisos se vuelven sus algoritmos (Van et al., 2016).

En paralelo, han emergido modelos de negocio basados en la suscripción algorítmica. Servicios como Netflix, Spotify o Coursera emplean inteligencia artificial para ofrecer contenido personalizado en tiempo real, con base en las preferencias y hábitos del usuario. Esta personalización no solo mejora la retención de clientes, sino que permite una segmentación continua, automatizando recomendaciones, actualizando in-

terfaces y priorizando contenidos según perfiles individuales. La IA actúa como motor de relación con el cliente, maximizando el tiempo de uso, la satisfacción percibida y el valor de vida del consumidor (Agrawal et al., 2018).

El modelo as-a-service también ha ganado tracción gracias a la IA. En este esquema, empresas comercializan capacidades algorítmicas como servicios bajo demanda. Startups y grandes corporaciones pueden acceder a motores de análisis predictivo, reconocimiento de imagen, procesamiento de lenguaje natural o automatización de procesos robóticos sin necesidad de desarrollarlos internamente. Empresas como Google Cloud, Microsoft Azure y Amazon Web Services ofrecen APIs de IA que permiten a terceros construir soluciones inteligentes de forma modular, reduciendo barreras de entrada y acelerando la innovación en sectores no tecnológicos (Lins et al., 2021a).

Asimismo, se observa un crecimiento en modelos híbridos de monetización algorítmica. Por ejemplo, algunas compañías combinan ventas de productos físicos con servicios digitales basados en IA. En el sector automotriz, fabricantes integran sistemas de asistencia al conductor, predicción de mantenimiento y actualización remota de software, lo que transforma el vehículo en una plataforma conectada de generación de datos y servicios. En la agricultura de precisión, sensores y drones combinados con algoritmos permiten vender recomendaciones sobre riego, fertilización y cosecha, añadiendo valor al producto mediante inteligencia embebida (Cavazza et al., 2023).

La economía de la atención ha sido profundamente transformada por la inteligencia artificial. Plataformas como YouTube, TikTok, Instagram o Facebook utilizan algoritmos de aprendizaje profundo para maximizar el tiempo de exposición de los usuarios, seleccionando contenidos que capturan su in-

terés con alta precisión. Estos sistemas no solo monetizan el tiempo mediante publicidad personalizada, sino que optimizan sus estructuras de monetización con base en el análisis de engagement, contexto de navegación y respuesta emocional. El negocio algorítmico se convierte así en una ingeniería de estímulos, capaz de predecir y modular comportamientos a escala (Zuboff, 2019a).

Otro modelo emergente es el de los gemelos digitales potenciados por IA. Estas representaciones virtuales de productos, procesos o usuarios permiten simular comportamientos y evaluar escenarios antes de ejecutar decisiones en el mundo real. Empresas en los sectores de energía, manufactura, salud y ciudades inteligentes están adoptando estos modelos para optimizar recursos, predecir fallos, reducir costos y acelerar tiempos de desarrollo. La inteligencia artificial en estos entornos se integra con sensores IoT, big data y simulación computacional, generando ecosistemas inteligentes donde el modelo digital aprende de su contraparte física y viceversa (Adelsberger et al., 2024).

En entornos empresariales tradicionales, la IA también ha permitido la creación de modelos de negocio basados en eficiencia automatizada. Desde la generación automática de reportes financieros, hasta la optimización logística o la gestión del talento humano, las soluciones basadas en IA reducen costos operativos, minimizan errores y aceleran procesos de decisión. La ventaja comparativa en estos modelos no proviene del producto final, sino del proceso interno altamente optimizado, difícilmente replicable sin capacidades algorítmicas avanzadas (Davenport & Ronanki, 2018).

Por último, destaca el surgimiento de modelos basados en inteligencia artificial generativa. Empresas creativas y tecnológicas incorporan IA para diseñar productos, componer música, redactar textos o producir contenido audiovisual. Estos

modelos permiten crear a partir de datos existentes, abriendo posibilidades para la producción masiva de contenidos sin intervención humana directa. Aunque todavía en etapa temprana de monetización, este enfoque ya está siendo aplicado en marketing automatizado, diseño gráfico, videojuegos y moda digital, estableciendo nuevas cadenas de valor (Bommasani et al., 2021).

El desarrollo de modelos de negocio en la era algorítmica no solo transforma sectores, sino que impone nuevas reglas de competencia, nuevos indicadores de desempeño y nuevas formas de interacción con el mercado. Las organizaciones que logran integrar inteligencia artificial no como una herramienta puntual, sino como base estructural de su modelo, están posicionadas para liderar en entornos caracterizados por velocidad, complejidad y personalización radical.

### **1.5 DESPLAZAMIENTO DE INDUSTRIAS Y CREACIÓN DE NUEVOS ECOSISTEMAS**

El impacto de la inteligencia artificial sobre la economía no se limita a la optimización de procesos existentes. Su capacidad de reconfigurar cadenas de valor, transformar estructuras sectoriales y generar dinámicas económicas inéditas está desplazando industrias tradicionales y dando lugar a nuevos ecosistemas productivos y organizacionales. Este proceso no es simplemente una transición tecnológica, sino una recomposición profunda de actores, competencias, infraestructuras y modelos de interacción en la actividad económica global.

Industrias tradicionales como la manufactura, la agricultura, el transporte o los servicios financieros están siendo transformadas por la automatización inteligente, la integración de sensores, el análisis predictivo y la toma de decisiones algorítmica. Estas transformaciones no son uniformes: en algunos casos, implican la desaparición progresiva de activi-

dades poco adaptables a la digitalización; en otros, abren espacios para su reconversión mediante la adopción de herramientas basadas en datos. Por ejemplo, en la agricultura, los sistemas de IA permiten gestionar cultivos de forma precisa, automatizar el monitoreo y reducir desperdicios, configurando un nuevo modelo de producción agroindustrial tecnificada (Wolfert et al., 2017).

En el ámbito manufacturero, la denominada industria 4.0 ha incorporado la inteligencia artificial para optimizar la producción, anticipar fallos, gestionar inventarios y personalizar productos en línea. Empresas que antes operaban con márgenes reducidos y tiempos de producción prolongados han mejorado su eficiencia mediante la integración de IA con robótica avanzada, big data y sistemas ciberfísicos. Esta transformación genera nuevos roles laborales, al tiempo que elimina puestos intermedios no adaptados a los entornos automatizados. La creación de fábricas inteligentes se acompaña de un nuevo ecosistema de proveedores de software, servicios de mantenimiento algorítmico y capacitación digital (Kamble et al., 2018).

En el sector transporte, la inteligencia artificial está modificando radicalmente las operaciones logísticas, la planificación de rutas, la gestión de flotas y la movilidad urbana. Empresas como Amazon, UPS y DHL han integrado modelos de predicción de demanda y algoritmos de asignación dinámica para optimizar la última milla, reducir tiempos de entrega y minimizar costos operativos. Al mismo tiempo, la conducción autónoma y los sistemas inteligentes de tráfico están transformando la relación entre las ciudades y la movilidad, dando lugar a un nuevo ecosistema de infraestructura urbana inteligente, fabricantes de vehículos autónomos, plataformas de datos de tránsito y proveedores de soluciones integradas (Litman, 2025).

En los servicios financieros, la IA ha desplazado modelos convencionales de atención, análisis de riesgo, segmentación de mercado y toma de decisiones. Fintechs y neobancos emplean algoritmos para automatizar procesos de originación de crédito, gestión de inversiones y prevención de fraudes. Estas innovaciones no solo compiten con bancos tradicionales, sino que configuran un ecosistema alternativo basado en interfaces digitales, plataformas móviles y microsegmentación algorítmica, lo que obliga a la industria financiera a redefinir su arquitectura tecnológica y su relación con el cliente (Vuković et al., 2025).

Más allá del desplazamiento sectorial, la inteligencia artificial ha catalizado la emergencia de ecosistemas económicos completamente nuevos. Uno de ellos es el entorno de los datos como servicio (DaaS), donde empresas monetizan datos estructurados, etiquetados y contextualizados mediante suscripción o licenciamiento. Este mercado ha creado un circuito autónomo de recolectores, curadores, etiquetadores y distribuidores de datos que interactúan con desarrolladores de IA, generando nuevas profesiones y modelos de especialización (Sobila, 2023).

Otro ecosistema emergente es el de la economía de la computación distribuida. Con el crecimiento del entrenamiento de modelos de gran escala, se ha intensificado la demanda por poder computacional descentralizado. Plataformas como Hugging Face, Runway o Stability AI han articulado redes de colaboración en código abierto, hardware compartido y comunidades técnicas, facilitando el acceso a capacidades algorítmicas avanzadas sin requerimientos centralizados. Esta lógica de redes ha transformado la dinámica de innovación, trasladándola a espacios abiertos, fluidos y altamente iterativos (Mueller, 2025).

La inteligencia artificial también ha habilitado ecosistemas

de productos y servicios completamente digitales. Las empresas de software como servicio (SaaS) integran motores de recomendación, chatbots, análisis de sentimiento y automatización en sus soluciones, ofreciendo herramientas personalizadas en ámbitos como educación, salud, recursos humanos y marketing. Este enfoque permite que pequeñas organizaciones accedan a inteligencia avanzada sin necesidad de desarrollarla internamente, democratizando el acceso a la tecnología y descentralizando la innovación (Lins et al., 2021b).

La IA está modificando las relaciones entre actores económicos en términos de colaboración, competencia y gobernanza. Los nuevos ecosistemas tienden a estructurarse en torno a plataformas tecnológicas, nodos de datos y estándares compartidos, en lugar de cadenas lineales de suministro. La colaboración entre empresas, gobiernos, universidades y startups se articula mediante hubs de innovación, acuerdos de interoperabilidad y coaliciones éticas, lo que da lugar a una gobernanza algorítmica distribuida. En este marco, los ecosistemas no solo compiten por eficiencia, sino por su capacidad de adaptación, transparencia y responsabilidad tecnológica (Righi et al., 2020).

La irrupción de la inteligencia artificial no implica un simple reemplazo de industrias por otras, sino la creación de entramados económicos nuevos, basados en flujos de datos, infraestructura digital, aprendizaje automatizado y cooperación distribuida. Entender y participar en estos ecosistemas resulta clave para cualquier organización que aspire a mantenerse relevante en un entorno económico redefinido por la inteligencia computacional.

## CAPÍTULO 2

### EL ADN DEL NUEVO EMPRENDEDOR TECNOLÓGICO

#### **2.1 PERFIL DEL EMPRENDEDOR DIGITAL FRENTE AL TRADICIONAL**

El emprendedor digital se diferencia del tradicional por la lógica sobre la cual construye su modelo de negocio, accede a recursos, gestiona su operación y se vincula con el mercado. Mientras el perfil tradicional se centra en estructuras jerárquicas, activos físicos y segmentación local, el emprendedor digital se apoya en activos intangibles, redes distribuidas, plataformas globales y decisiones fundamentadas en datos. Esta transformación exige un análisis detallado de sus características operativas, competencias técnicas, formas de interacción y procesos de aprendizaje (Nambisan, 2017).

El enfoque teórico que permite entender esta transformación encuentra sustento en la teoría de las capacidades dinámicas. Esta teoría sostiene que en entornos cambiantes, las organizaciones y los individuos exitosos no solo dependen de sus recursos actuales, sino de su habilidad para integrarlos, reconfigurarlos y transformarlos conforme a nuevas oportunidades del entorno. En el caso del emprendimiento digital, estas capacidades se expresan en la habilidad para implementar nuevos modelos de negocio, escalar productos mediante plataformas digitales y adaptarse a patrones emergentes de consumo impulsados por algoritmos y sistemas de automatización (Teece, 2018).

A nivel operativo, el emprendimiento digital parte de una infraestructura basada en servicios como computación en la nube, plataformas de pago en línea, sistemas de gestión de contenido y herramientas colaborativas. Este entorno reduce significativamente los costos fijos y permite escalar operaciones sin requerimientos proporcionales de inversión. La toma de decisiones se sustenta en el análisis de métricas obtenidas de forma automatizada a través de plataformas como Google Analytics, HubSpot o Meta Business Suite, donde cada interacción del usuario aporta información útil para rediseñar productos, ajustar precios o definir campañas (George et al., 2021).

Las competencias que definen al emprendedor digital combinan habilidades técnicas con pensamiento estratégico. La capacidad de manipular datos, configurar automatizaciones, interactuar con APIs y evaluar herramientas de inteligencia artificial se integra con una visión de negocio centrada en la iteración continua. Este tipo de emprendimiento no se estructura en función de una planificación lineal, sino mediante la validación permanente de hipótesis de valor, impulsada por ciclos cortos de prueba y corrección. La incorporación de metodologías como Lean Startup permite minimizar el riesgo asociado al desarrollo de productos y adaptarse con rapidez a las señales del mercado.

Otra teoría relevante es la de la internacionalización temprana (born global), la cual explica cómo muchas startups digitales apuntan desde su concepción a mercados internacionales. Esta estrategia se justifica por la naturaleza digital del producto o servicio, su escalabilidad y la reducción de barreras físicas o regulatorias en entornos tecnológicos. Plataformas como Amazon, Shopify o App Store permiten validar productos en múltiples regiones simultáneamente, lo cual redefine los criterios tradicionales de expansión por etapas (Oviatt & McDougall, 2005).

Figura 2

Perfil de Habilidades del Emprendedor con IA



El acceso a recursos adopta una forma modular y desagregada. A diferencia de los modelos tradicionales que requieren oficinas, inventarios y personal fijo, el emprendimiento digital se apoya en modelos de outsourcing, marketplaces,

freelancers, software como servicio y redes de aprendizaje continuo (Autio et al., 2018). Plataformas como GitHub, Stack Overflow y Udemy permiten adquirir o intercambiar conocimiento especializado, mientras que otras como Stripe Atlas o Deel facilitan la constitución legal y operación remota de empresas. Esta arquitectura basada en nodos interconectados permite responder con rapidez a oportunidades, sin comprometer estructuras organizativas pesadas.

El tipo de relación con el cliente también difiere sustancialmente. El emprendedor digital construye esta relación sobre canales asincrónicos, automatizados y altamente personalizados. Los formularios de contacto son reemplazados por chatbots, la segmentación demográfica se transforma en análisis de comportamiento y la experiencia del usuario se mide en tiempo real. Esta lógica permite implementar cambios inmediatos según los patrones de navegación, tasas de conversión, clics por sesión o nivel de retención (George et al., 2021).

En cuanto a la construcción de identidad emprendedora, los estudios de Maritz & Brown (2013), destacan que el perfil digital incorpora una dimensión pedagógica continua, en la cual el aprendizaje se integra como una actividad esencial del negocio. Este aprendizaje no solo incluye aspectos técnicos, sino también sociales, regulatorios, financieros y éticos, lo que amplía el campo de formación requerida para la sostenibilidad del emprendimiento. La gestión del riesgo reputacional en plataformas digitales, la gobernanza algorítmica y la protección de datos se han incorporado como competencias estratégicas para operar con legitimidad en entornos complejos.

Mientras el emprendedor tradicional prioriza estabilidad, estructura y consolidación, el emprendedor digital opera bajo principios de agilidad, flexibilidad y optimización continua.

Este contraste implica un rediseño de las métricas con las que se mide el éxito, la forma de gestionar talento, la estructura de costos y la lógica de relación con el cliente. La digitalización del emprendimiento no consiste en reemplazar un modelo por otro, sino en integrar capacidades tecnológicas con una lógica organizativa adecuada al entorno actual. La evolución del perfil emprendedor no es homogénea, pero la tendencia dominante se orienta hacia la capacidad de combinar herramientas tecnológicas con una mentalidad adaptable, analítica y enfocada en el crecimiento escalable (Ratten, 2020).

## **2.2 COMPETENCIAS CLAVE EN TIEMPOS DE AUTOMATIZACIÓN**

La automatización inteligente, en su expansión acelerada dentro de los sistemas productivos y organizacionales, ha alterado de manera estructural la naturaleza del trabajo, la demanda de habilidades y la forma en que las personas interactúan con las tecnologías. En este entorno, la identificación precisa de competencias clave es un proceso estratégico, necesario para el diseño de perfiles profesionales relevantes, la formulación de políticas de formación y la adaptación de las organizaciones a nuevos patrones operativos (World Economic Forum, 2023). El concepto de competencia, entendido como el conjunto articulado de conocimientos, habilidades y actitudes aplicables en situaciones reales, debe ser interpretado desde una perspectiva funcional, orientada a resultados y adaptabilidad sostenida. La automatización no elimina el trabajo humano, sino que transforma su contenido, reorganiza las tareas y redefine el valor agregado que se espera de los individuos (Deloitte, 2023).

Las competencias tecnológicas operativas ocupan un lugar central en este nuevo esquema. No se trata únicamente del uso instrumental de herramientas digitales, sino de la capa-

idad para comprender su lógica, integrar funcionalidades y adaptarlas a procesos específicos. Esta categoría incluye la gestión de datos, la programación básica, la manipulación de sistemas automatizados, el trabajo en entornos de nube y la comprensión del flujo de información en plataformas inteligentes. La integración de estas capacidades permite reducir tiempos, minimizar errores y generar interacciones más eficientes entre humanos y máquinas (Bughin et al., 2018). En sectores como la logística, el comercio digital o la manufactura avanzada, estas competencias determinan el rendimiento operativo y la posibilidad de integración en cadenas de suministro digitalizadas.

En paralelo, se requieren competencias analíticas orientadas a la resolución de problemas no estructurados. La automatización tiende a absorber las tareas rutinarias, delegando a las personas aquellas que implican interpretación, síntesis y juicio. El análisis de datos, la modelización de escenarios, la evaluación de impactos y la toma de decisiones informadas constituyen capacidades clave (OECD, 2022). Estas competencias deben articularse con habilidades lógicas y estructurales, capaces de generar sentido en condiciones de ambigüedad y responder con soluciones fundamentadas ante situaciones cambiantes. No se trata únicamente de interpretar gráficos o indicadores, sino de traducir información en decisiones estratégicas con consecuencias operativas.

La adaptabilidad como competencia transversal cobra relevancia en entornos de automatización sostenida. El aprendizaje permanente, la disposición al cambio y la capacidad para reconfigurar el propio desempeño profesional son indicadores funcionales de esta competencia. Las plataformas digitales, al renovar constantemente sus entornos y herramientas, exigen una mentalidad orientada a la actualización continua. Esta adaptabilidad no se limita a lo técnico, sino que abarca

marcos normativos, modelos de negocio, contextos culturales y dinámicas sociales. La capacidad para incorporar nuevos conceptos, reorganizar rutinas y adquirir competencias emergentes es el principal factor de resiliencia profesional ante la transformación tecnológica (World Economic Forum, 2023).

Las competencias interpersonales toman una nueva dimensión bajo condiciones de trabajo mediadas por sistemas automatizados y estructuras organizativas descentralizadas. La colaboración entre perfiles diversos, la gestión de equipos distribuidos, la comunicación asincrónica y la coordinación de tareas en plataformas digitales requieren habilidades específicas. Estas incluyen la argumentación efectiva, la negociación, la formulación de instrucciones claras, la documentación de decisiones y la transmisión eficiente de conocimiento tácito. Estas capacidades, cuando se integran en contextos tecnológicos, amplifican su impacto operativo al permitir que los sistemas inteligentes funcionen como soporte y no como obstáculo de la interacción humana (Deloitte, 2023).

La dimensión ética y regulatoria de las competencias adquiere una importancia creciente. La automatización conlleva riesgos asociados a la privacidad, la discriminación algorítmica, la transparencia en la toma de decisiones y la manipulación de resultados. La capacidad para identificar estos riesgos, comprender los marcos normativos aplicables y diseñar procesos que respeten principios de justicia, equidad y sostenibilidad se ha incorporado como parte del repertorio de competencias críticas. No se trata de formación jurídica especializada, sino de habilidades prácticas para integrar la dimensión ética en la gestión cotidiana de tecnologías automatizadas (Floridi, 2023). En sectores como la salud, la educación, la seguridad o las finanzas, esta competencia no es complementaria, sino estructural.

La automatización exige competencias emprendedoras que permitan detectar oportunidades en las disrupciones, generar soluciones creativas y construir modelos de negocio compatibles con el entorno tecnológico. La iniciativa, la orientación a resultados, la gestión de incertidumbre y la capacidad para movilizar recursos limitados se constituyen como competencias diferenciadoras. La automatización no suprime la función emprendedora, sino que la eleva al nivel de diseñar sistemas de creación de valor donde las tecnologías son instrumentos y no fines en sí mismos (Bughin et al., 2018). El conocimiento del comportamiento del usuario, la capacidad para prototipar soluciones y la articulación de redes de colaboración se convierten en vectores clave para el aprovechamiento de la automatización como palanca de desarrollo organizacional.

Las competencias clave en tiempos de automatización no son fijas ni homogéneas, sino que evolucionan junto con las tecnologías, los sectores y las expectativas sociales. El enfoque que privilegia la integración entre lo técnico, lo analítico, lo adaptativo, lo interpersonal, lo ético y lo emprendedor permite diseñar perfiles profesionales que no solo se ajustan a los cambios, sino que contribuyen activamente a configurarlos. Este tipo de competencias construye entornos de trabajo sostenibles, colaborativos y orientados a resultados medibles y pertinentes.

### **2.3 PENSAMIENTO COMPUTACIONAL Y MENTALIDAD ALGORÍTMICA**

El pensamiento computacional constituye una competencia estructural orientada a la resolución de problemas mediante procesos lógicos, sistemáticos y reproducibles. Incluye la capacidad para descomponer problemas complejos, identificar patrones, abstraer estructuras clave y formular

soluciones bajo la forma de algoritmos implementables. Esta habilidad, inicialmente asociada a la informática, se ha consolidado como un mecanismo cognitivo transversal aplicable en distintos campos técnicos, científicos y productivos. Según Sarmiento et al. (2023), su valor funcional radica en su utilidad para estructurar razonamientos, mejorar la precisión en el diagnóstico de situaciones complejas y diseñar soluciones que puedan replicarse o automatizarse.

La mentalidad algorítmica se configura como un marco cognitivo complementario, basado en el razonamiento estructurado a partir de condiciones, ciclos, secuencias y bifurcaciones lógicas. Esta mentalidad permite concebir procesos como sistemas compuestos de instrucciones evaluables, donde las decisiones pueden estructurarse en bloques de operaciones predefinidas. En el análisis de Song et al. (2021), esta forma de pensar no solo facilita la creación de soluciones programables, sino también la comprensión operativa de procesos complejos que requieren control, trazabilidad y posibilidad de mejora iterativa.

Los estudios recientes han señalado que el desarrollo del pensamiento computacional mejora el desempeño en la resolución de problemas que requieren análisis de datos, toma de decisiones estructuradas y modelado funcional. Tsarava et al. (2022), evidencian que estudiantes y profesionales que desarrollan esta competencia son más efectivos en tareas de síntesis de información, diseño de escenarios simulados y evaluación de variables críticas bajo condiciones de incertidumbre. Estas capacidades permiten un abordaje analítico que reemplaza la intuición por estructuras racionales medibles.

Una línea de investigación consolidada es la expansión del pensamiento computacional más allá del campo informático. Martin et al. (2020), analizaron su aplicabilidad en educación, biomedicina, ingeniería y economía, encontrando que la

transferencia de esta competencia mejora la capacidad para descomponer problemas técnicos, organizar el conocimiento en módulos funcionales y plantear soluciones articuladas en fases o ciclos. Esta habilidad resulta especialmente relevante en procesos automatizados, donde la lógica secuencial y la coherencia operativa son condiciones básicas para garantizar precisión y eficiencia.

El desarrollo de estas capacidades exige enfoques pedagógicos que integren teoría y práctica mediante metodologías basadas en proyectos, resolución de casos y simulación. Grover et al. (2022), proponen un modelo evaluativo que articula dimensiones conceptuales (entendimiento de estructuras computacionales), prácticas (implementación de procesos de prueba, depuración y evaluación) y disposiciones (autonomía en el diseño de soluciones, pensamiento lógico y atención a condiciones límite). Estas dimensiones permiten estructurar procesos de enseñanza que van más allá de la codificación y fomentan una comprensión profunda de la lógica de los sistemas digitales.

El pensamiento computacional y la mentalidad algorítmica permiten estructurar decisiones, optimizar flujos de información, construir soluciones replicables y establecer marcos de validación empírica. Estas competencias no solo habilitan el uso eficaz de herramientas digitales, sino que capacitan para participar activamente en el diseño, auditoría y mejora de procesos basados en datos. En entornos técnicos y organizacionales, su valor reside en la posibilidad de abstraer la lógica subyacente a sistemas complejos y traducirla en soluciones controlables, adaptables y transferibles a múltiples dominios de aplicación.

En el caso de los emprendedores tecnológicos, el pensamiento computacional resulta clave para el diseño de productos escalables, la estructuración de soluciones digitales y

la creación de modelos de negocio sostenidos en automatización. La capacidad para descomponer procesos del cliente, identificar nodos críticos de eficiencia y diseñar flujos lógicos que puedan implementarse mediante plataformas tecnológicas representa una ventaja competitiva directa. Según Grover et al. (2022), estas competencias permiten abordar el diseño de soluciones de forma modular y estratégica, favoreciendo el desarrollo de servicios ágiles, adaptables y orientados al análisis funcional.

La mentalidad algorítmica, por su parte, permite a los emprendedores estructurar decisiones recurrentes, automatizar respuestas ante condiciones dinámicas y escalar procesos sin pérdida de control. Desde el desarrollo de rutinas personalizadas en herramientas de productividad hasta la configuración de mecanismos de recomendación o segmentación automatizada, esta forma de pensar se integra en la lógica diaria del emprendimiento digital. Tsarava et al. (2022), indican que los individuos con alta disposición algorítmica muestran una mayor capacidad para traducir procesos de negocio en estructuras funcionales que pueden ser auditadas y optimizadas, lo cual incrementa la eficiencia operativa y la escalabilidad de la oferta.

## **2.4 RESILIENCIA Y ADAPTABILIDAD EN ENTORNOS VOLÁTILES**

La resiliencia y la adaptabilidad son competencias estructurales indispensables para sostener la funcionalidad en entornos de alta variabilidad. En contextos donde los parámetros operativos y estratégicos se modifican con frecuencia, las organizaciones requieren respuestas estables pero flexibles, capaces de sostener el rendimiento sin depender de condiciones ideales. La resiliencia permite preservar el desempeño ante eventos disruptivos, mientras que la adaptabilidad facili-

ta la reconfiguración rápida de procesos y estructuras en función de nuevas condiciones. Ambas capacidades operan como sistemas activos de gestión del cambio, no como atributos estáticos (Duchek, 2020).

La resiliencia organizacional se sustenta en tres funciones esenciales: la anticipación, orientada a identificar señales tempranas de disrupción; la absorción, enfocada en amortiguar el impacto operativo; y la transformación, dirigida a rediseñar procesos a partir del aprendizaje derivado. Este marco requiere estructuras organizativas que mantengan redundancia operativa, liderazgo distribuido e inteligencia funcional distribuida. Las organizaciones resilientes no reproducen respuestas estandarizadas, sino que establecen marcos de toma de decisiones dinámicos, con base en flujos de información continua y equipos multifuncionales (Linnenluecke, 2017).

La adaptabilidad estratégica se activa cuando los escenarios dejan de ser predecibles. En lugar de depender de planes rígidos, las organizaciones con alta adaptabilidad formulan hipótesis operativas, las validan empíricamente y reformulan sus sistemas en ciclos cortos. Este comportamiento no se vincula con improvisación, sino con una arquitectura deliberada de ensayo-control-ajuste. Las capacidades adaptativas derivan de la combinación entre vigilancia activa del entorno, cultura de validación ágil y descentralización de los puntos críticos de decisión.

En el plano individual, estas competencias se traducen en habilidades psicológicas y cognitivas aplicadas a la gestión del riesgo, la presión y la reestructuración de expectativas. La resiliencia personal no se limita a resistir emocionalmente una crisis, sino que incluye la capacidad de reordenar metas, reformular prioridades y mantener continuidad operativa con recursos variables. En el caso de líderes de equipos y res-

ponsables de procesos críticos, estas habilidades determinan la estabilidad funcional de las unidades operativas.

En los escenarios emprendedores, donde la volatilidad es estructural, la resiliencia y la adaptabilidad se convierten en requisitos para la viabilidad de cualquier iniciativa. El emprendedor resiliente mantiene la ejecución incluso cuando el entorno se vuelve hostil, ajusta recursos de forma proporcional al riesgo percibido y toma decisiones fundadas en información fragmentaria sin perder el foco estratégico. La resiliencia no opera como motivación abstracta, sino como patrón de funcionamiento operativo ante entornos inestables (Conduah & Essiaw, 2022).

Las investigaciones recientes destacan que los emprendimientos con mayores probabilidades de sostenibilidad son aquellos que integran mecanismos de adaptabilidad estructural desde el inicio. Esto implica trabajar con modelos de negocio modulares, canales de distribución alternativos, sistemas de ingresos flexibles y plataformas tecnológicas que permitan ajustes rápidos sin comprometer la integridad del servicio. La capacidad de reconfigurar la propuesta de valor sin alterar la promesa esencial del producto se convierte en una ventaja crítica ante condiciones de cambio acelerado (Conduah & Essiaw, 2022).

Desde una perspectiva metodológica, la incorporación de resiliencia y adaptabilidad en los proyectos emprendedores exige planificación basada en escenarios, estructura de costos variables, descentralización de las decisiones tácticas y monitoreo continuo de indicadores de contexto. Los emprendimientos que adoptan estos principios operan con menor fricción ante alteraciones del entorno, reducen su dependencia de condiciones externas favorables y fortalecen su capacidad de iterar sobre el modelo operativo sin perder cohesión estratégica.

Estas competencias no deben tratarse como soluciones reactivas a eventos inesperados, sino como capacidades centrales que se integran al diseño del modelo operativo desde su fase de ideación. Evaluar la madurez adaptativa de un emprendimiento implica examinar su infraestructura tecnológica, su cultura interna, sus mecanismos de control operativo y su capacidad de implementar decisiones ajustadas al contexto sin disfunciones estructurales. En entornos donde lo único constante es la variación, la resiliencia y la adaptabilidad no son ventajas diferenciales, sino condiciones mínimas para la permanencia funcional del emprendimiento.

## **2.5 APRENDIZAJE CONTINUO Y ALFABETIZACIÓN EN DATOS**

El aprendizaje continuo y la alfabetización en datos conforman un binomio fundamental en entornos donde el conocimiento se renueva a alta velocidad y las decisiones estratégicas deben respaldarse con información precisa. Estas competencias no se limitan a contextos académicos, sino que se proyectan como capacidades transversales que articulan la dinámica profesional, organizacional y emprendedora. La velocidad con la que emergen nuevas herramientas, lenguajes, procesos y marcos normativos hace inviable el desempeño eficiente sin mecanismos estructurados de actualización y dominio informativo. La integración de estos elementos define la capacidad real de adaptación, innovación y sostenibilidad en cualquier sector productivo.

El aprendizaje continuo implica un proceso sistemático y proactivo de adquisición, adaptación y aplicación de conocimientos a lo largo de toda la trayectoria profesional. Esta competencia requiere autonomía cognitiva, disposición al cambio y una estructura de evaluación permanente sobre la pertinencia del conocimiento adquirido. Echtenbruck et al. (2025), lo describen como un atributo funcional que permite

enfrentar disrupciones estructurales y avanzar hacia modelos operativos basados en mejora iterativa. No se trata únicamente de acumular saberes, sino de integrar de forma crítica información nueva con conocimientos previos para resolver problemas complejos en tiempo real.

La alfabetización en datos, por su parte, no se reduce a la lectura de cifras o gráficos. Se fundamenta en la capacidad para entender la lógica detrás de la recolección, el análisis y la presentación de datos, identificar sesgos, validar fuentes y traducir conjuntos de información en conclusiones operativas. Sandoval-Ríos et al. (2025), plantean que esta competencia habilita la autonomía decisional al reducir la dependencia de narrativas infundadas y fomentar el pensamiento basado en evidencia. Una persona alfabetizada en datos no solo consume información, sino que cuestiona, verifica, contrasta y utiliza dicha información para generar valor.

Ambas competencias se vinculan de forma estructural. El aprendizaje continuo se fortalece con herramientas de análisis de datos que permiten identificar brechas, priorizar conocimientos críticos y estructurar rutas de desarrollo formativo basadas en resultados. La alfabetización en datos, por su parte, exige actualización constante en técnicas, lenguajes y metodologías de análisis que solo pueden adquirirse mediante aprendizaje sistemático. Esta retroalimentación funcional impulsa capacidades organizativas como la innovación, la gestión del conocimiento, el control de calidad, el monitoreo del entorno y la toma de decisiones estratégicas bajo incertidumbre.

En los entornos profesionales, la implementación de una cultura de aprendizaje continuo asociada a prácticas de alfabetización en datos se traduce en equipos con mayor capacidad de reacción ante cambios del mercado, herramientas de evaluación interna más precisas y liderazgo orientado por

información verificable. El capital humano deja de estar anclado a títulos formales y se redefine en función de su capacidad para aprender, interpretar y aplicar datos en contextos diversos. Esto permite responder con agilidad a las exigencias del entorno y reconfigurar las operaciones sin necesidad de reconstrucciones estructurales.

El entorno emprendedor, en particular, se beneficia de estas competencias en múltiples dimensiones. Emprendedores que desarrollan una práctica sistemática de aprendizaje continuo acceden a nuevas tecnologías, metodologías ágiles, marcos regulatorios y herramientas de financiación con mayor velocidad. Al incorporar alfabetización en datos, son capaces de interpretar métricas de rendimiento, comportamiento del cliente, segmentación de mercado y tendencias emergentes, sin depender de terceros para el análisis o la formulación de hipótesis. Esta independencia operativa les otorga ventajas en la iteración del modelo de negocio, la validación de productos mínimos viables y la redefinición de canales estratégicos.

En la práctica, estos emprendedores desarrollan rutinas de revisión periódica de datos operativos, experimentan con estrategias basadas en resultados medibles y utilizan la retroalimentación informada para rediseñar aspectos clave de su oferta. Este enfoque reduce los márgenes de error, acelera los ciclos de innovación y permite ajustes incrementales que consolidan el crecimiento. La combinación entre actualización continua y dominio informativo representa un mecanismo funcional de resiliencia estructural ante la volatilidad del entorno y las exigencias de escalabilidad.

Para fomentar estas competencias, no es necesario un retorno constante a la educación formal. El aprendizaje continuo se articula mediante comunidades digitales, microcredenciales, plataformas abiertas, prácticas reflexivas y mentoría distribuida. La alfabetización en datos se impulsa mediante ejer-

cicios prácticos, análisis comparativos, uso de herramientas accesibles de visualización y discusión colectiva de resultados. Esta democratización del conocimiento fortalece no solo la competitividad individual, sino la sostenibilidad del ecosistema emprendedor en su conjunto.

Incorporar estas competencias en la lógica operativa de un proyecto no es opcional, sino una condición funcional para su permanencia. En un entorno donde los datos son recurso, lenguaje y mecanismo de control, y donde el conocimiento se renueva en ciclos cortos, los emprendimientos que no estructuren estos mecanismos corren el riesgo de quedar desfasados incluso antes de consolidarse. La sostenibilidad no depende exclusivamente de la idea inicial, sino de la capacidad de sus líderes para aprender sin pausa, interpretar sin error y ejecutar con fundamento.

## CAPÍTULO 3

### **DESCUBRIENDO OPORTUNIDADES DE NEGOCIO CON INTELIGENCIA ARTIFICIAL**

#### **3.1 METODOLOGÍAS PARA LA IDENTIFICACIÓN DE OPORTUNIDADES TECNOLÓGICAS**

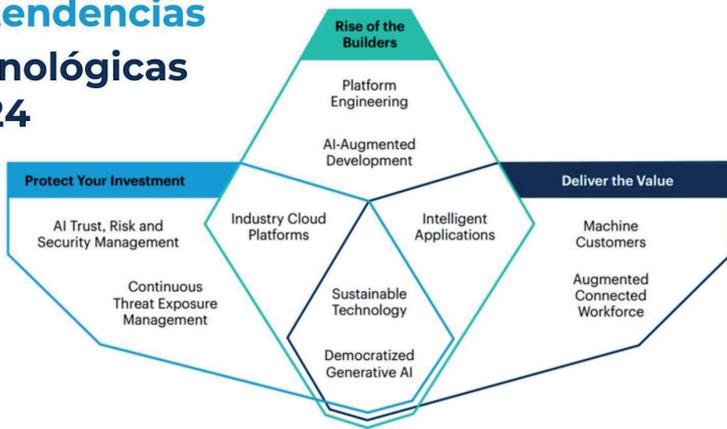
La identificación de oportunidades tecnológicas constituye un proceso estructurado, basado en herramientas analíticas que combinan vigilancia sistemática, tratamiento de datos y evaluación funcional. Este proceso permite descubrir áreas con alto potencial de innovación antes de que logren consolidarse comercialmente. Lejos de responder a impulsos especulativos, la detección de oportunidades requiere un análisis racional sobre el avance científico, la evolución de las capacidades productivas, los movimientos regulatorios y los cambios en los patrones de consumo. Según Wang et al. (2023), este análisis se articula a través del enfoque Technology Opportunity Analysis (TOA), que estructura etapas de exploración, reconocimiento temprano de señales, verificación técnica y validación del potencial de implementación.

La vigilancia tecnológica cumple una función instrumental dentro de esta arquitectura analítica. Consiste en recolectar, filtrar, procesar y sintetizar información clave sobre la evolución de tecnologías emergentes y campos científicos en expansión. Su aplicación práctica se apoya en fuentes como bases de datos científicas, registros de propiedad intelectual, informes sectoriales, normativas técnicas y publicaciones ins-

titucionales. Herramientas como la bibliometría, el análisis de patentes, la minería de textos especializados y los mapas de co-ocurrencia semántica permiten construir representaciones cuantitativas y cualitativas de los campos tecnológicos en movimiento. Según de Just (2024), la vigilancia tecnológica contribuye a detectar áreas con bajo nivel de saturación competitiva, trazar patrones de convergencia entre disciplinas y monitorear la aparición de soluciones con potencial disruptivo.

**Figura 3**  
*Tendencias tecnológicas 2024*

## 10 tendencias tecnológicas 2024



*Nota.* Tomado de <https://blog.bismart.com/10-tendencias-tecnologia-2024>

La aplicación de algoritmos de inteligencia artificial fortalece este proceso mediante la identificación automatizada de señales incipientes. Algoritmos de procesamiento de lenguaje natural (NLP) y técnicas de aprendizaje no supervisado permiten analizar extensos de documentos técnicos, papers científicos, foros especializados, bases de datos regulatorias y conjun-

tos abiertos de innovación. Estas técnicas facilitan la detección de clústeres temáticos emergentes, el análisis semántico de términos relevantes, la segmentación automatizada de dominios tecnológicos y la predicción de trayectorias futuras. Lee et al. (2022), demuestran que la integración de NLP con técnicas de clustering proporciona una base empírica sólida para anticipar líneas de desarrollo antes de su consolidación formal en productos, estándares o líneas de inversión pública.

