

Escuela de Negocios

Tipo de documento: Tesis de maestría



EMBA | Executive MBA

El impacto de la inteligencia artificial en las PYMES

Autoría: Campolonghi, Marco

Año: 2025

¿Cómo citar este trabajo?

Campolonghi, M. (2025) "El impacto de la inteligencia artificial en las PYMES". [Tesis de maestría. Universidad Torcuato Di Tella].

Repositorio Digital Universidad Torcuato Di Tella.

<https://repositorio.utdt.edu/handle/20.500.13098/13832>

El presente documento se encuentra alojado en el **Repositorio Digital de la Universidad Torcuato Di Tella** bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Internacional
Dirección: <https://repositorio.utdt.edu>



UNIVERSIDAD
TORCUATO DI TELLA

TESIS
MAESTRÍA EN DIRECCIÓN DE EMPRESAS

**"EL IMPACTO DE LA
INTELIGENCIA ARTIFICIAL EN LAS
PYMES"**

EMBA 2007

Alumno: MARCO CAMPOLONGHI

Tutor: Debbie Gutman

Abril 2025

DEDICATORIAS y AGRADECIMIENTOS

Me quiero tomar la licencia de contar por qué decidí escribir esta tesis después de tantos años de haber cursado el EMBA, allá por 2007. No fue una decisión académica, ni una meta pendiente en mi carrera. Fue, más bien, una necesidad profunda que fue madurando con el tiempo. A lo largo de los años, en mi rol como director y gerente general de distintas empresas, viví en carne propia lo difícil que es encontrar espacio para detenerse, pensar y reflexionar con profundidad. El vértigo del día a día, las urgencias operativas, las decisiones que no esperan... todo empuja a seguir avanzando, muchas veces sin tiempo real para cuestionar, imaginar o rediseñar.

Vivimos en un país donde el cambio es constante, los ciclos son cortos y la incertidumbre es parte del paisaje. Eso nos vuelve ágiles, creativos, resilientes... pero también nos vuelve reactivos. Y en ese movimiento permanente, es fácil perder de vista lo importante. Por eso escribí esta tesis: para ayudar a detenernos. Para aportar una mirada que invite a pensar con más calma, a conectar lo cotidiano con lo estratégico, y a inspirar decisiones con sentido, aún en medio del ruido. Porque creo, de verdad, que reflexionar también es una forma de actuar.

A mis compañeros y amigos del EMBA, y en particular al GG6, que después de tantos años siguen siendo fuente de inspiración.

A Dani, mi compañera de ruta, que me hace mejor persona cada día.

A Cande, mi cachorra, que me enseñó a ser papá.

A Tizi y Bruno, mi princesa y mi campeón, mi volver a empezar.

Y a vos, viejo, y a vos, vieja, que los extraño y los amo. Todo lo que hago, en algún punto, siempre vuelve a ustedes.

RESUMEN EJECUTIVO

¿Qué lugar pueden ocupar las pequeñas y medianas empresas en un mundo transformado por la inteligencia artificial? ¿Cómo tomar decisiones estratégicas cuando los recursos son escasos, el tiempo es limitado y la urgencia domina la agenda? ¿Qué se necesita para pasar de la inquietud a la acción, y construir una estrategia tecnológica propia, realista y sostenible?

Esta tesis nace con un propósito claro: inspirar, motivar y generar reflexión sobre el impacto de la inteligencia artificial en las pymes, y ofrecer herramientas concretas para acompañar ese proceso. Más que describir un fenómeno, busca habilitar conversaciones, ordenar prioridades y dar soporte a quienes enfrentan hoy decisiones complejas en un escenario de transformación profunda.

La inteligencia artificial ha dejado de ser una promesa futura. Hoy se consolida como el motor que impulsa una transformación real en la vida diaria, el trabajo y los negocios. Su impacto alcanza de lleno a las pequeñas y medianas empresas, que enfrentan el desafío de adaptarse a un entorno de innovación acelerada mientras buscan sostener su operación actual. Hoy la verdadera decisión no es si adoptamos inteligencia artificial, sino cómo la integramos de forma estratégica para asegurar nuestro lugar en un mercado en constante transformación.

Desde hace décadas, las tecnologías disruptivas han reconfigurado industrias, cambiado reglas de juego y obligado a repensar modelos de negocio. Internet, el comercio electrónico, los teléfonos móviles o las redes sociales no solo transformaron procesos, sino que modificaron la forma en que nos comunicamos, compramos, producimos y tomamos decisiones. La inteligencia artificial expande ese desafío, interviniendo no sólo en cómo nos vinculamos, sino también en cómo analizamos la realidad y tomamos decisiones. Ponemos en manos de sistemas automatizados funciones que hasta hace muy poco dependían exclusivamente de las personas.

En este escenario, las empresas transitan el proceso de transformación digital con avances desiguales y ritmos condicionados por su realidad operativa. Las decisiones urgentes, la necesidad de sostener el funcionamiento cotidiano, los contextos cambiantes y los recursos que casi nunca alcanzan condicionan cualquier posibilidad de innovación o planificación a largo plazo. Frente a este contexto, la inteligencia artificial aparece como una oportunidad concreta, pero también como un nuevo punto de tensión entre lo que sabemos que debemos hacer y lo que efectivamente logramos implementar. Frente a este contexto, la inteligencia artificial plantea posibilidades concretas, pero su adopción sigue siendo un desafío abierto.

Durante años, las grandes corporaciones han funcionado como laboratorios de prueba para la adopción de nuevas tecnologías. Con mayores recursos financieros y humanos, fueron pioneras en la incorporación de la inteligencia artificial para automatizar, optimizar y escalar sus operaciones. Hoy, esas soluciones ya no se limitan al mundo

corporativo, sino que se expanden, maduran y comienzan a derramar hacia estructuras más pequeñas, volviéndose cada vez más accesibles. Miles de empresas en todo el mundo utilizan IA en procesos reales: gestión de inventarios, atención al cliente, mantenimiento predictivo, control de calidad, análisis financiero, marketing personalizado y detección de fraudes. Lejos de ser una promesa de futuro, la inteligencia artificial ya opera como un recurso activo para mejorar eficiencia, reducir errores, anticipar comportamientos y acelerar decisiones.

En ese escenario, enfrentar una tecnología tan potente y diversa como la inteligencia artificial puede resultar abrumador. Hay demasiadas aplicaciones posibles, poco tiempo para explorarlas y escasos recursos para decidir con claridad. Para acompañar ese desafío, esta tesis propone una herramienta práctica y flexible: el Mapa de Oportunidades. Se trata de una guía que ayuda a identificar aplicaciones concretas de IA para la empresa, evaluarlas según atributos predefinidos y proyectar caminos de adopción alineados con la realidad y las capacidades de cada organización.

Esa tensión entre posibilidades tecnológicas y realidades operativas se refleja con claridad en el estudio de campo realizado con empresarios y directivos pymes de distintos sectores. Sus respuestas muestran interés creciente, disposición a explorar nuevas herramientas y, al mismo tiempo, barreras muy concretas vinculadas al desconocimiento, la falta de tiempo, los costos y la ausencia de referentes cercanos. Lejos de desalentar, estos hallazgos confirman que el desafío no está en la tecnología, sino en cómo acompañar mejor a quienes deben tomar decisiones.

La inteligencia artificial ya no es una frontera lejana. Está entre nosotros, disponible, y empieza a marcar diferencias reales. Para las pymes, el desafío no es seguir esperando, sino empezar a construir una estrategia propia, paso a paso, con criterio y con visión. El momento de hacerlo es ahora.

PALABRAS CLAVES

Inteligencia Artificial, Transformación Digital, Pymes, Machine Learning, IA Generativa, Innovación, Tecnología, Estrategia, Aplicaciones.

INTRODUCCIÓN

La inteligencia artificial se ha consolidado como una de las tecnologías más relevantes y transformadoras del siglo XXI. Su avance ya no se limita a los entornos académicos o experimentales sino que atraviesa sectores productivos, redefine procesos de negocio y plantea nuevos modelos de organización y decisión.

En el caso de las pymes, la adopción de tecnologías emergentes como la inteligencia artificial presenta oportunidades significativas, pero también barreras concretas: falta de conocimiento especializado, limitaciones presupuestarias, tiempos de gestión acotados y una tendencia generalizada a postergar lo estratégico frente a lo urgente. Esta tesis se sitúa en ese punto crítico, donde la posibilidad de innovar convive con la dificultad de decidir cómo y por dónde avanzar.

El objetivo de este trabajo es analizar el impacto de la inteligencia artificial en las pequeñas y medianas empresas, explorar sus aplicaciones más relevantes y aportar una herramienta práctica que facilite la reflexión, la priorización y la adopción estratégica de soluciones tecnológicas en función de la realidad de cada organización.

La tesis se estructura en cinco capítulos. El primer capítulo presenta el marco conceptual de la inteligencia artificial y la ubica dentro del recorrido histórico de las tecnologías disruptivas, repasando su evolución y los principales hitos que transformaron los modelos de negocio a lo largo del tiempo. Luego aborda los fundamentos más relevantes de esta tecnología, desde los distintos enfoques del aprendizaje automático, las redes neuronales, el auge del deep learning, los grandes modelos de lenguaje y las tendencias que anticipan la próxima etapa en su evolución.

El segundo capítulo introduce un análisis del panorama actual de las pymes en Argentina. Se abordan sus características estructurales, la dinámica demográfica, su evolución reciente y el contexto económico y productivo en el que operan, con el objetivo de entender mejor sus capacidades, sus condicionantes y su rol dentro del entramado empresarial del país. Luego focaliza en la relación entre las pymes y la transformación digital. Se exploran su grado de madurez tecnológica, las principales barreras que dificultan el proceso de digitalización, así como las oportunidades que pueden surgir cuando la innovación se articula con visión estratégica. También se analizan los factores que marcan la diferencia entre quienes logran avanzar y quienes quedan rezagados, tanto en Argentina como en comparación con la región.

El tercer capítulo trata sobre las aplicaciones actuales de la inteligencia artificial en distintos sectores empresariales, desde marketing y ventas, supply chain, producción y finanzas, hasta áreas como salud, legal o atención al cliente. Se exploran tanto tecnologías tradicionales como IA generativa, y se identifican riesgos, limitaciones y buenas prácticas para una implementación responsable.

A partir de ese análisis, el cuarto capítulo introduce el Mapa de Oportunidades, una herramienta práctica y flexible que permite a las pymes organizar, evaluar y priorizar posibles aplicaciones de IA según cinco atributos clave, proyectando recorridos viables de adopción tecnológica. El Mapa no solo clasifica, sino que habilita una reflexión estratégica adaptada a cada realidad organizacional.

Finalmente, el capítulo cinco presenta un estudio de campo realizado con empresarios y directivos pymes de distintos sectores, que permite relevar percepciones, niveles de conocimiento, barreras y expectativas frente a la inteligencia artificial. Ese trabajo se convierte en insumo directo para las conclusiones y recomendaciones finales, orientadas a acompañar a las pymes en el diseño de una estrategia tecnológica propia, realista y accionable.

Este trabajo no busca ofrecer respuestas cerradas, sino habilitar nuevas preguntas y facilitar decisiones más informadas, realistas y sostenibles en torno a una tecnología que ya está redefiniendo el presente y el futuro de las organizaciones.

DEDICATORIAS y AGRADECIMIENTOS.....	2
RESUMEN EJECUTIVO	3
PALABRAS CLAVES	4
INTRODUCCIÓN.....	5
CAPÍTULO 1: TECNOLOGÍAS DISRUPTIVAS Y LA INTELIGENCIA ARTIFICIAL	11
1.1 Tecnologías Disruptivas en la Historia Empresarial	12
1.1.1 Hitos Históricos	13
1.1.2 Transformación de Modelos de Negocio	13
1.1.3 Conclusiones.....	16
1.2 La Inteligencia Artificial.....	17
1.2.1 Historia y Evolución de la IA.....	19
1.2.1.1 Primeros Pasos hacia la IA (1943-1956)	19
1.2.1.2 Fase Inicial de Exploración (1956-1974).....	20
1.2.1.3 Primer Invierno de la IA (1974-1980).....	21
1.2.1.4 Renacimiento de la IA & Sistemas Expertos (1980-1987)	22
1.2.1.5 Segundo Invierno de la IA (1987-1993)	23
1.2.1.6 Nuevos Paradigmas de la IA (1993-2006).....	23
1.2.2 Machine Learning y Redes Neuronales	24
1.2.2.1 Modelos de Aprendizaje	25
1.2.2.2 Técnicas Clásicas de Machine Learning.....	27
1.2.2.3 Redes Neuronales	29
1.2.2.4 Aplicaciones y Desafíos de las Redes Neuronales	30
1.2.3 La Revolución del Deep Learning y Transformers	31
1.2.4 Los Grandes Modelos LLM.....	33
1.2.4.1 Google	34
1.2.4.2 Open AI	35
1.2.4.3 META.....	36
1.2.4.4 Anthropic	36
1.2.4.5 BigScience	37
1.2.4.6 Mistral.....	37
1.2.4.7 Otras Iniciativas Relevantes	37
1.2.5 Tendencias Futuras y Evolución de la IA.....	39
1.2.5.1 Tendencias Tecnológicas	40

1.2.5.2 Colaboración, Autonomía y Confianza	41
1.2.5.3 Gobernanza, Riesgos y Regulación.....	42
1.2.5.4 Acceso, Equidad y Sostenibilidad	42
1.2.6 Conclusiones.....	43
CAPÍTULO 2: LAS PYMES EN EL CONTEXTO TECNOLÓGICO ACTUAL.....	45
2.1. Panorama Actual de las Pymes en Argentina.....	45
2.1.1. Definiciones y Clasificación.....	46
2.1.2. Contexto Pyme: 2007-2023.....	47
2.1.3. Dinámica Demográfica	49
2.1.4. Escenario Actual: Año 2023.....	51
2.1.5. Resumen y Perspectivas	52
2.2 La Transformación Digital en las PYMES	53
2.2.1. Panorama actual: barreras y oportunidades.....	54
2.2.1.1 Principales barreras para la digitalización en las PYMES	55
2.2.1.2 Los beneficios de la digitalización en las PYMES	55
2.2.1.3 Oportunidades para el futuro	56
2.2.2. Factores que marcan la diferencia	57
2.2.3. Argentina y la región	60
2.2.4. La Inteligencia Artificial: Un paso al futuro.....	63
CAPÍTULO 3: APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LAS EMPRESAS ..	66
3.1. Primeras Aplicaciones de IA	66
3.1.1 Supply Chain: Gestión Dinámica del Inventario	67
3.1.2 Marketing y Publicidad: Segmentación de Clientes y Optimización de Campañas.....	68
3.1.3 Producción: Mantenimiento Predictivo.....	69
3.1.4 Control de Calidad en las líneas de manufactura y producción.....	70
3.1.5 Finanzas y Banca: Detección de Fraudes	72
3.1.6 Salud y Diagnóstico Médico: Análisis de Imágenes	73
3.2 La Revolución de la IA Generativa.....	75
3.2.1 Atención al Cliente: Chatbots y Automatización de Respuestas.....	76
3.2.2 Legal y Compliance: Análisis de Contratos	78
3.3 Riesgos, Limitaciones y Buenas Prácticas.....	80
3.3.1 Limitaciones Tecnológicas	81
3.3.1.1 Sesgos de información.....	81