Otra metodología ampliamente utilizada es el análisis de brechas tecnológicas, que permite identificar discrepancias entre lo que ofrece la tecnología existente y lo que requiere el entorno operativo o el mercado. Este análisis se ejecuta mediante herramientas como matrices de capacidad funcional, curvas S de desarrollo, benchmarking intersectorial y análisis del ciclo de vida tecnológico. El propósito es detectar nichos donde la demanda potencial no está cubierta por soluciones actuales, lo que permite diseñar estrategias orientadas a ocupar espacios no atendidos. Ye et al. (2020), destacan que el análisis de brechas se convierte en un insumo para decisiones de I+D, priorización de líneas de desarrollo y orientación de políticas públicas de innovación.

Los modelos híbridos, que combinan procesamiento algorítmico y validación experta, ofrecen una aproximación equilibrada al problema. Por un lado, la inteligencia artificial identifica correlaciones, relaciones emergentes y dinámicas ocultas a gran escala. Por otro, los expertos interpretan estas señales, considerando factores contextuales como barreras regulatorias, viabilidad técnica, efectos de red o aceptabilidad social. Esta combinación aumenta la robustez del proceso de identificación y reduce el riesgo de falsas oportunidades. Aplicaciones exitosas se han registrado en industrias como biotecnología, inteligencia ambiental, energías limpias y medicina personalizada, donde la complejidad técnica y norma-

tiva requiere una evaluación multidimensional.

En el ámbito emprendedor, estas metodologías pueden ser adoptadas de forma progresiva utilizando recursos de libre acceso. Emprendedores con formación básica en análisis de información pueden recurrir a bases de datos como Espacenet, WIPO, Google Patents, Google Scholar, ArXiv, PubMed, Statista o dashboards de vigilancia tecnológica. Estas fuentes permiten identificar tendencias técnicas, mapear líneas de investigación, evaluar concentración de patentes, medir intensidad innovadora por región y explorar las fronteras del conocimiento aplicado. Con herramientas como scraping de contenidos, análisis semántico básico y visualizaciones interactivas, es posible estructurar hipótesis fundamentadas sobre oportunidades tecnológicas sin depender de infraestructura corporativa.

Integrar estas metodologías en el diseño estratégico transforma la identificación de oportunidades tecnológicas en una actividad recurrente, medible y orientada a resultados. Las organizaciones que sistematizan este enfoque generan una ventaja funcional en la asignación de recursos, la formulación de propuestas de valor diferenciadas y la prevención de inversiones en tecnologías en declive. Esta perspectiva también refuerza la conexión entre vigilancia tecnológica y análisis predictivo, articulando una base empírica para anticipar mercados, redefinir segmentos y formular decisiones estratégicas con mayor precisión.

## **3.2 ANÁLISIS PREDICTIVO APLICADO AL ESTUDIO DE MERCADOS**

### **3.2.1 FUNDAMENTOS DEL ANÁLISIS PREDICTIVO EN MERCADOS**

El análisis predictivo en mercados se define como un proceso sistemático que utiliza datos históricos y actuales para

modelar comportamientos futuros de consumidores, sectores o variables económicas relevantes. Este enfoque no se basa en la observación intuitiva ni en estimaciones generales, sino en técnicas matemáticas, estadísticas y de inteligencia artificial que permiten establecer relaciones cuantificables entre distintas variables del entorno comercial. Su objetivo principal es anticipar comportamientos antes de que ocurran, permitiendo decisiones estratégicas más fundamentadas y eficaces (Shmueli, 2010).

Las metodologías utilizadas en análisis predictivo responden a modelos probabilísticos y algoritmos de aprendizaje que procesan grandes volúmenes de datos estructurados y no estructurados. Los modelos tradicionales incluyen la regresión lineal para estimar relaciones entre variables numéricas, y la regresión logística para predecir probabilidades de eventos categóricos como la conversión de clientes o la cancelación de servicios. Estos métodos han sido ampliamente adoptados en estudios de mercado por su claridad interpretativa y capacidad de generalización en contextos con relaciones simples (Kumar & Reinartz, 2016).

En escenarios complejos donde las interacciones entre variables no son lineales, los modelos tradicionales pierden capacidad predictiva. En estos casos, se emplean algoritmos de aprendizaje automático como árboles de decisión, random forests, máquinas de soporte vectorial y redes neuronales artificiales. Estos modelos permiten capturar patrones ocultos y correlaciones cruzadas que no serían detectables con técnicas convencionales. Su ventaja radica en la adaptabilidad, es decir, su capacidad para mejorar conforme se incorporan nuevos datos, permitiendo la actualización continua de los resultados predictivos (Waller & Fawcett, 2013).

La estructura funcional del análisis predictivo requiere una fase previa de depuración y selección de variables significati-

vas, seguida de un entrenamiento del modelo, validación con conjuntos independientes y evaluación mediante métricas específicas como la precisión, sensibilidad o área bajo la curva ROC. Esta lógica garantiza que los resultados no sean producto del azar ni de sobreajustes estadísticos, sino que reflejen patrones consistentes del comportamiento real. La solidez de esta arquitectura depende en gran medida de la calidad y representatividad de los datos, lo cual convierte la gestión de bases de información en una competencia estratégica para las organizaciones (Hazen et al., 2014).

La integración del análisis predictivo en la investigación de mercados transforma el paradigma de planificación. A diferencia de las proyecciones basadas en tendencias pasadas simples, estos modelos incorporan múltiples variables contextuales, como cambios regulatorios, estacionalidad, comportamiento competitivo y respuestas de clientes ante estímulos específicos. Esta capacidad permite modelar escenarios complejos y prever impactos derivados de decisiones de marketing, ajustes en precios, cambios de canal o lanzamientos de nuevos productos. El análisis predictivo no reemplaza el juicio estratégico, pero lo complementa con evidencia cuantitativa de alta resolución (Kumar & Reinartz, 2016).

En términos operativos, estos fundamentos se traducen en herramientas que permiten generar insights automatizados, reducir la incertidumbre y optimizar recursos. Al integrar modelos predictivos en los procesos analíticos, las empresas fortalecen su capacidad de respuesta y consolidan una cultura de toma de decisiones basada en datos. El análisis predictivo, en este sentido, representa una transición desde enfoques descriptivos hacia modelos de anticipación con base empírica, que dotan de mayor estabilidad y coherencia a las estrategias de posicionamiento y crecimiento en mercados dinámicos (Waller & Fawcett, 2013).

La inteligencia artificial se aplica en el análisis predictivo de mercados para anticipar comportamientos futuros de consumidores, identificar patrones emergentes y modelar dinámicas complejas en entornos competitivos. Esta disciplina combina métodos estadísticos, algoritmos de aprendizaje automático y técnicas de procesamiento masivo de datos con el objetivo de transformar información histórica y en tiempo real en estimaciones cuantificables. La IA no solo incrementa la velocidad y precisión de estos modelos, sino que permite integrar fuentes heterogéneas y datos no estructurados, como texto libre, comportamiento en línea o interacciones de clientes en plataformas digitales.

Entre las técnicas más relevantes en el análisis predictivo se encuentran los modelos de regresión supervisada, los algoritmos de clasificación, los árboles de decisión, las máquinas de vectores de soporte y, especialmente, las redes neuronales artificiales. Estas últimas son capaces de modelar relaciones complejas entre variables, capturando no linealidades que resultan invisibles para los métodos estadísticos tradicionales. Su capacidad para aprender directamente de los datos sin requerir supuestos rígidos las convierte en herramientas útiles en contextos de mercado altamente volátiles y con interacciones multifactoriales (Okeleke et al., 2024).

El aprendizaje automático, en particular, permite construir modelos que se ajustan progresivamente a medida que se incorporan nuevos datos. Esto es especialmente importante en sectores donde las preferencias del consumidor cambian con rapidez, como la moda, la tecnología o el entretenimiento digital. La validación cruzada, el entrenamiento iterativo y el uso de conjuntos de prueba permiten ajustar los modelos con niveles de precisión crecientes, reduciendo el riesgo de sobreajuste y mejorando la generalización de los resultados (Zhang, 2020).

En entornos donde el volumen de información no estructurada es elevado, el análisis predictivo se apoya en técnicas de procesamiento de lenguaje natural (PLN). Estas herramientas permiten extraer valor semántico de opiniones, reseñas, publicaciones en redes sociales o chats de atención al cliente. Al integrar esta información con datos estructurados como histórico de ventas o perfil sociodemográfico, los modelos predictivos ofrecen una representación más completa del comportamiento del consumidor. Hossain et al. (2023), destacan que el PLN ha permitido redefinir la forma en que se interpretan las preferencias del mercado, no solo por lo que los consumidores hacen, sino por lo que comunican explícitamente.

El análisis predictivo también incorpora arquitecturas profundas, como las redes neuronales recurrentes (RNN) o convolucionales (CNN), cuando se requiere trabajar con series temporales de alta granularidad o cuando los datos provienen de múltiples formatos como imágenes, texto y señales de comportamiento. Estas arquitecturas se han aplicado con éxito en estudios de abandono de clientes, segmentación dinámica, predicción de demanda en retail, y análisis de sentimiento vinculado a lanzamientos de producto. Su capacidad para identificar patrones ocultos convierte a estos modelos en aliados estratégicos para anticipar eventos clave que afectan las decisiones de consumo.

El diseño de un modelo predictivo con IA requiere una infraestructura sólida de datos, una etapa de limpieza y estructuración rigurosa, así como una selección crítica de variables. Una vez desplegado, el modelo debe monitorearse constantemente para detectar desviaciones en su rendimiento. En organizaciones con madurez analítica, estos modelos se integran en sistemas automatizados que ajustan campañas, precios o recomendaciones en tiempo real. Esto no sustituye el juicio

estratégico, pero proporciona una base empírica que reduce el margen de error en entornos altamente inciertos (Zhang, 2020).

La utilidad del análisis predictivo se extiende a múltiples funciones empresariales: desde la segmentación inteligente, pasando por la planificación de inventarios, hasta la optimización de canales digitales. Su valor reside en su capacidad para anticipar escenarios con fundamento estadístico y técnico, aportando una visión estructurada a procesos tradicionalmente dominados por la intuición o el análisis retrospectivo. La incorporación de IA en estos modelos eleva el estándar de precisión, velocidad de procesamiento y adaptabilidad frente a mercados dinámicos.

### **3.2.2 APLICACIONES PRÁCTICAS EN LA INVESTIGACIÓN DE MERCADOS**

La inteligencia artificial ha ampliado significativamente las posibilidades del análisis predictivo aplicado a la investigación de mercados, permitiendo automatizar tareas analíticas, aumentar la precisión de los modelos y generar predicciones en tiempo real a partir de datos dinámicos. Estas aplicaciones integran algoritmos de aprendizaje automático, redes neuronales y procesamiento de lenguaje natural en plataformas que permiten no solo describir el comportamiento del consumidor, sino anticiparlo con base en patrones derivados de grandes volúmenes de datos heterogéneos.

Una de las aplicaciones más extendidas de la IA en este campo es la segmentación predictiva de clientes. Los algoritmos de clustering, como K-means, DBSCAN o modelos basados en autoencoders, permiten clasificar consumidores a partir de su comportamiento digital, hábitos de compra o interacciones con contenidos en plataformas electrónicas. Por ejemplo, un modelo entrenado con datos de navegación web,

historial de compras y frecuencia de interacción puede identificar un grupo de clientes con alta afinidad hacia promociones en redes sociales o usuarios con patrones de abandono inminente. Estos perfiles se actualizan de forma automática a medida que ingresan nuevos datos, permitiendo a las empresas diseñar mensajes y productos personalizados (Le et al., 2024).

La predicción de demanda es otro caso ampliamente documentado. Modelos de aprendizaje profundo, como las redes neuronales recurrentes (RNN) y sus variantes como las LSTM, se utilizan para modelar series temporales de ventas que integran múltiples variables exógenas como condiciones climáticas, tendencias de búsqueda en internet, festividades y promociones en curso. Por ejemplo, en el sector minorista, un modelo LSTM puede anticipar el aumento de ventas de productos de temporada con una semana de antelación, permitiendo ajustar inventarios, logística y estrategias de precios de forma proactiva (Bandara et al., 2020).

En la predicción de abandono de clientes, los modelos supervisados como XGBoost, LightGBM y redes neuronales multicapa permiten estimar con alta precisión la probabilidad de deserción a partir de señales conductuales. Estas señales incluyen inactividad en la plataforma, disminución en la frecuencia de compra, cambios en el comportamiento de navegación, o respuestas negativas en encuestas de satisfacción. Una compañía de telecomunicaciones, por ejemplo, puede aplicar estos modelos para predecir qué clientes dejarán su servicio dentro de 30 días y activar automáticamente campañas de retención con ofertas personalizadas o mejoras en el plan (Muthupriya et al., 2022).

La optimización dinámica de precios también se beneficia del uso de IA. En marketplace y plataformas digitales de reserva, como aerolíneas o alojamientos turísticos, los modelos

de aprendizaje por refuerzo permiten ajustar precios hora a hora considerando la ocupación restante, el historial de reservas, la competencia, y el perfil del usuario que accede. El sistema aprende de los resultados previos y ajusta su política para maximizar ingresos sin perder competitividad, simulando escenarios de decisión similares a los que enfrentaría un analista humano, pero en tiempo real y a gran escala.

Otro uso extendido es la predicción de respuesta a estímulos de marketing mediante modelos de uplift modeling y redes causales. Estos modelos no solo predicen quién comprará un producto, sino quién lo hará únicamente si recibe una oferta específica, diferenciando entre los consumidores persuasibles, indiferentes o adversos al estímulo. Esta técnica se ha aplicado en campañas de correo electrónico, donde se maximiza el retorno enviando mensajes solo a quienes muestran una alta ganancia causal esperada, reduciendo el desperdicio de inversión en audiencias que no cambiarán su comportamiento (Rzepakowski & Jaroszewicz, 2010).

Todas estas aplicaciones de IA se integran en plataformas analíticas de ciclo completo, que combinan procesamiento de datos, modelado predictivo, generación de reportes y automatización de decisiones en tiempo real. Estas arquitecturas permiten implementar inteligencia de mercado continua, donde las decisiones se adaptan a medida que se actualizan los datos, y donde las predicciones alimentan sistemas operativos de atención, venta y comunicación. La inteligencia artificial no solo automatiza el análisis predictivo, sino que lo convierte en un componente activo del modelo de negocio basado en datos.

### **3.2.3 TECNOLOGÍAS Y HERRAMIENTAS UTILIZADAS EN ANÁLISIS PREDICTIVO**

Las tecnologías utilizadas en el análisis predictivo impul-

sado por inteligencia artificial abarcan una variedad de entornos de desarrollo, bibliotecas de software, plataformas en la nube y arquitecturas de datos que permiten el procesamiento, modelado y despliegue de soluciones analíticas en mercados dinámicos. Estas herramientas permiten transformar datos dispersos en modelos funcionales y reproducibles, facilitando la toma de decisiones automatizadas. La adopción de estas tecnologías ha sido fundamental para traducir algoritmos avanzados en aplicaciones prácticas, escalables y replicables en contextos comerciales reales (Zhang, 2020).

Entre los entornos de desarrollo más utilizados se destacan los lenguajes de programación Python y R, ampliamente adoptados por la comunidad de ciencia de datos debido a su flexibilidad, amplia documentación y soporte para bibliotecas especializadas. Python permite construir flujos de análisis completos gracias a bibliotecas como scikit-learn, que ofrece algoritmos básicos de machine learning; TensorFlow y PyTorch, que habilitan el diseño y entrenamiento de redes neuronales profundas; XGBoost, que destaca por su eficiencia en tareas de clasificación; y Keras, que proporciona una interfaz de alto nivel para desarrollar modelos con mayor rapidez (Pedregosa et al., 2011). Por otro lado, R es especialmente útil para análisis estadístico y visualización de datos mediante paquetes como forecast para series temporales, caret para modelado automatizado y mlr3 para benchmarking de modelos (Kuhn & Silge, n.d.).

Para el procesamiento de datos en entornos de gran escala, plataformas como Apache Spark, Databricks y BigQuery permiten ejecutar modelos de aprendizaje automático sobre volúmenes masivos de datos con arquitectura distribuida. Por ejemplo, Spark MLlib integra algoritmos de machine learning con capacidades de paralelización, lo que lo convierte en una herramienta clave en análisis predictivo para comercio elec-

trónico o logística, donde el tiempo de respuesta influye directamente en la competitividad. BigQuery, por su parte, permite realizar consultas predictivas sobre petabytes de datos en tiempo real, lo cual es crucial en sectores como banca o telecomunicaciones (García-Gil et al., 2019).

En términos de infraestructura basada en la nube, proveedores como Google Cloud Platform (GCP), Amazon Web Services (AWS) y Microsoft Azure han creado ecosistemas completos para el entrenamiento, validación y despliegue de modelos de IA. Vertex AI de Google permite gestionar el ciclo de vida completo de modelos predictivos, integrando AutoML, pipelines, y monitoreo en una sola interfaz. Amazon SageMaker permite construir, entrenar y desplegar modelos en producción con integración directa a servicios de datos, mientras que Azure ML Studio destaca por su capacidad de crear flujos sin código y facilitar el uso por parte de analistas de negocio (Choi et al., 2023).

Una categoría relevante corresponde a los sistemas AutoML, que automatizan la selección de algoritmos, ajuste de hiperparámetros, validación cruzada y evaluación de modelos. Estas herramientas, presentes en todas las plataformas cloud líderes, permiten generar modelos predictivos robustos sin requerir intervención manual experta. Su uso se ha extendido en empresas medianas, donde la capacidad técnica es limitada, pero la necesidad de predicción operativa es alta. AutoML reduce barreras de entrada y acelera la experimentación.

En el ámbito del procesamiento de lenguaje natural (PLN), esencial para analizar opiniones de consumidores, registros de atención o publicaciones sociales, destacan bibliotecas como spaCy y Transformers de Hugging Face. Estas permiten integrar modelos como BERT, RoBERTa y GPT, que procesan textos en lenguaje natural para tareas como clasificación de

sentimiento, resumen automático, detección de intenciones o análisis temático. Por ejemplo, los modelos BERT se han empleado con éxito para predecir el comportamiento de compra a partir de reseñas de productos, generando variables predictoras basadas en opiniones de usuarios.

Respecto a la interpretación de modelos complejos, herramientas como LIME (Local Interpretable Model-agnostic Explanations) y SHAP (SHapley Additive exPlanations) permiten visualizar la contribución de cada variable a la predicción de un modelo. Esto resulta especialmente útil en sectores regulados, donde es necesario justificar decisiones automatizadas. Ambas herramientas son utilizadas en análisis de riesgo crediticio, predicción de rotación de personal o segmentación de clientes, facilitando auditorías internas y transparencia ante entes reguladores.

En cuanto a visualización de resultados predictivos, herramientas como Power BI, Tableau, Plotly y Dash permiten construir tableros interactivos para explorar los datos y resultados de modelos. Estas plataformas facilitan que usuarios no técnicos comprendan el significado y las implicaciones de las predicciones generadas por IA, cerrando la brecha entre el análisis técnico y la acción comercial.

Estas tecnologías, cuando se integran de forma coherente en flujos de trabajo analíticos, permiten construir sistemas robustos de análisis predictivo basados en IA, desde la captura de datos hasta la implementación de acciones automatizadas. Su evolución ha sido clave para el despliegue de soluciones en sectores como banca, retail, salud y telecomunicaciones, donde la precisión y la velocidad de las predicciones impactan directamente en la ventaja competitiva.

### **3.2.4 LIMITACIONES, RIESGOS Y CONSIDERACIONES ÉTICAS**

El uso de inteligencia artificial en análisis predictivo ha

transformado los procesos de toma de decisiones en múltiples sectores. Sin embargo, su implementación conlleva limitaciones técnicas, riesgos operacionales y dilemas éticos que deben ser abordados con rigor. Estos aspectos no solo afectan la precisión de los modelos, sino también la equidad, transparencia y legalidad de las decisiones automatizadas. La supervisión responsable de estos sistemas es indispensable para preservar la confianza de los usuarios y la integridad de los resultados (Cath, 2018).

Una de las principales limitaciones técnicas radica en la calidad de los datos utilizados. Modelos de IA entrenados con datos incompletos, sesgados o desactualizados generan predicciones erróneas que pueden impactar negativamente en la estrategia comercial. Por ejemplo, si un modelo de predicción de abandono en telecomunicaciones se entrena con información histórica que refleja prácticas discriminatorias pasadas, tenderá a reproducir dichos sesgos al clasificar usuarios actuales (Mehrabi et al., 2021a). La literatura también alerta sobre el problema del “data shift”, cuando los datos de entrenamiento y los datos reales difieren significativamente, lo que deteriora el rendimiento del modelo en producción (Lu et al., 2019). Asimismo, los modelos pueden enfrentar el problema del sobreajuste, generando resultados precisos en datos de entrenamiento, pero con escasa capacidad de generalización en nuevos escenarios (Zhu et al., 2017).

El sesgo algorítmico representa un riesgo ético significativo. La IA puede amplificar desigualdades si las variables utilizadas como predictores están correlacionadas con factores sensibles como género, etnia o ubicación socioeconómica. En análisis predictivo aplicado al crédito, al empleo o al marketing, esto puede traducirse en decisiones injustas o discriminatorias, aun cuando el modelo no utilice explícitamente variables protegidas. Este fenómeno ha sido ampliamente

documentado en evaluaciones de sistemas de reconocimiento facial y motores de recomendación (Raji & Buolamwini, 2019). La identificación, monitoreo y mitigación de sesgos debe ser parte integral del ciclo de desarrollo y validación de modelos predictivos.

La falta de explicabilidad de los modelos también plantea desafíos en sectores regulados como salud, finanzas o educación. Modelos de caja negra, como las redes neuronales profundas, dificultan la interpretación de los resultados y la atribución de responsabilidades en caso de errores. La incorporación de técnicas como LIME o SHAP es una práctica necesaria para descomponer las predicciones y permitir su revisión por parte de expertos humanos. Estas herramientas no solo favorecen la auditabilidad del modelo, sino que fortalecen la transparencia frente a reguladores y consumidores (Lundberg et al., 2017). La necesidad de modelos interpretables ha motivado propuestas de diseño responsable de IA explicativa que combine precisión y comprensión del proceso de decisión.

Otra consideración crítica es la privacidad de los datos. El entrenamiento de modelos predictivos con datos personales debe cumplir marcos regulatorios como el Reglamento General de Protección de Datos (GDPR) en Europa o la Ley de Protección de Datos Personales en América Latina. La recopilación, almacenamiento y análisis deben respetar principios de consentimiento informado, minimización de datos y uso legítimo. Además, el uso de datos no estructurados obtenidos de redes sociales, dispositivos móviles o navegadores debe ser cuidadosamente evaluado para evitar prácticas invasivas o no autorizadas (Voigt & von dem Bussche, 2017). La anonimización diferencial y el uso de técnicas de privacidad computacional se proponen como soluciones complementarias para proteger los datos sensibles.

A nivel organizacional, los riesgos también incluyen una dependencia excesiva de sistemas automatizados sin mecanismos adecuados de supervisión humana. Esto puede derivar en una pérdida de criterio crítico, especialmente cuando los modelos operan en contextos de incertidumbre o cuando las predicciones contradicen la experiencia profesional. Por esta razón, el principio de “humano en el bucle” (human-in-the-loop) sigue siendo esencial en aplicaciones sensibles, permitiendo que las decisiones finales estén mediadas por juicio experto y no solo por la salida del algoritmo (Amershi, Weld, et al., 2019). Investigaciones recientes destacan la importancia de incorporar feedback humano continuo en entornos de aprendizaje reforzado, donde la intervención puede mejorar el alineamiento del modelo con los objetivos reales de la organización (Christiano et al., 2017).

La gestión ética del análisis predictivo con IA requiere una estructura de gobernanza que combine principios técnicos y valores sociales. Esto implica la definición de políticas claras sobre el uso de datos, la selección de variables permitidas, la documentación del proceso de entrenamiento, la trazabilidad de decisiones automatizadas y la creación de comités interdisciplinarios para revisión de modelos. Las organizaciones que institucionalizan estas prácticas no solo reducen el riesgo legal y reputacional, sino que fortalecen su legitimidad en mercados donde la confianza y la transparencia son factores decisivos.

### **3.3 SEGMENTOS EMERGENTES POTENCIADOS POR IA**

La inteligencia artificial ha posibilitado la identificación de segmentos emergentes con una precisión y velocidad antes inalcanzables. A través del análisis predictivo y el procesamiento masivo de datos, las organizaciones pueden detectar patrones de comportamiento que dan lugar a nuevos nichos

de mercado, redefiniendo la forma en que se agrupan y caracterizan los consumidores. Este enfoque supera los métodos tradicionales de segmentación, que se basaban en variables demográficas o geográficas estáticas, al introducir modelos dinámicos que integran interacciones digitales, contexto situacional y preferencias implícitas.

Los segmentos generados mediante inteligencia artificial se construyen a partir de algoritmos de clustering, redes neuronales autoorganizativas, análisis de grafos y modelado de temas en contenidos no estructurados. Estos métodos permiten descubrir comunidades de usuarios con intereses o necesidades similares, aunque no estén explícitamente declarados. Por ejemplo, un modelo de aprendizaje no supervisado puede identificar un grupo de usuarios que combinan comportamiento nocturno de navegación, alto consumo de contenido audiovisual y propensión a productos tecnológicos, revelando un segmento invisible bajo enfoques convencionales (Zhao, 2024).

Uno de los segmentos emergentes más relevantes es el de los consumidores predictivos, definidos por su dependencia de recomendaciones automatizadas para tomar decisiones de compra. Estos usuarios muestran una alta sensibilidad a los sistemas de personalización, como los motores de sugerencia basados en IA presentes en plataformas de e-commerce, servicios de streaming y marketplaces digitales. Su comportamiento no se explica por variables sociodemográficas tradicionales, sino por su interacción algorítmica, la cual puede ser medida y modelada en tiempo real (Y. Gao & Liu, 2023).

Otro grupo en expansión es el de los microconsumidores ecológicos digitales. Este segmento agrupa a usuarios cuyas decisiones están condicionadas por criterios de sostenibilidad, transparencia de cadenas de suministro y consumo consciente, y que utilizan plataformas digitales para validar sus

elecciones. La IA se emplea aquí para analizar sentimiento en redes sociales, comentarios en sitios de reseñas y metadatos de productos, generando perfiles basados en compromiso medioambiental y preferencias por marcas con propósito social (Hermann, 2023).

También han emergido los usuarios multisectoriales conectados, es decir, consumidores que interactúan simultáneamente con múltiples industrias (finanzas, salud, entretenimiento, educación), generando un rastro digital intersectorial que permite la creación de segmentos híbridos. Las herramientas de IA integran estos datos en modelos contextuales que revelan oportunidades de cross-selling y diseño de experiencias multicanal adaptadas al estilo de vida del usuario. Estos consumidores no responden a lógicas lineales de un solo sector, sino a trayectorias no convencionales detectadas mediante machine learning (Nazir et al., 2023).

Además, en mercados emergentes y zonas de menor penetración digital, la IA ha permitido identificar segmentos de adopción tardía que se activan mediante estrategias hiperlocales. Estos segmentos suelen estar vinculados a comunidades rurales, migrantes o poblaciones sin historial crediticio, cuya inclusión se ha logrado mediante modelos alternativos de scoring y segmentación con datos no tradicionales, como pagos móviles, patrones de geolocalización o uso de redes comunitarias (Cabrera-Sánchez et al., 2021).

La identificación de estos segmentos emergentes requiere capacidades analíticas avanzadas y una infraestructura tecnológica que permita integrar, procesar y modelar datos heterogéneos. La inteligencia artificial no solo mejora la segmentación existente, sino que redefine el concepto de segmento como una construcción dinámica, no lineal y sensible al contexto. Su utilidad estratégica radica en permitir un marketing adaptativo, el desarrollo de productos alineados con patro-

nes latentes y la activación de audiencias con alto potencial de conversión.

### **3.4 DETECTAR PROBLEMAS REALES SUSCEPTIBLES DE AUTOMATIZACIÓN**

La inteligencia artificial aplicada al análisis predictivo permite identificar con precisión creciente problemas operativos y estratégicos que pueden ser automatizados total o parcialmente. Esta capacidad se basa en el procesamiento de grandes volúmenes de datos históricos y en tiempo real, que revelan cuellos de botella, ineficiencias repetitivas, variabilidad operativa o decisiones críticas que dependen de patrones predecibles. La automatización no debe abordarse como una meta genérica, sino como una respuesta estructurada a problemas definidos y cuantificables, donde los modelos de IA ofrecen soluciones sostenibles y escalables (Brynjolfsson & McElheran, 2016).

Uno de los enfoques más efectivos consiste en utilizar modelos supervisados para detectar tareas de alto volumen y baja variabilidad, que consumen recursos humanos de forma rutinaria. Por ejemplo, los centros de atención al cliente acumulan registros que, al ser analizados con técnicas de procesamiento de lenguaje natural, permiten identificar temas recurrentes y solicitudes que pueden ser resueltas mediante asistentes virtuales. Esto ha permitido reducir tiempos de respuesta, liberar personal para casos complejos y mantener la calidad del servicio en picos de alta demanda (Shum et al., 2018).

Otro caso común es la detección de errores frecuentes en procesos logísticos, financieros o administrativos. Algoritmos de clasificación y detección de anomalías, como Isolation Forests o Autoencoders, permiten identificar transacciones inconsistentes, incumplimientos de políticas o patrones atípi-

cos en facturación y flujo de caja. Estos modelos operan sobre sistemas ERP o CRMs, identificando procesos manuales que presentan alta tasa de error y que son candidatos a automatización mediante RPA (automatización robótica de procesos) asistida por IA (Davenport & Ronanki, 2018).

También se pueden automatizar decisiones repetitivas en contextos dinámicos, como la gestión de inventario, asignación de recursos o ajustes de precios. En estos escenarios, los modelos predictivos estiman con precisión la demanda futura, permitiendo automatizar órdenes de reposición, redistribución de stock o generación de alertas para prevenir desabastecimientos. Esta capacidad ha sido particularmente efectiva en cadenas de suministro minoristas y plataformas de e-commerce, donde las decisiones deben adaptarse a variaciones rápidas del entorno (Fisher & Raman, 2018).

En el marketing, la automatización de campañas ha avanzado gracias a la IA al detectar el momento óptimo, el canal adecuado y el contenido más efectivo para cada cliente. Al integrar modelos de propensión, predicción de respuesta y segmentación dinámica, las plataformas de marketing automatizan la activación de campañas personalizadas, reduciendo la intervención manual y aumentando la tasa de conversión. Esta capacidad para automatizar la personalización a escala es fundamental en contextos donde el tiempo de reacción define la ventaja competitiva.

Para detectar problemas reales que puedan ser automatizados, se requiere una combinación de análisis descriptivo, conocimiento del proceso y modelado predictivo. Los datos operativos deben ser auditados no solo por su volumen o frecuencia, sino por su impacto acumulado, coste de oportunidad y repetitividad. La inteligencia artificial aporta la capacidad de escanear grandes flujos de información e identificar puntos críticos que no serían evidentes a simple vista. Al au-

tomatizar soluciones para estos puntos, se incrementa la eficiencia sin perder adaptabilidad ni control humano.

### **3.5 INNOVACIÓN BASADA EN NECESIDADES NO SATISFECHAS**

La inteligencia artificial actúa como un catalizador para identificar y abordar necesidades no satisfechas en diversos sectores de mercado. A diferencia de los métodos tradicionales de innovación, que dependen de encuestas, grupos focales o intuición empresarial, los sistemas basados en IA permiten explorar grandes volúmenes de datos estructurados y no estructurados para detectar patrones de insatisfacción, comportamientos anómalos o demandas latentes que aún no han sido resueltas por la oferta existente. Esta capacidad redefine el proceso de innovación, orientándolo hacia soluciones más precisas, oportunas y ajustadas al usuario.

Uno de los principales mecanismos para detectar necesidades no satisfechas es el análisis de sentimiento aplicado a redes sociales, reseñas de productos, chats de soporte y foros en línea. Herramientas de procesamiento de lenguaje natural (PLN), como BERT o GPT, permiten identificar quejas recurrentes, expresiones de frustración o solicitudes frecuentes no atendidas, que luego se categorizan en temáticas clave. Estas temáticas sirven como insumos para procesos de diseño centrado en el usuario, permitiendo traducir la voz del cliente en atributos funcionales y de experiencia. Por ejemplo, plataformas de delivery han mejorado funcionalidades como seguimiento de repartidores o sistemas de notificación tras detectar tendencias de molestia generalizada en comentarios online (Won et al., 2023).

Otro enfoque efectivo es el análisis de abandono de clientes o cancelación de suscripciones. A través de modelos predictivos supervisados, se identifican los factores que motivan el retiro de los usuarios. Estos factores pueden incluir defi-

ciencias en el producto, baja percepción de valor, atención deficiente o falta de adaptación al contexto del usuario. Cuando estas causas se documentan y validan, se convierten en focos de innovación prioritaria. La IA permite modelar trayectorias de cliente a lo largo del tiempo, segmentando a quienes abandonan por causas distintas y ofreciendo insights diferenciados para rediseño de ofertas o procesos.

En el diseño de nuevos productos, la IA se utiliza para realizar minería de ideas a partir de fuentes diversas como bases de datos de patentes, publicaciones científicas, reportes de tendencias y comportamientos de consumo digital. Algoritmos de aprendizaje no supervisado, como el topic modeling o LDA (Latent Dirichlet Allocation), detectan temas emergentes y relaciones conceptuales entre ellos. Esta técnica ha sido usada, por ejemplo, en la industria farmacéutica para identificar líneas de investigación poco exploradas o en el sector consumo para anticipar ingredientes y formatos preferidos por nuevas generaciones (Sharma, 2023).

La inteligencia artificial también permite generar innovación inclusiva, al identificar necesidades no satisfechas en grupos históricamente subatendidos, como adultos mayores, personas con discapacidades o usuarios de regiones periféricas. A partir del análisis de datos heterogéneos, como formularios de soporte técnico, feedback de programas sociales y patrones de uso digital, se pueden diseñar soluciones específicas adaptadas a estas poblaciones. Esto permite ampliar el impacto social de la innovación, generando tecnologías accesibles, interfaces adaptadas y servicios pensados desde la diversidad funcional y cultural.

Además, los modelos generativos basados en IA, como los transformers, ofrecen la posibilidad de prototipar soluciones a partir de las necesidades detectadas. Estas herramientas pueden generar de manera automatizada descripciones fun-

cionales de productos, simulaciones de interfaz de usuario o escenarios de uso, permitiendo testear rápidamente alternativas sin necesidad de invertir en desarrollo físico. En contextos de innovación ágil, esta capacidad ha reducido significativamente los ciclos de validación, facilitando pruebas con usuarios reales en fases tempranas del proceso.

La innovación basada en necesidades no satisfechas mediante IA exige una arquitectura de datos integrada, capacidades analíticas avanzadas y un enfoque centrado en el usuario. No se trata de inventar productos arbitrarios, sino de revelar problemas reales, sistematizar las evidencias que los sustentan y diseñar soluciones alineadas con patrones emergentes, maximizando tanto la relevancia como la viabilidad técnica y comercial de las iniciativas desarrolladas.

## CAPÍTULO 4

### **DISEÑO Y VALIDACIÓN DE PROPUESTAS DE VALOR CON INTELIGENCIA ARTIFICIAL**

#### **4.1 INTEGRACIÓN DE IA EN LA IDENTIFICACIÓN DE NECESIDADES DEL CLIENTE**

La inteligencia artificial constituye una herramienta decisiva para detectar y comprender las necesidades del cliente en entornos de mercado dinámicos. A través de algoritmos de aprendizaje automático y procesamiento de lenguaje natural, es posible extraer patrones, intenciones y expectativas que antes requerían costosos estudios cualitativos o investigaciones de campo prolongadas. Esta capacidad es especialmente valiosa en contextos donde el comportamiento del cliente cambia de forma acelerada y donde los ciclos de innovación deben responder con rapidez a señales tempranas del mercado. La IA permite integrar múltiples fuentes de información—incluyendo historiales de compra, navegación digital, opiniones en línea, consultas de soporte y métricas de interacción— para construir representaciones más completas del usuario y detectar vacíos entre lo que el cliente requiere y lo que el mercado ofrece (Paschen et al., 2019).

El análisis de interacciones digitales en plataformas web, redes sociales o aplicaciones móviles representa uno de los métodos más efectivos para identificar necesidades no explícitas. Mediante técnicas de clustering, análisis de afinidad y seguimiento de eventos, los modelos de IA revelan patrones

de comportamiento que permiten segmentar usuarios según su nivel de compromiso, sus obstáculos percibidos y su disposición al cambio. Estas segmentaciones son útiles para emprendedores que necesitan validar propuestas de valor con públicos objetivos definidos, sin depender exclusivamente de formularios o entrevistas. Al detectar microcomportamientos que preceden a una conversión o al abandono, las plataformas que integran IA pueden adaptar automáticamente la experiencia del cliente o sugerir contenidos personalizados que reduzcan la fricción (Mikalef et al., 2021).

El procesamiento de lenguaje natural, especialmente mediante arquitecturas basadas en transformadores como BERT o GPT, permite interpretar textos provenientes de múltiples fuentes, como reseñas de productos, encuestas abiertas, transcripciones de chats y comentarios en redes sociales. Estas herramientas convierten expresiones informales y lenguaje emocional en variables cuantificables, que pueden organizarse por temas, intensidad o polaridad. A partir de esta información, los emprendimientos pueden priorizar mejoras en características específicas del producto, identificar brechas de comunicación o evaluar la efectividad de su propuesta de valor en segmentos distintos. Esta capacidad resulta crítica para aquellos modelos de negocio que dependen del contacto directo con el usuario, como los modelos freemium, plataformas educativas, fintech o servicios de suscripción.