3.3.1.2 Falta de transparencia y explicabilidad	82
3.3.1.3 Generalización y Overfitting	83
3.3.2 Desafíos Organizacionales y Regulatorios	83
3.3.2.1 Gobernanza de datos y responsabilidad interna	84
3.3.2.2 Resistencia al cambio	85
3.3.2.3 Privacidad, confidencialidad y protección de datos	85
3.3.2.4 Riesgos legales y regulatorios.....	86
3.3.2.5 Dependencia tecnológica	87
3.3.3 Buenas prácticas para una implementación responsable	88
3.3.3.1 Evaluar la factibilidad antes de implementar IA.....	88
3.3.3.2 Enfoques graduales y controlados.....	89
3.3.3.3 Participación multidisciplinaria	90
3.3.3.4 Monitoreo, revisión y mejora continua.....	90
3.4 Conclusiones.....	91
CAPÍTULO 4: LA INTELIGENCIA ARTIFICIAL EN LAS PYMES	93
4.1 El Desafío de las Pymes frente a la IA	93
4.2 Aplicaciones de IA en las Pymes	96
4.2.1 Marketing, Ventas y Atención al Cliente.....	97
4.2.2 Producción, Calidad y Supply Chain.....	105
4.2.3 Administración y Finanzas	108
4.2.4 Soluciones Transversales con IA Generativa	111
CAPÍTULO 5: MAPA DE OPORTUNIDADES – UNA GUÍA PRÁCTICA	116
5.1 Universo de Aplicaciones	118
5.2 Definición de Atributos	119
5.3 Evaluación de los Atributos	120
5.3.1 Madurez Digital Requerida	123
5.3.2 Dificultad de Implementación.....	124
5.3.3 Costo de Implementación	125
5.3.4 Impacto en el Negocio	126
5.3.5 Tiempo de Retorno de Inversión	127
5.3.6 Ejemplo Ilustrativo de Evaluación de Aplicaciones	128
5.4 Sistema de Puntaje de Atributos.....	128
5.5 Ponderación de Atributos.....	129
5.6 Puntaje Global de cada Aplicación	130

5.7 Cuadro de Evaluación	131
CAPÍTULO 6: APLICACIÓN DEL MAPA EN UN CASO REAL	133
6.1 Presentación del Caso	134
6.2 Aplicación del Mapa de Oportunidades	135
6.3 Conclusiones del Caso	142
6.3.1 Síntesis de Resultados	143
6.3.2 Recomendaciones para la Adopción	144
CAPÍTULO 7: APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LAS EMPRESAS	145
7.1 Introducción y Propósito	145
7.2 Metodología de la Encuesta	146
7.3 Resultados Obtenidos	147
7.3.1 Perfil de los Encuestados	147
7.3.2 Nivel de Digitalización	148
7.3.3 Conocimiento y uso personal de IA	150
7.3.4 Percepciones Empresariales sobre la Inteligencia Artificial	152
7.3.4.1 Procesos de mayor impacto de IA	152
7.3.4.2 Percepción de adopción futura	154
7.3.4.3 Barreras para implementar IA	155
7.3.4.4 Oportunidades futuras con IA	157
7.3.4.5 Disposición a invertir en IA	159
7.3.5 Comentarios adicionales sobre las respuestas abiertas	161
7.4 Conclusiones	161
CONCLUSIONES Y RECOMENDACIONES	163
REFERENCIAS	167
ANEXO I – ENCUESTA	178
ANEXO II – RESULTADOS ENCUESTA	185

CAPÍTULO 1: TECNOLOGÍAS DISRUPTIVAS Y LA INTELIGENCIA ARTIFICIAL

Las tecnologías disruptivas han marcado hitos fundamentales en la historia empresarial, transformando sectores completos y redefiniendo la forma en que las organizaciones operan, se comunican y toman decisiones estratégicas. La adopción de innovaciones tecnológicas ha impulsado la eficiencia, mejorado la competitividad y generado nuevas oportunidades de negocio. Sin embargo, también ha planteado desafíos significativos, especialmente para las pequeñas y medianas empresas (PYMEs), que deben adaptarse rápidamente a un entorno cada vez más dinámico y complejo.

Estas innovaciones han transformado profundamente la sociedad en su conjunto, modificando hábitos de vida, consumo y formas de relacionarnos. Tecnologías como el teléfono móvil y las redes sociales cambiaron radicalmente la manera en que nos comunicamos, interactuamos y gestionamos nuestras actividades cotidianas, haciendo que la conexión permanente y la inmediatez se conviertan en una expectativa constante. Este contexto ha configurado un nuevo paradigma de negocios en las empresas en el que la tecnología no solo soporta procesos empresariales, sino que también redefine la relación entre las organizaciones y sus clientes.

Este capítulo analiza el impacto de las tecnologías disruptivas en el contexto empresarial, con un enfoque particular en la Inteligencia Artificial (IA) como una de las fuerzas más transformadoras de la actualidad. A lo largo del texto, se presentarán los conceptos fundamentales que explican cómo las tecnologías disruptivas han evolucionado y moldeado el mundo de los negocios, desde hitos históricos hasta aplicaciones contemporáneas.

El objetivo es proporcionar una visión integral que permita comprender cómo la IA ha cambiado el paradigma de la gestión empresarial, ofreciendo tanto oportunidades como desafíos. A través de ejemplos concretos, se explorarán los principales avances tecnológicos y su implementación en el ámbito empresarial, destacando los aprendizajes que pueden extraerse tanto de casos de éxito como de fracasos.

Además, el capítulo abordará las tendencias futuras y los posibles caminos de evolución de la IA, destacando cómo diferentes enfoques y modelos impulsan su avance constante. Al finalizar, se presentarán reflexiones sobre los desafíos éticos y regulatorios que las tecnologías emergentes plantean, así como sobre la capacidad de las PYMEs para aprovechar estos recursos en su estrategia de negocios, asegurando su sostenibilidad y competitividad en el entorno actual.

1.1 Tecnologías Disruptivas en la Historia Empresarial

A lo largo de la historia empresarial, la evolución de los mercados ha estado marcada por avances tecnológicos que han generado disrupciones significativas en múltiples sectores. El término "disrupción tecnológica" se popularizó gracias a Clayton Christensen, profesor de la Harvard Business School, reconocido por su teoría de la "innovación disruptiva" desarrollada en su obra *The Innovator's Dilemma* (Christensen, 1997). Según Christensen, las tecnologías disruptivas son aquellas que comienzan como soluciones más simples y económicas, pero que con el tiempo desplazan a tecnologías establecidas, alterando mercados enteros.