A nivel predictivo, la inteligencia artificial permite anticipar necesidades futuras mediante el análisis de tendencias conductuales, factores estacionales y cambios de preferencia. Modelos como redes neuronales recurrentes (RNN) y árboles de decisión en cascada permiten analizar secuencias de comportamiento, como la transición entre productos, la frecuencia de interacción o la respuesta a estímulos comerciales. Esta capacidad de anticipación permite a los emprendedores

actuar de forma proactiva, ajustando el diseño del producto, las condiciones del servicio o la estrategia de posicionamiento antes de que el mercado lo demande explícitamente. Así, la IA se convierte en un aliado estratégico que permite tomar decisiones informadas con menor margen de error (Ugbebor et al., 2024).

En emprendimientos con recursos limitados, herramientas de IA accesibles como AutoML, dashboards inteligentes y plataformas de business intelligence basadas en la nube ofrecen la posibilidad de realizar análisis complejos sin necesidad de contar con un equipo técnico especializado. Estas plataformas permiten ejecutar tareas como la detección de correlaciones significativas, la segmentación dinámica de usuarios o la predicción de comportamientos de compra de forma automatizada. Esta democratización del acceso a la analítica avanzada amplía la capacidad de los emprendedores para entender su mercado, incluso en fases tempranas del negocio o con volúmenes reducidos de datos (Rane et al., 2024).

La integración de IA en la identificación de necesidades del cliente transforma la lógica del desarrollo de producto y servicio. Al permitir una comprensión más profunda, personalizada y anticipada del usuario, los sistemas basados en IA refuerzan la toma de decisiones centradas en la demanda real, no en suposiciones. Esto representa una ventaja estratégica significativa para los emprendimientos que buscan minimizar el riesgo de fallos en el diseño, ajustar su propuesta de valor en tiempo real y construir relaciones sostenibles con sus audiencias desde los primeros ciclos del negocio.

## **4.2 HERRAMIENTAS ALGORÍTMICAS PARA EL DISEÑO DE PROTOTIPOS**

El diseño de prototipos mediante herramientas algorítmicas representa una evolución significativa en la forma en

que las organizaciones conceptualizan, evalúan y perfeccionan nuevas soluciones. Esta transformación se sustenta en la capacidad de la inteligencia artificial para generar, simular y validar versiones preliminares de productos o servicios con base en datos reales y criterios objetivos. A diferencia de los enfoques tradicionales, que requieren una secuencia lineal de pasos entre diseño, desarrollo y prueba, el uso de algoritmos permite acelerar los ciclos iterativos e introducir procesos de experimentación continua desde etapas tempranas del proyecto.

Los algoritmos de optimización evolutiva, como los algoritmos genéticos o de enjambre de partículas, se aplican en entornos donde existen múltiples restricciones y variables que interactúan entre sí. Estos algoritmos generan poblaciones de soluciones alternativas, que se evalúan mediante funciones objetivo-predefinidas como costo, ergonomía, tiempo de ejecución o facilidad de uso. Esta metodología es útil en el diseño de configuraciones mecánicas, layouts de productos, estructuras de software o interfaces gráficas, donde existen múltiples combinaciones viables y es necesario identificar aquellas que optimicen simultáneamente varios criterios. La capacidad de simular miles de variantes en segundos permite a los equipos tomar decisiones basadas en evidencia, minimizando errores costosos derivados de suposiciones arbitrarias.

Los modelos generativos como las redes adversariales generativas (GANs) y los transformers aplicados a texto y código han abierto nuevas posibilidades para la prototipación ágil. En contextos de diseño visual, las GANs permiten generar imágenes, estilos gráficos o versiones alternativas de productos visuales a partir de un conjunto de ejemplos o descripciones textuales. Esto resulta útil para crear propuestas visuales en branding, envases, UI/UX y contenidos digitales. Por su parte, los transformers como Codex permiten generar

fragmentos funcionales de código o scripts para automatizar tareas, acelerar la construcción de prototipos interactivos y validar funcionalidades mínimas (Brown et al., 2019). Estas capacidades han sido adoptadas en entornos de desarrollo low-code y no-code, facilitando el acceso a la prototipación funcional a equipos con capacidades técnicas limitadas.

En el ámbito del diseño de servicios, los modelos de simulación basados en NLP (procesamiento de lenguaje natural) se emplean para construir y evaluar flujos conversacionales, escenarios de atención al cliente, onboarding automatizado o pruebas de asistencia digital. Herramientas como Dialogflow, Rasa o IBM Watson Assistant permiten modelar las interacciones previstas, generar respuestas automáticas coherentes y testear múltiples escenarios de usuario. Esta simulación anticipa problemas de comprensión, ambigüedad o fricción en la experiencia antes del despliegue real, permitiendo ajustes tempranos sin comprometer la operación (Vibha, 2024). La posibilidad de analizar métricas como el tiempo de respuesta, tasa de error conversacional o satisfacción simulada permite mejorar la precisión del diseño sin requerir pruebas extensivas con usuarios reales.

Para productos físicos o híbridos, el uso de herramientas de diseño asistido por inteligencia artificial ha permitido automatizar procesos de generación geométrica, análisis de viabilidad y simulación estructural. Plataformas como Autodesk Generative Design o Fusion 360 integran algoritmos que generan propuestas de diseño optimizadas para condiciones específicas, como reducción de peso, resistencia estructural, eficiencia de materiales o compatibilidad con impresión 3D. Estas herramientas no solo producen modelos CAD inteligentes, sino que permiten validar en paralelo sus propiedades mediante simulaciones predictivas, como análisis de fatiga, transferencia térmica o resistencia al impacto, lo que reduce

la necesidad de iteraciones físicas costosas (Liu et al., 2023).

En entornos colaborativos, las herramientas algorítmicas se integran con plataformas de prototipado como Figma, Miro o Webflow, donde la IA puede sugerir mejoras automáticas, analizar consistencia de diseño o adaptar interfaces a distintos perfiles de usuario. Esta integración entre diseño visual y datos permite que los prototipos no sean estáticos, sino que evolucionen dinámicamente según los patrones de interacción registrados en pruebas internas o experimentos A/B. Algunos sistemas avanzados permiten incluso generar dashboards de retroalimentación automática donde se visualizan los puntos críticos, el flujo de navegación más común o los elementos con mayor tasa de abandono, facilitando decisiones iterativas basadas en métricas.

El uso de herramientas algorítmicas en la creación de prototipos no elimina la necesidad de pruebas con usuarios reales, pero sí transforma la forma en que los equipos llegan a esa fase. Al automatizar la generación de variantes, integrar validación temprana y simular escenarios complejos, la inteligencia artificial convierte al proceso de prototipado en una dinámica de exploración continua, adaptativa y basada en evidencia. Esto incrementa la capacidad de los negocios emergentes para reducir el riesgo de sus propuestas, responder a señales del entorno con mayor agilidad y construir soluciones más ajustadas a las expectativas reales de sus usuarios.

#### **4.3 VALIDACIÓN AUTOMATIZADA DE HIPÓTESIS DE MERCADO**

La validación de hipótesis de mercado constituye un eje central en el diseño ágil de modelos de negocio emergentes. En este proceso, la inteligencia artificial permite sustituir procedimientos manuales y especulativos por análisis sistemáticos que integran evidencia observable desde etapas tempranas del desarrollo. A través de algoritmos supervisados,

motores de inferencia estadística y modelos de simulación con datos reales, es posible determinar si las suposiciones iniciales sobre el comportamiento del cliente, la viabilidad del producto o la aceptación del modelo de ingresos se sostienen con evidencia cuantificable (Kohavi et al., 2013).

Una hipótesis de mercado parte de una relación presunta entre un grupo de usuarios, un problema concreto y una solución propuesta. Para operacionalizar esta suposición, se definen variables medibles como intención de compra, tasa de conversión o nivel de interacción. A partir de ello, se despliegan experimentos controlados en plataformas digitales con múltiples versiones de una oferta, monitoreando el desempeño relativo mediante métricas instrumentadas. Herramientas como Google Optimize o Adobe Target permiten ejecutar estas pruebas A/B con segmentaciones precisas, recolectar datos de navegación y aplicar modelos de atribución para determinar la respuesta más probable ante cada estímulo.

La automatización mejora estos procesos al integrar múltiples flujos de datos y ajustar las condiciones del experimento en tiempo real. Algoritmos de aprendizaje automático procesan indicadores como frecuencia de interacción, tasas de rebote o duración de la sesión para detectar correlaciones que confirmen o cuestionen la hipótesis original. Plataformas como Mixpanel o Amplitude permiten rastrear recorridos completos del usuario y analizar eventos clave dentro del embudo de conversión, generando insights sobre funcionalidad, percepción de valor o fricción operativa (Bernard & Andritsos, 2017).

En validaciones de tipo predictivo, se utilizan modelos de propensión para simular cómo reaccionarían distintos perfiles ante variaciones en elementos críticos del negocio, como el modelo de precios, el formato del servicio o el canal de adquisición. La inteligencia artificial permite construir escena-

rios comparativos con datos históricos y proyectar métricas como la retención esperada, el lifetime value o la elasticidad del precio, anticipando así el impacto potencial de decisiones estratégicas sin ejecutarlas todavía.

Otra dimensión clave es la evaluación automatizada de retroalimentación cualitativa. Mediante procesamiento de lenguaje natural, se analizan comentarios en redes sociales, formularios abiertos, chats o reseñas de usuarios. Los modelos de análisis de sentimiento y clasificación semántica permiten identificar patrones discursivos relacionados con satisfacción, barreras percibidas o atributos no valorados por el usuario. Esta información se estructura en categorías temáticas que aportan soporte adicional a las hipótesis testeadas y ofrecen indicios para nuevas iteraciones (Cui et al., 2023).

La validación automatizada de hipótesis de mercado no reemplaza el juicio estratégico, pero sí proporciona un soporte cuantificable y reproducible para tomar decisiones con menor incertidumbre. En emprendimientos tecnológicos con recursos limitados, estas herramientas permiten acelerar los ciclos de aprendizaje, reducir errores de percepción y construir propuestas más alineadas con los patrones reales del comportamiento del cliente.

#### **4.4 MEDICIÓN EN TIEMPO REAL DEL COMPORTAMIENTO DEL USUARIO**

La medición en tiempo real del comportamiento del usuario ha cobrado especial relevancia en proyectos tecnológicos donde el diseño de productos y servicios requiere un ciclo iterativo, adaptativo y basado en datos. Este enfoque se apoya en la implementación de sistemas analíticos que recopilan, procesan y visualizan información sobre interacciones del usuario a medida que estas ocurren. La inteligencia artificial permite no solo capturar estos datos de forma automatizada,

sino también interpretarlos en contextos de decisión que alimentan procesos de personalización, mejora de experiencia o detección temprana de fricciones (B. Gao et al., 2023). Esta capacidad mejora sustancialmente los tiempos de respuesta, facilita la segmentación dinámica de audiencias y permite adaptar la oferta en función de señales de comportamiento que serían invisibles bajo esquemas de análisis diferido.

El seguimiento en tiempo real se realiza principalmente mediante instrumentación de eventos dentro de plataformas digitales. Cada clic, desplazamiento, permanencia en pantalla o acción dentro de un flujo puede ser registrado y transformado en una unidad de análisis. Herramientas como Google Analytics 4, Amplitude, Hotjar o Segment permiten integrar estas señales en tableros dinámicos que muestran el comportamiento del usuario en múltiples puntos de contacto. Estas herramientas utilizan técnicas de procesamiento de eventos complejos (CEP) y transmisión de datos mediante flujos (streaming), lo cual posibilita una evaluación continua y actualizada de la experiencia del usuario. A través del procesamiento continuo, estas plataformas detectan patrones que revelan niveles de interés, abandono, resistencia o conversión, lo que permite ajustar en el momento la interfaz, el contenido o la oferta.

La inteligencia artificial amplía la capacidad de estas soluciones mediante el uso de modelos de machine learning entrenados para reconocer secuencias conductuales típicas y desviaciones relevantes. Por ejemplo, un modelo puede identificar en tiempo real que un usuario con determinado patrón de navegación está próximo a abandonar el sitio, o que otro muestra señales tempranas de intención de compra. A partir de estas inferencias, los sistemas pueden activar respuestas automáticas, como recomendaciones personalizadas, pop-ups con ofertas contextuales o derivación a un canal de soporte.

Estos sistemas se integran con motores de reglas y aprendizaje por refuerzo para adaptar la respuesta al comportamiento observado, optimizando así la tasa de conversión o reduciendo la pérdida de clientes o usuarios (Lin, 2025).

Este enfoque tiene aplicación en múltiples verticales. En el comercio electrónico, permite adaptar la visualización de productos según el perfil de navegación y la secuencia de interés detectada. En educación digital, se emplea para detectar niveles de compromiso o frustración en estudiantes, activando recursos de apoyo o mensajes motivacionales según la interacción. En plataformas de servicios financieros, ayuda a prevenir fraudes a partir de la identificación de acciones atípicas o a detectar usuarios que requieren asistencia adicional. También se ha documentado su uso en aplicaciones de salud digital para monitorear adherencia al tratamiento o anticipar situaciones de riesgo a partir de patrones de uso de apps o dispositivos conectados.

Además, las tecnologías de visualización en dashboards inteligentes han evolucionado para permitir no solo la observación pasiva, sino la toma de decisiones directa desde la interfaz. Por ejemplo, mediante tableros conectados con motores de recomendación, es posible modificar parámetros del flujo de usuarios, reordenar contenidos o pausar campañas sin salir del entorno analítico. Estos tableros integran alertas basadas en umbrales dinámicos, comparación con series históricas y detección de anomalías, lo cual mejora la gestión operativa en tiempo real. Esto reduce el tiempo entre la observación del comportamiento y la acción correctiva, lo que resulta esencial en entornos digitales donde cada segundo de fricción puede traducirse en pérdida de conversión o abandono definitivo.

La medición en tiempo real no solo mejora la experiencia del usuario, sino que también fortalece la capacidad de los

negocios para ejecutar estrategias de personalización profunda, responder con agilidad a eventos inesperados y validar de manera continua hipótesis sobre la experiencia. Esta capacidad permite desarrollar modelos de negocio centrados en la retroalimentación constante del usuario, integrando sus acciones en procesos de diseño, comunicación y desarrollo funcional. En negocios digitales emergentes, esta orientación basada en datos vivos se traduce en una ventaja operativa que permite iterar con precisión, detectar señales débiles de insatisfacción o interés, y ajustar la propuesta de valor con rapidez y bajo costo.

#### **4.5 OPTIMIZACIÓN ITERATIVA DEL PRODUCTO BASADA EN DATOS**

La optimización iterativa basada en datos constituye un componente central en la gestión de productos digitales y en el desarrollo continuo de propuestas de valor ajustadas al comportamiento del usuario. Este enfoque permite a las organizaciones transformar el proceso tradicional de diseño y mejora —caracterizado por decisiones infrecuentes y basadas en suposiciones— en un ciclo permanente de ajuste guiado por evidencia empírica. A través de modelos de análisis predictivo, métricas de uso, analítica multicanal y algoritmos de retroalimentación continua, los equipos pueden identificar, priorizar e implementar mejoras que elevan la calidad funcional, la satisfacción del usuario y el rendimiento comercial del producto (Chen et al., 2025).

El proceso iterativo se estructura en ciclos breves de análisis, ajuste y medición. Cada iteración comienza con la recolección sistemática de datos provenientes de interacciones reales: uso de funciones, tiempos de permanencia, rutas de navegación, errores frecuentes, abandonos o conversiones. Estas señales se procesan en herramientas de análisis como

Mixpanel, Heap o Datadog, donde son interpretadas mediante indicadores clave (KPIs) definidos para cada segmento del producto. A partir de esta información, se detectan patrones de uso subóptimo, demandas no atendidas o fricciones que obstaculizan la experiencia, lo que orienta a ajustes específicos en diseño, funcionalidad o contenido. También se identifican microsegmentos con comportamientos emergentes, lo que permite adaptar el producto a necesidades latentes antes de que se manifiesten como problemas generalizados.

La inteligencia artificial amplía esta capacidad al introducir modelos que no solo describen el comportamiento, sino que lo predicen y recomiendan cursos de acción. Algoritmos supervisados y no supervisados permiten identificar segmentos de usuarios con riesgo de abandono, funcionalidades con baja adopción o características asociadas a mayor fidelización. Estos hallazgos alimentan sistemas de toma de decisión automatizada o dashboards que priorizan iniciativas con mayor retorno esperado. En algunos casos, se implementan pruebas A/B automatizadas, donde distintas variantes del producto se exponen simultáneamente a subgrupos, y el sistema selecciona la opción con mejor rendimiento de forma adaptativa. Esta validación continua garantiza que cada versión del producto esté ajustada a condiciones de uso reales y actualizadas.

La iteración basada en datos también facilita una gestión más eficiente de los recursos. Al conocer con precisión qué componentes del producto generan mayor valor o pérdida, los equipos pueden asignar esfuerzos técnicos y presupuestarios a las áreas de mayor impacto. Esta priorización guiada por métricas reduce el riesgo de invertir en funcionalidades irrelevantes y permite escalar aquellas que demuestran efectividad comprobada. Asimismo, al medir el impacto de cada cambio en tiempo real, se evita el costo de decisiones ineficaces prolongadas y se valida rápidamente el valor agregado

de cada versión lanzada (Yildiz et al., 2022). Este enfoque se traduce en un modelo operativo que combina agilidad táctica con orientación estratégica sostenida por datos empíricos.

El modelo iterativo requiere, sin embargo, una infraestructura organizativa y tecnológica adecuada. Es necesario contar con una arquitectura de datos que garantice la calidad, integridad y trazabilidad de las métricas utilizadas. Esto incluye desde sistemas de captura en el front-end hasta herramientas de almacenamiento estructurado y motores analíticos conectados a tableros de visualización. Además, los equipos deben desarrollar capacidades analíticas para interpretar correctamente los resultados y traducirlos en decisiones accionables. Las herramientas actuales, como plataformas de product analytics y sistemas de experimentación algorítmica, ya ofrecen entornos integrados donde estos requisitos se pueden gestionar sin necesidad de desarrollar soluciones desde cero (Qin et al., 2024). Estas soluciones permiten una alineación más estrecha entre producto, marketing y experiencia del usuario.

La optimización iterativa basada en datos no implica simplemente reaccionar a métricas, sino diseñar un sistema de mejora continua donde la lógica de decisiones esté anclada en la realidad del comportamiento del usuario. Esta perspectiva transforma la relación entre el producto y sus usuarios en una conversación activa: cada interacción informa una posible mejora, y cada mejora se evalúa de nuevo bajo condiciones reales. Para emprendimientos en etapa de crecimiento, esta capacidad puede marcar la diferencia entre escalar con eficiencia o consolidar modelos poco alineados con las expectativas reales del mercado. En entornos de alta competencia, esta práctica también contribuye a diferenciar la propuesta de valor mediante la adaptabilidad y la pertinencia de sus funcionalidades.

## CAPÍTULO 5

### **AUTOMATIZACIÓN INTELIGENTE EN STARTUPS DIGITALES**

#### **5.1 PROCESOS OPERATIVOS SUSCEPTIBLES DE AUTOMATIZACIÓN**

La automatización de procesos operativos responde a la necesidad de simplificar tareas estructuradas en organizaciones con alta exposición a actividades repetitivas. En entornos digitales y proyectos emergentes, este enfoque se implementa con tecnologías que operan sobre datos estandarizados, instrucciones predecibles y entornos interconectados. Las áreas funcionales con mayor frecuencia de aplicación incluyen la gestión contable, el procesamiento documental, el control de inventarios, la atención al cliente, el análisis operativo automatizado, la gestión de talento humano, el procesamiento de pagos y la supervisión de cumplimiento normativo. La selección de estos procesos no obedece únicamente a criterios técnicos, sino a su relevancia sobre indicadores de eficiencia, calidad, trazabilidad y continuidad operativa.

Las actividades contables, por su regularidad y dependencia normativa, representan un segmento automatizable. Facturación electrónica, conciliaciones bancarias, generación de reportes y declaraciones tributarias se ejecutan mediante plataformas parametrizadas que minimizan errores humanos, estandarizan el tratamiento de datos y permiten trazabilidad en tiempo real. En proyectos formales de baja escala, este tipo de automatización reduce la carga administrativa,

mejora el control financiero y permite cumplir con regulaciones tributarias sin requerir estructuras contables complejas (Ruiz & González, 2024; Terrazas et al., 2024). En organizaciones con operaciones dispersas o flujos de caja variables, esta funcionalidad también contribuye a la estabilidad operativa y al fortalecimiento de la capacidad analítica.

El procesamiento documental comprende operaciones como la captura, validación, clasificación y archivo de información contenida en comprobantes, solicitudes o formularios. La integración de sistemas con tecnología de reconocimiento óptico y flujos digitales reduce la intervención manual, acelera el acceso a datos, elimina redundancias y asegura consistencia en los registros. Estas plataformas incrementan la trazabilidad documental, mejoran la eficiencia de auditoría interna y permiten monitorear el cumplimiento de requisitos legales y contractuales en tiempo real (Edtiyarsih, 2023). El impacto es particularmente visible en proyectos con operaciones regulatorias críticas o que gestionan contratos, garantías y certificaciones.

Las operaciones logísticas orientadas al inventario también son sensibles a la automatización. A través del uso de sensores, algoritmos de actualización y módulos de predicción de consumo, los sistemas automatizados realizan ajustes sobre existencias, programan órdenes de reposición y actualizan indicadores de rotación sin intervención directa. Esta solución optimiza el capital operativo, reduce el riesgo de ruptura de stock, minimiza pérdidas por obsolescencia y mejora la relación entre demanda proyectada y abastecimiento disponible (Pekonen & Lähteinen, 2021). En entornos donde la rotación de productos es alta o la entrega puntual resulta crítica, la automatización del inventario constituye un componente central de la ventaja competitiva.

La atención automatizada al cliente funciona mediante

asistentes virtuales capaces de interpretar requerimientos, emitir respuestas con base en datos programados y canalizar interacciones de alta complejidad. Esta función permite mantener continuidad en los canales de soporte, reducir tiempos de espera, sistematizar el análisis de métricas de satisfacción y liberar recursos humanos para funciones especializadas. En proyectos de escala digital, el volumen de consultas, la necesidad de disponibilidad continua y la presencia en múltiples canales convierten esta opción en un recurso estratégico para mantener la experiencia del usuario y capturar datos conductuales que retroalimenten otras funciones (Richmond & Sulaiman, 2023).

La analítica operativa también puede automatizarse mediante modelos predictivos que procesan grandes volúmenes de datos para apoyar decisiones de marketing, distribución o asignación de recursos. Estas herramientas identifican patrones de comportamiento, evalúan tendencias y proponen ajustes con base en objetivos definidos. La automatización del análisis reduce la latencia en la toma de decisiones, mejora la precisión de las predicciones y permite monitorear en tiempo real los desvíos respecto a los indicadores esperados (Richmond & Sulaiman, 2023). Esto resulta especialmente útil en mercados dinámicos o altamente competitivos, donde los márgenes de error son reducidos.

La gestión de talento humano también incorpora procesos automatizables. Reclutamiento digital, verificación de antecedentes, gestión de nómina, cálculo de beneficios y planificación de formación pueden ejecutarse con apoyo de sistemas integrados. La automatización en esta área permite reducir errores de cálculo, asegurar el cumplimiento de políticas laborales, monitorear indicadores de desempeño y optimizar la asignación de recursos humanos. Este tipo de herramientas contribuye a establecer una cultura de gestión basada en da-

tos y reduce los ciclos de respuesta frente a cambios regulatorios o demandas internas.

El procesamiento de pagos, tanto a proveedores como a colaboradores, puede integrarse con flujos automatizados que verifican cumplimiento, aplican controles antifraude, programan transferencias y generan comprobantes. Estas soluciones reducen la exposición a errores contables, fortalecen la trazabilidad de operaciones financieras y permiten responder con rapidez ante auditorías o requerimientos externos. La automatización de esta función resulta especialmente relevante cuando el volumen de transacciones es elevado o se gestiona en múltiples monedas.

La supervisión de cumplimiento normativo constituye otra dimensión automatizable, mediante el uso de motores de reglas que validan transacciones frente a disposiciones legales, estándares de calidad u obligaciones contractuales. Esta función genera alertas, bloqueos preventivos y reportes para la toma de decisiones. En entornos donde el incumplimiento conlleva sanciones financieras o riesgos reputacionales, este tipo de automatización refuerza los mecanismos de control y permite responder con agilidad frente a revisiones externas.

La identificación de procesos operativos susceptibles de automatización requiere un diagnóstico estructurado que considere frecuencia, volumen, criticidad, dependencia de reglas estables y posibilidad de integración digital. Los procesos prioritarios se localizan en actividades con alta repetibilidad, flujos constantes, bajo margen de decisión humana y fuerte dependencia de datos estructurados. La planificación debe contemplar estándares de gobernanza tecnológica, mecanismos de actualización, monitoreo de desempeño y capacitación continua del personal para asegurar la operatividad sostenida del sistema automatizado.

## **5.2 PLATAFORMAS ACCESIBLES PARA STARTUPS SIN INFRAESTRUCTURA PROPIA**

Las startups que operan sin infraestructura tecnológica propia requieren herramientas que les permitan ejecutar funciones clave sin necesidad de servidores físicos, personal especializado ni inversiones iniciales elevadas. Estas organizaciones encuentran en las soluciones digitales basadas en la nube una opción viable para estructurar y escalar operaciones. Los modelos de provisión tecnológica como Software como Servicio (SaaS), Infraestructura como Servicio (IaaS) y Plataforma como Servicio (PaaS) ofrecen acceso inmediato a herramientas de gestión, almacenamiento, procesamiento y despliegue sin necesidad de activos físicos. Estos recursos digitales permiten implementar funciones empresariales críticas mediante esquemas escalables, bajo demanda y con costos ajustados a la actividad real del proyecto.

En la gestión administrativa y financiera, plataformas como Odoo, Zoho Books y QuickBooks Online permiten registrar operaciones contables, gestionar pagos, emitir facturas y realizar conciliaciones bancarias. Estas herramientas operan en la nube, se actualizan automáticamente y ofrecen integraciones con bancos, pasarelas de pago y sistemas fiscales. Este tipo de servicios facilita la gestión documental y contable en empresas que no disponen de departamentos financieros internos. Jayeola et al. (2022) identifican una disminución significativa en errores operativos y mejoras en la trazabilidad de los procesos contables al adoptar estas soluciones. También se ha documentado una reducción del tiempo invertido en tareas repetitivas y una mejora en la puntualidad de los reportes financieros, lo que impacta positivamente en la capacidad de reacción del equipo directivo.

La automatización de tareas repetitivas puede implementarse sin recursos técnicos avanzados mediante plataformas

como Zapier, Make o n8n. Estas herramientas conectan formularios, hojas de cálculo, correos electrónicos, bases de datos y CRM sin necesidad de programación. Los flujos se configuran visualmente y permiten ejecutar acciones desencadenadas por eventos. Este tipo de automatización elimina tareas manuales, reduce tiempos de respuesta y garantiza consistencia en los procesos de captura y distribución de información. Cuando se integran con sistemas de seguimiento de clientes o canales de atención, también permiten segmentar acciones y optimizar recursos mediante reglas de priorización. En proyectos con personal reducido, estas plataformas permiten mantener niveles operativos estables sin expandir el equipo.

Los servicios IaaS y PaaS permiten gestionar aplicaciones, sitios web, bases de datos y procesos sin instalar servidores ni adquirir infraestructura física. Amazon Web Services (AWS), Microsoft Azure y Google Cloud Platform proporcionan entornos virtuales configurables según la carga de trabajo. Estas plataformas ofrecen escalabilidad inmediata, respaldo automatizado, cifrado de datos y herramientas de monitoreo. Yang et al. (2021), destacan que la adopción de infraestructura en la nube mejora la agilidad de respuesta ante cambios operativos, facilita el despliegue de nuevos productos y reduce los costos de mantenimiento. Las capacidades de observabilidad, segmentación de entornos y balanceo automático de carga también contribuyen a sostener operaciones críticas sin interrupciones, incluso bajo condiciones de crecimiento acelerado o alta demanda puntual.

Las plataformas de comercio electrónico permiten construir catálogos digitales, gestionar pedidos, aceptar pagos y organizar campañas de marketing sin necesidad de diseñar aplicaciones desde cero. Shopify, WooCommerce y Wix integran funcionalidades prediseñadas para operaciones comerciales, logística y atención al cliente. Estas herramientas es-

tán diseñadas para escalar según el tráfico o el volumen de ventas, y no requieren habilidades técnicas avanzadas para su implementación. Incluyen además funcionalidades de análisis de comportamiento del consumidor, recuperación de carritos abandonados y gestión de campañas promocionales. Para startups que dependen del canal digital como principal vía de ingresos, estas soluciones permiten comenzar a operar con tiempos mínimos de configuración y con costos proporcionales al volumen de ventas.

El enfoque conocido como Startup-as-a-Service (SuaaS) utiliza una combinación de herramientas en la nube, recursos modulares y servicios profesionales bajo demanda para construir proyectos completos sin necesidad de activos propios. Esta estrategia permite concentrarse en la validación del modelo de negocio, mientras que el desarrollo, la gestión de clientes, la atención, el análisis de datos y la infraestructura se configuran mediante servicios disponibles en el ecosistema digital. Moreno (2025), identifica esta metodología como una alternativa viable para reducir las barreras técnicas, eliminar dependencias de capital físico y acelerar la ejecución de nuevas ideas. Este enfoque también promueve la creación de empresas con estructuras flexibles, que pueden pivotar sus operaciones con rapidez al no estar sujetas a inversiones rígidas ni a modelos de infraestructura tradicionales.

La selección de plataformas debe considerar compatibilidad funcional, posibilidad de integración, soporte técnico, política de seguridad de datos y flexibilidad contractual. La documentación de procesos, la capacitación en el uso de las herramientas y la estandarización de flujos permiten reducir el impacto de la rotación de personal, los cambios en la demanda o las modificaciones en el entorno normativo. Estas condiciones son fundamentales para asegurar la continuidad operativa y facilitar la evolución progresiva de las ope-

raciones sin comprometer la estabilidad organizacional. Una estrategia de adopción gradual y la evaluación periódica del desempeño de cada solución permiten mantener alineadas las herramientas tecnológicas con los objetivos de crecimiento de la startup.

### **5.3 APLICACIÓN DE RPA E IA EN GESTIÓN INTERNA**

La implementación de tecnologías como la Automatización Robótica de Procesos (RPA) y la Inteligencia Artificial (IA) en la gestión interna permite establecer una estructura operativa eficiente, escalable y basada en evidencia. Estas herramientas proporcionan a las startups la posibilidad de operar con flujos sistematizados y decisiones automatizadas sin necesidad de una infraestructura física compleja. RPA se encarga de ejecutar tareas basadas en reglas definidas, mientras que la IA introduce capacidades para interpretar datos, identificar patrones y aplicar lógica adaptativa. Esta combinación cubre un espectro amplio de funciones internas, lo cual resulta esencial para iniciativas que deben escalar con recursos limitados.

RPA se aplica en procesos administrativos como la actualización de datos en hojas de cálculo compartidas, el control de inventarios, la organización de archivos digitales, el envío automatizado de correos de seguimiento, la gestión de pedidos en marketplace y la sistematización de tareas repetitivas en herramientas de gestión de proyectos. Estas actividades, comunes en emprendimientos digitales, demandan precisión y regularidad. Cuando se gestionan manualmente, consumen tiempo operativo sin aportar valor estratégico. La automatización permite ejecutar estas acciones con consistencia, reducir errores humanos y mantener el ritmo operativo sin necesidad de ampliar la plantilla (Cabezas, 2022).

La IA permite ampliar las capacidades de estos procesos al integrar funciones como la clasificación automática de

mensajes entrantes, el análisis de sentimientos en opiniones de usuarios, la segmentación inteligente de clientes y la predicción de comportamientos en plataformas digitales. Esto permite identificar patrones útiles para mejorar la toma de decisiones en áreas como marketing, soporte al cliente, priorización de leads y recomendaciones personalizadas. En una startup con modelos de negocio digitales o híbridos, estas capacidades permiten adaptar las acciones de manera continua en función del comportamiento observado, mejorando la conversión y optimizando el uso de recursos (Wordofprint, 2021).

La combinación de RPA e IA permite desarrollar flujos inteligentes que conectan múltiples tareas en un mismo circuito de trabajo. Un caso común es el procesamiento de formularios web: RPA puede extraer los datos recibidos, IA puede interpretar su contenido para determinar su categoría o urgencia, y luego RPA puede derivar la información al área correspondiente, enviar un correo de confirmación y registrar el caso en la base de datos. Este enfoque reduce el tiempo de respuesta, garantiza trazabilidad y permite ofrecer una experiencia más profesional con menos intervención humana. La configuración modular de estos sistemas permite escalar su complejidad conforme se amplía el volumen de datos o aumenta la diversidad de usuarios.

En startups orientadas a productos digitales o servicios por suscripción, estas tecnologías también se aplican en procesos como la validación de pagos, la administración de renovaciones, la atención de consultas frecuentes y la evaluación de métricas de uso. La IA permite predecir abandono, detectar disminuciones en la interacción y activar respuestas automatizadas como ofertas, encuestas o contenido adaptado. RPA ejecuta estas respuestas mediante integraciones con plataformas de correo, CRM o sistemas de notificaciones. Esta

automatización incrementa la retención y reduce los costos de soporte, al tiempo que proporciona indicadores precisos para ajustar la propuesta de valor (Zell, 2025).

Las startups que aplican estas tecnologías de forma progresiva logran mantener equipos reducidos sin sacrificar capacidad de gestión. La priorización de procesos a automatizar debe guiarse por criterios como frecuencia de ejecución, impacto operativo, posibilidad de estandarización y necesidad de escalabilidad. Las implementaciones iniciales pueden enfocarse en tareas críticas de bajo riesgo, permitiendo al equipo validar el funcionamiento antes de expandir la automatización hacia otras funciones. Este enfoque iterativo reduce la fricción interna y facilita la adaptación tecnológica sin interrupciones significativas.

La sostenibilidad de los sistemas basados en RPA e IA requiere una estructura mínima de gobernanza. Esta incluye la documentación de los flujos, la asignación de responsables de revisión periódica, el registro de excepciones y la actualización de algoritmos o reglas según nuevas condiciones del negocio. El monitoreo continuo y la mejora incremental aseguran que la automatización evolucione con el proyecto y mantenga su utilidad conforme se transforman los objetivos estratégicos.

#### **5.4 ESCALABILIDAD SIN INCREMENTO ESTRUCTURAL GRACIAS A IA**

La inteligencia artificial permite a las startups ampliar el alcance de sus operaciones sin aumentar de forma proporcional su estructura organizativa. Este principio se basa en la posibilidad de automatizar decisiones, reducir la dependencia del trabajo manual y delegar funciones repetitivas o intensivas en sistemas inteligentes. Esta forma de escalar resulta especialmente relevante para iniciativas que enfren-

tan restricciones presupuestarias, limitaciones de personal o entornos altamente dinámicos donde la velocidad de adaptación representa una ventaja estratégica. A diferencia de los modelos de crecimiento tradicionales, donde el incremento en la demanda requería una expansión paralela en recursos humanos y físicos, las soluciones basadas en IA permiten sostener aumentos en la carga operativa sin generar desequilibrios internos.

Uno de los mecanismos que facilita esta escalabilidad es la capacidad de la inteligencia artificial para administrar múltiples interacciones en paralelo. Los sistemas de atención automatizada, los motores de recomendación y las plataformas de clasificación automática permiten atender a grandes volúmenes de usuarios sin necesidad de incrementar proporcionalmente el personal operativo. Esta capacidad es crucial en startups que ofrecen servicios digitales o atención asincrónica en múltiples zonas horarias. Por ejemplo, los asistentes virtuales entrenados con modelos de procesamiento del lenguaje natural pueden responder simultáneamente a miles de usuarios, ofreciendo contenido personalizado y resolviendo solicitudes con niveles de precisión que mejoran con el uso (Gentsch, 2022). Esto implica que el crecimiento en la base de clientes no exige necesariamente un aumento en la infraestructura de atención.

La gestión del conocimiento interno también se ve beneficiada por la incorporación de sistemas de IA. Las plataformas inteligentes permiten almacenar, categorizar, buscar y actualizar información técnica, comercial u operativa sin necesidad de estructuras jerárquicas o manuales complejas. A través de motores de búsqueda semántica, sistemas de indexación automática y algoritmos de inferencia, los equipos pueden acceder a respuestas precisas en función del contenido consultado y del historial de interacciones anteriores. Esta capacidad

reduce los tiempos de entrenamiento de nuevos colaboradores, disminuye la dependencia del conocimiento tácito y favorece la continuidad operativa en entornos de alta rotación o cambio constante. De esta forma, el capital intelectual de la organización se transforma en un recurso accesible y reutilizable, sin requerir personal dedicado a funciones de soporte o documentación.

En términos operativos, la inteligencia artificial permite optimizar el uso de recursos logísticos, técnicos y humanos mediante algoritmos de predicción, planificación y asignación dinámica. Sistemas de IA pueden anticipar picos de demanda, redistribuir cargas de trabajo, ajustar horarios o reorganizar prioridades sin intervención humana. Esta capacidad permite mantener la eficiencia en procesos de producción, distribución o prestación de servicios incluso ante variaciones significativas en el volumen de operaciones. Por ejemplo, startups dedicadas al comercio electrónico pueden utilizar IA para prever variaciones en el tráfico, ajustar automáticamente el stock disponible y optimizar las rutas de entrega en tiempo real, todo ello sin aumentar su personal logístico (Smit et al., 2020).

La escalabilidad también se refleja en la capacidad de análisis organizacional. Las herramientas de inteligencia artificial permiten procesar grandes volúmenes de datos generados por clientes, productos o procesos y transformarlos en información útil para la toma de decisiones. Este análisis automatizado incluye desde la detección de anomalías hasta la segmentación de audiencias y la generación de recomendaciones operativas. En vez de conformar equipos analíticos internos o contratar consultores especializados, las startups pueden configurar sistemas de análisis que operen de forma continua, alerten sobre desviaciones clave y propongan ajustes fundamentados. Esta capacidad no solo mejora la preci-

sión de las decisiones, sino que también reduce los tiempos de respuesta y facilita el aprendizaje organizacional en ciclos cortos (Haefner et al., 2023).

Para aplicar un modelo de escalabilidad sin incremento estructural, es necesario que la arquitectura tecnológica de la startup se base en principios de modularidad, interoperabilidad y automatización progresiva. Esto implica que las plataformas utilizadas deben integrarse fácilmente, permitir la incorporación de nuevas funcionalidades sin rediseños costosos y sostener su rendimiento ante cargas crecientes. También es clave implementar una estrategia de gestión del cambio que prepare al equipo para la colaboración con sistemas inteligentes, promoviendo una cultura de control supervisado, mejora continua y responsabilidad compartida entre humanos y algoritmos (Chui, Manyika & Miremadi, 2021).

Este modelo no reemplaza la intervención humana, sino que la reconfigura. En lugar de expandir estructuras verticales o aumentar el número de supervisores, se optimiza el rol de las personas hacia tareas de supervisión estratégica, diseño de excepciones, validación ética y alineación con objetivos de negocio. La IA asume funciones tácticas y operativas, mientras los equipos humanos se concentran en la interpretación de contexto, la adaptación a lo inesperado y la creación de valor diferencial. Este equilibrio permite sostener el crecimiento de manera eficiente y mantener estructuras livianas que favorecen la agilidad organizacional.

## **5.5 USO DE DASHBOARDS INTELIGENTES PARA MEJORA CONTINUA**

Los dashboards inteligentes constituyen una herramienta técnica para la gestión continua del rendimiento organizacional mediante el uso de inteligencia artificial. Estas plataformas integran datos operativos, comerciales y analíticos en

visualizaciones automatizadas que permiten monitorear indicadores clave, identificar desviaciones y generar recomendaciones de ajuste con base en modelos de aprendizaje. Su implementación permite reducir el tiempo de análisis, eliminar la intervención manual en la consolidación de datos y establecer ciclos de revisión que facilitan el mejoramiento constante de los procesos. Esta automatización del análisis mejora la precisión, reduce la carga cognitiva de interpretación y permite establecer criterios de evaluación dinámicos según las condiciones operativas del negocio (Fuselab Creative, 2025).

Los sistemas impulsados por inteligencia artificial operan con datos estructurados y no estructurados extraídos de múltiples fuentes conectadas, como plataformas de gestión de clientes, sistemas internos de operación, herramientas de comercio digital y redes sociales. Esta capacidad de integración permite que los dashboards funcionen como entornos centralizados de monitoreo y control. La aplicación de algoritmos de clasificación, detección de anomalías y predicción de comportamiento incrementa el valor de las visualizaciones al generar alertas, estimaciones de impacto y recomendaciones automáticas sin requerir programación adicional por parte del usuario. Estas funciones permiten priorizar acciones correctivas, alinear operaciones con objetivos cuantificables y fortalecer los mecanismos de control en tiempo real (Forbes Technology Council, 2025).

En entornos de negocio donde la agilidad y la toma de decisiones basada en evidencia son prioritarias, estos dashboards permiten evaluar la efectividad de campañas, ciclos de producción, interacción con usuarios y cumplimiento de metas. Los modelos inteligentes integrados realizan comparaciones entre periodos, segmentan datos por criterios definidos y actualizan en tiempo real los resultados conforme ingresan nuevas entradas. Esta funcionalidad permite corregir

desviaciones en tiempo operativo, establecer prioridades de ajuste y rediseñar procesos sin esperar ciclos prolongados de evaluación. La mejora continua se habilita mediante una arquitectura que favorece la retroalimentación inmediata y la ejecución ajustada a objetivos dinámicos, lo que fortalece la capacidad de reacción y mejora la calidad de las decisiones operativas (Datahub, 2025).

La utilidad de estas herramientas se incrementa cuando los equipos de trabajo pueden configurar sus propios indicadores, visualizar proyecciones generadas por la inteligencia artificial y acceder a informes interactivos desde múltiples dispositivos. Estas condiciones técnicas favorecen la descentralización de las decisiones tácticas y la autonomía de las unidades funcionales. Al reducir la dependencia de analistas especializados, se distribuye la capacidad de interpretación en toda la organización, lo cual permite actuar de forma coordinada y con menor latencia. El sistema no solo muestra datos históricos, sino que aplica inferencias para anticipar comportamientos futuros y recomendar intervenciones alineadas con los objetivos establecidos. Los dashboards inteligentes con interfaces conversacionales también permiten realizar consultas en lenguaje natural, facilitando su uso por parte de equipos no técnicos y promoviendo la democratización del análisis (Krause, 2024).

Los dashboards inteligentes no solo fortalecen la operación diaria, sino que también permiten observar la evolución de métricas clave a lo largo del tiempo, estableciendo ciclos de mejora basados en resultados medibles. Esta funcionalidad permite implementar metodologías de mejora continua como PDCA (Plan-Do-Check-Act) o Lean Six Sigma, ya que los datos generados pueden utilizarse para definir estándares, monitorear cambios, evaluar impacto y reajustar procesos de forma estructurada. Al incluir capacidades de IA, estos table-

ros no solo muestran información sino que sugieren cursos de acción ante desviaciones, ofreciendo una base empírica para decisiones más oportunas y fundamentadas.

El uso de dashboards inteligentes también permite gestionar recursos de forma más eficiente. Al visualizar en tiempo real los niveles de productividad, carga operativa, tiempos de ciclo o tasas de conversión, los equipos pueden reasignar tareas, identificar cuellos de botella y optimizar flujos sin necesidad de estructuras jerárquicas adicionales. En negocios de rápido crecimiento, esta capacidad de adaptación instantánea resulta fundamental para mantener la competitividad y prevenir disfunciones operativas que suelen aparecer al escalar.

El diseño e implementación de dashboards inteligentes requiere una definición clara de los objetivos de monitoreo, la estandarización de las fuentes de datos y la validación de los modelos que generan recomendaciones. La arquitectura debe asegurar la trazabilidad de los datos procesados, la periodicidad de actualización y la coherencia entre lo visualizado y lo ejecutado. La inteligencia artificial, al operar sobre datos de calidad y bajo un esquema estructurado, permite que los resultados reflejados en el dashboard no solo representen el estado actual, sino que actúen como guías operativas en la mejora de productos, servicios y flujos internos. La actualización periódica de los modelos, la supervisión de sus predicciones y el ajuste de sus parámetros permiten sostener su relevancia en entornos cambiantes y mantener la integridad de las decisiones automatizadas.

## CAPÍTULO 6

### **ÉTICA, SEGOS Y GOBERNANZA ALGORÍTMICA EN PROYECTOS EMPRENDEDORES**

#### **6.1 SEGOS EN MODELOS UTILIZADOS POR STARTUPS TECNOLÓGICAS**

Los modelos algorítmicos implementados en proyectos tecnológicos de reciente creación están expuestos a múltiples formas de sesgo que afectan directamente la calidad de sus predicciones, la equidad en sus decisiones y la credibilidad del sistema. Estos sesgos suelen originarse en los datos de entrenamiento, en la arquitectura del modelo o en la etapa de despliegue operativo, comprometiendo la objetividad de los resultados. En entornos emprendedores, donde los equipos técnicos suelen operar con recursos limitados y bajo presión de tiempo, el riesgo de introducir sesgos no controlados se intensifica debido al uso de conjuntos de datos preentrenados o no auditados, la adopción de bibliotecas automatizadas sin validación contextual y la falta de procesos formales de evaluación ética.

El sesgo de representación es uno de los más comunes en los modelos utilizados por organizaciones emergentes. Este tipo de sesgo ocurre cuando los datos utilizados para entrenar el modelo no reflejan adecuadamente la diversidad del entorno real en el que se aplicará. Esto puede generar exclusiones sistemáticas de ciertos perfiles de usuarios o sobrerepresentación de características que inducen resultados

distorsionados. Por ejemplo, un sistema de recomendación entrenado con interacciones de usuarios de un único grupo geográfico puede generar resultados irrelevantes para públicos distintos. La limitada disponibilidad de datos etiquetados también puede inducir al uso de proxies que sustituyen variables sensibles sin garantía de neutralidad estadística (Mehra-*bi et al.*, 2021b).

El sesgo de confirmación, vinculado a las decisiones tomadas durante la construcción del modelo, también afecta a las iniciativas que desarrollan productos con componentes automatizados. Este sesgo se manifiesta cuando las configuraciones algorítmicas refuerzan patrones observados en los datos históricos sin cuestionar su validez o impacto ético. Al replicar decisiones previas sesgadas, el sistema perpetúa desigualdades presentes en los datos, como sesgos de género en procesos de selección o discriminación indirecta en clasificaciones automatizadas. Este fenómeno puede amplificarse cuando los equipos técnicos validan la precisión del modelo sin segmentar su rendimiento por subgrupos poblacionales o sin implementar métricas específicas de equidad algorítmica (Friedler *et al.*, 2021).

El sesgo introducido por la infraestructura tecnológica también debe considerarse. Los modelos alojados en plataformas externas, o entrenados con datasets estándar disponibles en bibliotecas públicas, pueden incorporar lógicas implícitas que no son visibles en el proceso de entrenamiento. Esta situación es común en proyectos que utilizan APIs de inteligencia artificial comercial o modelos preentrenados como GPT, BERT o similares, sin adaptar sus salidas a los requisitos normativos, culturales o sociales del entorno donde se despliegan. El riesgo técnico se incrementa cuando se integran estos modelos en flujos automatizados sin mecanismos de revisión manual ni auditoría de decisiones. Estudios recientes alertan sobre la

necesidad de diseñar pipelines de aprendizaje que incluyan validación adversarial y mecanismos de detección de sesgos durante la inferencia (Raji et al., 2020).

Las organizaciones que operan en el ecosistema emprendedor deben establecer procesos estructurados para mitigar estos sesgos desde las etapas iniciales del desarrollo del producto. Estas acciones incluyen la documentación exhaustiva de los datos utilizados, el monitoreo del rendimiento del modelo en distintas condiciones de uso, la segmentación de métricas de desempeño por atributos sensibles y la incorporación de revisiones técnicas orientadas a la equidad. El uso de frameworks como Fairlearn, Aequitas o AI Fairness 360 proporciona herramientas técnicas para auditar y corregir desviaciones sistemáticas en los modelos implementados. La formación de los equipos en ética algorítmica y en análisis de impacto diferencial resulta imprescindible para integrar la gobernanza técnica en los procesos de desarrollo de producto (Holstein et al., 2019).

## **6.2 TOMA DE DECISIONES AUTOMATIZADAS Y RESPONSABILIDAD ÉTICA**

La implementación de sistemas de toma de decisiones automatizadas en iniciativas tecnológicas introduce implicaciones éticas que deben ser abordadas mediante marcos estructurados de gobernanza. Estos sistemas, diseñados para ejecutar procesos de clasificación, predicción o recomendación sin intervención humana directa, modifican la distribución de la responsabilidad organizacional. La delegación parcial o total de decisiones a algoritmos requiere una evaluación rigurosa de los criterios bajo los cuales estos modelos operan, de su trazabilidad técnica y del impacto que generan sobre usuarios, clientes o terceros afectados. En negocios emergentes, la adopción de sistemas automatizados suele responder a

necesidades de eficiencia, escalabilidad o reducción de carga operativa, lo que incrementa la urgencia de establecer límites éticos claros y mecanismos de supervisión efectiva.

Los modelos de inteligencia artificial utilizados en procesos decisionales pueden generar acciones con consecuencias jurídicas, económicas o sociales significativas. Estos modelos, al operar sobre entradas variables y ajustarse mediante funciones de optimización, introducen una capa de opacidad que dificulta la asignación de responsabilidad directa cuando se producen errores o resultados no deseados. La literatura técnica reconoce que los algoritmos utilizados en clasificación crediticia, priorización de candidatos, detección de fraude o segmentación de precios pueden afectar derechos fundamentales si no están adecuadamente documentados y supervisados (Binns, 2020). Esta condición exige que las organizaciones responsables de su desarrollo o despliegue definan mecanismos de revisión y establezcan criterios técnicos para justificar cada decisión automatizada implementada.

La trazabilidad algorítmica constituye una medida clave para asignar responsabilidad ética en sistemas automatizados. Esta trazabilidad implica la capacidad de reconstruir el proceso mediante el cual una decisión ha sido tomada por el sistema, incluyendo los datos de entrada, las transformaciones intermedias y la salida generada. La ausencia de trazabilidad impide identificar el origen de errores o analizar el impacto diferencial de las decisiones sobre distintos grupos. Herramientas como auditorías internas de algoritmos, registros de inferencia y versiones controladas de modelos permiten documentar el funcionamiento del sistema bajo condiciones específicas, facilitando la evaluación posterior por actores internos o externos (Morley et al., 2020). La trazabilidad se refuerza cuando los modelos incluyen mecanismos de logging estructurado, lo que permite capturar metadatos

sobre las condiciones de ejecución y facilitar auditorías posteriores por entes reguladores o terceros independientes.

La supervisión humana significativa constituye otra dimensión crítica en la toma de decisiones automatizadas. Este principio plantea que, aun cuando una decisión se base en una predicción algorítmica, debe existir un proceso humano capaz de revisar, modificar o anular dicha decisión. En situaciones donde las decisiones tienen implicaciones sensibles, como aceptación de solicitudes, evaluación de desempeño o asignación de recursos, la supervisión humana permite garantizar proporcionalidad, evitar automatismos injustificados y evaluar excepciones no capturadas por el modelo. Este enfoque requiere diseñar procesos híbridos donde la intervención humana se integre como parte del ciclo operativo sin comprometer la eficiencia (Mittelstadt, 2019). La presencia de profesionales capacitados en ética algorítmica y el establecimiento de roles técnicos responsables por la revisión de decisiones incrementa la legitimidad del sistema automatizado y permite su adaptación continua.

La responsabilidad ética también implica definir límites en la autonomía operativa de los sistemas automatizados. Estos límites se relacionan con la criticidad de las decisiones delegadas, la sensibilidad de los datos utilizados y la posibilidad de control externo. Establecer niveles diferenciados de autonomía permite acotar el uso de modelos en función de criterios de riesgo, aplicando restricciones técnicas como validaciones cruzadas, revisión por pares o bloqueo automático ante desviaciones significativas. Este control modular fortalece la gobernanza interna del sistema, facilita la conformidad regulatoria y permite una adaptación progresiva de las capacidades algorítmicas a los objetivos institucionales (Jobin et al., 2019). Estas prácticas también pueden incluir el desarrollo de matrices de riesgo algorítmico, que asignan niveles de

supervisión y documentación según el impacto potencial del modelo en la vida de los usuarios.

La toma de decisiones automatizadas en proyectos de base tecnológica requiere una revisión estructurada de los límites técnicos y normativos aplicables. La documentación técnica de cada modelo, la identificación de los puntos de intervención humana, la elaboración de protocolos de revisión y la implementación de métricas de evaluación ética constituyen pilares fundamentales para una gobernanza responsable. Estas prácticas, al estar integradas desde la fase de diseño, reducen los riesgos operativos y permiten una trazabilidad clara ante auditorías externas o requerimientos regulatorios. El compromiso organizacional con una ética operativa sólida permite que la automatización mantenga su funcionalidad sin comprometer la equidad, la legalidad ni la confianza de los actores involucrados.

### **6.3 PRIVACIDAD DE DATOS EN PLATAFORMAS EMERGENTES**

La gestión de datos personales en plataformas tecnológicas requiere marcos operativos que garanticen la protección de la información desde la etapa de diseño hasta su ciclo completo de uso, almacenamiento y eliminación. En proyectos digitales que operan en entornos dinámicos y con escalabilidad variable, el cumplimiento de principios de privacidad exige una articulación entre medidas técnicas, normativas y organizativas. La recolección masiva de datos por parte de sistemas de inteligencia artificial y aprendizaje automático incrementa la exposición a riesgos relacionados con la identificación indebida de usuarios, filtración de información sensible o uso no autorizado de patrones de comportamiento. Esta realidad adquiere mayor relevancia cuando se trata de modelos de negocio basados en plataformas de interacción digital, donde el volumen, variedad y velocidad del tratamiento de datos in-

tensifican las exigencias de control y supervisión continua.

Las iniciativas tecnológicas orientadas a servicios digitales suelen operar con bases de datos construidas a partir de formularios, navegación web, dispositivos móviles, sensores u otras interacciones automatizadas. Estos datos, en muchos casos, incluyen elementos identificables directa o indirectamente, como correos electrónicos, ubicaciones geográficas, historiales de consumo o comportamientos predictivos. La integración de múltiples fuentes, sin mecanismos de anonimización o minimización de datos, aumenta la vulnerabilidad ante accesos no autorizados, exposiciones accidentales o tratamientos incompatibles con las expectativas de los usuarios. La falta de control sobre las cadenas de procesamiento externo, como la subcontratación de servicios de almacenamiento o analítica, también introduce variables adicionales de riesgo operativo y jurídico (Voigt & von dem Bussche, 2024).

La implementación del principio de privacidad desde el diseño (privacy by design) constituye una condición técnica indispensable para mitigar estos riesgos. Este principio implica que los sistemas deben construirse considerando de forma estructural las obligaciones legales y éticas asociadas al uso de datos. Su aplicación incluye prácticas como la limitación de la recolección a lo estrictamente necesario, la separación de bases de datos por finalidad, el cifrado de los registros sensibles, el acceso segmentado por roles y la configuración predeterminada en favor de la privacidad. Estas prácticas deben estar documentadas y mantenidas mediante auditorías regulares, con la participación de responsables internos o asesores externos. La adopción de estas medidas permite que las plataformas operen con criterios de proporcionalidad y legalidad desde el inicio del desarrollo del producto, reduciendo las contingencias asociadas a incidentes de seguridad o inspecciones regulatorias (Cavoukian, 2011).

El cumplimiento normativo en entornos que procesan datos personales requiere alineación con marcos como el Reglamento General de Protección de Datos (GDPR) en Europa, la Ley de Privacidad del Consumidor de California (CCPA), o las legislaciones locales aplicables según el país de operación. Estos marcos exigen, entre otros elementos, la existencia de una base legal para el tratamiento de datos, la definición clara de las finalidades, el consentimiento informado, el derecho de acceso, rectificación, cancelación y oposición, así como la obligación de notificar violaciones de seguridad en plazos determinados. En entornos emergentes, donde los modelos de negocio pueden modificarse de forma continua, el cumplimiento exige una revisión periódica de prácticas, contratos, proveedores y flujos de datos. Este proceso debe estar respaldado por herramientas de trazabilidad, inventarios de activos informacionales y documentación accesible que permita demostrar conformidad en caso de requerimientos regulatorios (Tene & Polonetsky, 2015).

Las plataformas emergentes deben contar con un sistema de gobernanza de datos que permita identificar qué información se recopila, quién tiene acceso, con qué herramientas se procesa y bajo qué condiciones puede ser eliminada. Este sistema debe estar respaldado por políticas documentadas, responsables técnicos, registros de procesamiento y mecanismos de control interno. La existencia de evaluaciones de impacto sobre protección de datos (DPIA) en sistemas que implican riesgos elevados permite anticipar consecuencias negativas y definir medidas preventivas antes del despliegue. Estas evaluaciones deben considerar no solo los aspectos técnicos del sistema, sino también los efectos sobre los derechos y libertades de los individuos, en especial en contextos donde las decisiones automatizadas puedan generar exclusión, discriminación o exposición indebida. Las organizaciones que

adoptan estas estructuras mejoran su capacidad de respuesta ante auditorías, demandas regulatorias o incidentes de seguridad (IAPP, 2024).

La privacidad en plataformas emergentes requiere una comprensión integral de los flujos de información, los riesgos asociados a cada componente del ecosistema tecnológico y las obligaciones que derivan de las relaciones contractuales con usuarios, proveedores y autoridades. Esta comprensión debe traducirse en acciones específicas como la clasificación de los tipos de datos manejados, la aplicación de técnicas de seudonimización, la implementación de periodos definidos de retención y la existencia de procedimientos claros para ejercer los derechos ARCO (acceso, rectificación, cancelación y oposición). El diseño de arquitecturas resilientes, junto con una cultura organizacional orientada a la ética digital, permite construir modelos de operación sostenibles que prioricen la confianza como un activo estratégico.

#### **6.4 TRANSPARENCIA ALGORÍTMICA Y VALIDACIÓN ANTE TERCEROS**

La transparencia algorítmica en sistemas automatizados implementados en proyectos tecnológicos representa una condición técnica esencial para garantizar la explicabilidad, la trazabilidad y la rendición de cuentas. Esta transparencia implica la posibilidad de comprender, auditar y justificar las decisiones generadas por modelos predictivos o clasificadores, tanto por parte de los equipos técnicos como por terceros autorizados. Cuando los algoritmos afectan el acceso a servicios, definen condiciones comerciales o influyen en decisiones organizacionales automatizadas, los requisitos de auditabilidad y exposición metodológica deben integrarse dentro de la arquitectura del sistema. Esto permite anticipar escenarios de riesgo legal, operativo o reputacional y desarrollar mecanis-

mos internos que garanticen el cumplimiento normativo y la confianza institucional.

La explicabilidad algorítmica se refiere a la capacidad de interpretar cómo y por qué un modelo ha generado una determinada predicción o decisión. Este principio adquiere relevancia técnica cuando se utilizan modelos complejos como redes neuronales profundas, árboles de decisión ensamblados o sistemas de aprendizaje reforzado, cuyos procesos internos no resultan fácilmente comprensibles. Herramientas como SHAP (SHapley Additive exPlanations), LIME (Local Interpretable Model-agnostic Explanations), Permutation Importance y otros métodos de interpretación post hoc permiten descomponer las salidas del modelo para identificar la influencia de cada variable de entrada. La implementación de estas técnicas debe ser incorporada desde el diseño del sistema, con documentación accesible, versiones auditables del modelo bajo condiciones controladas y una estructura que facilite la explicación técnica a actores no especialistas (Doshi-Vélez & Kim, 2017).

La validación ante terceros constituye un componente crítico para verificar la confiabilidad, la robustez y la equidad de los sistemas automatizados. Este proceso implica la revisión de los modelos por actores externos independientes, como auditores técnicos, consultoras especializadas, organismos certificadores o autoridades regulatorias. La validación puede adoptar formas como pruebas de caja negra, simulaciones controladas, análisis de sesgos o revisión del cumplimiento normativo en materia de protección de datos, no discriminación y calidad del servicio. Para permitir esta validación, los proyectos deben contar con registros estructurados, documentación técnica completa, reportes de métricas desagregadas y evidencia del cumplimiento de principios éticos y legales. Estas acciones fortalecen la gobernanza y permiten una respuesta efectiva ante procesos de fiscalización, litigios

o procesos de acreditación externa (Raji et al., 2020).

El diseño de mecanismos de transparencia requiere integrar criterios de interpretabilidad desde las primeras etapas del desarrollo del sistema. Esto implica seleccionar algoritmos cuya estructura permita su análisis posterior, definir variables observables, controlar la complejidad del modelo y limitar el uso de técnicas opacas en entornos de alto impacto. La transparencia no se restringe al aspecto técnico del código fuente, sino que también abarca la arquitectura del flujo de datos, las decisiones de ingeniería, los criterios de entrenamiento y los controles aplicados durante la validación. Esta información debe estar disponible de forma controlada para las partes interesadas, garantizando tanto la confidencialidad como la rendición de cuentas. La estandarización de reportes de validación, las plantillas de revisión ética y los esquemas de clasificación de riesgos permiten organizar esta información de forma estructurada y auditable.

Las organizaciones que integran prácticas de transparencia algorítmica fortalecen su gobernanza interna y mejoran su preparación para enfrentar procesos regulatorios, demandas de transparencia pública o solicitudes de información por parte de clientes, usuarios o instituciones. La trazabilidad completa del modelo, desde sus datos de entrenamiento hasta sus decisiones finales, permite identificar errores, ajustar parámetros y documentar desviaciones. Esta trazabilidad también facilita la respuesta a requerimientos normativos como el derecho a explicación o los principios de equidad en el tratamiento algorítmico. La estructuración de esta información bajo protocolos estandarizados permite su reutilización, mejora la interoperabilidad de sistemas y facilita la participación de organismos de control en procesos de verificación independiente. Adicionalmente, las plataformas que operan con modelos que afectan el acceso a bienes, servicios o de-

rechos fundamentales deben implementar mecanismos para realizar evaluaciones de impacto algorítmico, que incluyan tanto variables técnicas como consecuencias organizativas, reputacionales o jurídicas.

## **6.5 BUENAS PRÁCTICAS DE GOBERNANZA DIGITAL EN EMPRENDIMIENTOS**

La gobernanza digital constituye un componente esencial en la estructuración de proyectos tecnológicos que utilizan sistemas automatizados, procesamiento masivo de datos o inteligencia artificial. Esta gobernanza se refiere al conjunto de principios, estructuras y procedimientos mediante los cuales una organización define las reglas para la operación responsable de sus activos digitales. La implementación de estas prácticas tiene como objetivo asegurar la integridad de los procesos algorítmicos, la protección de los datos gestionados, el cumplimiento de las normativas vigentes y la transparencia frente a los distintos grupos de interés. En escenarios donde los ciclos de innovación son acelerados, la existencia de un marco de gobernanza clara permite sostener la calidad técnica y ética del sistema.

Una práctica central en la gobernanza digital es la definición explícita de políticas internas que regulen el uso de tecnologías digitales, algoritmos y datos. Estas políticas deben establecer criterios sobre la recopilación, almacenamiento, tratamiento, difusión y eliminación de información digital. Asimismo, deben incorporar cláusulas sobre supervisión humana, intervención ante fallos, trazabilidad de decisiones automatizadas, y niveles de responsabilidad técnica y legal. La formalización de estas políticas permite estandarizar comportamientos, facilitar auditorías internas y reducir la ambigüedad operativa. Para mantener su efectividad, estas políticas requieren una revisión periódica, ajustada a cambios en

la tecnología, el entorno normativo y las características del producto o servicio ofrecido (OECD, n.d.).

La gobernanza digital también requiere estructuras organizativas que asignen funciones, responsabilidades y flujos de reporte relacionados con los sistemas digitales. Esto implica establecer roles como responsable de protección de datos, oficial de cumplimiento algorítmico, auditor técnico o comité de ética tecnológica. Estos actores deben contar con la autoridad operativa para evaluar sistemas, detener despliegues, exigir documentación o recomendar ajustes técnicos. La definición clara de estos roles fortalece la supervisión continua y crea instancias formales para el control cruzado, evitando que la toma de decisiones sobre sistemas sensibles quede en manos de actores únicos o sin formación especializada (Floridi et al., 2018).

Otro componente fundamental es la documentación técnica estructurada de los sistemas digitales. Esta documentación debe incluir el diseño de los modelos, las fuentes de datos utilizadas, los parámetros de entrenamiento, las métricas de desempeño, los procedimientos de validación y las decisiones tomadas durante el desarrollo. La disponibilidad de esta información permite reconstruir el funcionamiento del sistema, verificar su coherencia con los objetivos del proyecto y facilitar la revisión por terceros. La gobernanza digital exige que esta documentación no sea tratada como un requisito final, sino como un elemento dinámico integrado en cada iteración del sistema.

La evaluación de impacto algorítmico representa una herramienta de control que permite anticipar los efectos técnicos, sociales, económicos o legales de un sistema automatizado. Esta evaluación debe realizarse antes del despliegue del sistema y actualizarse ante modificaciones sustanciales. Su objetivo es identificar posibles riesgos, proponer medidas

de mitigación, y establecer indicadores que permitan monitorear el comportamiento del modelo en condiciones reales de uso. Esta práctica se refuerza mediante la adopción de marcos de evaluación estandarizados y el uso de indicadores multidimensionales de riesgo, alineados con el tipo de datos procesados, el grado de automatización y la criticidad de las decisiones generadas (Binns & Veale, 2021).

La gestión de incidentes digitales también forma parte de las buenas prácticas de gobernanza. Toda organización que opere con modelos automatizados debe contar con un protocolo para identificar, registrar, comunicar y resolver eventos como fallos de funcionamiento, decisiones incorrectas, accesos no autorizados o desviaciones estadísticas. Este protocolo debe estar activado por mecanismos automáticos de alerta o por auditorías internas programadas. El seguimiento de estos incidentes permite identificar patrones recurrentes, priorizar correcciones y establecer retroalimentaciones para mejorar los sistemas en producción. La trazabilidad de estos procesos es indispensable para demostrar diligencia organizativa ante eventuales requerimientos regulatorios o contractuales (Wachter et al., 2021).

La gobernanza digital efectiva se fortalece mediante la formación continua de los equipos técnicos y estratégicos. Esta formación debe abarcar competencias en ética digital, normativas sectoriales, diseño responsable de algoritmos, evaluación de impacto y metodologías de documentación. La generación de capacidades internas permite una implementación más robusta de las estructuras de gobernanza y reduce la dependencia de soluciones externas que no siempre se ajustan al marco operativo de cada organización. La gobernanza no se limita a evitar riesgos, sino que también permite generar valor a partir de la confianza, la trazabilidad y la legitimidad institucional.

## CAPÍTULO 7

### **INTELIGENCIA ARTIFICIAL Y TRANSFORMACIÓN DEL TRABAJO**

#### **7.1 NUEVOS PERFILES HÍBRIDOS EN STARTUPS BASADAS EN DATOS**

La expansión de sistemas inteligentes y el uso intensivo de datos en organizaciones innovadoras ha generado la necesidad de perfiles profesionales con competencias mixtas, que articulen capacidades técnicas con conocimiento funcional de negocio. Estos perfiles híbridos operan en entornos que integran herramientas de inteligencia artificial, automatización de procesos y analítica avanzada, y requieren una formación adaptativa que combine disciplinas tradicionalmente separadas. Su incorporación permite a las organizaciones diseñar soluciones centradas en datos, interpretar resultados generados por algoritmos y contribuir a la evolución de productos o servicios desde una perspectiva técnica y estratégica (Wilson & Daugherty, 2022).

Entre los perfiles más demandados se encuentran los analistas de producto con dominio en machine learning, los diseñadores UX con experiencia en sistemas adaptativos, los científicos de datos con capacidad para liderar decisiones operativas y los desarrolladores de software que integran modelos predictivos en arquitecturas digitales. Estos perfiles no se definen únicamente por el conocimiento técnico, sino por la capacidad de traducir requerimientos organizacionales en soluciones basadas en datos, y de comunicar resultados

técnicos a equipos interfuncionales. Esta versatilidad funcional exige una base sólida en programación, estadística, arquitectura de datos y aprendizaje automático, complementada por habilidades en comunicación, gestión de proyectos y pensamiento analítico aplicado (Mckinsey and Company, 2020).

La formación de estos perfiles puede provenir de rutas académicas no lineales, donde profesionales de áreas como diseño, economía, sociología o comunicación adquieren capacidades técnicas mediante programas intensivos, certificaciones o aprendizaje autodirigido. También se identifican trayectorias inversas, donde perfiles provenientes de la ingeniería o la informática desarrollan habilidades para el análisis de mercado, diseño centrado en el usuario o evaluación de impacto. Esta convergencia funcional da lugar a equipos con alto grado de autonomía, capaces de operar en todas las fases del ciclo de vida de un sistema basado en datos, desde la exploración hasta la implementación y monitoreo de resultados (Frank et al., 2018).

La configuración organizativa debe facilitar la identificación, formación y retención de estos perfiles, mediante esquemas flexibles de trabajo, planes de desarrollo continuo y espacios de interacción entre funciones técnicas y estratégicas. Los procesos de reclutamiento deben reformularse para evaluar la capacidad de adaptación tecnológica, la comprensión de procesos de inferencia automatizada y la experiencia previa en resolución de problemas con base en datos. La gestión del conocimiento dentro de la organización debe promover la documentación de aprendizajes técnicos, la estandarización de procesos analíticos y el desarrollo de capacidades compartidas entre áreas con distintos niveles de especialización (Wilson & Daugherty, 2022).

El incremento de perfiles híbridos plantea también la necesidad de establecer sistemas de colaboración con límites fun-

cionales claros, mecanismos de validación cruzada y estructuras de toma de decisiones donde se valore tanto el juicio humano como el aporte de los sistemas automatizados. La interacción entre humanos y sistemas inteligentes exige que los profesionales comprendan las limitaciones de los modelos, sus supuestos técnicos y las implicaciones que sus decisiones pueden tener sobre el comportamiento del sistema completo. La adopción de principios de gobernanza algorítmica y estándares de calidad en los flujos de trabajo colaborativos permite maximizar el aporte de estos perfiles y reducir el riesgo asociado al uso indiscriminado de tecnologías predictivas en decisiones estratégicas.

## **7.2 IA COMO COMPLEMENTO DE EQUIPOS HUMANOS EN PROYECTOS ÁGILES**

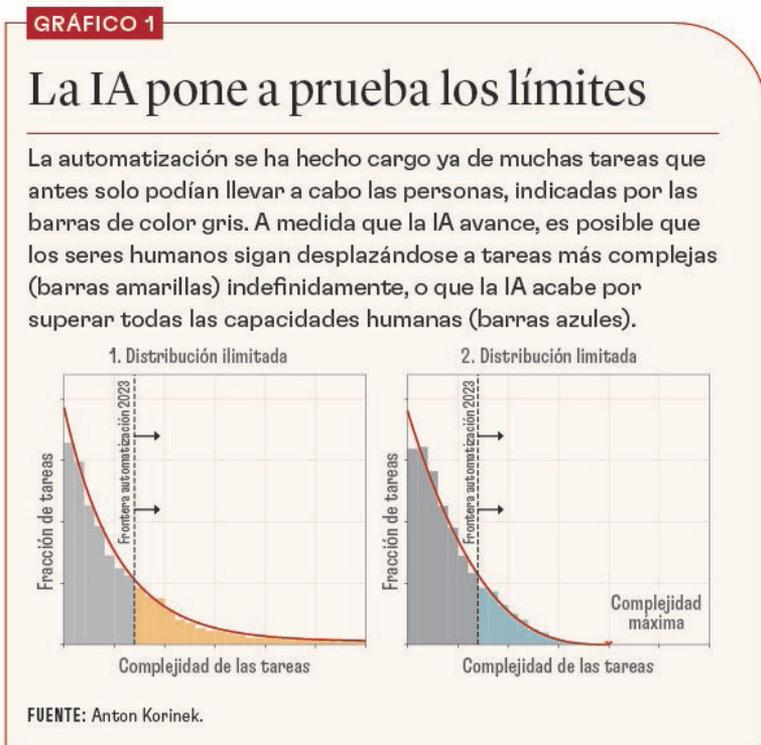
La incorporación de herramientas de inteligencia artificial como soporte técnico en metodologías de desarrollo ágil redefine los esquemas tradicionales de colaboración y entrega de valor en organizaciones orientadas a la innovación. En ciclos iterativos de planificación, ejecución y validación, la IA contribuye como mecanismo de asistencia, optimización y análisis, integrándose en diferentes etapas del flujo operativo sin reemplazar la supervisión humana. Este modelo de trabajo distribuido entre humanos y algoritmos permite incrementar la velocidad de respuesta, reducir la carga cognitiva en tareas repetitivas y mejorar la precisión en la toma de decisiones.

En entornos que adoptan marcos de trabajo como Scrum, Lean o Kanban, la inteligencia artificial se aplica en la generación automática de historias de usuario, priorización de tareas con base en datos históricos, estimaciones de carga por sprint, monitoreo de productividad o análisis de dependencias. Estos sistemas extraen patrones del comportamiento del equipo, del backlog acumulado o de las métricas de entregas

anteriores para emitir recomendaciones en tiempo real. Herramientas como Jira, Asana, Notion o ClickUp integran módulos de IA que permiten automatizar recordatorios, identificar retrasos, reasignar tareas según disponibilidad o proponer reorganización de flujos (Alliata et al., 2025).

**Figura 4**

*La IA pone a prueba los límites.*



*Nota.* Tomado de <https://www.imf.org/es/Publications/fandd/issues/2023/12/Scenario-Planning-for-an-AGI-future-Anton-korinek>

El valor funcional de la IA como complemento reside en su capacidad de operar como una capa de apoyo técnico al equipo, sin interferir con la toma de decisiones autónoma. Su diseño debe garantizar que las recomendaciones generadas

sean interpretables, parametrizables y sujetas a revisión por parte de los roles de liderazgo, como product owners o scrum masters. Esta integración requiere asegurar la trazabilidad de cada sugerencia, registrar las condiciones bajo las cuales se generaron y evaluar retrospectivamente su utilidad en los objetivos del proyecto. El objetivo no es sustituir la capacidad crítica del equipo, sino ofrecer insumos que reduzcan la incertidumbre operativa en entornos iterativos. Esto exige que los algoritmos sean entrenados con datos alineados al entorno funcional, actualizados periódicamente y evaluados bajo métricas específicas de efectividad organizacional.

La implementación de IA en proyectos ágiles también exige un rediseño del ciclo de retroalimentación. La evaluación del desempeño ya no se limita al análisis de métricas cuantitativas o percepciones del equipo, sino que puede incluir datos generados por los módulos inteligentes: número de predicciones aceptadas, desviaciones respecto a los objetivos iniciales, correlación entre alertas emitidas y eventos reales. Este ciclo de revisión permite calibrar los algoritmos en función de las condiciones reales de uso, optimizar las recomendaciones futuras y fortalecer la alineación entre herramientas automáticas y metas de producto. También permite identificar patrones no observables por humanos, como cuellos de botella estructurales, dependencias no documentadas o dinámicas de carga desequilibradas dentro del equipo (Haidabrus, 2024).

Para asegurar la eficacia de esta complementariedad, se requiere un marco técnico que regule el nivel de autonomía otorgado a los sistemas de IA dentro de los flujos ágiles. Esta regulación incluye la definición de umbrales de intervención automática, validación manual de ciertas operaciones y mecanismos de override explícitos ante decisiones críticas. Asimismo, es necesario establecer criterios de diseño explicativo y auditabilidad, de manera que cualquier miembro del equipo

pueda comprender cómo se originó una sugerencia algorítmica. Esta claridad funcional favorece la adopción tecnológica, reduce la resistencia operativa y garantiza el uso responsable de la automatización en procesos colaborativos. En organizaciones que trabajan con equipos distribuidos o multiculturales, esta transparencia también permite alinear expectativas y distribuir la responsabilidad operativa de forma equitativa (Li et al., 2025).

La colaboración efectiva entre sistemas de IA y equipos humanos en entornos ágiles depende también de la capacitación técnica transversal. Esta capacitación debe abordar el funcionamiento básico de los modelos implementados, sus limitaciones operativas, los criterios utilizados en sus predicciones y las condiciones bajo las cuales sus recomendaciones deben ser priorizadas o descartadas. Este conocimiento compartido permite al equipo establecer relaciones funcionales con la tecnología, mantener la autonomía operativa y distribuir la carga de validación entre los distintos actores involucrados en el ciclo de desarrollo ágil. Adicionalmente, la capacitación debe incorporar elementos de ética algorítmica, análisis de impacto en procesos productivos y técnicas de interpretación de resultados para asegurar que los equipos mantengan una visión crítica y supervisada del uso de IA en entornos de cambio continuo.