En su obra, Christensen introduce métricas para evaluar el impacto de una tecnología disruptiva, incluyendo la capacidad de alcanzar nuevos segmentos de mercado, el cambio en la relación costo-beneficio y la rapidez con que desplaza tecnologías incumbentes. Por ejemplo, explica cómo los discos duros pequeños y baratos superaron eventualmente a los grandes, no porque fueran mejores en un principio, sino porque satisfacían necesidades ignoradas por los líderes del sector. Este concepto ha sido un punto de referencia clave para entender cómo las empresas pueden adaptarse o sucumbir ante los cambios tecnológicos (Christensen, 1997).

A este marco teórico podemos sumar las ideas de Everett Rogers, sociólogo y pionero en el estudio de la difusión de innovaciones. Su libro *Diffusion of Innovations* (Rogers, 2003) introduce el concepto de la "curva de adopción tecnológica", que clasifica a los usuarios en cinco categorías: innovadores, primeros adoptantes, mayoría temprana, mayoría tardía y rezagados. Esta teoría es particularmente útil para las pequeñas y medianas empresas (PYMEs), que suelen encontrarse en la fase de mayoría tardía debido a limitaciones de recursos y aversión al riesgo. Rogers también subraya que la percepción de utilidad relativa, compatibilidad con valores existentes y simplicidad son factores clave para la adopción tecnológica.

Por su parte, Eric Ries, emprendedor y autor de *The Lean Startup* (Ries, 2011), ofrece una perspectiva contemporánea sobre cómo las PYMEs pueden enfrentar la disrupción tecnológica. Ries propone un enfoque ágil basado en la experimentación rápida, el aprendizaje continuo y la optimización de recursos, principios que pueden ayudar a las PYMEs a competir en mercados dominados por grandes corporaciones. Su metodología pone énfasis en crear "productos mínimos viables" (MVPs) para validar ideas con clientes reales, permitiendo ajustes rápidos antes de invertir grandes recursos.

En conjunto, los aportes de Christensen, Rogers y Ries ofrecen perspectivas complementarias para comprender cómo las tecnologías disruptivas pueden transformar mercados, impulsando tanto oportunidades como riesgos para las empresas que buscan mantenerse competitivas (Christensen, 1997; Rogers, 2003; Ries, 2011).

1.1.1 Hitos Históricos

A lo largo de las últimas décadas, la evolución tecnológica ha transformado radicalmente el mundo empresarial, dando lugar a innovaciones que rompieron esquemas tradicionales y redefinieron sectores completos. Cada avance ha marcado un punto de inflexión, impulsando nuevas formas de operar, comunicarse y competir en el mercado. Algunas tecnologías han tenido un impacto tan profundo que se convirtieron en referencias ineludibles para entender la transformación de los negocios en la era moderna (Castells, 2001; McGrath, 2013).

- ✓ Internet (1990-2000): Conectó personas y empresas globalmente, redefiniendo la comunicación y el comercio.
- ✓ Teléfono móvil (1990-2005): Movilizó la comunicación, impulsando nuevos modelos de negocio y conectividad.
- ✓ Comercio electrónico (1995-2010): Permitió transacciones en línea, liderado por empresas como Amazon.
- ✓ Energías renovables (2000-2015): Cambió paradigmas energéticos, con tecnologías como paneles solares accesibles.
- ✓ Redes sociales (2004-2015): Transformaron la comunicación y el marketing empresarial.
- ✓ Inteligencia artificial (2000 en adelante): Automatizó procesos y personalizó servicios a gran escala.
- ✓ Impresión 3D (2010 en adelante): Democratizó la fabricación personalizada, revolucionando sectores como el diseño y la salud.
- ✓ Blockchain (2008 en adelante): Introdujo confianza descentralizada, con aplicaciones en finanzas y logística.
- ✓ Vehículos eléctricos (2010 en adelante): Impulsados por Tesla, redefinieron la movilidad sostenible.

El impacto acumulado de estas tecnologías ha transformado el ecosistema empresarial, impulsando innovaciones en la forma de producir, comercializar y consumir bienes y servicios. Las empresas que lograron adaptarse a tiempo consolidaron posiciones de liderazgo, mientras que aquellas que subestimaron su potencial disruptivo enfrentaron enormes dificultades para mantenerse relevantes. En este contexto, resulta fundamental comprender cómo cada tecnología aportó a la transformación del mundo de los negocios (Russell & Norvig, 2021; Tapscott & Tapscott, 2016).

1.1.2 Transformación de Modelos de Negocio

La disrupción tecnológica no solo introduce nuevas herramientas, sino que transforma profundamente los modelos de negocio, creando oportunidades únicas para quienes

logran anticipar su impacto y capturar el valor que estas innovaciones pueden generar. A lo largo de la historia reciente, empresas como Netflix, Airbnb y Uber no solo lograron posicionarse como líderes en sus respectivos sectores, sino que directamente redefinieron las reglas del juego en industrias que antes parecían inamovibles. Estas organizaciones demostraron que quienes tienen la visión estratégica de aprovechar el potencial disruptivo pueden emerger como referentes de éxito, alcanzando ventajas competitivas que parecían impensables en otro contexto (Christensen, Raynor, & McDonald, 2015).

Sin embargo, no todas las empresas han logrado capitalizar el potencial de la disrupción tecnológica. Mientras algunas organizaciones han sabido reinventarse y mantenerse a la vanguardia, otras, al subestimar los cambios o no gestionarlos adecuadamente, se han encontrado rápidamente fuera del mercado. Esta dualidad resalta la necesidad de una planificación estratégica que permita integrar la innovación en el núcleo del negocio.

El recorrido histórico nos muestra que aquellas empresas que anticiparon el posible impacto de la disrupción tecnológica lograron consolidarse como líderes en sus sectores, mientras que otras, al no reconocer a tiempo el alcance de las transformaciones, se vieron superadas por nuevos modelos de negocio más ágiles y modernos. A continuación, analizaremos algunos casos emblemáticos que ilustran tanto los éxitos logrados mediante la adopción tecnológica como las lecciones aprendidas de quienes no supieron adaptarse a tiempo.

Casos emblemáticos de disrupciones exitosas

A lo largo de los últimos años, múltiples empresas han logrado aprovechar la disrupción tecnológica para transformar industrias completas y redefinir modelos de negocio tradicionales. Los casos más emblemáticos no solo muestran la capacidad de adaptación, sino también el poder de la innovación estratégica para generar ventajas competitivas sostenibles. A continuación, revisaremos algunos ejemplos destacados que ilustran cómo la visión tecnológica puede convertirse en el motor del éxito empresarial.

Por ejemplo, Netflix pasó de ser un servicio de alquiler de DVDs en 1997 a una plataforma líder de streaming que utiliza big data e inteligencia artificial para personalizar la experiencia del usuario. Este enfoque disruptivo le permitió superar a competidores tradicionales como Blockbuster y convertirse en un referente del entretenimiento digital (Marr, 2016).

Mientras Netflix consolidaba su liderazgo en el entretenimiento digital, otra industria tradicional experimentaba una transformación radical. Tesla revolucionó la industria automotriz al apostar por vehículos eléctricos y software avanzado. Bajo el liderazgo de Elon Musk, Tesla no solo popularizó la movilidad sostenible, sino que también redefinió la percepción del automóvil como un dispositivo tecnológico conectado. Su capacidad para innovar rápidamente ha obligado a fabricantes tradicionales como Ford y General Motors a replantear sus estrategias.

Otros ejemplos destacados incluyen Amazon, que desde 1994 transformó el comercio minorista global mediante la combinación de comercio electrónico, logística avanzada e inteligencia artificial. Su modelo centrado en el cliente y la eficiencia operativa ha redefinido cómo compramos y consumimos bienes.

Del mismo modo que Amazon revolucionó el comercio minorista, Airbnb rompió paradigmas en la industria hotelera al crear una plataforma que conecta anfitriones y viajeros. Este modelo basado en la economía colaborativa permite monetizar espacios infrautilizados y democratizar el acceso a alojamiento (Guttentag, 2015).

De manera similar, Uber revolucionó la industria del transporte al ofrecer una plataforma que conecta conductores independientes con pasajeros, eliminando la necesidad de empresas de taxis tradicionales. Fundada en 2009, Uber se expandió rápidamente a nivel global gracias a su modelo de negocio flexible y basado en la economía colaborativa. La accesibilidad de la aplicación y la facilidad para ofrecer y solicitar servicios de transporte rompieron con el paradigma de la movilidad urbana, impulsando la creación de un ecosistema que hoy en día incluye servicios de delivery y transporte de mercancías.

En el ámbito de la tecnología, Apple ha sido una fuerza disruptiva en múltiples industrias. Con productos como el iPhone, lanzado en 2007, no solo transformó la comunicación móvil, sino que también estableció un ecosistema digital que incluye hardware, software y servicios. Del mismo modo, Google revolucionó el acceso a la información con su motor de búsqueda y posteriormente diversificó su impacto con innovaciones en publicidad digital, inteligencia artificial y más.

Estos casos comparten un enfoque en anticipar las necesidades del cliente y adoptar tecnologías emergentes para ofrecer valor de maneras completamente nuevas. Cada uno demuestra cómo la disrupción tecnológica no solo introduce nuevos productos, sino que transforma industrias y redefine las expectativas de los consumidores. En todos ellos, el común denominador es la capacidad de anticiparse a los cambios y de utilizar la tecnología no solo como una herramienta operativa, sino como el núcleo mismo de la estrategia empresarial. Estas organizaciones no solo respondieron a la disrupción, sino que la impulsaron activamente, logrando construir nuevas realidades de negocio que transformaron industrias enteras.

Empresas que no se adaptaron: lecciones aprendidas

No todas las empresas han logrado sobrevivir a la disrupción tecnológica. Las historias de fracasos empresariales nos enseñan que la falta de adaptación frente a los avances tecnológicos puede resultar fatal, incluso para líderes consolidados del mercado. En muchos casos, la resistencia al cambio o la subestimación del impacto de nuevas tecnologías llevó a decisiones estratégicas erróneas que terminaron debilitando a grandes compañías. A continuación, repasaremos algunos casos emblemáticos que reflejan cómo la falta de visión estratégica puede convertir el éxito en fracaso.

Algunas de las historias más emblemáticas de fracasos incluyen ejemplos como Blockbuster, que ignoró el cambio hacia el streaming liderado por Netflix. A pesar de tener la oportunidad de adquirir Netflix en sus primeras etapas, Blockbuster subestimó el impacto de esta tecnología y se aferró a su modelo tradicional de alquiler de DVDs, lo que eventualmente llevó a su desaparición.

Así como Blockbuster ignoró el cambio hacia el streaming, Kodak también subestimó el poder de la innovación tecnológica en su propio sector. A pesar de ser pionera en el desarrollo de la fotografía digital, no supo adaptarse al cambio. Kodak decidió proteger su negocio de películas fotográficas, ignorando la creciente popularidad de las cámaras digitales. Este error estratégico la llevó a perder relevancia en un mercado que ella misma ayudó a crear.

Pero no solo en la industria del entretenimiento y la fotografía se subestimaron las disrupciones tecnológicas. La industria de la telefonía móvil también vivió su propio colapso de liderazgo cuando Nokia, un gigante indiscutido, no logró adaptarse a los cambios que introdujeron los teléfonos inteligentes. Su falta de innovación en software y la sobredependencia en sus diseños tradicionales resultaron en una pérdida significativa de cuota de mercado.

La historia se repitió en la industria de los smartphones con el caso de BlackBerry, una marca que dominaba el mercado corporativo pero que fue incapaz de reconocer el giro hacia dispositivos con pantallas táctiles y ecosistemas robustos de aplicaciones. Aunque BlackBerry había dominado el mercado corporativo, su resistencia a adoptar cambios en diseño y funcionalidad la dejó fuera de competencia.

Estos casos muestran que incluso las empresas más consolidadas están en riesgo si no reconocen las señales de cambio y no se adaptan a tiempo. La resistencia a aceptar nuevas realidades, la falta de visión estratégica y la dependencia de modelos de negocio obsoletos son factores comunes en estos fracasos. La lección es clara: la capacidad de reinventarse frente a las disrupciones tecnológicas no es una opción, sino una necesidad para la supervivencia empresarial en el entorno contemporáneo (Grant & Jordan, 2023).

1.1.3 Conclusiones

El análisis de la disrupción tecnológica en el ámbito empresarial revela patrones recurrentes que han definido el éxito o el fracaso de las empresas frente a los cambios impulsados por la innovación. A lo largo del recorrido por casos emblemáticos, hemos podido identificar elementos comunes en aquellas organizaciones que lograron transformar el cambio en ventaja competitiva, así como en aquellas que sucumbieron al impacto disruptivo. A lo largo de la historia, aquellas organizaciones que han sabido prosperar han compartido una característica fundamental: la capacidad de adaptarse al cambio. Identificar tempranamente las oportunidades que ofrecen las nuevas tecnologías y ejecutar estrategias claras ha sido un factor decisivo. Más allá de los

recursos disponibles, lo que verdaderamente ha marcado la diferencia es la voluntad de aprender, experimentar y transformar las amenazas en ventajas competitivas.

Por otro lado, las empresas que han sucumbido a las disrupciones comparten errores comunes. La rigidez organizacional y la resistencia al cambio, combinadas con la subestimación del impacto de las tecnologías emergentes, han llevado a muchas al estancamiento. Esto se ha visto agravado por la incapacidad de cuestionar los modelos de negocio tradicionales y por una falta de visión estratégica que les habría permitido reinventarse a tiempo.

En el caso particular de las PYMEs, estas dinámicas presentan ciertos matices específicos. Si bien su tamaño y estructura pueden limitar los recursos disponibles, también les otorgan una flexibilidad única que les permite adaptarse más rápidamente a los cambios. Además, su proximidad al cliente y el conocimiento del mercado local son ventajas competitivas que les permiten identificar oportunidades antes que las grandes corporaciones. Por lo tanto, si adoptan una postura proactiva hacia la innovación, pueden capitalizar rápidamente las nuevas tecnologías y consolidarse en sectores donde la agilidad es fundamental.

A pesar de estas limitaciones, el panorama no es adverso. Las PYMEs que invierten en capacitación, fomentan una cultura de apertura al cambio y buscan alianzas estratégicas con actores del ecosistema tecnológico tienen mayores probabilidades de convertir la disrupción en una herramienta para su crecimiento. En este sentido, las lecciones extraídas de los casos analizados son claras: el éxito no depende únicamente del acceso a recursos, sino de la capacidad de las organizaciones para transformar el cambio en una oportunidad estratégica. Para las PYMEs, esto implica adoptar un enfoque activo hacia la innovación, combinando su flexibilidad intrínseca con una visión de futuro clara y bien estructurada.