### **7.3 AUTOMATIZACIÓN DE TAREAS EMPRENDEDORAS REPETITIVAS**

La automatización de tareas repetitivas mediante inteligencia artificial representa una estrategia operativa clave para iniciativas digitales que requieren eficiencia, escalabilidad y mayor enfoque en el desarrollo de soluciones diferenciales. Este enfoque consiste en delegar a sistemas automatizados funciones operativas recurrentes que no requieren

supervisión constante, permitiendo que los equipos reorienten sus recursos hacia el diseño, validación y ejecución de actividades que aportan valor técnico y estratégico. La automatización no implica solamente velocidad, sino también estandarización de procesos, reducción de errores manuales, mejora en la trazabilidad operativa y sostenibilidad en ciclos de trabajo intensivos.

Los procesos repetitivos automatizables incluyen clasificación de correos electrónicos, respuestas predefinidas en canales de atención, consolidación de reportes financieros, programación de reuniones, actualización de bases de datos, control de inventarios, segmentación de públicos, monitoreo de indicadores clave, procesamiento de formularios y generación de comprobantes operativos. Estas funciones pueden ser gestionadas mediante herramientas que integran aprendizaje automático, procesamiento de lenguaje natural, sistemas de reglas condicionales y flujos preconfigurados por plataformas de automatización. Herramientas como Make, Zapier, Power Automate, UiPath, AirTable o Notion AI permiten configurar soluciones operativas en entornos sin necesidad de codificación avanzada, adaptables a estructuras organizativas con recursos técnicos limitados (Jackson et al., 2024).

La implementación de automatizaciones requiere una fase inicial de mapeo de procesos, donde se identifiquen tareas con alta frecuencia, baja variabilidad y dependencia mínima de juicio humano. Posteriormente, se procede con la definición de condiciones de entrada y salida, integración con otras herramientas digitales y validación de comportamiento en entornos controlados. Los flujos deben incluir mecanismos de seguimiento, alertas ante errores y puntos de control manual para operaciones sensibles. Este diseño funcional debe estar documentado mediante protocolos operativos, matrices de verificación y procedimientos de escalamiento ante des-

viaciones, asegurando que cada automatización se mantenga alineada con las necesidades operativas y los objetivos del equipo (Dam et al., 2019).

La automatización no elimina la necesidad de supervisión. Los flujos implementados deben ser auditables en tiempo real, mediante paneles que permitan visualizar actividad, errores detectados, tiempos de respuesta, volumen procesado y trazabilidad de cada ejecución. Estos paneles deben estar disponibles para los responsables operativos, con permisos diferenciados por niveles de acceso. La revisión periódica de métricas permite detectar oportunidades de mejora, optimizar reglas condicionales, ajustar los puntos de integración y garantizar que el sistema continúe entregando valor funcional. En entornos donde se manipulan datos sensibles o se ejecutan procesos financieros, la trazabilidad completa y la reversibilidad de acciones son requisitos técnicos obligatorios.

La automatización de tareas repetitivas contribuye a liberar recursos humanos, mejorar la experiencia de usuario y consolidar operaciones más sostenibles. No obstante, su implementación debe evitar la delegación indiscriminada de procesos críticos. Se recomienda priorizar aquellas actividades con alto volumen y bajo riesgo, diseñando mecanismos de escalamiento manual y protocolos de reversión inmediata. La introducción de capacidades cognitivas, como análisis semántico o clasificación probabilística, permite expandir las automatizaciones a tareas con cierta variabilidad estructurada, como revisión de mensajes, agrupamiento de solicitudes o análisis de encuestas. Esta transición debe ser progresiva y acompañada por procesos de validación cruzada con el equipo técnico para evitar dependencias estructurales inadecuadas.

## **7.4 RECONVERSIÓN DE ROLES Y ADQUISICIÓN DE COMPETENCIAS CLAVE**

La gestión automatizada del ciclo de vida del cliente mediante inteligencia artificial representa un pilar estructural en la configuración de modelos de negocio orientados a la eficiencia algorítmica y la personalización masiva. Este enfoque permite integrar de forma coordinada y automatizada los distintos momentos que componen la relación entre el cliente y la organización, desde su captación inicial hasta su reactivación tras un periodo de inactividad. Cada fase del ciclo de vida se estructura a partir de flujos de trabajo soportados por algoritmos de inteligencia artificial que permiten optimizar decisiones, anticipar comportamientos y ejecutar acciones adaptadas a perfiles individuales. El despliegue de estos sistemas permite reducir costos operativos, minimizar errores humanos, incrementar el valor de vida del cliente (CLV) y sostener una relación comercial coherente a lo largo del tiempo.

Durante la fase de captación, los algoritmos de aprendizaje supervisado procesan grandes volúmenes de datos procedentes de diversas fuentes, incluyendo redes sociales, buscadores, historiales de navegación y registros de interacción anteriores, para identificar prospectos con alta probabilidad de conversión. Esta segmentación predictiva permite dirigir esfuerzos publicitarios de forma precisa, asignando recursos sólo a aquellos usuarios que presentan mayor propensión a convertirse en clientes. Las plataformas de publicidad programática, como Meta Ads, Google Ads o Taboola, utilizan estos modelos para ejecutar subastas automáticas de espacios publicitarios, definiendo en milisegundos cuándo mostrar un anuncio, a quién, en qué formato y con qué mensaje, generando un ecosistema de captación dinámico y sensible al comportamiento en tiempo real (Google, 2025).

En la etapa de activación, el foco se desplaza hacia la per-

sonalización de la experiencia inicial del usuario con el producto o servicio. Los sistemas algorítmicos se integran con plataformas de experiencia digital para configurar flujos de bienvenida que se ajustan automáticamente a las características de cada usuario. Mediante el análisis de eventos de interacción, tiempos de permanencia, clics y rutas de navegación, plataformas como Mixpanel, Amplitude y Heap permiten determinar en tiempo real las acciones que deben ejecutarse para facilitar la comprensión del producto y acelerar el primer valor percibido. Este tipo de onboarding adaptativo mejora la retención temprana, disminuye la tasa de abandono inicial y sienta las bases para una experiencia sostenida y productiva (Kolbl et al., 2020).

En lo que respecta a la fase de retención, los modelos predictivos desempeñan un papel clave al identificar patrones de conducta que anticipan el abandono. El aprendizaje automático, mediante algoritmos como XGBoost, LightGBM o redes neuronales multicapa, permite estimar la probabilidad de churn de cada cliente en función de su comportamiento reciente, la frecuencia de uso, las solicitudes de soporte y la evolución de su satisfacción. Cuando estos modelos detectan un riesgo elevado, se activan flujos de prevención personalizados que pueden incluir descuentos exclusivos, mejoras en el servicio, intervenciones humanas o seguimiento mediante canales automatizados como chatbots. Estas acciones buscan restablecer el valor percibido por el cliente y evitar su desvinculación (Verbeke et al., 2014).

La monetización se potencia mediante sistemas de inteligencia artificial que optimizan los procesos de conversión y aumentan el valor de cada transacción. A través del uso de modelos de deep learning entrenados sobre comportamientos de compra, preferencias declaradas y patrones de navegación, las organizaciones pueden ofrecer productos relevantes,

ajustar precios de forma dinámica y sugerir combinaciones complementarias (cross-selling) o superiores (upselling) que incrementan el ticket promedio. Plataformas como Dynamic Yield y Salesforce Einstein operan como motores de personalización que ajustan en tiempo real la composición de la página, los mensajes y las ofertas, creando trayectorias de consumo únicas y adaptadas al usuario.

La reactivación de clientes inactivos también se apoya en inteligencia artificial, a través de modelos que predicen el momento más adecuado para contactar a cada usuario y el tipo de incentivo que puede motivar su retorno. Estas estrategias utilizan modelos de retargeting y scoring de reenganche que analizan el historial de interacciones, las razones probables de abandono y las ventanas de oportunidad para recuperar el interés del cliente. Plataformas como Braze, OneSignal y Customer.io permiten configurar campañas automatizadas que se ejecutan en canales asincrónicos como correo electrónico, notificaciones push o mensajes dentro de la aplicación, mejorando la efectividad de las acciones de recuperación.

Todo este ecosistema funcional se sostiene sobre infraestructuras de datos integradas denominadas Customer Data Platforms (CDP). Estas plataformas consolidan información procedente de diferentes canales y puntos de contacto, generando un perfil unificado y actualizado del cliente (AWS, n.d.). Los datos recolectados alimentan los modelos de inteligencia artificial mediante flujos automatizados de extracción, transformación y carga (ETL), permitiendo la toma de decisiones automática sin intervención manual. Esta arquitectura favorece una orquestación inteligente del ciclo de vida del cliente, donde cada acción es consecuencia de un análisis preciso y una predicción fundamentada.

La gestión automatizada del ciclo de vida del cliente mediante inteligencia artificial no sólo representa un avance en

términos de eficiencia operativa, sino que redefine la relación entre las organizaciones y sus usuarios. Al pasar de estrategias genéricas a sistemas de microsegmentación y personalización en tiempo real, se transforma la forma en que se construye, mantiene y expande el vínculo comercial. Esta transformación estática hacia una interacción adaptativa convierte a la IA en un componente central del diseño organizativo, no como una herramienta complementaria, sino como el motor estructural de la decisión automatizada y la optimización continua (Davenport et al., 2020a).

## **7.5 PLATAFORMAS DE IA PARA ORGANIZACIÓN DEL TRABAJO COLABORATIVO**

La integración de inteligencia artificial en la optimización del customer journey permite transformar los procesos de interacción entre el cliente y una organización en trayectorias sistemáticas, medibles y adaptables en tiempo real. Esta aplicación se fundamenta en la capacidad de los algoritmos para recolectar, analizar y predecir comportamientos a lo largo de los distintos puntos de contacto, con el objetivo de maximizar la satisfacción del usuario, la conversión efectiva y la rentabilidad del ciclo de vida del cliente. La inteligencia artificial permite no solo detectar fricciones o abandonos en las etapas críticas del recorrido, sino también personalizar contenidos, automatizar respuestas, anticipar necesidades y rediseñar puntos de contacto según patrones emergentes en los datos. Esta capacidad de adaptación algorítmica convierte el customer journey en una secuencia de decisiones optimizadas, alineadas con las expectativas individuales de cada usuario y ajustadas a los objetivos operativos del negocio.

Uno de los componentes centrales en este proceso es el mapeo automatizado del customer journey. Este mapeo se realiza mediante herramientas que integran registros tran-

saccionales, datos de navegación, interacciones en redes sociales y comunicaciones previas, permitiendo construir representaciones funcionales del trayecto que sigue cada usuario. Algoritmos de clustering, aprendizaje no supervisado y detección de anomalías se utilizan para identificar segmentos conductuales, reconocer trayectorias atípicas y establecer correlaciones entre eventos críticos y decisiones del cliente. Estas representaciones se visualizan en dashboards interactivos y sistemas de monitoreo continuo, que permiten a los equipos de marketing, ventas y soporte ejecutar ajustes tácticos basados en datos empíricos. El mapeo automatizado habilita una comprensión profunda de los puntos de fricción, los momentos de conversión y las oportunidades latentes de valor, articulando un ecosistema operativo orientado a la mejora constante (Duarte et al., 2022).

La inteligencia artificial también permite optimizar la secuencia, calidad y sincronización de los puntos de contacto con el cliente. A través del análisis predictivo y los sistemas de recomendación en tiempo real, es posible determinar cuándo y cómo intervenir para maximizar el impacto positivo sobre el comportamiento del usuario. Por ejemplo, los modelos de aprendizaje profundo pueden anticipar la necesidad de soporte antes de que se exprese explícitamente, permitiendo que sistemas de atención automatizada desplieguen sugerencias o resoluciones en el momento preciso. Esta capacidad también se aplica a la configuración automática de contenidos y promociones, ajustadas al canal, dispositivo y perfil del usuario, mejorando la relevancia de cada interacción y reduciendo la fatiga informativa. Las plataformas digitales que integran IA son capaces de ajustar dinámicamente el contenido visual, el texto, el orden de las recomendaciones y el ritmo de las notificaciones, construyendo experiencias que se sienten personalizadas sin necesidad de intervención humana directa.

Otra aplicación técnica relevante es la detección de cuellos de botella y puntos de fuga a lo largo del recorrido del cliente. Mediante el uso de modelos secuenciales, aprendizaje supervisado y análisis de abandono en cada etapa, la IA permite identificar eventos que anteceden a decisiones de retiro, inactividad o cancelación. Estos hallazgos se integran en sistemas de alerta temprana que pueden activar intervenciones específicas, como recontacto personalizado, ajustes en la oferta o rediseño del flujo de experiencia. En sectores como servicios financieros, educación en línea o suscripciones digitales, esta aplicación permite reducir la deserción, mejorar la experiencia continua y optimizar los recursos destinados a la retención. El monitoreo permanente mediante sistemas algoritmos permite actualizar las estrategias de contacto en función de nuevas condiciones de uso, estacionalidad, patrones externos y segmentaciones emergentes, generando una capacidad adaptativa estructurada en tiempo real (Lim & Rasul, 2022).

La aplicación de IA en el customer journey se vincula también con la medición en tiempo real del engagement y de los niveles de interacción significativa del usuario. A través de sensores digitales, registros de comportamiento, datos biométricos y análisis de sentimiento en texto o voz, los sistemas inteligentes pueden calcular el nivel de implicación del usuario con un producto o servicio y correlacionarlo con indicadores clave de desempeño. La IA permite generar puntuaciones de engagement por sesión, detectar desviaciones en la curva de uso, calcular tasas de fricción, clasificar estados emocionales y proponer micro ajustes en diseño, contenido o interacción. Estas mediciones no solo mejoran la experiencia directa del cliente, sino que alimentan los modelos de retroalimentación continua que se utilizan para rediseñar productos, plataformas o flujos operativos. La inteligencia artificial, por tanto, permite transformar el engagement en una variable operati-

va, gestionable y optimizable (Hossain et al., 2022).

Estas funcionalidades se articulan en arquitecturas tecnológicas que integran plataformas de datos del cliente (CDP), sistemas de gestión de experiencia (CEM), motores de automatización y modelos analíticos interconectados. La eficacia de estas soluciones depende de la calidad de los datos recolectados, la coherencia de las reglas de negocio, la capacidad de los equipos para interpretar los resultados y la velocidad de ejecución en la implementación de los ajustes sugeridos por los modelos. Cuando estas condiciones se cumplen, la inteligencia artificial permite estructurar un customer journey adaptativo, optimizado y centrado en el valor. Este recorrido no solo responde en tiempo real a condiciones individuales y cambios contextuales, sino que también habilita una operación continua basada en evidencia, en la que cada punto de contacto contribuye a la consolidación de una experiencia integrada y funcional.

## CAPÍTULO 8

### ACCESIBILIDAD Y BRECHAS EN EL EMPRENDIMIENTO CON IA

#### 8.1 ASIMETRÍAS EN EL ACCESO A INFRAESTRUCTURA Y DATOS

Las condiciones de acceso a infraestructura tecnológica y datos determinan de manera directa las capacidades de adopción y desarrollo de soluciones basadas en inteligencia artificial dentro de los entornos productivos. La brecha estructural entre regiones, sectores y organizaciones condiciona la viabilidad de implementar sistemas algorítmicos, tanto por la disponibilidad de recursos computacionales como por la calidad y cantidad de datos accesibles. Esta asimetría no se manifiesta únicamente en el acceso a hardware especializado, sino también en los niveles de conectividad, la disponibilidad de servicios en la nube, el acceso a bibliotecas digitales y la existencia de plataformas de datos abiertos relevantes para los objetivos del proyecto. En el caso particular de los proyectos emprendedores, esta brecha define la posibilidad real de construir, escalar y mantener soluciones digitales con componente algorítmico.

En los entornos de infraestructura, las limitaciones más frecuentes se relacionan con la escasez de unidades de procesamiento gráfico, capacidades limitadas de almacenamiento distribuido, redes inestables y restricciones presupuestarias. Estas condiciones afectan especialmente a negocios incipientes, que no cuentan con capital de riesgo suficiente para con-

tratar servicios avanzados de computación en la nube o adquirir estaciones de trabajo especializadas (Mahajan, 2025). Sin esta capacidad técnica, la construcción de modelos propios resulta inviable, obligando a depender de herramientas preexistentes con baja capacidad de personalización. Las limitaciones no solo comprometen la eficiencia de los procesos, sino que también afectan la calidad de los productos digitales ofrecidos, reduciendo su competitividad frente a actores con mayor infraestructura.

El acceso desigual a datos relevantes constituye un obstáculo operativo crítico. La inteligencia artificial requiere bases de datos extensas, representativas y actualizadas. Muchos proyectos emprendedores no disponen de mecanismos adecuados para recolectar, limpiar, almacenar y explotar datos en volúmenes suficientes. Cuando existen registros disponibles, estos suelen estar fragmentados, incompletos o no estandarizados, lo que impide su uso directo en procesos de entrenamiento algorítmico. Esta situación restringe la posibilidad de generar soluciones contextualmente válidas, pues los algoritmos dependen de datos pertinentes para el entorno o sector específico en el que se aplican (Ecuación Digital, 2025).

También existen barreras legales, técnicas y culturales para acceder a fuentes externas de información. Muchos repositorios operan bajo licencias restrictivas o presentan formatos propietarios que dificultan su reutilización. A nivel organizacional, no todas las instituciones están dispuestas a compartir datos relevantes por temor a vulnerar regulaciones, comprometer la seguridad informática o perder ventajas competitivas. Esta cultura de protección restringe la posibilidad de construir ecosistemas colaborativos basados en datos compartidos, lo que limita las oportunidades de innovación abierta y aprendizaje entre organizaciones.

Desde una perspectiva funcional, esta asimetría reduce la

capacidad de los proyectos emergentes para validar sus propuestas de valor, automatizar decisiones críticas y escalar modelos de negocio basados en inteligencia artificial (Aithor, 2024). La carencia de datos adecuados limita el entrenamiento de sistemas predictivos, impide personalizar productos digitales y restringe la generación de indicadores confiables sobre el comportamiento del usuario. En consecuencia, los procesos de mejora continua, iteración y adaptación se ven comprometidos, afectando la eficiencia operativa y el crecimiento proyectado.

Reducir estas asimetrías implica promover medidas concretas orientadas a la equidad digital. Esto incluye la generación de infraestructura compartida para procesamiento y almacenamiento, el establecimiento de redes de cooperación técnica entre iniciativas similares, el diseño de marcos regulatorios que faciliten la apertura de datos y la creación de incentivos para fomentar el acceso igualitario a plataformas de desarrollo. Para que un ecosistema emprendedor basado en IA prospere, es indispensable garantizar que el acceso a recursos tecnológicos y datos no dependa de la ubicación geográfica ni de la escala financiera del proyecto.

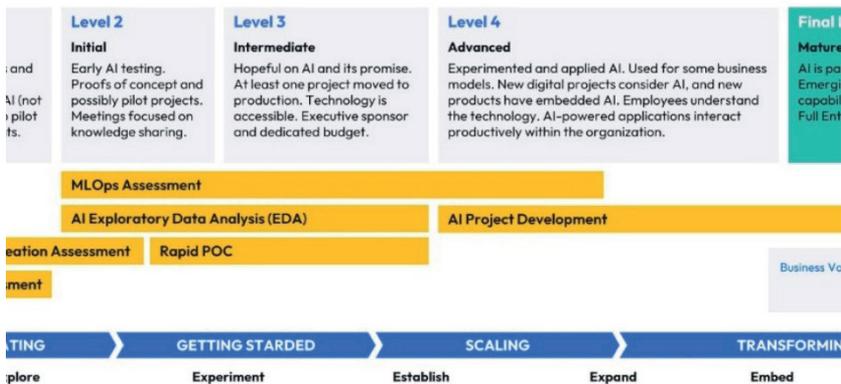
## **8.2 FORMACIÓN TÉCNICA Y BARRERAS COGNITIVAS**

El aprovechamiento efectivo de la inteligencia artificial en iniciativas productivas requiere un nivel avanzado de competencias técnicas en áreas como programación, análisis de datos, estadística y modelado algorítmico. La ausencia de estas habilidades limita la capacidad de los equipos para diseñar soluciones adaptadas a sus necesidades, evaluar el rendimiento de modelos automatizados o interpretar los resultados generados por sistemas inteligentes. Esta brecha en la formación especializada restringe la adopción de herramientas basadas en IA y refuerza una dependencia hacia platafor-

mas preconfiguradas que no siempre se alinean con los objetivos del proyecto. La falta de personal capacitado también obstaculiza la implementación de metodologías de desarrollo propias, impidiendo construir arquitecturas flexibles, escalables y eficientes. En los entornos productivos donde la capacitación técnica es escasa, los procesos de innovación quedan supeditados a la incorporación pasiva de tecnologías, en lugar de fomentar su desarrollo interno con una visión estratégica (OECD, 2025).

### Figura 5

*Niveles de madurez en la adopción de inteligencia artificial. Esta figura ilustra el proceso de adopción progresiva de tecnologías de inteligencia artificial dentro de las organizaciones, desde el nivel fundacional hasta su integración plena en la estrategia empresarial. Cada fase está asociada a prácticas específicas como la exploración de datos, desarrollo de pruebas de concepto, implementación de proyectos y despliegue de modelos en producción. El modelo permite evaluar el grado de madurez y establecer rutas estructuradas de avance en entornos corporativos.*



Nota. Fuente: <https://www.plainconcepts.com>

El acceso limitado a programas educativos orientados a IA, tanto en niveles universitarios como en formación continua, agrava las diferencias entre regiones y sectores productivos. En muchos territorios, la oferta académica no responde a las

demandas reales del mercado, ni contempla la inclusión de tecnologías emergentes en los planes curriculares. Esta desconexión curricular dificulta la formación de perfiles técnicos intermedios y avanzados, lo que reduce la disponibilidad de talento para liderar procesos de transformación digital en proyectos de pequeña y mediana escala. Adicionalmente, las barreras económicas y geográficas limitan el acceso a cursos especializados, eventos de actualización tecnológica o certificaciones profesionales. Las organizaciones que operan en entornos rurales o periféricos enfrentan mayores obstáculos para capacitar a sus equipos en competencias digitales avanzadas, lo que prolonga las brechas de adopción tecnológica. Esta situación es más crítica en iniciativas que no cuentan con soporte institucional, alianzas académicas o acceso a redes de conocimiento abierto (Sindakis & Showkat, 2024).

A la carencia de formación estructurada se suman barreras cognitivas relacionadas con la percepción y comprensión de la inteligencia artificial. Muchas personas asocian esta tecnología con conceptos abstractos o inaccesibles, lo que genera resistencias iniciales en los procesos de adopción. Esta barrera cognitiva se manifiesta en la subestimación del valor práctico de la IA, la sobreestimación de su complejidad o el temor a su impacto laboral. Además, en contextos donde el nivel de alfabetización digital es bajo, existe una propensión a delegar decisiones críticas en proveedores externos, sin contar con criterios técnicos para evaluar la idoneidad de las soluciones propuestas. La falta de capacidades para comprender el funcionamiento básico de los algoritmos, su lógica operativa o sus limitaciones éticas y técnicas, restringe la autonomía de las organizaciones y aumenta los riesgos de dependencia tecnológica. Esta desconexión también dificulta la apropiación social de la IA, reduciendo las posibilidades de integrar enfoques inclusivos, colaborativos y responsables en el diseño de

soluciones digitales (Lu, 2024).

La formación técnica también se ve limitada por la falta de materiales actualizados, adaptados al idioma y al entorno local. Muchos de los recursos disponibles se encuentran en inglés técnico, lo que representa una barrera significativa para equipos cuya lengua principal es distinta. Además, una gran parte de los contenidos responde a marcos de referencia desarrollados en contextos altamente industrializados, lo que impide su aplicación directa en proyectos con limitaciones estructurales, económicas o culturales distintas. Esta desconexión entre teoría y práctica dificulta la generación de soluciones pertinentes para las realidades locales. Para revertir esta condición, se requiere una articulación entre los sistemas de educación formal, los programas de formación continua y las estrategias nacionales de transformación digital. Esta articulación debe priorizar la creación de contenidos contextualizados, traducidos y accesibles, que respondan a problemas específicos de cada sector o región. Solo mediante una estrategia coordinada y sostenida será posible reducir las brechas cognitivas y técnicas que limitan la incorporación efectiva de la inteligencia artificial en los entornos productivos.

### **8.3 COSTOS REALES DE IMPLEMENTAR IA EN PROYECTOS PEQUEÑOS**

La adopción de tecnologías de inteligencia artificial en proyectos de escala reducida implica una evaluación precisa y detallada de los costos asociados, considerando tanto los componentes tangibles como los intangibles del proceso de implementación. En términos directos, se identifican rubros como las licencias de software especializado, la adquisición de hardware con capacidad para procesos de inferencia y entrenamiento, y la contratación de servicios en la nube orientados al procesamiento masivo y almacenamiento de datos. Este

conjunto de elementos constituye la base estructural sobre la cual se soporta la operación del sistema inteligente. La toma de decisiones entre implementar soluciones preentrenadas o desarrollar modelos personalizados influye significativamente en el costo total de propiedad (TCO). Las soluciones personalizadas, aunque más adaptables a las particularidades del negocio, exigen mayores niveles de inversión inicial, disponibilidad de talento técnico especializado y recursos de mantenimiento continuo que pueden desbordar las capacidades de organizaciones con presupuestos restringidos (Amershi, Begel et al., 2019).

A nivel operativo, los costos derivados de la integración de sistemas de IA en procesos existentes representan una carga adicional en términos de adecuaciones tecnológicas, rediseño organizacional y capacitación intensiva. Es habitual que los proyectos pequeños deban actualizar su infraestructura de red, adquirir nuevas interfaces de integración y modificar los flujos de trabajo tradicionales para adaptarse a los requerimientos computacionales y funcionales de los modelos de IA. Esto genera una curva de aprendizaje que impacta directamente sobre la eficiencia operativa inicial, afectando los plazos de ejecución y las expectativas de resultados. Asimismo, deben contemplarse los costos ocultos vinculados a actividades de refactorización de datos, pruebas exhaustivas, validación de rendimiento y resolución de errores inesperados durante el despliegue. En iniciativas con márgenes financieros estrechos, estos elementos incrementan la probabilidad de desbordes presupuestarios si no son identificados y cuantificados desde las fases tempranas de planificación (Sculley et al., n.d.).

Un componente crítico de la estructura de costos está relacionado con la dependencia de servicios externos, particularmente aquellos asociados a plataformas de machine lear-

ning as a service (MLaaS), consultorías en analítica avanzada y acceso a interfaces de programación de aplicaciones (APIs) bajo modelos de tarifa por uso. Si bien esta modalidad permite acelerar la adopción tecnológica sin necesidad de construir capacidades internas, introduce una volatilidad financiera significativa. El costo variable de estos servicios se ve afectado por factores como el volumen de datos procesados, la frecuencia de llamadas al sistema, el uso intensivo de recursos de cómputo y la necesidad de actualizaciones periódicas. Por tanto, resulta imperativo establecer políticas de control y monitoreo del consumo, así como diseñar escenarios de sensibilidad financiera que permitan anticipar posibles sobrecostos o desviaciones respecto al presupuesto inicial.

Desde una perspectiva estratégica, es necesario considerar los costos de oportunidad que conlleva la implementación de IA en proyectos pequeños. Esto incluye la reasignación de recursos humanos y financieros desde otras iniciativas clave, la interrupción o ralentización de actividades operativas en curso, y la necesidad de redefinir estructuras internas para dar soporte al nuevo componente tecnológico. En muchos casos, los retornos de inversión no son inmediatos, lo que exige una comunicación clara respecto al horizonte de beneficios esperados. Además, deben valorarse impactos intangibles como la mejora en la percepción de innovación del negocio, la atracción de nuevos segmentos de clientes o el fortalecimiento del posicionamiento competitivo. La correcta gestión de estos elementos requiere alineamiento entre los objetivos estratégicos de la organización y las métricas de evaluación del proyecto, para evitar disonancias en la asignación de recursos y expectativas de desempeño.

La medición y control de los costos reales de implementación deben apoyarse en herramientas especializadas que permitan evaluar el impacto económico y técnico del sistema

desplegado. Indicadores como el costo por predicción realizada, el costo marginal por actualización del modelo, y el ratio de retorno por unidad automatizada son fundamentales para establecer una gobernanza financiera robusta. Esta aproximación facilita la toma de decisiones informadas respecto a futuras optimizaciones, el reemplazo de componentes poco eficientes y la reasignación de recursos hacia áreas con mayor impacto. En proyectos con restricciones presupuestarias, la visibilidad granular sobre estos indicadores constituye un requisito operativo clave para sostener la viabilidad de la inversión tecnológica a largo plazo.

#### **8.4 MODELOS OPEN-SOURCE Y RECURSOS GRATUITOS DISPONIBLES**

La disponibilidad de modelos de inteligencia artificial de código abierto ha ampliado de forma significativa las posibilidades de desarrollo para proyectos que carecen de grandes presupuestos. Estas soluciones permiten acceder a arquitecturas preentrenadas, marcos de trabajo optimizados y bibliotecas especializadas sin necesidad de licencias comerciales. Plataformas como Hugging Face, TensorFlow, PyTorch y ONNX proporcionan entornos colaborativos y documentación accesible para la implementación de modelos de procesamiento de lenguaje natural, visión computacional y análisis predictivo. Estas herramientas facilitan la experimentación, el prototipado rápido y la transferencia de conocimiento entre comunidades técnicas globales, reduciendo las barreras de entrada para organizaciones con limitaciones económicas o geográficas (Kleinman, 2025).

Los repositorios públicos, como GitHub y Papers With Code, permiten acceder a implementaciones reproducibles de modelos recientes, acompañadas de métricas de rendimiento, configuraciones de entrenamiento y conjuntos de datos de

prueba. Esta apertura del conocimiento técnico ha generado un ecosistema de innovación distribuida que promueve la mejora continua de algoritmos, la adaptación a nuevos dominios y la inclusión de criterios de evaluación más rigurosos. Para los equipos técnicos, estos recursos representan una base sólida sobre la cual construir soluciones específicas, evaluarlas con criterios objetivos y escalarlas de forma modular. La naturaleza abierta de estos modelos permite, además, una revisión comunitaria que reduce riesgos técnicos asociados a cajas negras comerciales y fomenta buenas prácticas en seguridad y trazabilidad algorítmica.

Entre los recursos gratuitos más relevantes destacan las bases de datos abiertas, esenciales para entrenar y validar modelos. Iniciativas como Common Crawl, ImageNet, COCO, The Pile y OpenML proporcionan conjuntos de datos de amplio espectro que pueden ser utilizados para diversos fines, desde tareas de clasificación hasta generación de lenguaje. Estas colecciones son especialmente útiles para proyectos que no cuentan con infraestructura propia de recolección o que requieren validar modelos en múltiples dominios antes de su despliegue operativo. La disponibilidad de datos etiquetados, distribuidos por tareas y con licencias de uso explícitas, contribuye a estandarizar los procesos de desarrollo y a reducir tiempos de entrenamiento inicial.

Para iniciativas que buscan aplicaciones prácticas inmediatas, existen soluciones open-source ya operativas que pueden adaptarse a necesidades específicas. Por ejemplo, Stable Diffusion y DALL·E mini permiten la generación automática de imágenes a partir de texto, útiles en marketing visual y prototipado gráfico. Whisper de OpenAI, disponible en versión open-source, ofrece capacidades de transcripción automática multilingüe, lo que permite automatizar tareas de entrada de datos o generación de subtítulos. Otros modelos como Auto-

GPT y LangChain permiten orquestar tareas más complejas combinando múltiples modelos en flujos automáticos, útiles para asistentes virtuales, atención al cliente o automatización documental. Estas herramientas pueden integrarse mediante APIs o ejecutarse localmente si se dispone del hardware mínimo necesario, ampliando el margen de control sobre la arquitectura y el flujo de datos.

Además de los modelos y datos, existen recursos de formación técnica y laboratorios virtuales que refuerzan las capacidades de los equipos. Plataformas como Fast.ai, DeepLearning.AI, Coursera y Google Developers ofrecen cursos gratuitos y laboratorios interactivos centrados en el uso de modelos open-source. Estas iniciativas permiten adquirir competencias especializadas sin necesidad de infraestructura propia ni gastos elevados, lo que facilita la incorporación progresiva de prácticas avanzadas en inteligencia artificial dentro de organizaciones pequeñas o en expansión. La alineación entre contenido educativo y herramientas libres permite una transferencia inmediata del conocimiento a entornos de aplicación real, cerrando el ciclo entre formación, experimentación e implementación.

Para maximizar el impacto de los recursos open-source, los proyectos deben establecer criterios técnicos claros para seleccionar modelos, evaluar su idoneidad frente a las necesidades específicas y garantizar su mantenimiento en condiciones operativas (CDAO, 2024). Esto implica definir métricas de desempeño, requerimientos computacionales, compatibilidad con entornos de producción y niveles de interpretabilidad exigidos. El uso estratégico de herramientas abiertas no solo representa una oportunidad de ahorro económico, sino también un mecanismo para aumentar la autonomía tecnológica, fomentar la innovación local y reducir la dependencia de proveedores cerrados.

## **8.5 ESTRATEGIAS DE INCLUSIÓN DIGITAL PARA EMPRENDEDORES**

La inclusión digital representa un eje estructural para garantizar la participación efectiva de iniciativas emergentes en entornos impulsados por inteligencia artificial. Las estrategias orientadas a este objetivo deben abordar tanto el acceso a infraestructura tecnológica como la apropiación significativa de competencias digitales. Esto implica implementar medidas que faciliten la conectividad en regiones con cobertura limitada, fomentar la alfabetización digital funcional y promover entornos colaborativos de formación técnica. La inclusión no debe entenderse únicamente como acceso físico a dispositivos o redes, sino como la capacidad real de utilizar tecnologías para resolver problemas productivos, automatizar procesos o diseñar soluciones adaptadas a las necesidades del entorno (Fundación de Diseño de Interacción - IxDF, 2024). Estas capacidades permiten reducir asimetrías estructurales en el ecosistema digital y aumentar la autonomía tecnológica de los proyectos emergentes (OECD, 2021).

Una estrategia efectiva de inclusión digital debe contemplar la interoperabilidad entre plataformas, la neutralidad tecnológica y la sostenibilidad operativa de los recursos implementados. Esto requiere integrar soluciones abiertas, accesibles y escalables que se adapten a contextos con limitaciones técnicas, económicas o institucionales. La utilización de herramientas open-source, la adopción de estándares abiertos y el diseño de infraestructuras modulares favorecen la replicabilidad de las soluciones y la formación de capacidades locales. Esta lógica de desarrollo distribuido fortalece la resiliencia tecnológica de los equipos e impulsa modelos colaborativos de innovación. Asimismo, los programas de subsidio a la conectividad, las alianzas público-privadas para la provisión de servicios digitales y las plataformas de capa-

citación gratuita constituyen mecanismos claves para reducir brechas en la base productiva.

La inclusión también requiere un enfoque territorial que considere las particularidades culturales, lingüísticas y económicas de las comunidades. Las estrategias centralizadas tienden a reproducir esquemas de exclusión si no incorporan mecanismos de adaptación contextual. En este sentido, resulta fundamental desarrollar contenidos educativos multilingües, metodologías pedagógicas inclusivas y acompañamiento técnico continuo. Las plataformas de formación deben incorporar rutas flexibles que permitan avanzar por niveles, integrar aprendizajes previos y aplicar conocimientos en entornos reales. Esta estructura incremental facilita la apropiación progresiva de competencias en IA y fomenta su aplicación en problemas específicos del territorio. Al mismo tiempo, promueve el surgimiento de soluciones con pertinencia local, con mayor probabilidad de sostenibilidad técnica y adopción social (UNESCO, 2023).

La colaboración interinstitucional entre gobiernos, universidades, empresas tecnológicas y organizaciones sociales permite articular recursos, compartir experiencias y escalar buenas prácticas en inclusión digital. Estas alianzas deben orientarse a la construcción de marcos normativos que garanticen el acceso abierto al conocimiento, la protección de los datos personales y la transparencia en el uso de tecnologías inteligentes. La participación de actores locales en el diseño de políticas digitales fortalece su relevancia operativa y promueve una cultura de apropiación tecnológica basada en la corresponsabilidad. Esta articulación multisectorial también facilita la identificación de nodos críticos de exclusión y permite intervenir con acciones focalizadas, evitando la dispersión de esfuerzos y recursos.

El monitoreo y evaluación de las estrategias de inclusión

digital debe apoyarse en indicadores específicos de acceso, uso, calidad y apropiación tecnológica. Estos indicadores deben construirse con datos desagregados por territorio, género, grupo etario y nivel socioeconómico, a fin de detectar patrones de exclusión y ajustar las intervenciones. La inteligencia artificial puede emplearse para analizar estos datos y generar modelos predictivos sobre factores de riesgo, permitiendo una gestión proactiva de la inclusión. Esta integración analítica contribuye a mejorar la eficiencia de los programas implementados y refuerza la trazabilidad de sus impactos en el ecosistema digital productivo.

## CAPÍTULO 9

### **MARCO LEGAL Y REQUISITOS REGULATORIOS PARA EMPRENDER CON IA**

#### **9.1 NORMATIVAS APLICABLES A STARTUPS CON BASE ALGORÍTMICA**

Las startups con base algorítmica operan en un entorno legal caracterizado por una evolución constante de marcos normativos que buscan equilibrar la innovación tecnológica con la protección de derechos fundamentales. Estas iniciativas, al emplear sistemas de inteligencia artificial para procesar datos, tomar decisiones automatizadas o generar servicios personalizados, se enfrentan a regulaciones específicas relacionadas con la ética, la transparencia, la responsabilidad legal y la protección de datos personales. La ausencia de un marco legal uniforme a nivel global obliga a las organizaciones a realizar un seguimiento continuo de las normativas locales e internacionales que afectan directamente el diseño, la operación y la comercialización de sus soluciones basadas en algoritmos. Las áreas regulatorias más relevantes incluyen la gobernanza algorítmica, la auditoría de sistemas inteligentes, la trazabilidad de decisiones automatizadas y la garantía de no discriminación algorítmica.

Uno de los principales marcos legales que condicionan el funcionamiento de estos proyectos es la legislación sobre protección de datos, como el Reglamento General de Protección de Datos (GDPR) de la Unión Europea. Esta normativa

exige que los responsables de tratamiento implementen medidas técnicas y organizativas que aseguren la confidencialidad, integridad y disponibilidad de la información procesada. En el caso de algoritmos que toman decisiones automatizadas, se establece la obligación de proporcionar explicaciones comprensibles a los usuarios, permitir revisiones humanas y evitar efectos discriminatorios o injustificados. Para las startups que desarrollan productos basados en aprendizaje automático, esta regulación implica una revisión profunda de los flujos de datos, la validación de los modelos y la implementación de mecanismos de supervisión continua que garanticen el cumplimiento normativo desde el diseño del sistema (Foitzick, 2024).