En última instancia, la disrupción tecnológica no debe ser vista únicamente como una amenaza, sino como un motor de transformación que, con la estrategia adecuada, puede impulsar a las PYMEs hacia nuevos horizontes de crecimiento y sostenibilidad. La clave radica en adoptar una mentalidad abierta al cambio, fomentar la capacidad de aprendizaje continuo y construir estrategias que integren la innovación como pilar fundamental del modelo de negocio. Quienes asuman este desafío con determinación y visión estratégica estarán mejor posicionados para liderar el futuro empresarial en un entorno cada vez más cambiante y competitivo.

1.2 La Inteligencia Artificial

A lo largo de la historia, las tecnologías disruptivas han transformado industrias, redefinido modelos de negocio y cambiado la forma en que las empresas operan. Sin embargo, pocas tecnologías han logrado un impacto tan amplio y profundo como la inteligencia artificial (IA). Su capacidad de transformar tanto los procesos operativos

como la conceptualización misma del trabajo y la toma de decisiones la posiciona como una de las fuerzas más significativas de la era contemporánea.

La inteligencia artificial, entendida como la simulación de procesos de inteligencia humana mediante sistemas computacionales, ha pasado de ser un concepto teórico a una realidad tangible con aplicaciones prácticas en casi todos los sectores. El término fue acuñado en la conferencia de Dartmouth en 1956, donde se planteó por primera vez la posibilidad de desarrollar máquinas capaces de simular el razonamiento humano (McCarthy et al., 1955). Desde entonces, la IA ha evolucionado rápidamente, no solo en capacidad técnica sino en su impacto en la vida cotidiana y el ámbito empresarial.

Desde una perspectiva técnica, la IA puede definirse como un conjunto de algoritmos y sistemas diseñados para interpretar datos, aprender de ellos y tomar decisiones de manera autónoma. Sus áreas principales incluyen el aprendizaje automático (Machine Learning, ML), que permite identificar patrones y mejorar el rendimiento a lo largo del tiempo sin intervención humana. Además, el procesamiento de lenguaje natural (Natural Language Processing, NLP) capacita a las máquinas para comprender y responder al lenguaje humano de manera efectiva, mientras que la visión por computadora (Computer Vision) permite analizar y comprender imágenes y videos. Junto con la robótica, los sistemas expertos y las redes neuronales profundas, estos pilares constituyen la base que hace de la IA una tecnología altamente versátil y transformadora.

Lo que distingue a la IA de otras tecnologías disruptivas es su capacidad para imitar funciones cognitivas humanas, como el razonamiento, la resolución de problemas y el aprendizaje. A diferencia de las máquinas convencionales, que se limitan a ejecutar instrucciones predefinidas, los sistemas de IA pueden adaptarse y optimizar su desempeño al interactuar con datos en tiempo real. Esto les otorga una flexibilidad única que amplifica su potencial disruptivo y la convierte en un motor de transformación profunda para las empresas.

En el contexto empresarial, esta capacidad de aprendizaje y adaptación ha llevado a que la IA sea utilizada para optimizar procesos, personalizar experiencias de cliente, predecir tendencias y reducir costos operativos. No obstante, su adopción también plantea desafíos éticos y estratégicos, especialmente para las pequeñas y medianas empresas (PYMEs), que deben equilibrar los beneficios con la inversión y los riesgos asociados (Bughin et al., 2019).

Por tanto, la IA no debe considerarse solo como una tecnología disruptiva, sino como un fenómeno transformador que redefine las reglas del juego empresarial. Su capacidad de aprender, adaptarse y resolver problemas complejos con una precisión creciente la convierte en una herramienta fundamental para cualquier empresa que aspire a mantenerse competitiva en el contexto actual. Integrar la IA de manera estratégica no es una opción, sino una necesidad para enfrentar los desafíos del futuro con éxito.

1.2.1 Historia y Evolución de la IA

La inteligencia artificial (IA) ha recorrido un camino lleno de altibajos desde sus primeras conceptualizaciones teóricas hasta su consolidación como una de las tecnologías más influyentes del siglo XXI. A lo largo de las últimas décadas, la evolución de la IA se ha visto marcada por ciclos de gran optimismo seguidos de períodos de escepticismo y falta de financiamiento, conocidos como inviernos de la IA. Estos altibajos no solo reflejan las expectativas cambiantes de la comunidad científica y empresarial, sino también la complejidad inherente a desarrollar sistemas capaces de emular la inteligencia humana.

Hoy en día, la IA ha superado muchos de esos obstáculos iniciales, alcanzando un nivel de madurez tecnológica que la posiciona como un pilar fundamental en la transformación digital de las organizaciones. Sin embargo, para comprender plenamente su impacto actual y futuro, es necesario recorrer su evolución histórica y analizar las etapas que la han definido, desde sus inicios teóricos hasta las innovaciones más recientes que impulsan el aprendizaje automático y las redes neuronales profundas.

1.2.1.1 Primeros Pasos hacia la IA (1943-1956)

La inteligencia artificial, como disciplina científica, tuvo sus primeras raíces a mediados del siglo XX, cuando los avances en matemáticas, lógica y computación comenzaron a abrir la posibilidad de crear máquinas capaces de simular procesos cognitivos humanos. Estos primeros pasos no solo sentaron las bases teóricas de la IA, sino que también impulsaron el interés en construir sistemas que pudieran imitar el razonamiento y el aprendizaje humano.

A mediados de la década de 1940, el matemático y lógico Warren McCulloch y el neurofisiólogo Walter Pitts desarrollaron el primer modelo matemático de una neurona artificial. Aunque el modelo era sencillo, resultó fundamental para sentar las bases de lo que más tarde se convertiría en las redes neuronales, abriendo el camino hacia la representación matemática del pensamiento humano (McCulloch & Pitts, 1943).

En paralelo, Alan Turing, matemático británico y pionero de la computación, propuso en 1950 el famoso "Test de Turing", diseñado para evaluar si una máquina podía exhibir un comportamiento inteligente indistinguible al de un ser humano. El test consistía en un juego de imitación donde un juez humano debía determinar si estaba interactuando con una persona o con una máquina, solo a través de respuestas escritas. Este experimento no solo planteó preguntas fundamentales sobre la naturaleza de la inteligencia, sino que también marcó un hito al desafiar a la comunidad científica a concebir máquinas capaces de aprender y razonar (Turing, 1950).

Sin embargo, el verdadero punto de inflexión ocurrió en 1956, cuando la Conferencia de Dartmouth marcó el inicio formal de la inteligencia artificial como campo de estudio. Organizada por figuras influyentes como John McCarthy, Marvin Minsky, Nathaniel Rochester y Claude Shannon, la conferencia reunió a científicos de diversas disciplinas

con el propósito de explorar la posibilidad de que una máquina pudiera simular cualquier aspecto de la inteligencia humana. Fue en este evento donde se acuñó el término "Inteligencia Artificial" y se trazaron las primeras líneas de investigación que impulsarían la evolución de la disciplina en las décadas siguientes (McCarthy et al., 1955).

Estos primeros pasos no solo consolidaron el concepto de IA, sino que también abrieron un abanico de posibilidades para futuras investigaciones y desarrollos tecnológicos que transformarían profundamente el mundo empresarial y social en el siglo XXI.

1.2.1.2 Fase Inicial de Exploración (1956-1974)

Tras la Conferencia de Dartmouth en 1956, la inteligencia artificial ingresó en una fase inicial de exploración, caracterizada por desarrollos experimentales que buscaban probar los conceptos teóricos planteados previamente. Durante esta etapa, la comunidad científica y tecnológica se concentró en transformar ideas visionarias en sistemas concretos capaces de realizar tareas específicas, sentando las bases para aplicaciones más sofisticadas en el futuro.

Uno de los primeros avances significativos en esta etapa fue el desarrollo del Perceptron en 1958, creado por Frank Rosenblatt, un psicólogo e ingeniero estadounidense. Inspirado en las neuronas biológicas, el Perceptron representó el primer sistema de aprendizaje automático capaz de clasificar datos de entrada en categorías, aprendiendo a partir de ejemplos etiquetados. Básicamente, funcionaba como una red neuronal de una sola capa que recibía información, la procesaba mediante cálculos matemáticos y aplicaba una regla sencilla para determinar la clasificación correspondiente. Cuando cometía errores, ajustaba su enfoque aprendiendo de ellos, mejorando progresivamente con cada intento. Aunque sus capacidades eran limitadas, el Perceptron marcó el inicio de la exploración hacia sistemas de aprendizaje más complejos y adaptativos (Rosenblatt, 1958).

Poco después, en 1965, el campo de la inteligencia artificial dio un paso hacia el procesamiento de lenguaje natural con el desarrollo de Eliza, el primer chatbot creado por Joseph Weizenbaum, profesor del MIT. Aunque su capacidad de simular conversaciones humanas era rudimentaria y basada en patrones básicos de texto, Eliza logró demostrar que las máquinas podían interactuar de manera conversacional, abriendo la puerta a investigaciones posteriores en el tratamiento del lenguaje (Weizenbaum, 1966).

En 1969, la comunidad científica fue testigo de un nuevo avance cuando el Stanford Research Institute presentó Shakey, un robot capaz de percibir su entorno y tomar decisiones basadas en reglas predefinidas. Desarrollado bajo la dirección de Charles Rosen, Shakey representó un paso crucial hacia la robótica cognitiva. Aunque sus capacidades eran limitadas por el poder de cómputo y la simplicidad de los algoritmos disponibles en esa época, su capacidad para moverse, reconocer objetos y realizar tareas

autónomas sentó las bases para el desarrollo de robots más avanzados en el futuro (Nilsson, 1984).

Esta fase inicial de exploración dejó un legado significativo al demostrar que los conceptos teóricos podían traducirse en desarrollos experimentales concretos. Aunque los resultados aún eran limitados en comparación con las expectativas iniciales, estos avances sentaron las bases para investigaciones futuras que eventualmente transformarían la inteligencia artificial en una herramienta práctica y robusta para el ámbito empresarial y científico.

1.2.1.3 Primer Invierno de la IA (1974-1980)

Tras el entusiasmo inicial generado por avances como el Perceptron, Eliza y Shakey, la comunidad científica y tecnológica comenzó a enfrentarse a una realidad compleja y desalentadora. Lo que en un principio parecía el inicio de una revolución tecnológica pronto reveló limitaciones significativas que frenaron el progreso esperado.

Los avances logrados con el Perceptron y otros sistemas iniciales habían generado expectativas desmesuradas en torno al potencial de la inteligencia artificial. Sin embargo, rápidamente se hizo evidente que estos modelos eran incapaces de abordar problemas complejos que requerían relaciones no lineales o razonamiento abstracto. El Perceptron, por ejemplo, podía resolver tareas sencillas de clasificación lineal, pero fracasaba ante problemas más complejos, como la resolución de la función XOR (Minsky & Papert, 1969). De manera similar, sistemas como Eliza y Shakey, aunque conceptualmente innovadores, se mostraron ineficaces en aplicaciones prácticas debido a la limitada capacidad de procesamiento y a la simplicidad de los algoritmos empleados.

Los altos costos de los sistemas, sumados a las expectativas desmesuradas y a la falta de aplicaciones prácticas, generaron frustración tanto en la comunidad científica como en los financiadores. Muchos sistemas fallaban al enfrentar situaciones reales, exponiendo la brecha entre la teoría y la práctica. Esto llevó a una drástica reducción de la financiación, ya que gobiernos y empresas comenzaron a priorizar proyectos con resultados más tangibles.

La discrepancia entre las expectativas y los resultados reales generó un desencanto profundo en la comunidad científica, lo que resultó en un drástico recorte de financiación por parte de gobiernos y empresas. Los proyectos de inteligencia artificial comenzaron a percibirse como poco viables, y muchos centros de investigación se vieron obligados a redirigir sus esfuerzos hacia otras áreas tecnológicas. Este período de estancamiento, conocido como el "primer invierno de la IA", supuso un golpe significativo para el desarrollo del campo (Crevier, 1993). Sin embargo, también permitió un replanteamiento fundamental sobre los objetivos y estrategias de la investigación en inteligencia artificial, sentando las bases para futuras aproximaciones más realistas y estructuradas.

1.2.1.4 Renacimiento de la IA & Sistemas Expertos (1980-1987)

Tras el desencanto que marcó el primer invierno de la IA, la década de 1980 trajo consigo un renacimiento impulsado por enfoques más pragmáticos y específicos. Lejos de las ambiciones de crear una inteligencia general, los investigadores optaron por desarrollar aplicaciones concretas y especializadas que pudieran aportar valor inmediato en contextos delimitados. Esta estrategia permitió el florecimiento de los Sistemas Expertos, programas diseñados para resolver problemas específicos y tomar decisiones en áreas especializadas como la medicina y la ingeniería.

Uno de los casos más emblemáticos de esta etapa fue el desarrollo de MYCIN, un Sistema Experto creado por Edward Shortliffe en la Universidad de Stanford a principios de los años 80. Diseñado para diagnosticar infecciones bacterianas y recomendar tratamientos específicos, MYCIN representó un avance significativo en la medicina asistida por inteligencia artificial. Su capacidad para procesar datos clínicos y generar recomendaciones precisas marcó un hito en el uso de la IA en entornos médicos (Shortliffe, 1976). Aunque nunca se utilizó de manera comercial debido a problemas éticos y de responsabilidad médica, MYCIN demostró el potencial de la IA para realizar tareas complejas en ámbitos especializados.

Otro desarrollo destacado fue XCON, un Sistema Experto creado por Digital Equipment Corporation (DEC) para la configuración automática de ordenadores. XCON ayudaba a los ingenieros a ensamblar sistemas complejos, garantizando configuraciones precisas y optimizadas. Gracias a su capacidad de manejar miles de reglas y procesar configuraciones complicadas, XCON se convirtió en un caso de éxito empresarial, ahorrando tiempo y reduciendo errores humanos en el proceso de ensamblaje (McDermott, 1982).

Al mismo tiempo, la investigación en redes neuronales experimentó un avance crucial con la introducción del algoritmo de Backpropagation. Impulsado por figuras influyentes como Geoffrey Hinton y David Rumelhart, este algoritmo permitió el entrenamiento de redes neuronales multicapa de manera más eficiente, superando una de las mayores limitaciones del Perceptron original. Aunque el impacto inmediato fue limitado, el desarrollo de Backpropagation sentó las bases para el resurgimiento del Machine Learning en décadas posteriores (Rumelhart et al., 1986).

A pesar del entusiasmo renovado que trajeron los Sistemas Expertos y los avances en redes neuronales, el progreso fue limitado y no alcanzó las expectativas de una inteligencia artificial generalizada. Aunque se lograron avances concretos en dominios específicos, estos sistemas demostraron ser demasiado rígidos y especializados, lo que frenó su expansión hacia aplicaciones más generales. Además, el apoyo financiero y el interés de la comunidad científica no alcanzaron los niveles esperados, lo que eventualmente conduciría a un segundo enfriamiento en la investigación. No obstante, esta etapa de renacimiento sentó las bases conceptuales y técnicas que luego impulsarían el resurgimiento definitivo de la IA en los años 90 y 2000.