A nivel sectorial, diversas industrias imponen regulaciones específicas cuando se emplea inteligencia artificial en áreas sensibles como salud, finanzas, transporte o educación. Por ejemplo, la utilización de algoritmos en diagnósticos médicos, puntuación crediticia o sistemas de selección académica requiere el cumplimiento de estándares regulatorios adicionales que incluyen pruebas de precisión, mitigación de sesgos y mecanismos de apelación para decisiones automatizadas. Estas exigencias implican que las iniciativas con base algorítmica deban incorporar profesionales con conocimientos legales y técnicos que puedan coordinar procesos de auditoría interna, certificación de sistemas y elaboración de documentación técnica para demostrar conformidad. En muchos casos, se requieren evaluaciones de impacto algorítmico antes de desplegar soluciones en entornos reales, lo que añade una capa adicional de análisis jurídico y técnico previo a la operación comercial.

Otra dimensión normativa clave es la relacionada con los derechos de propiedad intelectual en proyectos que desarrollan modelos de IA propios o adaptan soluciones open-sour-

ce. La titularidad del código fuente, la licencia de uso de datos y los derechos de explotación comercial de los modelos entrenados deben quedar claramente establecidos en contratos, políticas internas o acuerdos con terceros. En entornos colaborativos o de transferencia tecnológica, la falta de regulación adecuada puede derivar en disputas legales que afectan la continuidad operativa del negocio. Por esta razón, las organizaciones deben implementar marcos contractuales robustos y mecanismos de protección legal que regulen tanto el acceso como la modificación, reutilización y distribución de activos algorítmicos. La claridad jurídica en estos aspectos resulta esencial para atraer inversión, establecer alianzas estratégicas y garantizar la escalabilidad de las soluciones propuestas.

Las autoridades de distintos países también han comenzado a definir principios rectores para el desarrollo responsable de la inteligencia artificial, que si bien no constituyen leyes vinculantes en todos los casos, orientan las prácticas aceptables desde una perspectiva ética y de sostenibilidad. Entre estos principios se encuentran la equidad, la rendición de cuentas, la transparencia, la seguridad y la supervisión humana. Incorporar estos lineamientos en los procesos internos de diseño y operación permite a las organizaciones anticipar requisitos regulatorios futuros, fortalecer su reputación institucional y construir confianza con los usuarios. En ciertos países, estos principios ya se traducen en normativas obligatorias o guías técnicas de cumplimiento obligatorio para sistemas clasificados como de alto riesgo. Por tanto, adoptar una cultura de cumplimiento normativo proactivo representa no solo una medida de gestión de riesgos legales, sino también una estrategia de diferenciación y sostenibilidad para las iniciativas basadas en IA.

## **9.2 DERECHOS DEL USUARIO Y RESPONSABILIDAD DEL CREADOR DE SISTEMAS**

La integración de sistemas algorítmicos en productos digitales implica exigencias técnicas, jurídicas y éticas que inciden directamente en la configuración de derechos de los usuarios y en las obligaciones operativas de los equipos que desarrollan estas soluciones. Desde una perspectiva normativa, los marcos regulatorios contemporáneos delimitan condiciones explícitas para la recolección, procesamiento y uso de datos personales, así como para los procesos automatizados de toma de decisiones. Estas disposiciones se concretan en derechos como la transparencia algorítmica, la supervisión humana obligatoria sobre decisiones automatizadas y el acceso a explicaciones técnicas comprensibles respecto al funcionamiento del sistema. Dichos principios son esenciales para evitar que las organizaciones impongan modelos opacos que comprometan la autonomía informativa o exploten información sensible sin consentimiento explícito (Vítor, 2023).

De manera complementaria, los desarrolladores de sistemas con base en inteligencia artificial asumen una responsabilidad integral sobre la arquitectura, entrenamiento, despliegue y supervisión continua de sus modelos. Esta responsabilidad técnica implica prever consecuencias no deseadas, garantizar condiciones de no discriminación y establecer procesos de control interno que permitan auditar decisiones automatizadas. La trazabilidad de los resultados, la documentación exhaustiva de los modelos y la rendición de cuentas institucional forman parte de las exigencias establecidas en directrices regulatorias avanzadas. La omisión de estos elementos puede derivar en decisiones injustificadas o erróneas, con repercusiones significativas para los usuarios o grupos afectados.

Desde una perspectiva de gestión, los proyectos que in-

tegran algoritmos deben adoptar prácticas anticipadas de evaluación ética y legal desde las fases de diseño. Este enfoque estructurado contempla evaluaciones de impacto sobre derechos fundamentales, análisis de equidad algorítmica, pruebas de privacidad y simulación de efectos adversos en poblaciones específicas. La implementación sistemática de estos procesos reduce riesgos legales y protege la legitimidad operativa de las organizaciones. La responsabilidad del creador trasciende la dimensión técnica individual y adquiere una dimensión institucional que compromete la sostenibilidad, reputación y legalidad del producto o servicio ofrecido (Floridi et al., 2018).

Las recomendaciones internacionales emitidas por organismos como la Unión Europea, la OCDE y la UNESCO proporcionan marcos de referencia aplicables para armonizar el desarrollo algorítmico con los principios de equidad, seguridad y respeto a los derechos humanos. Por ejemplo, la Unión Europea ha establecido los requisitos del Reglamento de Inteligencia Artificial (AI Act), que establece obligaciones según el nivel de riesgo del sistema, promoviendo la transparencia, la supervisión humana y la trazabilidad. La OCDE ha definido principios rectores para sistemas confiables de inteligencia artificial, incluyendo valores como la inclusión, la justicia y la rendición de cuentas técnica. La UNESCO, por su parte, ha emitido directrices centradas en la protección de los derechos humanos y la diversidad cultural, señalando que los sistemas deben ser explicables, seguros, resilientes y auditables. Estos estándares definen requisitos mínimos para asegurar que los sistemas sean auditables, explicables, resilientes y diseñados con criterios de robustez frente a fallas o usos indebidos. La incorporación temprana de estas directrices permite que los modelos se alineen con las tendencias regulatorias globales, evitando conflictos normativos y mejorando su aceptabilidad

social. En este marco técnico, la responsabilidad del desarrollador no solo consiste en responder ante incidentes, sino en configurar arquitecturas algorítmicas diseñadas con responsabilidad anticipada, supervisión continua y mecanismos de participación activa.

### **9.3 GESTIÓN DEL CONSENTIMIENTO Y TRAZABILIDAD EN MODELOS PREDICTIVOS**

La integración de modelos predictivos en productos digitales sustentados por sistemas de inteligencia artificial impone requerimientos específicos sobre la gestión del consentimiento y la trazabilidad de los datos. El consentimiento informado representa la base legal fundamental para el procesamiento de datos personales, particularmente cuando estos datos son empleados en sistemas algorítmicos que generan decisiones o recomendaciones automatizadas. Para cumplir con marcos regulatorios como el Reglamento General de Protección de Datos (GDPR), el consentimiento debe ser libre, informado, específico y revocable. Esto implica que las organizaciones deben implementar mecanismos que garanticen la comprensión del usuario sobre el uso de sus datos, incluyendo la posibilidad de retirarlo en cualquier momento sin que ello afecte su acceso a los servicios digitales (EDPB, 2020).

Desde una perspectiva técnica, la trazabilidad permite identificar, registrar y analizar el recorrido completo de cada dato desde su origen hasta su influencia en las predicciones generadas por el modelo. Esta capacidad es clave para mantener la transparencia y auditabilidad de los sistemas algorítmicos, permitiendo rastrear entradas, transformaciones intermedias y resultados. La implementación de bitácoras de acceso, esquemas de versionamiento de datos, control de metadatos estructurados y documentación formal de procesos garantiza la trazabilidad operativa. Esta práctica no solo faci-

lita la respuesta ante auditorías regulatorias o incidentes de seguridad, sino que también fortalece la integridad sistémica y la confiabilidad de las operaciones automatizadas .

En términos funcionales, la relación entre consentimiento y trazabilidad debe estar formalmente codificada en los sistemas. Cada dato procesado por modelos predictivos debe asociarse a un registro explícito del consentimiento recibido: origen, finalidad, vigencia y restricciones. Esta documentación permite verificar en cualquier momento si un dato específico se encuentra autorizado para un uso determinado y si esa autorización sigue siendo válida. La omisión de estos registros representa un riesgo operativo y legal, ya que impide comprobar la conformidad del modelo con la normativa vigente. Por tanto, la trazabilidad no es una función técnica aislada, sino un componente esencial de la gobernanza algorítmica, que se interrelaciona con la gestión de riesgos, la rendición de cuentas y la ética en la inteligencia artificial.

Asimismo, la responsabilidad sobre el tratamiento de datos personales no se limita a la etapa inicial de recopilación o entrenamiento, sino que se extiende durante todo el ciclo de vida del sistema predictivo. Esto incluye actualizaciones del modelo, cambios en la finalidad del tratamiento y ajustes en los mecanismos de inferencia. La gobernanza algorítmica robusta exige estructuras institucionales capaces de monitorear el cumplimiento normativo de manera continua, así como procedimientos técnicos para actualizar los registros de consentimiento y verificar la consistencia del modelo con las condiciones autorizadas por los usuarios. La trazabilidad, por tanto, habilita una supervisión integral de la conducta algorítmica y permite detectar desviaciones, errores o impactos no deseados antes de que afecten a los usuarios o a la organización .

Para facilitar este proceso, algunas herramientas técnicas

incluyen sistemas de control de versiones orientados a trazabilidad, módulos de monitoreo de cumplimiento normativo, mecanismos de verificación automatizada de metadatos y estructuras de registro vinculadas a cada etapa de procesamiento. Estas herramientas permiten consolidar entornos de desarrollo y operación más transparentes, configurando un entorno técnico que soporte las demandas legales sin comprometer la eficiencia operativa del modelo predictivo.

#### **9.4 PROPIEDAD INTELECTUAL EN PRODUCTOS GENERADOS CON IA**

La integración de sistemas de inteligencia artificial en procesos de desarrollo de productos plantea interrogantes específicos sobre la titularidad y protección de los resultados generados. Las salidas producidas por modelos algorítmicos —ya sean textos, imágenes, códigos, diseños u otras expresiones creativas— no siempre encajan con claridad dentro del marco legal vigente de propiedad intelectual. En muchos sistemas jurídicos, la protección por derecho de autor requiere que la obra sea resultado de una actividad humana original, lo que excluye a los productos generados exclusivamente por algoritmos sin intervención humana directa.

Desde una perspectiva operativa, los equipos que desarrollan soluciones con IA deben establecer mecanismos contractuales que definan la autoría, la asignación de derechos patrimoniales y el uso permitido de los contenidos generados. Esto resulta especialmente relevante en entornos colaborativos o cuando se utilizan modelos preentrenados disponibles públicamente, como los de código abierto. En estos casos, es necesario verificar si el modelo subyacente impone restricciones de uso, licencia o redistribución, ya que ello afecta la posibilidad de comercializar el producto derivado. Los modelos con licencias permisivas como Apache 2.0 o MIT suelen permitir

usos comerciales sin mayores restricciones, mientras que otros, como ciertas versiones de Creative Commons, pueden limitar el uso a contextos no comerciales o exigir atribución .

Por otro lado, el entrenamiento de modelos sobre datos protegidos también introduce riesgos jurídicos. Si una organización utiliza grandes volúmenes de datos sujetos a derechos de autor sin autorización para entrenar modelos predictivos o generativos, puede enfrentar reclamaciones por uso indebido. La legalidad de estas prácticas depende de factores como el tipo de datos, la finalidad del tratamiento, las medidas de anonimización aplicadas y la existencia de excepciones legales como el uso justo o la copia técnica temporal. Por tanto, se requiere una evaluación jurídica técnica antes de incorporar datasets externos en procesos de entrenamiento.

Un aspecto adicional para considerar es la protección de los propios modelos algorítmicos. Aunque los algoritmos en sí mismos pueden estar protegidos por secreto industrial, su código fuente puede ser registrado como software bajo regímenes de derecho de autor. Esta protección es aplicable siempre que el código sea resultado de un trabajo original y esté fijado en un medio tangible. Asimismo, los modelos optimizados o entrenados sobre bases de datos específicas pueden ser objeto de protección adicional como know-how técnico, siempre que se apliquen medidas para mantener su confidencialidad.

La evolución legislativa sobre propiedad intelectual en relación con la inteligencia artificial aún está en desarrollo. Organismos internacionales como la OMPI y la Oficina de Propiedad Intelectual de la Unión Europea están promoviendo consultas y estudios para adaptar los marcos normativos a los entornos generativos y automatizados. Estos esfuerzos incluyen la elaboración de directrices sobre la atribución de derechos, el uso responsable de modelos preentrenados y la de-

finición de criterios objetivos para establecer la contribución humana en la creación algorítmica. Mientras no se consoliden reformas específicas, las organizaciones deben aplicar principios de diligencia técnica, trazabilidad de la autoría y verificación de licencias en todas las etapas de diseño y explotación de productos generados mediante IA.

## **9.5 BUENAS PRÁCTICAS PARA LA LEGALIDAD OPERATIVA DE EMPRENDIMIENTOS**

La legalidad operativa constituye un elemento estructural para la sostenibilidad y escalabilidad de los proyectos empresariales, particularmente en aquellos que integran tecnologías emergentes como la inteligencia artificial. La formalización de las operaciones, el cumplimiento de marcos regulatorios y la implementación de procesos con trazabilidad legal son componentes que determinan la viabilidad jurídica de las iniciativas tecnológicas. La omisión de estos elementos incrementa el riesgo de sanciones administrativas, litigios contractuales o bloqueos regulatorios, afectando la capacidad del proyecto para acceder a financiamiento institucional y establecer relaciones de confianza con aliados estratégicos o usuarios finales.

La elección de una estructura jurídica adecuada es un requisito fundamental para garantizar la legalidad operativa. Las organizaciones deben seleccionar la figura legal conforme a su objeto económico, tipo societario y proyección de escalabilidad. Esta decisión repercute en el régimen fiscal, la delimitación de responsabilidades, las obligaciones laborales y la elegibilidad para incentivos gubernamentales. Adicionalmente, resulta imprescindible documentar estatutos, pactos de accionistas y acuerdos de confidencialidad, estableciendo parámetros legales claros para la gestión del conocimiento, la propiedad de los desarrollos y la gobernanza interna. En el

caso de los modelos algorítmicos, también se deben registrar protocolos de integridad algorítmica, políticas de uso ético de los datos y lineamientos de cumplimiento regulatorio .

El cumplimiento documental y regulatorio debe ser sistemático. Las organizaciones deben mapear las normativas que inciden en su actividad, tales como leyes de protección de datos, estándares de ciberseguridad, exigencias sectoriales o licencias específicas. Para garantizar la trazabilidad, se recomienda implementar sistemas integrados de gestión documental que permitan almacenar, clasificar y recuperar registros operativos clave. La trazabilidad documental es particularmente relevante ante auditorías, certificaciones de cumplimiento o procesos de due diligence. A nivel global, mecanismos como los programas de cumplimiento normativo, las auditorías internas periódicas y la designación de oficiales de cumplimiento son prácticas consolidadas para mitigar el riesgo legal y evitar sanciones .

La gestión de relaciones contractuales exige protocolos claros. Cualquier vínculo con proveedores, clientes, plataformas tecnológicas o aliados debe formalizarse mediante contratos estructurados que definan con precisión las obligaciones, derechos y límites de cada parte. En proyectos que desarrollan o utilizan sistemas de IA, estos contratos deben considerar aspectos como la calidad y procedencia de los datos, la transparencia de los algoritmos, los niveles de responsabilidad frente a errores de predicción y los derechos sobre productos generados automáticamente. Dado el dinamismo normativo y tecnológico, estos instrumentos deben ser objeto de revisión periódica y ajustes conforme evolucionan los riesgos y las exigencias regulatorias

El desarrollo de competencias legales dentro del equipo técnico y operativo es una práctica necesaria para consolidar una cultura de cumplimiento. Se recomienda que los inte-

grantes de las áreas técnicas, administrativas y estratégicas cuentan con formación básica en normativas aplicables a su función. Esta capacitación puede lograrse mediante programas internos, asesoramiento externo o convenios con instituciones especializadas. Esta preparación jurídica transversal reduce errores operativos, fortalece la gestión de riesgos legales y mejora la reputación del proyecto ante aliados financieros o institucionales. Un enfoque legal preventivo no solo limita las contingencias, sino que potencia la capacidad de escalar de forma responsable y sostenida.

CAPÍTULO 10

**ESCENARIOS FUTUROS PARA EL EMPRENDIMIENTO  
CON INTELIGENCIA ARTIFICIAL**

**10.1 INTELIGENCIA GENERATIVA Y NUEVOS FORMATOS DE NEGOCIO**

La inteligencia generativa permite automatizar tareas intensivas en creatividad, lenguaje o diseño, mediante modelos de lenguaje de gran escala que procesan datos para producir contenido adaptado a distintos contextos operativos. Herramientas como GPT-4, Claude 3, Gemini o LLaMA-3 posibilitan generar desde textos, imágenes y código hasta recomendaciones estratégicas y visualizaciones de datos, todo ello con mínima supervisión humana. Estas capacidades se integran en entornos productivos como desarrollo de software, diseño de productos, asesoría de negocios, generación de prototipos y automatización de propuestas comerciales.

El uso empresarial de estos modelos permite a organizaciones crear nuevos formatos de negocio fundamentados en la generación automática de valor. Entre los esquemas más recurrentes se encuentran los servicios de generación como producto (Generative AI-as-a-Service), plataformas SaaS que incorporan módulos generativos para sus usuarios, herramientas internas para prototipado ágil y asistentes cognitivos personalizados. Estas configuraciones permiten responder con agilidad a demandas variables, reduciendo tiempos de ejecución, costes operativos y barreras técnicas de entrada

para nuevos actores. Recursos como Hugging Face Transformers y LangChain aportan marcos modulares para adaptar modelos existentes a nichos comerciales específicos (Singh et al., 2024)

Desde la perspectiva organizativa, los sistemas generativos modifican funciones tradicionales al incorporar algoritmos que desempeñan tareas de análisis, diseño, interacción y síntesis. Proyectos de pequeña escala pueden automatizar la generación de descripciones de producto, propuestas de negocio, simulaciones de escenarios o campañas de marketing con herramientas entrenadas previamente. Esta dinámica requiere nuevos perfiles como gestores de modelos generativos, auditores de contenido automatizado o diseñadores de flujos de interacción hombre-máquina. Estas funciones permiten alinear la producción algorítmica con los objetivos técnicos, regulatorios y comerciales de cada proyecto.

Las estrategias de monetización en torno a estos modelos incluyen licencias de uso, suscripciones basadas en consumo de tokens, acceso por niveles a funcionalidades avanzadas o tarifas por incremento en métricas clave de productividad. Muchas iniciativas combinan inteligencia generativa con analítica en tiempo real para ajustar la entrega de contenido al comportamiento del usuario final, optimizando la conversión en comercio electrónico, atención personalizada o generación de leads. Esta interacción entre generación y análisis plantea condiciones específicas sobre la titularidad del contenido, la trazabilidad de los datos usados en el entrenamiento y la responsabilidad sobre resultados derivados de las salidas algorítmicas.

El ecosistema técnico de la inteligencia generativa incorpora plataformas de entrenamiento especializado, repositorios de modelos optimizados, bibliotecas de prompts estructurados y herramientas para evaluar la calidad y sesgos del

contenido generado. Estos recursos permiten que iniciativas con restricciones presupuestarias desarrollen soluciones competitivas en áreas como servicios creativos, asesoría virtual, generación de cursos o redacción automatizada. La disponibilidad de infraestructuras open-source y marketplaces de modelos favorece la replicabilidad, la mejora continua y la validación técnica, ampliando las posibilidades para negocios digitales en fases iniciales.

## **10.2 PLATAFORMAS AUTÓNOMAS Y MODELOS DE DECISIÓN SIN INTERVENCIÓN HUMANA**

El desarrollo de plataformas autónomas que ejecutan decisiones sin intervención humana directa representa un cambio estructural en los entornos organizacionales impulsados por inteligencia artificial. Estas plataformas integran componentes de percepción, razonamiento y ejecución basados en modelos algorítmicos que operan con niveles crecientes de autonomía, regulando operaciones sin requerir aprobaciones humanas en tiempo real. La arquitectura técnica de estos sistemas se compone de sensores, módulos de inferencia y motores de decisión que analizan datos en flujo continuo para activar respuestas automáticas, optimizar procesos o tomar determinaciones estratégicas en función de objetivos previamente parametrizados (Xia et al., 2024).

En el ámbito de los negocios, estas plataformas se utilizan para coordinar cadenas de suministro, administrar inventarios, ajustar precios, gestionar campañas de marketing y tomar decisiones de inversión mediante algoritmos de trading. La capacidad de procesar grandes volúmenes de datos estructurados y no estructurados en tiempo real permite que estos sistemas adapten su comportamiento a condiciones dinámicas del mercado o del entorno operativo. Esto se traduce en mayor velocidad de reacción, precisión en la asignación de re-

cursos y reducción de errores humanos, aspectos clave para organizaciones que operan en sectores de alta volatilidad o dependencia de información externa.

La integración de estas plataformas en negocios emergentes demanda la implementación de modelos de gobierno algorítmico que aseguren la trazabilidad, auditabilidad y control sobre las decisiones automatizadas. Es necesario definir criterios explícitos para la supervisión del ciclo de vida del modelo, establecer límites operativos para la autonomía funcional y configurar mecanismos de intervención humana ante situaciones imprevistas. A nivel técnico, esto implica la incorporación de logs transaccionales, sistemas de explicación de decisiones (explainability) y alertas ante desviaciones de comportamiento, con el fin de mantener la conformidad normativa y operativa del sistema (Raji & Buolamwini, 2019).

En iniciativas con recursos limitados, la adopción de plataformas autónomas puede lograrse mediante soluciones open-source como AutoML frameworks, gestores de decisiones como OpenRules o sistemas de automatización con capacidades embebidas como Apache NiFi o Node-RED. Estas herramientas permiten a proyectos en etapas iniciales configurar flujos de decisión complejos sin necesidad de construir sistemas desde cero, reduciendo las barreras técnicas de entrada. La accesibilidad de estos entornos facilita la exploración de modelos de negocio basados en operaciones automatizadas, como marketplaces autoajustables, servicios de suscripción dinámicos o plataformas de recomendaciones contextuales.

La implementación de estos modelos sin supervisión constante plantea implicaciones éticas y legales en torno a la responsabilidad sobre las decisiones generadas. Las organizaciones deben definir estructuras claras de responsabilidad operativa, prever escenarios de error algorítmico y estable-

cer protocolos de compensación o reparación ante fallos. Las normativas actuales, como la AI Act de la Unión Europea, requieren que los sistemas de alto riesgo mantengan registros auditables y garanticen supervisión humana significativa en decisiones que impacten derechos fundamentales. Por tanto, los equipos que desarrollan y despliegan plataformas autónomas deben incorporar desde su diseño principios de seguridad, transparencia, no discriminación y rendición de cuentas (EDPB, 2020).

Estas consideraciones son especialmente relevantes cuando las plataformas operan en sectores sensibles como salud, finanzas, logística de insumos críticos o educación personalizada. La combinación de autonomía funcional y sensibilidad contextual exige una calibración precisa de los sistemas, validaciones constantes del rendimiento y mecanismos sólidos de gobernanza algorítmica. La estabilidad operativa de los modelos debe ser contrastada con métricas que evalúen impactos distributivos, calidad de decisiones, equidad en el tratamiento de usuarios y alineación con los objetivos del negocio. Esto refuerza la necesidad de competencias interdisciplinarias en los equipos responsables, abarcando tanto conocimientos técnicos como comprensión normativa y ética.

### **10.3 CONVERGENCIA CON BLOCKCHAIN, IOT Y REALIDAD EXTENDIDA**

La integración de inteligencia artificial con tecnologías emergentes como blockchain, Internet de las cosas (IoT) y realidad extendida (XR) transforma radicalmente las capacidades operativas y estratégicas de los modelos de negocio. Esta convergencia tecnológica amplía los marcos de interacción digital, permite nuevos mecanismos de validación y automatización, y genera experiencias inmersivas que modifican tanto la relación con los usuarios como los procesos

internos de las organizaciones. Cada una de estas tecnologías actúa como un vector de especialización para la IA, incrementando su funcionalidad, control y adaptabilidad en entornos distribuidos, físicos o virtuales.

El blockchain aporta trazabilidad, integridad de datos y mecanismos de gobernanza distribuida a los sistemas inteligentes. En el contexto de los negocios digitales, la IA puede operar sobre cadenas de bloques para validar contratos inteligentes (smart contracts), verificar procedencia de productos, o gestionar tokens asociados a servicios automatizados. Esta arquitectura reduce los costos de intermediación, mejora la confiabilidad de las transacciones y permite establecer reglas algorítmicas que se ejecutan sin intervención humana, con respaldo criptográfico verificable. La incorporación de la IA en redes blockchain también permite analizar patrones de comportamiento de nodos, detectar anomalías o automatizar ajustes de gobernanza en plataformas descentralizadas (Soori et al., 2023).

Por su parte, el IoT amplifica el alcance operativo de los sistemas inteligentes al generar datos continuos desde dispositivos físicos conectados. La interconexión de sensores, actuadores y sistemas embebidos con algoritmos de IA permite realizar inferencias contextuales, ajustar procesos en tiempo real y optimizar recursos en entornos físicos como plantas industriales, cadenas logísticas o entornos urbanos. Las soluciones basadas en IA e IoT son utilizadas para predecir fallos, adaptar inventarios dinámicamente, personalizar servicios en función de datos ambientales o detectar condiciones de seguridad en infraestructuras críticas. Para iniciativas de base tecnológica, estas sinergias habilitan modelos de negocio de mantenimiento predictivo, logística inteligente o entornos productivos autoajustables.

La realidad extendida, que incluye tanto la realidad au-

mentada como la virtual, genera entornos de interacción inmersivos donde la IA puede ser aplicada para personalizar la experiencia, interpretar gestos, optimizar la interfaz y generar contenido dinámico. Los negocios que integran XR con IA pueden crear simuladores adaptativos para entrenamiento, vitrinas virtuales con recomendaciones inteligentes o sistemas de asistencia aumentada en tareas de precisión. La incorporación de algoritmos de machine learning en entornos XR también permite analizar el comportamiento del usuario para ajustar narrativas, realizar segmentaciones o predecir decisiones en tiempo real, elementos cruciales para experiencias centradas en la interacción .

La convergencia de estas tres tecnologías con la inteligencia artificial exige una arquitectura de integración robusta, así como una gestión eficiente de la interoperabilidad, la latencia y la seguridad de los datos. Las organizaciones que despliegan estas soluciones deben contar con marcos de referencia técnicos que permitan el diseño modular de sistemas, así como la evaluación continua del rendimiento combinado. Herramientas como los edge devices para procesamiento local, protocolos de comunicación como MQTT o blockchain híbridas con validadores de confianza permiten superar barreras operativas en entornos donde coexisten múltiples capas de tecnología. Para proyectos de menor escala, plataformas open-source como Hyperledger Fabric, ThingsBoard o A-Frame ofrecen entornos accesibles para desarrollar prototipos funcionales sin necesidad de infraestructura propietaria.

La evolución de esta convergencia impulsa la creación de entornos autónomos interconectados, donde la IA no solo interpreta y decide, sino que también coordina recursos físicos, valida transacciones digitales y modula experiencias inmersivas. Este tipo de ecosistemas plantea nuevas implicaciones éticas, regulatorias y operativas que deben ser consideradas

desde la fase de diseño, especialmente cuando los sistemas afectan la privacidad, la seguridad o los derechos de los usuarios. Por tanto, los equipos responsables deben incorporar principios de transparencia, supervisión humana y protección de datos, garantizando que las soluciones tecnológicas mantengan estándares elevados de calidad técnica y responsabilidad social.

#### **10.4 TENDENCIAS DE AUTOMATIZACIÓN TOTAL EN MICROEMPRESAS**

Las microempresas enfrentan limitaciones estructurales en cuanto a capital humano, recursos tecnológicos y capacidades operativas. Estas restricciones han impulsado la adopción acelerada de herramientas de automatización como estrategia para mantener la continuidad operativa, aumentar la eficiencia y reducir los costos fijos. La automatización total se basa en la integración de sistemas que abarcan desde la captura de datos hasta la ejecución de decisiones sin intervención manual. Plataformas como Zapier, Make o n8n permiten orquestar tareas repetitivas entre aplicaciones, mientras que asistentes virtuales basados en procesamiento del lenguaje natural asumen funciones de atención al cliente, programación de citas y gestión de pedidos. Estas herramientas transforman procesos fragmentados en flujos continuos, mejorando la trazabilidad y disminuyendo la carga administrativa.

En el área comercial, las microempresas automatizan la generación de leads, el seguimiento de clientes y la publicación de contenidos mediante sistemas que emplean algoritmos de recomendación y análisis predictivo. Por ejemplo, herramientas como HubSpot o Mailchimp permiten configurar campañas que se adaptan al comportamiento del usuario, segmentando audiencias en tiempo real y enviando respuestas automatizadas según niveles de interacción. Este tipo de

funcionalidades, antes restringidas a empresas medianas o grandes, hoy están disponibles bajo esquemas freemium que reducen la barrera de entrada tecnológica. El acceso a estas capacidades ha permitido que negocios de menor escala operen con niveles de sofisticación comparables, optimizando el uso de cada contacto, clic o conversión.

En el plano operativo, soluciones como Shopify, Wix y WooCommerce incluyen módulos de automatización para gestión de inventarios, procesamiento de pagos, emisión de facturas y sincronización logística con operadores externos. Estas plataformas combinan interfaces intuitivas con lógica automatizada que se ajusta a las reglas definidas por el negocio. La automatización de operaciones básicas libera tiempo del personal, permitiendo enfocarse en actividades de diseño, personalización del servicio o análisis estratégico. Incluso en casos donde no se dispone de conocimientos técnicos avanzados, entornos visuales y plantillas prediseñadas permiten a los equipos implementar procesos automatizados sin requerir desarrollo personalizado.

Una tendencia creciente es el uso de sistemas de inteligencia artificial generativa que asisten en la creación de contenido gráfico, textual o audiovisual, permitiendo que microempresas generen materiales de marketing, presentaciones o descripciones de productos con rapidez y bajo costo. Herramientas como Canva con IA, Copy.ai o Lumen5 generan contenido adaptado a parámetros de entrada definidos, acortando los ciclos creativos. Esta automatización creativa permite mantener una presencia digital activa sin necesidad de contratar personal especializado, lo cual resulta crítico para iniciativas con presupuestos limitados o que operan con estructuras mínimas.

El uso intensivo de automatización en microempresas requiere considerar aspectos relacionados con la seguridad di-

gital, la calidad de los datos y la integridad de los procesos. La automatización mal configurada o sin control puede reproducir errores de manera escalada o afectar la experiencia del cliente. Por ello, es indispensable establecer protocolos de validación periódica, monitoreo continuo de flujos automatizados y políticas de respaldo ante fallos. Asimismo, los procesos deben ser auditables para garantizar cumplimiento normativo, especialmente en operaciones que implican tratamiento de datos personales o transferencias financieras.

El avance de la automatización total también plantea interrogantes sobre el perfil del trabajo en las microempresas. La eliminación de tareas manuales básicas reconfigura los roles, priorizando habilidades digitales, capacidad de análisis y pensamiento estratégico. Esto exige procesos de capacitación continua y acceso a formación técnica que prepare a los equipos para operar y mantener sistemas automatizados. Programas de formación pública y alianzas con plataformas tecnológicas pueden facilitar este proceso, democratizando el acceso a capacidades que antes requerían grandes inversiones.

### **10.5 PROYECCIONES ÉTICAS, SOCIALES Y ECONÓMICAS DEL EMPRENDIMIENTO ALGORÍTMICO**

El uso intensivo de inteligencia artificial en actividades productivas ha incrementado la necesidad de analizar sus implicaciones estructurales desde múltiples dimensiones. En el plano ético, los modelos algorítmicos utilizados en negocios y plataformas digitales requieren criterios robustos de diseño y operación que garanticen el respeto por los derechos fundamentales. La opacidad algorítmica y la posibilidad de sesgos en los datos de entrenamiento pueden derivar en discriminación indirecta, decisiones injustas o exclusión de grupos vulnerables. Por esta razón, organismos internacionales como la UNESCO han promovido marcos éticos orientados a la equi-

dad, la justicia algorítmica y la supervisión significativa en entornos automatizados (UNESCO, 2021a). El emprendimiento algorítmico debe incorporar desde su fase inicial evaluaciones de impacto ético que contemplen los efectos de las decisiones automatizadas sobre distintos perfiles de usuarios, sobre todo en sectores sensibles como salud, empleo, finanzas o servicios públicos.

### Figura 6

Áreas clave de política pública para la gobernanza de la inteligencia artificial. Esta representación circular sintetiza once dominios estratégicos que deben abordarse en los marcos regulatorios de IA, incluyendo la gobernanza ética, la cooperación internacional, la protección de datos, el impacto social, ambiental y económico, así como la equidad de género y la promoción de la investigación. Fue elaborada con base en las directrices de la Recomendación sobre la Ética de la Inteligencia Artificial de la UNESCO, publicada en 2021.



Desde una perspectiva social, la penetración de sistemas de inteligencia artificial en estructuras económicas ha modificado la distribución del trabajo, los mecanismos de inclusión productiva y la participación ciudadana en entornos digitales. La automatización de tareas en microempresas, plataformas de servicios y operaciones logísticas ha generado oportunidades de eficiencia, pero también ha intensificado debates sobre el desplazamiento de empleos tradicionales, la precarización laboral o la consolidación de plataformas digitales con efectos concentradores. El emprendimiento basado en algoritmos debe ser evaluado no solo por sus métricas de eficiencia, sino también por su capacidad de generar valor inclusivo y redistribuido. Es fundamental incorporar principios de accesibilidad tecnológica, apertura de conocimiento y colaboración intersectorial como parte de las condiciones habilitantes de modelos de negocio sostenibles desde lo social.

En términos económicos, los emprendimientos algorítmicos abren posibilidades para reconfigurar modelos de producción, distribución y comercialización a través de estructuras intensivas en datos. Estas iniciativas pueden operar con costos marginales decrecientes, escalabilidad casi inmediata y acceso a múltiples mercados sin necesidad de intermediación tradicional. No obstante, este modelo económico plantea riesgos relacionados con la hiperconcentración de datos, la dependencia tecnológica de grandes plataformas y la vulnerabilidad ante asimetrías informativas. Para que el emprendimiento algorítmico sea sostenible a largo plazo, es necesario establecer mecanismos regulatorios que garanticen la transparencia de los modelos, la interoperabilidad entre sistemas y la neutralidad de las infraestructuras digitales. El diseño institucional debe promover entornos de competencia justa, estándares abiertos y control sobre la extracción de valor derivado de la información personal.

Las proyecciones futuras indican que el emprendimiento impulsado por algoritmos no será una excepción dentro de los mercados, sino una forma predominante de creación de valor. Esto implica que las políticas públicas, los sistemas educativos y los marcos normativos deberán adaptarse a realidades donde la lógica de la decisión algorítmica sustituya parcialmente a las decisiones humanas tradicionales. La formación de talento híbrido, con capacidad técnica y comprensión ética, será un factor crítico para garantizar la integridad de estos modelos de negocio. Asimismo, la cooperación internacional deberá establecer marcos multilaterales que regulen el flujo transfronterizo de datos, el uso de inteligencia artificial en plataformas digitales y la apropiación equitativa de los beneficios derivados de estas tecnologías.

La anticipación de estos impactos requiere incorporar metodologías de prospectiva tecnológica y análisis de escenarios que permitan evaluar las trayectorias posibles del emprendimiento algorítmico. Estas herramientas deben considerar variables políticas, económicas, tecnológicas y culturales para construir mapas de riesgos y oportunidades adaptados a diferentes contextos regionales. En el caso de las economías emergentes, la asimilación de modelos algorítmicos en iniciativas productivas debe ser acompañada por estrategias de fortalecimiento de capacidades locales, inversión en infraestructura digital y regulación diferenciada para evitar la dependencia estructural de soluciones importadas o descontextualizadas. La sostenibilidad del emprendimiento algorítmico dependerá en gran medida de su capacidad para integrarse de forma coherente en estructuras económicas y sociales existentes, aportando innovación sin comprometer la equidad ni la autonomía de los actores involucrados.

## GLOSARIO DE TÉRMINOS

**AI (Artificial Intelligence).** Sistema informático capaz de ejecutar tareas asociadas tradicionalmente a la inteligencia humana, como reconocimiento de patrones, toma de decisiones, procesamiento de lenguaje natural y aprendizaje autónomo. Su uso permite automatizar procesos, optimizar recursos y generar valor en actividades productivas y de servicios.

**AlphaZero.** Sistema de inteligencia artificial desarrollado por DeepMind que aprende a jugar juegos complejos sin intervención humana directa, mediante técnicas de autoaprendizaje por refuerzo. Fue diseñado inicialmente para dominar juegos como ajedrez, Go y shogi sin conocimientos previos más allá de las reglas.

**Amazon SageMaker.** Servicio de Amazon Web Services que permite crear, entrenar y desplegar modelos de aprendizaje automático de forma escalable y automatizada, integrando flujos de trabajo (pipelines) y herramientas de monitorización.

**Amazon Web Services (AWS).** Plataforma de servicios en la nube que ofrece APIs de inteligencia artificial para reconocimiento de imágenes, análisis de texto, síntesis de voz y predicción automatizada. Utilizada en soluciones empresariales de diversa escala.

**Apache Spark.** Motor de procesamiento de datos de código abierto diseñado para análisis a gran escala. Se utiliza en proyectos de inteligencia artificial para procesamiento distribuido de datos masivos y entrenamiento de modelos.

**ArXiv.** Repositorio de artículos académicos de libre acceso

que alberga investigaciones en física, matemáticas, informática, inteligencia artificial y otras disciplinas científicas.

**Autoencoders.** Tipo de red neuronal utilizada en aprendizaje no supervisado que busca codificar los datos de entrada en una representación comprimida y luego reconstruirlos. Se utiliza en reducción de dimensionalidad, detección de anomalías y generación de datos sintéticos.

**AutoML.** Conjunto de herramientas que automatizan el proceso de selección, entrenamiento y ajuste de modelos de aprendizaje automático, reduciendo la necesidad de intervención manual especializada.

**BigQuery.** Herramienta de análisis de datos de Google que permite ejecutar consultas SQL sobre grandes volúmenes de datos de forma rápida y escalable, integrándose con modelos de aprendizaje automático.

**Blockchain.** Infraestructura digital descentralizada basada en bloques de datos enlazados criptográficamente. Se utiliza para registrar transacciones de forma segura, verificable e inmutable, siendo aplicada en trazabilidad, contratos inteligentes y autenticación de procesos en proyectos digitales.

**Chatbots.** Sistemas informáticos basados en IA que simulan conversaciones con humanos a través de texto o voz. Se implementan en atención al cliente, comercio conversacional y automatización de soporte.

**CLIP.** Modelo de IA desarrollado por OpenAI que combina procesamiento de imágenes y lenguaje natural para asociar descripciones textuales con contenido visual. Es utilizado para búsquedas multimodales, clasificación de imágenes y análisis de contenido digital.

**Clustering.** Técnica de aprendizaje no supervisado que agrupa datos similares en función de sus características, sin etiquetas previas. Se emplea en segmentación de clientes, detección de patrones y exploración de datos.

**CNN (Redes Neuronales Convolucionales).** Tipo de arquitectura de redes neuronales especialmente eficaz para el procesamiento de datos visuales. Se aplica en reconocimiento de imágenes, visión por computadora y sistemas biométricos.

**CRM (Customer Relationship Management).** Conjunto de herramientas que permiten gestionar la relación con clientes, centralizando información relevante y automatizando actividades comerciales, de marketing y soporte, con el fin de optimizar la fidelización y personalización del servicio.

**Cross-selling.** Estrategia comercial que consiste en ofrecer productos complementarios al que el cliente ya adquirió, utilizando modelos de recomendación impulsados por IA para aumentar el valor de la venta.

**DALL·E.** Sistema de generación de imágenes basado en IA desarrollado por OpenAI. A partir de descripciones textuales, genera imágenes sintéticas que reflejan los elementos semánticos del texto.

**Dash.** Framework de código abierto para construir aplicaciones web interactivas orientadas al análisis de datos, integrando Python, Plotly y componentes HTML.

**Databricks.** Plataforma de análisis de datos y ciencia de datos que facilita la ingeniería de datos, el aprendizaje automático y la colaboración en notebooks integrados.

**DBSCAN.** Algoritmo de agrupamiento que identifica regiones de alta densidad en conjuntos de datos. Es robusto frente a ruido y no requiere especificar el número de grupos.

**Deep Learning.** Rama del aprendizaje automático que emplea redes neuronales artificiales de múltiples capas para procesar grandes volúmenes de datos no estructurados. Es aplicado en reconocimiento de voz, visión artificial, generación de imágenes y comprensión de lenguaje natural.

**Dynamic Yield.** Plataforma digital que permite personalizar contenido en tiempo real utilizando modelos de apren-

dizaje automático, ajustando mensajes, precios o productos visibles en función del comportamiento del usuario en entornos digitales.

**Espacenet.** Base de datos de patentes de la Oficina Europea de Patentes que permite búsquedas técnicas en documentos de propiedad industrial a nivel mundial.

**Figma.** Herramienta colaborativa de diseño de interfaces que permite prototipado visual, validación de experiencias de usuario y trabajo en equipo en proyectos digitales.

**Fintech.** Término que agrupa a las tecnologías aplicadas a servicios financieros. Las fintech ofrecen soluciones innovadoras en pagos digitales, crédito, gestión de inversiones y seguros.

**Flamingo.** Modelo multimodal desarrollado por DeepMind que permite interpretar simultáneamente datos visuales y texto, facilitando tareas de generación, clasificación o análisis en entornos de IA generativa.

**Freelancers.** Profesionales independientes que ofrecen servicios especializados en plataformas digitales. Su contratación es frecuente en el desarrollo de soluciones tecnológicas ágiles y escalables.

**Fusion 360.** Software de diseño asistido por computadora (CAD) que incorpora herramientas de diseño generativo, simulación y manufactura asistida.

**Generative Design.** Enfoque de diseño asistido por IA que explora múltiples alternativas estructurales u operativas mediante algoritmos evolutivos, considerando restricciones físicas y objetivos funcionales.

**GitHub.** Plataforma de desarrollo colaborativo utilizada para alojar, revisar y gestionar código fuente de proyectos de software, incluyendo bibliotecas de IA y aprendizaje automático.

**Google Cloud.** Plataforma de servicios en la nube de Goo-

gle que integra APIs de inteligencia artificial, incluyendo modelos de lenguaje, visión por computadora y análisis predictivo.

**Google Cloud Platform (GCP).** Conjunto de servicios en la nube de Google que permite desarrollar, desplegar y escalar soluciones de inteligencia artificial, big data y almacenamiento distribuido.

**Google Optimize.** Herramienta de pruebas A/B y personalización de experiencias web que permite realizar experimentos controlados en productos digitales.

**Google Patents.** Herramienta de búsqueda de patentes ofrecida por Google que permite explorar documentos de invención registrados a nivel mundial.

**Google Scholar.** Motor de búsqueda especializado en literatura académica y científica que permite acceder a artículos, tesis, libros y conferencias revisadas por pares.

**GPT (Generative Pre-trained Transformer).** Arquitectura de modelo de lenguaje desarrollada por OpenAI basada en transformadores, entrenada con grandes cantidades de datos para generar texto coherente. Se emplea en redacción automática, asistentes conversacionales y generación de código.

**GPT-4.** Cuarta generación de los modelos generativos de OpenAI, caracterizada por mayor capacidad de comprensión, generación de texto coherente y análisis multimodal de datos (texto e imagen).

**Heap.** Software de analítica de productos digitales que registra de forma automática las interacciones de usuarios en aplicaciones y sitios web, facilitando el análisis del comportamiento sin necesidad de codificación manual de eventos.

**Hugging Face.** Comunidad y repositorio de modelos de procesamiento de lenguaje natural, incluyendo librerías como Transformers para el uso de modelos como BERT o GPT.

**Hyperledger Fabric.** Plataforma de código abierto para la

creación de soluciones de blockchain empresariales con permisos, utilizada para la trazabilidad y verificación en cadenas de suministro.

**IoT (Internet of Things).** Red de objetos físicos interconectados mediante sensores y software que recogen y transmiten datos. Permite automatizar entornos, optimizar operaciones y generar nuevos modelos de negocio basados en datos en tiempo real.

**Isolation Forest.** Algoritmo de detección de anomalías basado en árboles de decisión, eficaz para identificar comportamientos atípicos en grandes volúmenes de datos.

**K-means.** Algoritmo de agrupamiento que particiona los datos en un número predefinido de grupos, minimizando la varianza dentro de cada grupo. Es ampliamente usado en segmentación de datos.

**Keras.** Biblioteca de alto nivel para el desarrollo de redes neuronales en Python, que funciona como interfaz sobre TensorFlow.

**Lasers y LIDAR.** Dispositivos de detección óptica que permiten mapear entornos tridimensionales mediante pulsos de luz. Son esenciales para vehículos autónomos, robótica y cartografía digital.

**LightGBM (Light Gradient Boosting Machine).** Algoritmo de boosting basado en árboles de decisión, optimizado para alta velocidad y bajo consumo de memoria. Se utiliza en clasificación, predicción de series temporales y modelado de variables complejas.

**LLaMA.** Modelo de lenguaje de código abierto desarrollado por Meta AI, diseñado para tareas de generación y comprensión de texto, entrenado sobre grandes volúmenes de datos multilingües.

**Machine Learning.** Técnica que permite que los sistemas mejoren su rendimiento mediante el análisis de datos sin pro-

gramación explícita. Es clave en clasificación, predicción, segmentación de clientes y automatización de decisiones.

**Marketplace.** Plataforma digital que intermedia productos o servicios entre múltiples oferentes y demandantes. En IA, los marketplaces permiten contratar modelos, soluciones o expertos bajo demanda.

**Microsoft Azure.** Plataforma en la nube de Microsoft que ofrece servicios cognitivos, modelos de predicción, reconocimiento facial y herramientas de IA integradas para desarrollo empresarial.

**Midjourney.** Herramienta basada en inteligencia artificial para la generación de imágenes digitales a partir de comandos textuales, utilizada en diseño gráfico, arte conceptual y prototipado visual.

**Mixpanel.** Plataforma de analítica especializada en productos digitales que rastrea eventos de usuarios y proporciona métricas para la mejora iterativa del diseño, funcionalidades y usabilidad de soluciones digitales.

**MuZero.** Algoritmo de aprendizaje por refuerzo desarrollado por DeepMind, capaz de aprender a través de simulaciones internas sin conocer previamente las reglas del entorno. Se aplica en juegos, optimización de decisiones y planificación automática.

**MusicLM.** Modelo generativo desarrollado por Google para crear música a partir de descripciones textuales. Utiliza aprendizaje profundo para generar composiciones musicales coherentes y estilizadas.

**NLP (Natural Language Processing).** Conjunto de tecnologías orientadas a la comprensión, análisis y generación de lenguaje humano por sistemas computacionales. Facilita el desarrollo de asistentes virtuales, motores de búsqueda y análisis semántico.

**Outsourcing.** Estrategia empresarial que consiste en dele-

gar procesos o servicios a proveedores externos especializados, con el fin de mejorar eficiencia, reducir costos o acceder a competencias técnicas avanzadas.

**PaLM.** Modelo de lenguaje de gran escala desarrollado por Google, entrenado sobre una arquitectura de transformadores para tareas de generación de texto, razonamiento lógico y respuesta a preguntas complejas.

**Permutation Importance.** Técnica de interpretación de modelos que evalúa la importancia de las variables mediante la alteración aleatoria de sus valores y observación del impacto en el desempeño del modelo.

**Pipelines.** Secuencias estructuradas de procesos que permiten automatizar flujos de trabajo en proyectos de ciencia de datos y aprendizaje automático, integrando pasos de limpieza, entrenamiento y evaluación de modelos.

**Plotly.** Biblioteca interactiva de visualización de datos para Python, utilizada en dashboards y análisis exploratorios con componentes gráficos avanzados.

**Power BI.** Plataforma de Microsoft para la visualización interactiva de datos y la creación de informes dinámicos conectados a múltiples fuentes.

**PubMed.** Base de datos de artículos científicos en el área de la biomedicina, administrada por la Biblioteca Nacional de Medicina de EE. UU., ampliamente consultada para investigaciones en salud e IA aplicada.

**PyTorch.** Biblioteca de código abierto para la construcción de modelos de aprendizaje profundo, ampliamente utilizada por desarrolladores e investigadores para crear aplicaciones basadas en redes neuronales dinámicas.

**R (lenguaje de programación).** Lenguaje especializado en análisis estadístico, visualización de datos y modelado predictivo, utilizado en aplicaciones científicas y empresariales.

**RNN (Redes Neuronales Recurrentes).** Arquitectura de

red neuronal diseñada para procesar secuencias de datos, como texto o series temporales, utilizando memoria interna que captura dependencias a lo largo del tiempo.

**Reinforcement Learning.** Método de aprendizaje donde un agente mejora sus decisiones en un entorno mediante retroalimentación basada en recompensas. Es utilizado en sistemas autónomos, juegos estratégicos y control robótico.

**SaaS (Software as a Service).** Modelo de distribución de software que permite acceder a aplicaciones a través de Internet bajo suscripción, sin requerir instalación local. Facilita la escalabilidad y el acceso a soluciones actualizadas.

**Salesforce.** Plataforma en la nube especializada en la gestión de relaciones con clientes. Incluye módulos para ventas, marketing, atención al cliente y automatización, siendo utilizada en proyectos de base digital.

**scikit-learn.** Biblioteca de Python especializada en aprendizaje automático. Ofrece herramientas para clasificación, regresión, clustering, reducción de dimensionalidad y validación de modelos.

**Sensores.** Dispositivos electrónicos que detectan variaciones físicas o químicas del entorno y las convierten en señales procesables. Su uso en IA e IoT permite recoger datos esenciales para la automatización y análisis.

**SHAP (SHapley Additive exPlanations).** Método de interpretación de modelos que atribuye importancia a cada variable basada en teoría de juegos para explicar predicciones individuales.

**SpaCy.** Biblioteca de procesamiento de lenguaje natural en Python, optimizada para aplicaciones de producción con tareas como análisis sintáctico, extracción de entidades y tokenización.

**Stack Overflow.** Comunidad en línea para desarrolladores de software, donde se comparten preguntas, respuestas

y fragmentos de código. Es fuente frecuente de aprendizaje técnico en inteligencia artificial.

**Startup.** Iniciativa empresarial de carácter innovador y tecnológico que busca escalar rápidamente en el mercado. Se caracteriza por operar bajo incertidumbre y validar modelos de negocio repetibles.

**Statista.** Plataforma de estadísticas y estudios de mercado que ofrece datos estructurados sobre industrias, tecnologías y consumo, utilizados para análisis y toma de decisiones estratégicas.

**Tableau.** Herramienta de visualización de datos que permite crear paneles interactivos y gráficos avanzados para análisis exploratorios en entornos empresariales.

**TensorFlow.** Entorno de desarrollo de código abierto creado por Google para la implementación de modelos de aprendizaje automático y redes neuronales. Permite desarrollar soluciones para visión computacional, reconocimiento de voz y predicción.

**ThingsBoard.** Plataforma open-source para IoT que facilita la recolección, procesamiento y visualización de datos provenientes de sensores distribuidos.

**Transformers.** Arquitectura de modelos de procesamiento de lenguaje natural que utiliza mecanismos de atención para manejar secuencias de datos. Base de modelos como BERT, GPT y RoBERTa.

**Udemy.** Plataforma de educación en línea que ofrece cursos sobre inteligencia artificial, programación, análisis de datos y otras habilidades tecnológicas orientadas al desarrollo profesional.

**Uplift Modeling.** Técnica utilizada para identificar el impacto diferencial de una intervención, prediciendo qué individuos cambiarán su comportamiento ante una acción específica. Es aplicada en campañas de marketing personalizado y

segmentación avanzada.

**Vertex AI.** Plataforma de Google Cloud que integra herramientas de aprendizaje automático para construir, entrenar y desplegar modelos en entornos empresariales con flujos de trabajo automatizados.

**Webflow.** Plataforma de diseño visual de sitios web que permite construir páginas dinámicas sin programación, facilitando prototipado y despliegue rápido.

**WIPO.** Organización Mundial de la Propiedad Intelectual. Facilita el registro, consulta y protección de derechos sobre invenciones, marcas y obras creativas a nivel internacional.

**XGBoost (Extreme Gradient Boosting).** Algoritmo de boosting basado en árboles de decisión, optimizado para precisión y velocidad en tareas de clasificación y regresión. Se aplica ampliamente en soluciones predictivas y ciencia de datos.

## BIBLIOGRAFÍA

- Adelsberger, R. T., Antons, O. & Arlinghaus, J. (2024). Digital Twins and their Implications for Business Models: Overview and Potentials. *IFAC-PapersOnLine*, 58, 409–414. <https://doi.org/10.1016/j.ifacol.2024.09.246>
- Agrawal, A., Gans, J. & Goldfarb, A. (2018). *Prediction Machines: The Simple Economics of Artificial Intelligence*. Harvard Business Review Press. [https://cdn.chools.in/DIG\\_LIB/E-Book/Prediction%20Machines-The%20Simple%20Economics%20of%20Artificial%20Intelligence%20by%20Ajay%20Agrawal\\_.pdf](https://cdn.chools.in/DIG_LIB/E-Book/Prediction%20Machines-The%20Simple%20Economics%20of%20Artificial%20Intelligence%20by%20Ajay%20Agrawal_.pdf)
- Aithor. (2024). *El avance de la inteligencia artificial en las startups latinoamericanas*. [https://Aithor.Com/Essay-Examples/El-Avance-de-La-Inteligencia-Artificial-En-Las-Startups-Latinoamericanas?utm\\_source=chatgpt.Com](https://Aithor.Com/Essay-Examples/El-Avance-de-La-Inteligencia-Artificial-En-Las-Startups-Latinoamericanas?utm_source=chatgpt.Com).
- Alalawi, Z., Bova, P., Cimpeanu, T., Di Stefano, A., Duong, M. H., Domingos, E. F., Han, T. A., Krellner, M., Ogbo, B., Powers, S. T. & Zimmaro, F. (2024). *Trust AI Regulation? Discerning users are vital to build trust and effective AI regulation*.
- Alayrac, J. B., Donahue, J., Luc, P., Miech, A., Barr, I., Hasson, Y., Lenc, K., Mensch, A., Millican, K., Reynolds, M., Ring, R., Rutherford, E., Han, S. C. T., Gong, Z., Samangooei, S., Monteiro, M., Menick, J., Borgeaud, S., Brock, A., ... Simonyan, K. (2022). Flamingo: a Visual Language Model for Few-Shot Learning. *Advances in Neural Information*

*Processing Systems, 35.*

- Alliata, Z., Singhal, T. & Bozagi, A. M. (2025). The AI Scrum Master: Using Large Language Models (LLMs) to Automate Agile Project Management Tasks. *Lecture Notes in Business Information Processing, 524*, 110–122. [https://doi.org/10.1007/978-3-031-72781-8\\_12](https://doi.org/10.1007/978-3-031-72781-8_12)
- Almansour, M. (2023). Artificial intelligence and resource optimization: A study of Fintech start-ups. *Resources Policy, 80*. <https://doi.org/10.1016/j.resourpol.2022.103250>
- Alsaigh, R., Mehmood, R. & Katib, I. (2023). AI explainability and governance in smart energy systems: A review. In *Frontiers in Energy Research* (Vol. 11). Frontiers Media S.A. <https://doi.org/10.3389/fenrg.2023.1071291>
- Amershi, S., Begel, A., Bird, C., DeLine, R., Gall, H., Kamar, E., Nagappan, N., Nushi, B. & Zimmermann, T. (2019). Software Engineering for Machine Learning: A Case Study. *Proceedings - 2019 IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice, ICSE-SEIP 2019*, 291–300. <https://doi.org/10.1109/ICSE-SEIP.2019.00042>
- Amershi, S., Weld, D., Vorvoreanu, M., Fournery, A., Nushi, B., Collisson, P., Suh, J., Iqbal, S., Bennett, P. N., Inkpen, K., Teevan, J., Kikin-Gil, R. & Horvitz, E. (2019, May). Guidelines for human-AI interaction. *Conference on Human Factors in Computing Systems - Proceedings*. <https://doi.org/10.1145/3290605.3300233>
- Autio, E., Nambisan, S., Thomas, L. D. W. & Wright, M. (2018). Digital affordances, spatial affordances, and the genesis of entrepreneurial ecosystems. *Strategic Entrepreneurship Journal, 12*, 72–95. <https://doi.org/10.1002/sej.1266>
- AWS. (n.d.). *¿Qué es la CDP? - Explicación de la plataforma*

- de datos de clientes - AWS*. [https://aws.amazon.com/what-is/customer-data-platform/?utm\\_source=chatgpt.com](https://aws.amazon.com/what-is/customer-data-platform/?utm_source=chatgpt.com).
- Bandara, K., Bergmeir, C. & Smyl, S. (2020). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert Systems with Applications*, 140. <https://doi.org/10.1016/j.eswa.2019.112896>
- Binns, R. (2020). On the apparent conflict between individual and group fairness. *FAT\* 2020 - Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency*, 514–524. <https://doi.org/10.1145/3351095.3372864>
- Binns, R. & Veale, M. (2021). Is that your final decision? Multi-stage profiling, selective effects, and Article 22 of the GDPR. *International Data Privacy Law*, 11, 319–332. <https://doi.org/10.1093/idpl/ipab020>
- Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., Bernstein, M. S., Bohg, J., Bosselut, A., Brunskill, E., Brynjolfsson, E., Buch, S., Card, D., Castellon, R., Chatterji, N., Chen, A., Creel, K., Davis, J. Q., Demszky, D., ... Liang, P. (2021). *On the Opportunities and Risks of Foundation Models*.
- Bommasani, R., Klyman, K., Longpre, S., Kapoor, S., Maslej, N., Xiong, B., Zhang, D. & Liang, P. (2023). *The Foundation Model Transparency Index*.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D., Wu, J., Winter, C., ... Amodei, D. (2019). *Language Models are Few-Shot Learners*. <https://Proceedings.Neurips.Cc/Paper/2020/Hash/1457c0d6bfcb4967418bfb8ac->

142f64a-Abstract.Html.

- Brynjolfsson, E. & McElheran, K. (2016). The rapid adoption of data-driven decision-making. *American Economic Review*, 106, 133–139. <https://doi.org/10.1257/aer.p20161016>
- Bughin, J., Hazan, E., Lund, S., Dahlstöm, P., Wiesinger, A. & Subramaniam, A. (2018). *Skill shift: Automation and the future of the workforce*. <https://www.mckinsey.com/featured-insights/future-of-work/skill-shift-automation-and-the-future-of-the-workforce>.
- Cabezas, D. (2022). *Automatización Robótica de Procesos (RPA) e Inteligencia Artificial (AI) - Actuaría*. <https://actuaría.com/automatizacion-robotica-de-procesos-rpa-e-inteligencia-artificial-ai/>.
- Cabrera-Sánchez, J. P., Villarejo-Ramos, Á. F., Liébana-Caballinas, F. & Shaikh, A. A. (2021). Identifying relevant segments of AI applications adopters – Expanding the UTAUT2’s variables. *Telematics and Informatics*, 58. <https://doi.org/10.1016/j.tele.2020.101529>
- Caron, M., Touvron, H., Misra, I., Jégou, H., Mairal, J., Bojanowski, P. & Joulin, A. (2021). *Emerging Properties in Self-Supervised Vision Transformers*. <https://github.com/facebookresearch/dino>
- Cath, C. (2018). Governing artificial intelligence: ethical, legal and technical opportunities and challenges. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 376, 20180080. <https://doi.org/10.1098/rsta.2018.0080>
- Cavazza, A., Dal Mas, F., Paoloni, P. & Manzo, M. (2023). Artificial intelligence and new business models in agriculture: a structured literature review and future research agenda. *British Food Journal*, 125, 436–461. <https://doi.org/10.1108/BFJ-02-2023-0132>

- Cavoukian, A. (2011). Privacy by Design: Origins, meaning, and prospects for assuring privacy and trust in the information era. In *Privacy Protection Measures and Technologies in Business Organizations: Aspects and Standards* (pp. 170–208). IGI Global. <https://doi.org/10.4018/978-1-61350-501-4.ch007>
- CDAO. (2024). *Test and Evaluation of Artificial Intelligence Models*.
- Chen, Y., Liu, H., Zhang, J. & Wu, J. (2025). A Data-Driven Methodology for Industrial Design Optimization and Consumer Preference Modeling: An Application of Computer-Aided Design in Sustainable Refrigerator Design Research. *Symmetry*, 17(4). <https://doi.org/10.3390/sym17040621>
- Choi, W., Choi, T. & Heo, S. (2023). A Comparative Study of Automated Machine Learning Platforms for Exercise Anthropometry-Based Typology Analysis: Performance Evaluation of AWS SageMaker, GCP VertexAI, and MS Azure. *Bioengineering*, 10(8). <https://doi.org/10.3390/bioengineering10080891>
- Christiano, P. F., Leike, J., Brown, T. B., Martic, M., Legg, S. & Amodei, D. (2017). *Deep Reinforcement Learning from Human Preferences*.
- Conduah, A. K. & Essiaw, M. N. (2022). Resilience and entrepreneurship: a systematic review. *F1000Research*, 11, 348. <https://doi.org/10.12688/f1000research.75473.1>
- Corrado, C., Haskel, J. & Jona-Lasinio, C. (2021). Artificial intelligence and productivity: An intangible assets approach. *Oxford Review of Economic Policy*, 37, 435–458. <https://doi.org/10.1093/oxrep/grab018>
- Cui, J., Wang, Z., Ho, S. & Cambria, E. (2023). Survey on sentiment analysis: evolution of research methods and topics. *Artificial Intelligence Review*, 56, 1–42. <https://doi.org/10.1007/s12559-023-1000-0>

- org/10.1007/s10462-022-10386-z
- Dam, H. K., Tran, T., Grundy, J., Ghose, A. & Kamei, Y. (2019). Towards effective AI-powered agile project management. *Proceedings - 2019 IEEE/ACM 41st International Conference on Software Engineering: New Ideas and Emerging Results, ICSE-NIER 2019*, 41–44. <https://doi.org/10.1109/ICSE-NIER.2019.00019>
- Datahub. (2025, April 28). *AI-Driven Business Intelligence: Smarter Dashboards, Faster Decisions Datahub Analytics*. <https://datahubanalytics.com/ai-driven-business-intelligence-smarter-dashboards-faster-decisions/>.
- Davenport, T., Guha, A., Grewal, D. & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48, 24–42. <https://doi.org/10.1007/s11747-019-00696-0>
- Davenport, T. & Ronanki, R. (2018). *Artificial Intelligence for the Real World*. <https://hbr.org/2018/01/artificial-intelligence-for-the-real-world>.
- Deloitte. (2023). *Five 2023 workflow automation trends reshaping the future*. <https://www.deloitte.com/global/en/alliances/servicenow/about/2023-workflow-automation-trends.html>.
- Doshi-Velez, F. & Kim, B. (2017). *Towards A Rigorous Science of Interpretable Machine Learning*. <http://arxiv.org/abs/1702.08608>
- Duarte, V., Zuniga-Jara, S. & Contreras, S. (2022). Machine Learning and Marketing: A Systematic Literature Review. In *IEEE Access*, (Vol. 10, pp. 93273–93288. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2022.3202896>
- Duchek, S. (2020). Organizational resilience: a capability-based conceptualization. *Business Research*, 13,

- 215–246. <https://doi.org/10.1007/s40685-019-0085-7>
- Echtenbruck, M. M., Fühles-Ubach, S., Naujoks, B. & Kaliva, E. (2025). *A Data Literacy Competence Model for Higher Education and Research*.
- Ecuación Digital. (2025, March 17). *5 barreras que dificultan la implementación de la IA en empresas*. [https://www.laecuaciondigital.com/tecnologias/inteligencia-artificial/5-barreras-que-dificultan-la-implementacion-de-la-ia-en-empresas/?utm\\_source=chatgpt.com](https://www.laecuaciondigital.com/tecnologias/inteligencia-artificial/5-barreras-que-dificultan-la-implementacion-de-la-ia-en-empresas/?utm_source=chatgpt.com).
- EDPB. (2020). *Directrices 5/2020 sobre el consentimiento en el sentido del Reglamento (UE) 2016/679*. [https://www.edpb.europa.eu/sites/default/files/files/file1/edpb\\_guidelines\\_202005\\_consent\\_es.pdf](https://www.edpb.europa.eu/sites/default/files/files/file1/edpb_guidelines_202005_consent_es.pdf)
- Edtiyarsih, D. D. (2023). Analysis of Bankruptcy Prediction with Financial Ratios Altman Z-Score Model: Case Study of Oil and Gas Companies Listed on IDX in 2017–2021. *West Science Interdisciplinary Studies*, 1, 18–30. <https://doi.org/10.58812/wsis.v1i02.44>
- Fisher, M. & Raman, A. (2018). Using Data and Big Data in Retailing. *Production and Operations Management*, 27, 1665–1669. <https://doi.org/10.1111/poms.12846>
- Floridi, L. (2023). Future. In *The Ethics of Artificial Intelligence* (pp. 31–54). Oxford University Press Oxford. <https://doi.org/10.1093/oso/9780198883098.003.0003>
- Floridi, L., Cows, J., Beltrametti, M., Chatila, R., Chazerand, P., Dignum, V., Luetge, C., Madelin, R., Pagallo, U., Rossi, F., Schafer, B., Valcke, P. & Vayena, E. (2018). AI4People—An Ethical Framework for a Good AI Society: Opportunities, Risks, Principles, and Recommendations. *Minds and Machines*, 28, 689–707. <https://doi.org/10.1007/s11023-018-9482-5>

- Foitzick, K. (2024, October 11). *Automated decision-making by AI* | activeMind.legal. <https://www.activemind.legal/Guides/Automated-Decision-Making-Ai/>.
- Frank, M. R., Sun, L., Cebrian, M., Youn, H. & Rahwan, I. (2018). Small cities face greater impact from automation. *Journal of The Royal Society Interface*, 15, 20170946. <https://doi.org/10.1098/rsif.2017.0946>
- Friedler, S.A., Scheidegger, C. & Venkatasubramanian, S. (2021). The (Im)possibility of fairness. *Communications of the ACM*, 64, 136–143. <https://doi.org/10.1145/3433949>
- Fundación de Diseño de Interacción - IxDF. (2024, February 6). *What is Digital Inclusion?* <https://www.interaction-design.org/literature/topics/digital-inclusion>.
- Fuselab Creative. (2025). *AI Dashboard Design: Business Insights 2025* | Fuselab Creative. <https://fuselabcreative.com/Ai-Dashboard-Future-Proofing-Business-Analytics/>.
- Gao, B., Wang, Y., Xie, H., Hu, Y. & Hu, Y. (2023). Artificial Intelligence in Advertising: Advancements, Challenges, and Ethical Considerations in Targeting, Personalization, Content Creation, and Ad Optimization. In *SAGE Open* (Vol. 13). SAGE Publications Inc. <https://doi.org/10.1177/21582440231210759>
- Gao, Y. & Liu, H. (2023). Artificial intelligence-enabled personalization in interactive marketing: a customer journey perspective. *Journal of Research in Interactive Marketing*, 17, 663–680. <https://doi.org/10.1108/JRIM-01-2022-0023>
- García-Gil, D., Luengo, J., García, S. & Herrera, F. (2019). Enabling Smart Data: Noise filtering in Big Data classification. *Information Sciences*, 479, 135–152. <https://doi.org/10.1016/j.ins.2018.12.002>
- Gentsch, P. (2022). AI in Marketing, Sales and Service. In

- <https://www.springerprofessional.de/en/ai-in-marketing-sales-and-service/16217826>.
- George, G., Merrill, R. K. & Schillebeeckx, S. J. D. (2021). Digital Sustainability and Entrepreneurship: How Digital Innovations Are Helping Tackle Climate Change and Sustainable Development. *Entrepreneurship: Theory and Practice*, 45, 999–1027. <https://doi.org/10.1177/1042258719899425>
- Google. (2025, May 21). *Get more from your ads with the latest AI measurement tools*. [https://blog.google/products/ads-commerce/google-ai-ad-campaign-measurement-update/?utm\\_source=chatgpt.com](https://blog.google/products/ads-commerce/google-ai-ad-campaign-measurement-update/?utm_source=chatgpt.com).
- Grover, S., Dominguez, X., Leones, T., Kamdar, D., Vahay, P. & Gracely, S. (2022). *Strengthening early STEM learning by integrating CT into science and math activities at home* (pp. 72–84). <https://doi.org/10.1145/3507951.3519290>
- Haefner, N., Parida, V., Gassmann, O. & Wincent, J. (2023). Implementing and scaling artificial intelligence: A review, framework, and research agenda. *Technological Forecasting and Social Change*, 197. <https://doi.org/10.1016/j.techfore.2023.122878>
- Haidabrus, B. (2024). Generative AI in Agile, Project, and Delivery Management. *Lecture Notes in Mechanical Engineering*, 100–110. [https://doi.org/10.1007/978-3-031-61797-3\\_9](https://doi.org/10.1007/978-3-031-61797-3_9)
- Han, S., Zhang, Q., Yao, Y., Jin, W., Xu, Z. & He, C. (2024). *LLM Multi-Agent Systems: Challenges and Open Problems*.
- Hazen, B. T., Boone, C. A., Ezell, J. D. & Jones-Farmer, L. A. (2014). Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications. *International Journal of Production*

- Economics*, 154, 72–80. <https://doi.org/10.1016/j.ijpe.2014.04.018>
- Hermann, E. (2023). Artificial intelligence in marketing: friend or foe of sustainable consumption? In *AI and Society* (Vol. 38, pp. 1975–1976). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s00146-021-01227-8>
- Hilbert, M. (2020). Digital Technology and Social Change: The Digital Transformation of Society from a Historical Perspective. *Dialogues in Clinical Neuroscience*, 22, 189–194. <https://doi.org/10.31887/DCNS.2020.22.2/mhilbert>
- Holstein, K., Vaughan, J. W., Daumé, H., Dudík, M. & Wallach, H. (2019, May). Improving fairness in machine learning systems: What do industry practitioners need? *Conference on Human Factors in Computing Systems - Proceedings*. <https://doi.org/10.1145/3290605.3300830>
- Hossain, E., Rana, R., Higgins, N., Soar, J., Barua, P. D., Pisani, A. R., D, Ph. & Turner, K. (2023). *Natural Language Processing in Electronic Health Records in Relation to Healthcare Decision-making: A Systematic Review*.
- Hossain, M. A., Akter, S., Yanamandram, V. & Gunasekaran, A. (2022). Operationalizing Artificial Intelligence-Enabled Customer Analytics Capability in Retailing. In *Journal of Global Information Management* (Vol. 30, Issue 8). IGI Global. <https://doi.org/10.4018/JGIM.298992>
- Huang, Y.-H. & Lin, C.-T. (2023). Indoor Localization Method for a Mobile Robot Using LiDAR and a Dual AprilTag. *Electronics*, 12(4). <https://doi.org/10.3390/electronics12041023>
- IAPP. (2024). Privacy Governance Report 2024 – Executive Summary. In <https://iapp.org/resources/article/pri>

vacy-governance-report/.

- Jackson, I., Dmitry, I., Alexandre, D. & Namdar, J. (2024). Generative artificial intelligence in supply chain and operations management: a capability-based framework for analysis and implementation. *International Journal of Production Research*, 62(17), 6120–6145. <https://doi.org/10.1080/00207543.2024.2309309>
- Jayeola, O., Sidek, S., Rahman, A. A., Mahomed, A. S. B. & Hu, J. (2022). Cloud computing adoption in small and medium enterprises (smes): a systematic literature review and directions for future research. *International Journal of Business and Society*, 23, 226–243. <https://doi.org/10.33736/ijbs.4610.2022>
- Jobin, A., Ienca, M. & Vayena, E. (2019). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1, 389–399. <https://doi.org/10.1038/s42256-019-0088-2>
- Jorzik, P., Klein, S. P., Kanbach, D. K. & Kraus, S. (2024). AI-driven business model innovation: A systematic review and research agenda. *Journal of Business Research*, 182. <https://doi.org/10.1016/j.jbusres.2024.114764>
- Just, J. (2024). Natural language processing for innovation search – Reviewing an emerging non-human innovation intermediary. *Technovation*, 129. <https://doi.org/10.1016/j.technovation.2023.102883>
- Kamble, S. S., Gunasekaran, A. & Gawankar, S. A. (2018). Sustainable Industry 4.0 framework: A systematic literature review identifying the current trends and future perspectives. *Process Safety and Environmental Protection*, 117, 408–425. <https://doi.org/10.1016/j.psep.2018.05.009>
- Kleinman, A. (2025, May 22). *New research: Open source AI drives economic growth and cost savings*. <https://www.>

[axios.com/sponsored/new-research-open-source-ai-drives-economic-growth-and-cost-savings?utm\\_source=chatgpt.com](https://axios.com/sponsored/new-research-open-source-ai-drives-economic-growth-and-cost-savings?utm_source=chatgpt.com).

- Kohavi, R., Deng, A., Frasca, B., Walker, T., Xu, Y. & Pohlmann, N. (2013). Online controlled experiments at large scale. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Part F128815*, 1168–1176. <https://doi.org/10.1145/2487575.2488217>
- Kolbl, Ž., Diamantopoulos, A., Arslanagic-Kalajdzic, M. & Zabkar, V. (2020). Do brand warmth and brand competence add value to consumers? A stereotyping perspective. *Journal of Business Research*, 118, 346–362. <https://doi.org/https://doi.org/10.1016/j.jbusres.2020.06.048>
- Krause, C. (2024, September 1). *AI for Analytics: Breaking Free from Legacy Dashboards*. <https://cdotimes.com/2024/08/01/ai-for-analytics-breaking-free-from-legacy-dashboards/>.
- Kuhn, M. & Silge, J. (n.d.). *Tidy Modeling with R*. <https://www.tmw.org/>.
- Kumar, V. & Reinartz, W. (2016). Creating enduring customer value. *Journal of Marketing*, 80, 36–68. <https://doi.org/10.1509/jm.15.0414>
- Le, H. S., Do, T. V. H., Nguyen, M. H., Tran, H. A., Pham, T. T. T., Nguyen, N. T. & Nguyen, V. H. (2024). Predictive model for customer satisfaction analytics in E-commerce sector using machine learning and deep learning. *International Journal of Information Management Data Insights*, 4. <https://doi.org/10.1016/j.jjime.2024.100295>
- Lee, J., Park, S. & Lee, J. (2022). Technology Opportunity Analysis Based on Machine Learning. *Axioms*, 11(12).

- <https://doi.org/10.3390/axioms11120708>
- Li, Y. H., Li, Y. L., Wei, M. Y. & Li, G. Y. (2024). Innovation and challenges of artificial intelligence technology in personalized healthcare. *Scientific Reports*, 14. <https://doi.org/10.1038/s41598-024-70073-7>
- Li, Y., Jing, S., Ding, R., Josyula, H. P. & Todorović, M. (2025). AI for project management: Revolutions, trends, and challenges. In *Frontiers of Engineering Management. Higher Education Press Limited Company*. <https://doi.org/10.1007/s42524-025-5015-0>
- Lim, W. M. & Rasul, T. (2022). Customer engagement and social media: Revisiting the past to inform the future. *Journal of Business Research*, 148, 325–342. <https://doi.org/10.1016/j.jbusres.2022.04.068>
- Lin, J. (2025). Application of machine learning in predicting consumer behavior and precision marketing. *PLoS ONE*, 20. <https://doi.org/10.1371/journal.pone.0321854>
- Linnenluecke, M. K. (2017). Resilience in Business and Management Research: A Review of Influential Publications and a Research Agenda. *International Journal of Management Reviews*, 19, 4–30. <https://doi.org/10.1111/ijmr.12076>
- Lins, S., Pandl, K. D., Teigeler, H., Thiebes, S., Bayer, C. & Sunyaev, A. (2021a). Artificial Intelligence as a Service: Classification and Research Directions. *Business and Information Systems Engineering*, 63, 441–456. <https://doi.org/10.1007/s12599-021-00708-w>
- Lins, S., Pandl, K. D., Teigeler, H., Thiebes, S., Bayer, C. & Sunyaev, A. (2021b). Artificial Intelligence as a Service: Classification and Research Directions. *Business and Information Systems Engineering*, 63, 441–456. <https://doi.org/10.1007/s12599-021-00708-w>
- Litman, T. (2025, May 22). *Autonomous Vehicle Implementa-*

- tion Predictions*. [www.vtppi.org](http://www.vtppi.org)
- Liu, V., Vermeulen, J., Fitzmaurice, G. & Matejka, J. (2023). *3DALL-E: Integrating Text-to-Image AI in 3D Design Workflows*. 1955–1977. <https://doi.org/10.1145/3563657.3596098>
- Lu, J., Liu, A., Dong, F., Gu, F., Gama, J. & Zhang, G. (2019). Learning under Concept Drift: A Review. In *IEEE Transactions on Knowledge and Data Engineering* (Vol. 31, pp. 2346–2363). IEEE Computer Society. <https://doi.org/10.1109/TKDE.2018.2876857>
- Lu, W. (2024). Inevitable challenges of autonomy: ethical concerns in personalized algorithmic decision-making. *Humanities and Social Sciences Communications*, 11. <https://doi.org/10.1057/s41599-024-03864-y>
- Lundberg, S. M., Allen, P. G. & Lee, S.-I. (2017). *A Unified Approach to Interpreting Model Predictions*. <https://github.com/slundberg/shap>
- Mahajan, K. (2025, May 16). *El mercado de GPU para centros de datos refleja un enorme crecimiento del 14,2%*. <https://scoop.market.us/noticias-del-mercado-de-gpu-para-centros-de-datos/>.
- Maritz, A. & Brown, C. R. (2013). Illuminating the black box of entrepreneurship education programs. In *Education and Training* (Vol. 55, pp. 234–252). <https://doi.org/10.1108/00400911311309305>
- Martin, F., Lee, I., Lytle, N., Sentance, S. & Lao, N. (2020). Extending and evaluating the use-modify-create progression for engaging youth in computational thinking. *SIGCSE 2020 - Proceedings of the 51st ACM Technical Symposium on Computer Science Education*, 807–808. <https://doi.org/10.1145/3328778.3366971>
- Mckinsey and Company. (2020, June 10). *The future of work in Europe*. <https://www.mckinsey.com/featured-in->

- sights/future-of-work/the-future-of-work-in-europe.
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K. & Galstyan, A. (2021a). A Survey on Bias and Fairness in Machine Learning. In *ACM Computing Surveys* (Vol. 54). Association for Computing Machinery. <https://doi.org/10.1145/3457607>
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K. & Galstyan, A. (2021b). A Survey on Bias and Fairness in Machine Learning. In *ACM Computing Surveys* (Vol. 54). Association for Computing Machinery. <https://doi.org/10.1145/3457607>
- Mikalef, P., Conboy, K. & Krogstie, J. (2021). Artificial intelligence as an enabler of B2B marketing: A dynamic capabilities micro-foundations approach. *Industrial Marketing Management*, 98, 80–92. <https://doi.org/10.1016/j.indmarman.2021.08.003>
- Mittelstadt, B. (2019). Principles alone cannot guarantee ethical AI. *Nature Machine Intelligence*, 1, 501–507. <https://doi.org/10.1038/s42256-019-0114-4>
- Mokyr, J. (2016). A Culture of Growth: The Origins of the Modern Economy. In *Presidential Address, Atlantic Economic Association*. <https://www.iaes.org/wp-content/uploads/2016/03/mokyr-slides-lisbon.pdf>
- Moreno, S. (2025, May 4). *Startup-as-a-Service: Emprender Sin Ataduras - Easy World Business*. [https://easy-world-business.com/2025/05/04/startup-as-a-service-emprender-sin-ataduras/#google\\_vignette](https://easy-world-business.com/2025/05/04/startup-as-a-service-emprender-sin-ataduras/#google_vignette).
- Morley, J., Floridi, L., Kinsey, L. & Elhalal, A. (2020). From What to How: An Initial Review of Publicly Available AI Ethics Tools, Methods and Research to Translate Principles into Practices. *Science and Engineering Ethics*, 26(4), 2141–2168. <https://doi.org/10.1007/s11948-019-00165-5>

- Mueller, M. L. (2025). It's just distributed computing: Rethinking AI governance. *Telecommunications Policy*, 49(3), 102917. <https://doi.org/https://doi.org/10.1016/j.telpol.2025.102917>
- Muthupriya, V., Narayanan, R., Nakeeb, S. & Abhishek, A. (2022). Customer churn analysis using XGBoosted decision trees. *Indonesian Journal of Electrical Engineering and Computer Science*, 25, 488. <https://doi.org/10.11591/ijeecs.v25.i1.pp488-495>
- Nambisan, S. (2017). Digital Entrepreneurship: Toward a Digital Technology Perspective of Entrepreneurship. *Entrepreneurship: Theory and Practice*, 41, 1029–1055. <https://doi.org/10.1111/etap.12254>
- Nazir, S., Khadim, S., Ali Asadullah, M. & Syed, N. (2023). Exploring the influence of artificial intelligence technology on consumer repurchase intention: The mediation and moderation approach. *Technology in Society*, 72. <https://doi.org/10.1016/j.techsoc.2022.102190>
- OECD. (n.d.). *OECD Framework for the Classification of AI systems*. [https://www.oecd.org/en/publications/oecd-framework-for-the-classification-of-ai-systems\\_cb-6d9eca-en.html](https://www.oecd.org/en/publications/oecd-framework-for-the-classification-of-ai-systems_cb-6d9eca-en.html).
- OECD. (2022, December 13). *What skills and abilities can automation technologies replicate and what does it mean for workers?* [https://www.oecd.org/en/publications/what-skills-and-abilities-can-automation-technologies-replicate-and-what-does-it-mean-for-workers\\_646aad77-en.html](https://www.oecd.org/en/publications/what-skills-and-abilities-can-automation-technologies-replicate-and-what-does-it-mean-for-workers_646aad77-en.html).
- OECD. (2025, April 24). *Bridging the AI skills gap*. [https://www.oecd.org/en/publications/bridging-the-ai-skills-gap\\_66d0702e-en.html](https://www.oecd.org/en/publications/bridging-the-ai-skills-gap_66d0702e-en.html).
- Okeleke, P. A., Ajiga, D., Olaoluwa Folorunsho, S. & Ezeigweneme, C. (2024). Predictive analytics for market trends

- using AI: A study in consumer behavior. *International Journal of Engineering Research Updates*, 7(1), 036–049. <https://doi.org/10.53430/ijeru.2024.7.1.0032>
- Oviatt, B. M. & McDougall, P. P. (2005). Defining international entrepreneurship and modeling the speed of internationalization. In *Entrepreneurship: Theory and Practice* (Vol. 29, pp. 537–554). Blackwell Publishing Inc. <https://doi.org/10.1111/j.1540-6520.2005.00097.x>
- Paschen, J., Kietzmann, J. & Kietzmann, T. C. (2019). Artificial intelligence (AI) and its implications for market knowledge in B2B marketing. *Journal of Business and Industrial Marketing*, 34, 1410–1419. <https://doi.org/10.1108/JBIM-10-2018-0295>
- Pedregosa, F., Michel, V., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Vanderplas, J., Cournapeau, D., Pedregosa, F., Varoquaux, G., Gramfort, A., Thirion, B., Grisel, O., Dubourg, V., Passos, A., Brucher, M. & Duchesnay, F. (2011). Scikit-learn: Machine Learning in Python Gaël Varoquaux Bertrand Thirion Vincent Dubourg Alexandre Passos PEDREGOSA, VAROQUAUX, GRAMFORT ET AL. Matthieu Perrot. In *Journal of Machine Learning Research* (Vol. 12). <http://scikit-learn.sourceforge.net>.
- Pekonen, I. & Lähteinen, J. (2021). *Robotic Process Automation (RPA) As A Digitalization Related Tool To Process Enhancement And Time Saving*. <https://doi.org/10.13140/RG.2.2.13974.68161>
- Qin, V., Pauwels, K. & Zhou, B. (2024). Data-driven budget allocation of retail media by ad product, funnel metric, and brand size. *Journal of Marketing Analytics*, 12, 235–249. <https://doi.org/10.1057/s41270-024-00294-2>
- Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., Clark, J., Krueger,

- G. & Sutskever, I. (2021). Learning Transferable Visual Models From Natural Language Supervision. *Proceedings of Machine Learning Research*, 139, 8748–8763.
- Raji, I. D. & Buolamwini, J. (2019). Actionable auditing: Investigating the impact of publicly naming biased performance results of commercial AI products. *AIES 2019 - Proceedings of the 2019 AAAI/ACM Conference on AI, Ethics, and Society*, 429–435. <https://doi.org/10.1145/3306618.3314244>
- Raji, I. D., Smart, A., White, R. N., Mitchell, M., Gebru, T., Hutchinson, B., Smith-Loud, J., Theron, D. & Barnes, P. (2020). Closing the AI accountability gap: Defining an end-to-end framework for internal algorithmic auditing. *FAT\*2020 - Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency*, 33–44. <https://doi.org/10.1145/3351095.3372873>
- Rane, N., Paramesha, M., Choudhary, S. & Rane, J. (2024). Business Intelligence through Artificial Intelligence: A Review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4831916>
- Ratten, V. (2020). Entrepreneurial ecosystems. In *Thunderbird International Business Review* (Vol. 62, pp. 447–455). Wiley-Liss Inc. <https://doi.org/10.1002/tie.22164>
- Razvi, S. S., Feng, S., Narayanan, A., Lee, Y.-T. & Witherell, P. (2019). *A Review of Machine Learning Applications in Additive Manufacturing*. <https://doi.org/10.1115/DETC2019-98415>
- Richmond, A. & Sulaiman, O. (2023). Artificial intelligence and automation for the future of startups. In *Ecosystem Dynamics and Strategies for Startups Scalability* (pp. 133–153). IGI Global. <https://doi.org/10.4018/979-8-3693-0527-0.ch007>

- Righi, R., Samoili, S., López Cobo, M., Vázquez-Prada Baillet, M., Cardona, M. & De Prato, G. (2020). The AI techno-economic complex System: Worldwide landscape, thematic subdomains and technological collaborations. *Telecommunications Policy*, 44(6), 101943. <https://doi.org/https://doi.org/10.1016/j.telpol.2020.101943>
- Ruiz, M. & González, N. (2024). *La automatización de procesos en Pymes del municipio de Santa María como impulso a su productividad*. Universidad Nacional Abierta y a Distancia – UNAD.
- Rzepakowski, P. & Jaroszewicz, S. (2010). Decision trees for uplift modeling. *Proceedings - IEEE International Conference on Data Mining, ICDM*, 441–450. <https://doi.org/10.1109/ICDM.2010.62>
- Sandoval-Ríos, F., Gajardo-Poblete, C. & López-Núñez, J. A. (2025). Role of data literacy training for decision-making in teaching practice: a systematic review. *Frontiers in Education*, 10. <https://doi.org/10.3389/educ.2025.1485821>
- Sarmiento, J., Lijo, R. & Quevedo Gutiérrez, E. (2023). *El Pensamiento Computacional en el Currículo de Matemáticas de la Enseñanza Básica y la Formación del Profesorado: ¡Una Segunda Oportunidad! 15*, 203–226.
- Schwab, K. (2016). *The Fourth Industrial Revolution*. World Economic Forum. [https://law.unimelb.edu.au/\\_data/assets/pdf\\_file/0005/3385454/Schwab-The\\_Fourth\\_Industrial\\_Revolution\\_Klaus\\_S.pdf](https://law.unimelb.edu.au/_data/assets/pdf_file/0005/3385454/Schwab-The_Fourth_Industrial_Revolution_Klaus_S.pdf)
- Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F. & Dennison, D. (n.d.). *Hidden Technical Debt in Machine Learning Systems*.
- Sharma, A. (2023). *Product design and development using Artificial Intelligence (AI) techniques: A review*. <https://>

doi.org/10.31224/2958

- Shmueli, G. (2010). To explain or to predict? *Statistical Science*, 25(3), 289–310. <https://doi.org/10.1214/10-STS330>
- Shum, H. yeung, He, X. dong & Li, D. (2018). From Eliza to XiaoIce: challenges and opportunities with social chatbots. In *Frontiers of Information Technology and Electronic Engineering* (Vol. 19, pp. 10–26). Zhejiang University. <https://doi.org/10.1631/FITEE.1700826>
- Sindakis, S. & Showkat, G. (2024). The digital revolution in India: bridging the gap in rural technology adoption. *Journal of Innovation and Entrepreneurship*, 13. <https://doi.org/10.1186/s13731-024-00380-w>
- Singh, N., Chaudhary, V., Singh, N., Soni, N. & Kapoor, A. (2024). *Transforming Business with Generative AI: Research, Innovation, Market Deployment and Future Shifts in Business Models*.
- Smit, S., Tacke, T., Lund, S., Manyika, J. & Thiel, L. (2020, June 10). *The future of work in Europe*. <https://www.mckinsey.com/featured-insights/future-of-work/the-future-of-work-in-europe>.
- Sobila, V. S. C. (2023). *Data-as-a-Service (DaaS): At a Glance*. [https://Papers.Ssrn.Com/Sol3/Papers.Cfm?Abstract\\_id=4575640](https://Papers.Ssrn.Com/Sol3/Papers.Cfm?Abstract_id=4575640).
- Song, B., Li, K., Orellana-Martín, D., Pérez-Jiménez, M. J. & Pérez-Hurtado, I. (2021). A Survey of Nature-Inspired Computing: Membrane Computing. In *ACM Computing Surveys* (Vol. 54). Association for Computing Machinery. <https://doi.org/10.1145/3431234>
- Soori, M., Dastres, R. & Arezoo, B. (2023). AI-powered blockchain technology in industry 4.0, a review. *Journal of Economy and Technology*, 1, 222–241. <https://doi.org/10.1016/J.JECT.2024.01.001>

- Stearns, P. N. (2021). *The Industrial Revolution in World History* (5th ed.). Routledge. [https://api.pageplace.de/preview/DT0400.9781000227048\\_A40092561/preview-9781000227048\\_A40092561.pdf](https://api.pageplace.de/preview/DT0400.9781000227048_A40092561/preview-9781000227048_A40092561.pdf)
- Tan, L. & Luhrs, M. (2024). Using Generative AI Midjourney to Enhance Divergent and Convergent Thinking in an Architect's Creative Design Process. *The Design Journal*, 27. <https://doi.org/10.1080/14606925.2024.2353479>
- Teece, D. J. (2018). Business models and dynamic capabilities. *Long Range Planning*, 51, 40–49. <https://doi.org/10.1016/j.lrp.2017.06.007>
- Tene, O. & Polonetsky, J. (2015). *A Theory of Creepy: Technology, Privacy, and Shifting Social Norms*. <https://Openyls.Law.Yale.Edu/Handle/20.500.13051/7788>.
- Terrazas, L., Barrios, E. & Brito, E. (2024). Automatización de los procesos contables de emprendimientos formales localizados en el Municipio Monteagudo. *Revista Mundo Financiero*, 5.
- Terven, J. (2025). Deep Reinforcement Learning: A Chronological Overview and Methods. *AI*, 6(3). <https://doi.org/10.3390/ai6030046>
- Thoenig, M. (2024). *Trade in the shadow of war: A quantitative toolkit for geoeconomics* (pp. 325–380). <https://doi.org/10.1016/bs.hoec.2024.10.003>
- Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56. <https://doi.org/10.1038/s41591-018-0300-7>
- Tsarava, K., Moeller, K., Román-González, M., Golle, J., Leifheit, L., Butz, M. & Ninaus, M. (2022). A cognitive definition of computational thinking in primary education. *Computers & Education*, 179, 104425. <https://doi.org/10.1016/j.compedu.2022.104425>

- org/10.1016/j.compedu.2021.104425
- Ugbebor, F. O., Adeteye, D. A. & Ugbebor, J. O. (2024). Predictive analytics models for smes to forecast market trends, customer behavior, and potential business risks. *Journal of Knowledge Learning and Science Technology*, 3, 355–381. <https://doi.org/10.60087/jklst.v3.n3.p355-381>
- UNCTAD. (2021). *Technology and Innovation Report 2021: Catching Technological Waves – Innovation with Equity*. United Nations. <https://unctad.org/page/technology-and-innovation-report-2021>
- UNESCO. (2021a). *Recomendación sobre la ética de la inteligencia artificial preámbulo*. [https://unesdoc.unesco.org/ark:/48223/pf0000380455\\_spa](https://unesdoc.unesco.org/ark:/48223/pf0000380455_spa)
- UNESCO. (2021b). *Reimaginar juntos nuestros futuros: Un nuevo contrato social para la educación*. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000381560>
- UNESCO. (2023, June 20). *Flexible learning pathways: A more relevant future for all*. <https://www.unesco.org/en/articles/flexible-learning-pathways-more-relevant-future-all>.
- Van, M., Parker, G. & Choudary, P. (2016, April). *Pipelines, Platforms, and the New Rules of Strategy*. <https://hbr.org/2016/04/pipelines-platforms-and-the-new-rules-of-strategy>.
- Verbeke, W., Martens, D. & Baesens, B. (2014). Social network analysis for customer churn prediction. *Applied Soft Computing*, 14(PART C), 431–446. <https://doi.org/10.1016/J.ASOC.2013.09.017>
- Vibha M. B. (2024). NLP Chatbot For Order Assistance Using Dialogflow. *Journal of Electrical Systems*, 20, 2580–2594. <https://doi.org/10.52783/jes.5624>
- Vítor, B. (2023). *EDPS TechDispatch on Explainable Artificial*

- Intelligence*. <https://doi.org/10.2804/132319>
- Voigt, P. & von dem Bussche, A. (2017). *The EU General Data Protection Regulation (GDPR)*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-57959-7>
- Voigt, P. & von dem Bussche, A. (2024). *The EU General Data Protection Regulation (GDPR)*. Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-62328-8>
- Vuković, D. B., Dekpo-Adza, S. & Matović, S. (2025). AI integration in financial services: a systematic review of trends and regulatory challenges. In *Humanities and Social Sciences Communications* (Vol. 12). Springer Nature. <https://doi.org/10.1057/s41599-025-04850-8>
- Wachter, S., Mittelstadt, B. & Russell, C. (2021). Why fairness cannot be automated: Bridging the gap between EU non-discrimination law and AI. *Computer Law and Security Review*, 41. <https://doi.org/10.1016/j.clsr.2021.105567>
- Waller, M. A. & Fawcett, S. E. (2013). Data science, predictive analytics, and big data: A revolution that will transform supply chain design and management. *Journal of Business Logistics*, 34, 77–84. <https://doi.org/10.1111/jbl.12010>
- Wang, J., Zhang, Z., Feng, L., Lin, K. Y. & Liu, P. (2023). Development of technology opportunity analysis based on technology landscape by extending technology elements with BERT and TRIZ. *Technological Forecasting and Social Change*, 191. <https://doi.org/10.1016/j.techfore.2023.122481>
- Wang, W., Chen, Y., Zhang, T., Deveci, M. & Kadry, S. (2024). The use of AI to uncover the supply chain dynamics of the primary sector: Building resilience in the

- food supply chain. *Structural Change and Economic Dynamics*, 70, 544–566. <https://doi.org/10.1016/j.strueco.2024.05.010>
- Wilson, J. & Daugherty, P. (2022, April 26). *Radically Human: How New Technology is Transforming Business and Shaping our Future*. <https://hbr.org/webinar/2022/03/radically-human-how-new-technology-is-transforming-business-and-shaping-our-future>.
- Wolfert, S., Ge, L., Verdouw, C. & Bogaardt, M. J. (2017). Big Data in Smart Farming – A review. In *Agricultural Systems* (Vol. 153, pp. 69–80). Elsevier Ltd. <https://doi.org/10.1016/j.agsy.2017.01.023>
- Won, J., Lee, D. & Lee, J. (2023). Understanding experiences of food-delivery-platform workers under algorithmic management using topic modeling. *Technological Forecasting and Social Change*, 190. <https://doi.org/10.1016/j.techfore.2023.122369>
- Wordofprint. (2021). *When to use RPA and AI? RPA and Artificial Intelligence use cases in HR*. <https://www.wordofprint.com/2020/06/when-to-use-rpa-and-ai-rpa-and.html>.
- World Economic Forum. (2023). *The Future of Jobs Report 2023*. <https://www.weforum.org/publications/the-future-of-jobs-report-2023/>.
- Xia, Y., Liu, S., Yu, Q., Deng, L., Zhang, Y., Su, H. & Zheng, K. (2024). Parameterized Decision-Making with Multi-Modality Perception for Autonomous Driving. *Proceedings - International Conference on Data Engineering*, 4463–4476. <https://doi.org/10.1109/ICDE60146.2024.00340>
- Yang, L., Tan, B., Zheng, V., Chen, K. & Yang, Q. (2020). *Federated Recommendation Systems* (pp. 225–239). [https://doi.org/10.1007/978-1-4939-9832-7\\_10](https://doi.org/10.1007/978-1-4939-9832-7_10)

- org/10.1007/978-3-030-63076-8\_16
- Ye, C., Ye, Q., Shi, X. & Sun, Y. (2020). Technology gap, global value chain and carbon intensity: Evidence from global manufacturing industries. *Energy Policy*, 137. <https://doi.org/10.1016/j.enpol.2019.111094>
- Ylldiz, I., Dy, J., Erdoğan, D., Ostmo, S., Campbell, J. P., Chiang, M. F. & Ioannidis, S. (2022). Spectral Ranking Regression. *ACM Transactions on Knowledge Discovery from Data*, 16(6). <https://doi.org/10.1145/3530693>
- Zell, H. (2025, April 26). *Is RPA Dead? The Rise of AI in Business Process Automation*. <https://linfordco.com/blog/is-rpa-dead/>.
- Zhang, Z. (2020). Predictive analytics in the era of big data: opportunities and challenges. *Annals of Translational Medicine*, 8, 68. <https://doi.org/10.21037/atm.2019.10.97>
- Zhao, Z. (2024). The Interaction of Consumer Behavior and Artificial Intelligence Technologies: New Trends in Marketing. *Frontiers in Business, Economics and Management*, 15, 264–269. <https://doi.org/10.54097/w4wrk941>
- Zhu, Y., Li, H., Liao, Y., Wang, B., Guan, Z., Liu, H. & Cai, D. (2017). *What to Do Next: Modeling User Behaviors by Time-LSTM*.
- Zuboff, S. (2019a). *La era del capitalismo de vigilancia: La lucha por un futuro humano en la nueva frontera del poder*. PublicAffairs. <https://www.hbs.edu/faculty/Pages/item.aspx?num=56791>
- Zuboff, S. (2019b). *The Age of Surveillance Capitalism: The Fight for a Human Future at the New Frontier of Power*. PublicAffairs. <https://www.hbs.edu/faculty/Pages/item.aspx?num=56791>

## AUTORES

### **HUMPHREY XAVIER RUBIO TOBAR**



Es un profesional ecuatoriano en formación doctoral en la Universidad de Investigación e Innovación de México (UIIX), enfocado en el análisis educativo, la inteligencia artificial aplicada y la mejora de la permanencia estudiantil en carreras técnicas y universitarias. Su trabajo investigativo se orienta al estudio de variables socioeconómicas, psicosociales y académicas que inciden en la deserción, incorporando modelos de predicción mediante aprendizaje automático.

Cuenta con experiencia en asesoría académica y técnica para instituciones educativas, especialmente en el diseño de estrategias de retención, mejora continua y uso de tecnologías emergentes en entornos formativos. Ha participado en el desarrollo de proyectos vinculados a la innovación educativa y el emprendimiento digital, orientados a la creación de soluciones escalables que optimicen los procesos de enseñanza-aprendizaje.

Su perfil combina una sólida base investigativa con la capacidad de estructurar propuestas aplicadas, integrando herramientas digitales, metodologías activas y modelos de evaluación. Destaca por su capacidad analítica, su orientación a resultados y su compromiso con la calidad académica y la transformación institucional desde una perspectiva técnica y sustentada.

Orcid: <https://orcid.org/0009-0004-6660-6491>

Correo: [hruibot@comunidad.uiix.edu.mx](mailto:hruibot@comunidad.uiix.edu.mx)

### **LINDSAY KATHERINE RANGEL ANCHUNDIA**



(Caracas, 1984) es Ingeniera Industrial, máster en Investigación de Mercados por la Universidad Internacional de La Rioja (UNIR) y posee una especialidad en Neuromarketing por la misma institución. Actualmente, está cursando un Doctorado en Integración Económica en la Universidad del País Vasco.

Como docente en la Universidad Laica Eloy Alfaro de Manabí, lidera el proyecto de pre-incubadoras de empresas, enfocado en promover la cultura emprendedora entre los estudiantes de ingeniería. Su trayectoria académica incluye la dirección de numerosos proyectos de investigación y la tutoría de tesis en áreas clave como la ingeniería industrial y la gestión empresarial.

Rangel es autora de varios libros disponibles en Amazon, tales como *Análisis de Datos Cuantitativos con SPSS y Motivación y Rendimiento*

Laboral en Empresas. Sus obras están dirigidas a estudiantes y profesionales interesados en mejorar sus habilidades en análisis de datos y gestión empresarial.

Reconocida por su habilidad para fusionar teoría y práctica, Lindsay ha contribuido significativamente al diseño y rediseño de carreras académicas y es miembro activo de comisiones de innovación y emprendimiento. Su enfoque en la aplicación de metodologías modernas en la enseñanza subraya su compromiso con la mejora continua de la educación superior.

Orcid: <https://orcid.org/0000-0001-5007-5324>

Correo: [lindsay.rangel@uleam.edu.ec](mailto:lindsay.rangel@uleam.edu.ec)

### **CARMEN KATERINE ZAMBRANO VÉLEZ**



Periodista profesional con formación de tercer y cuarto nivel en Ciencias de la Comunicación, con mención en Periodismo. Cuenta con una amplia trayectoria en medios de comunicación nacionales y regionales, así como una sólida experiencia como docente universitaria e investigadora en el ámbito de la comunicación social, digital y académica.

Actualmente se desempeña como docente titular y coordinadora de la carrera de Comunicación en la Universidad San Gregorio de Portoviejo (USGP), donde también ha ejercido cargos de liderazgo académico en las áreas de Maestría en Comunicación Digital, Artes Escénicas y Seguridad Ciudadana. Su experiencia en gestión curricular, dirección de programas y formación de posgrado la posiciona como una figura clave en el fortalecimiento institucional y la innovación pedagógica.

Su línea de trabajo se complementa con la dirección y coautoría de proyectos de investigación centrados en el impacto de los medios en la percepción ciudadana, la memoria histórica y la identidad cultural, con publicaciones presentadas en congresos nacionales e internacionales. Su capacidad de generar contenido en múltiples formatos se ha expresado también a través de su rol como presentadora y productora de programas informativos en radio, prensa y televisión.

Reconocida por instituciones académicas y gremiales, ha recibido múltiples distinciones por su aporte al periodismo, la docencia y la organización de eventos académicos. Su perfil integra habilidades en producción audiovisual, redacción científica, coordinación académica y comunicación estratégica, consolidándose como una referente en el ámbito de la educación superior y la comunicación pública.

Correo: [katerinezambrano@hotmail.com](mailto:katerinezambrano@hotmail.com)

### **SANTOS ALCIBIADES ÁLAVA MACÍAS**

Profesional ecuatoriano con formación en Química y Farmacia, y Maestría en Gestión Ambiental. Actualmente se desempeña como docente a



tiempo completo en la Facultad de Ingeniería Industrial de la Universidad Laica Eloy Alfaro de Manabí (ULEAM), donde imparte asignaturas en el área de química aplicada y lidera procesos formativos orientados a la integración de la ciencia con soluciones prácticas para el entorno.

Su labor docente se caracteriza por el uso de metodologías activas que articulan la teoría con experiencias experimentales, especialmente en asignaturas como Química Analítica, impulsando el desarrollo de competencias técnicas y científicas en estudiantes de nivel superior. Ha participado en investigaciones sobre la calidad del agua, aportando al diseño de propuestas para el monitoreo y mejora del sistema de tratamiento y distribución en entornos universitarios.

Complementa su trayectoria académica con actividades de asesoría y apoyo a iniciativas de emprendimiento tecnológico con enfoque ambiental, especialmente en proyectos estudiantiles orientados a la creación de soluciones innovadoras en análisis de contaminantes, manejo de residuos y producción sostenible. Su enfoque combina la rigurosidad científica con la proyección de impacto local, promoviendo la generación de emprendimientos basados en la ciencia y la transferencia de conocimiento.

Comprometido con la mejora continua, su perfil refleja una intersección entre la docencia, la investigación aplicada y el fomento de la cultura emprendedora desde la ciencia, como eje para el desarrollo sostenible regional.

Orcid: <https://orcid.org/0009-0000-1423-2329>

Correo: [santos.alava@uleam.edu.ec](mailto:santos.alava@uleam.edu.ec)



### **ROBERTO JONATHAN PICO MACÍAS**

(Ecuador, 1982) es magíster en Educación Matemática Universitaria por la Universidad de Holguín en Cuba y especialista en Diseño Curricular por Competencias por la Universidad del Mar en Chile. Es Ingeniero Industrial egresado de la Universidad Laica Eloy Alfaro de Manabí (ULEAM), donde actualmente se desempeña como docente en la Carrera de Ingeniería Industrial, perteneciente a la Facultad de Ingeniería Industrial y Arquitectura.

A lo largo de su trayectoria académica, ha sido autor de varios artículos científicos y ponente en congresos tanto nacionales como internacionales. Es responsable de Titulación de la carrera de Ingeniería Industrial en ULEAM y ha participado en importantes proyectos de vinculación, como la implementación de una vaca mecánica para la producción de leche de soya en la comunidad San José en 2016, y el mejoramiento de la calidad de agua potable en puntos estratégicos de la universidad en 2018.

En 2022, participó como colíder en el proyecto de la pre-incubadora

de empresas, enfocado en fomentar la cultura emprendedora entre los estudiantes de la Facultad de Ingeniería Industrial.

Orcid: <https://orcid.org/0000-0001-9580-8368>

Correo: [roberto.pico@uleam.edu.ec](mailto:roberto.pico@uleam.edu.ec)

### **HÉCTOR JUNIOR ESPINOZA ALCÍVAR**



Ingeniero Industrial y Licenciado en Mecánica Naval por la Universidad Laica Eloy Alfaro de Manabí (ULEAM), con estudios de posgrado como Magíster en Estadística con mención en Gestión de la Calidad y Productividad por la Escuela Superior Politécnica del Litoral y Magíster en Gestión de la Cadena de Suministro por la Universidad Tecnológica ECOTEC. Con experiencia en

docencia universitaria, ha impartido asignaturas en áreas como estadística, métodos numéricos y bioquímica de los alimentos en la ULEAM. Su trayectoria profesional incluye roles como auditor de gestión, coordinador de operaciones y supervisor de flotas en reconocidas empresas del sector industrial y logístico. Ha participado como ponente en eventos académicos y congresos internacionales, destacándose por su investigación en la optimización de operaciones y gestión logística. Además, cuenta con formación en herramientas estadísticas avanzadas como R y SPSS, y ha desarrollado competencias en el uso de inteligencia artificial aplicada a la educación

Correo: [hector.espinoza@uleam.edu.ec](mailto:hector.espinoza@uleam.edu.ec)

### **PABLO HORACIO HIDROVO ALCÍVAR**



Ingeniero Industrial con mención en Seguridad Industrial y Ambiental, y Máster en Gestión Ambiental, ambos títulos obtenidos en la Universidad Laica Eloy Alfaro de Manabí (ULEAM). Con una destacada trayectoria profesional en gestión ambiental y seguridad industrial, ha liderado proyectos clave en organizaciones como Autoridad Portuaria de Manta y Consulsismica,

desempeñándose como Coordinador General de Proyectos. Sus áreas de especialización incluyen la elaboración e implementación de sistemas de gestión ambiental, manejo de residuos industriales y peligrosos, y coordinación de monitoreos ambientales. Su experiencia abarca proyectos de gran relevancia, como estudios para la Refinería del Pacífico "Eloy Alfaro" y la regeneración urbana en Manta, demostrando habilidades en administración de cronogramas, gestión estratégica y manejo de indicadores de desempeño. Además, ha participado en seminarios internacionales y nacionales en temas de seguridad industrial, liderazgo, inteligencia emocional, y normativas ISO, consolidando su perfil técnico y gerencial. Reconocido por su compromiso con la calidad y el cumplimiento de estándares

ambientales, Pablo Hidrovo combina su sólida formación académica con una experiencia profesional integral, aportando valor en proyectos estratégicos de infraestructura y sostenibilidad.

Correo: [pablo.hidrovo@uleam.edu.ec](mailto:pablo.hidrovo@uleam.edu.ec)

Orcid: <https://orcid.org/0009-0002-9812-9736>

### **ÁNGEL FABIÁN MOREIRA ROMERO**



Ingeniero Industrial con una destacada formación académica y experiencia profesional. Posee dos maestrías: una en Transportación de Petróleo y Derivados por la Escuela Politécnica Nacional y otra en Procesos Industriales por la Universidad Central del Ecuador. Además, es docente a tiempo completo en la Facultad de Ingeniería Industrial de la Universidad Laica Eloy Alfaro de Manabí (ULEAM), donde imparte cátedras en áreas como Termodinámica, Mecánica de Fluidos y Transferencia de Calor. 284 Calidad y competitividad: cómo crear productos que destaquen en el mercado. A lo largo de su carrera, ha combinado su experiencia en el sector industrial con una trayectoria docente de más de una década. Entre sus logros profesionales, ha ocupado cargos como Gerente General en la Empresa Pública Aguas de Manta (EPAM) y ha sido ingeniero industrial en proyectos de gran envergadura, como el de la Refinería del Pacífico con Odebrecht. También ha trabajado como asesor en seguridad industrial y supervisor laboratorista en Petrocomercial. Su formación complementaria incluye numerosos cursos y seminarios en temas de seguridad laboral, prevención de riesgos, calidad industrial y metodologías de investigación. Ha participado en congresos internacionales y ha publicado varios artículos científicos indexados sobre temas relacionados con la ingeniería industrial y la gestión de riesgos. Ha dirigido múltiples proyectos de investigación y tesis de grado en áreas como la optimización de procesos industriales, el diseño y construcción de máquinas, y la implementación de sistemas de gestión de seguridad y salud ocupacional. Además, es un activo colaborador en el ámbito académico, desempeñándose como docente investigador y asesor de proyectos para mejorar procesos productivos en diversas industrias.

Correo: [angel.moreirar@uleam.edu.ec](mailto:angel.moreirar@uleam.edu.ec)

Orcid: <https://orcid.org/0000-0002-2416-0127>

### **WAGNER OSWALDO VILLAFUERTE MUÑOZ**



Docente e Investigador de la Universidad Laica Eloy Alfaro de Manabí (ULEAM), con más de diez años de experiencia en Educación Superior. Es Licenciado en Educación con mención en Inglés, cuenta con una Maestría en Enseñanza del Idioma Inglés por la UNESUM y un Diplomado en Gestión Directiva por la ESPE. Actualmente

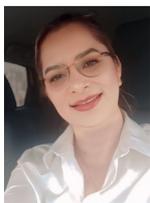
curso estudios doctorales en Proyectos y Gestión del Riesgo en México, fortaleciendo su perfil académico con una visión estratégica y orientada a la sostenibilidad institucional.

Ha combinado su formación militar como Oficial de Estado Mayor; curso de ascenso de Coronel. Fue Rector de la Unidad Educativa No4 de Manta, tres años, nombramiento otorgado por el Ministerio de Educación. Formación en instituciones internacionales como la Universidad Estatal de Kansas (Advanced Profile – C2), graduado de Honor Tyndall Air Force Base en los Estados Unidos.

Ha ocupado cargos estratégicos como Director de navegación Aérea en la SUBDAC, Coordinador General de Seguridad de la ULEAM y ha sido autor de más de 14 artículos científicos, ponente en congresos internacionales y coautor de libros especializados en gestión del riesgo, educación y comunicación.

Ha recibido múltiples condecoraciones, Encomios Simples, Encomios Solemnes y por el Comando Conjunto “Caballero en el grado de Comendador”, por su participación en el Conflicto del Alto Cenepa en 1995 y por la ONU, por acciones en dos Misiones en el África.

Correo: [wagner.villafuerte@uleam.edu.ec](mailto:wagner.villafuerte@uleam.edu.ec)



### **MARIUXI ELIZABETH ZAMBRANO CHAVARRÍA**

Ha desarrollado una destacada trayectoria en el Ministerio de Relaciones Exteriores y Movilidad Humana desde el año 2012. En su experiencia incluye roles como, Atención Prioritaria de Personas en Movilidad Humana, desde donde apoya a ecuatorianos en el exterior, con procesos para repatriación de cadáveres, retornos asistidos de ecuatorianos en situación de vulnerabilidad en el Exterior; Atención a migrantes retornados, Atención a personas de otras nacionalidades en situación de vulnerabilidad que residan en la Zona 4. Además, ha trabajado en otras áreas como, Secretaria de la Dirección Zonal 4 durante cuatro años, Encargada de la Unidad de Pasaportes en los años 2016 y 2017; Encargada de la Unidad Legalización y Apostilla de documentos que saldrán del país y Certificaciones de Poder Consulares.

Cuenta con una maestría en Dirección y Administración de Empresas por la Universidad Internacional de La Rioja y un título en Ingeniería de Marketing por la Universidad Laica Eloy Alfaro de Manabí. Ha complementado su formación con diversos cursos y seminarios, enfocados en liderazgo, servicios ciudadanos y movilidad humana, lo que le ha permitido fortalecer sus habilidades en diferentes ámbitos empresariales privados y públicos.

Profesional con espíritu orientado al emprendimiento y de servicio, con creatividad para ver las oportunidades y ofrecer soluciones diferentes a necesidades existentes, asumiendo los riesgos que pudieran presentarse.

Continúa con su emprendimiento “Tintorería Manta”, desde donde brinda un importante servicio a los ciudadanos mantenses.

Orcid: <https://orcid.org/0000-0002-0381-4953>

Correo: [marielizazambrano@hotmail.com](mailto:marielizazambrano@hotmail.com)

La inteligencia artificial es un eje funcional en la transformación de los sistemas económicos, organizativos y productivos actuales. Su integración en procesos de análisis, automatización y toma de decisiones permite redefinir funciones operativas, estructuras de costos y modelos de escalabilidad. Esta tecnología no opera como herramienta aislada, sino como una arquitectura técnica que reorganiza flujos de valor y condiciones de competencia en entornos dinámicos. *Emprender en la era de la inteligencia artificial: oportunidades y retos*, examina cómo la inteligencia artificial modifica los entornos técnicos y operativos necesarios para la estructuración y desarrollo de proyectos emprendedores. El enfoque está dirigido a identificar mecanismos mediante los cuales estas iniciativas pueden organizar procesos, validar propuestas de valor y operar con eficiencia en escenarios condicionados por automatización, procesamiento de datos y escalabilidad computacional. El alcance del análisis se orienta de forma precisa a las aplicaciones funcionales de la inteligencia artificial en la lógica operativa del emprendimiento digital.



ISBN: 978-9942-631-38-1



9789942631381