1.2.1.5 Segundo Invierno de la IA (1987-1993)

Tras el renacimiento impulsado por los sistemas expertos en la década de 1980, la inteligencia artificial volvió a enfrentar un período de enfriamiento conocido como el "segundo invierno de la IA". Aunque los sistemas expertos demostraron su utilidad en dominios específicos, su incapacidad para generalizar el conocimiento y resolver problemas complejos alimentó nuevamente el escepticismo en torno al potencial transformador de la IA (Hendler, 2008).

Las expectativas generadas en torno a la inteligencia artificial no se cumplieron, ya que los avances no fueron tan rápidos ni tan amplios como se anticipaba. Uno de los mayores desafíos fue la incapacidad de los sistemas expertos para adaptarse a contextos nuevos o distintos a su configuración original. Además, la falta de avances significativos en redes neuronales y algoritmos de aprendizaje automático limitó el desarrollo de sistemas más versátiles.

A esto se sumaron las limitaciones tecnológicas, especialmente en términos de capacidad de procesamiento y almacenamiento de datos, que impedían llevar a la práctica modelos más complejos y robustos. El costo elevado de la infraestructura necesaria y la baja eficiencia de los algoritmos también contribuyeron al desencanto generalizado.

Como resultado, muchas empresas comenzaron a recortar sus presupuestos de investigación y desviaron recursos hacia proyectos con un retorno más inmediato y tangible. La comunidad científica también redujo sus expectativas, y el interés de los inversores disminuyó considerablemente. Sin embargo, aunque el segundo invierno de la IA representó un período de estancamiento y desilusión, también permitió una reflexión crítica sobre los enfoques metodológicos que eventualmente darían lugar al resurgimiento de la IA en la década de 1990 (Crevier, 1993).

1.2.1.6 Nuevos Paradigmas de la IA (1993-2006)

Tras superar las dificultades del segundo invierno de la IA, la década de 1990 trajo consigo un renacimiento impulsado por nuevos enfoques y avances tecnológicos que cambiarían el rumbo de la inteligencia artificial para siempre. En lugar de depender exclusivamente de reglas explícitas, los investigadores comenzaron a centrarse en algoritmos capaces de aprender de grandes volúmenes de datos, lo que permitió enfrentar problemas complejos con mayor eficiencia.

Un avance fundamental en esta etapa fue el resurgimiento de las redes neuronales, impulsado por la introducción del algoritmo de Backpropagation en 1986, desarrollado por Geoffrey Hinton, David Rumelhart y Ronald J. Williams. Este algoritmo permitió entrenar redes neuronales multicapa de manera efectiva, superando una de las principales limitaciones de los modelos anteriores y habilitando el desarrollo de arquitecturas más complejas (Rumelhart et al., 1986). En la siguiente sección,

profundizaremos en cómo funcionan estos mecanismos de aprendizaje y optimización dentro de las redes neuronales.

Un ejemplo emblemático de este renacimiento fue el enfrentamiento en 1997 entre Deep Blue, la supercomputadora de IBM, y Garry Kasparov, campeón mundial de ajedrez. Deep Blue, capaz de evaluar millones de posibles jugadas por segundo, logró derrotar al campeón en una partida histórica, demostrando el poder de las máquinas para resolver problemas complejos en tiempo real (Campbell et al., 2002). Este evento no solo marcó un hito en el ámbito de los juegos de estrategia, sino que también mostró el potencial de la IA para abordar tareas tradicionalmente dominadas por la inteligencia humana.

Simultáneamente, la investigación en redes neuronales fue impulsada por científicos visionarios como Geoffrey Hinton, Yann LeCun y Yoshua Bengio, quienes perfeccionaron técnicas clave que sentaron las bases del Deep Learning moderno. Hinton, profesor en la Universidad de Toronto, fue pionero en redes neuronales profundas; LeCun, director del Laboratorio de IA de Facebook y profesor en la Universidad de Nueva York, desarrolló redes neuronales convolucionales para el reconocimiento de imágenes; mientras que Bengio, profesor en la Universidad de Montreal, avanzó en el estudio de algoritmos de aprendizaje profundo (LeCun et al., 2015).

Estos avances fueron posibles gracias a mejoras significativas en el poder computacional, especialmente con el uso de GPUs desarrolladas por empresas como NVIDIA, que facilitaron el procesamiento de grandes volúmenes de datos mediante cálculos en paralelo. Así, áreas como el reconocimiento de imágenes y la traducción automática experimentaron un progreso acelerado, consolidando el enfoque de Deep Learning como un pilar fundamental en la inteligencia artificial moderna (Raina et al., 2009).

1.2.2 Machine Learning y Redes Neuronales

El resurgimiento de la inteligencia artificial en la década de 1990 estuvo impulsado por el avance del aprendizaje automático (Machine Learning), que cambió por completo la manera de abordar la resolución de problemas. Hasta entonces, los programas tradicionales eran diseñados manualmente, siguiendo una lógica explícita en la que cada paso debía ser detalladamente programado para anticipar cualquier situación posible. Esto implicaba un esfuerzo considerable en la definición de reglas precisas para cada contexto, lo que hacía que los sistemas fueran rígidos y difíciles de adaptar.

El enfoque de Machine Learning transformó esta lógica al introducir modelos capaces de aprender directamente de los datos, identificando patrones y realizando predicciones sin necesidad de reglas predefinidas. En lugar de seguir un conjunto fijo de instrucciones, los algoritmos analizan grandes volúmenes de información y ajustan sus parámetros internos para capturar relaciones relevantes (Domingos, 2015).

El proceso de aprendizaje se lleva a cabo mediante una etapa de entrenamiento, en la que el modelo procesa ejemplos conocidos, ajusta sus parámetros y evalúa su precisión.

A medida que el modelo recibe más datos, optimiza su rendimiento y mejora su capacidad para generalizar el conocimiento adquirido a situaciones nuevas.

Dependiendo del tipo de datos disponibles y del objetivo de la tarea, el modelo puede entrenarse mediante diversos enfoques:

- ✓ **Aprendizaje supervisado:** Utiliza datos etiquetados para entrenar el modelo a partir de ejemplos conocidos.
- ✓ **Aprendizaje no supervisado:** Trabaja con datos no etiquetados para descubrir patrones ocultos o agrupamientos.
- ✓ **Aprendizaje semi-supervisado:** Combina datos etiquetados y no etiquetados para mejorar la precisión.
- ✓ **Aprendizaje por refuerzo:** El modelo aprende mediante prueba y error, recibiendo recompensas o penalizaciones según sus acciones.

Cada uno de estos métodos responde a necesidades específicas y permite abordar problemas desde perspectivas diversas, dependiendo de la naturaleza de los datos y el objetivo del análisis.

Dentro de este paradigma, las redes neuronales se destacaron rápidamente por su capacidad para procesar información compleja y descubrir patrones no lineales. Inspiradas en la estructura biológica del cerebro humano, estas redes están compuestas por unidades llamadas neuronas artificiales, que se interconectan y organizan en capas sucesivas. Los datos ingresan por la capa de entrada, se procesan en múltiples capas intermedias y generan finalmente un resultado en la capa de salida. Esta organización en capas permite capturar relaciones complejas y características relevantes del problema abordado.

El desarrollo de estas arquitecturas complejas permitió a las redes neuronales abordar problemas antes inabordables, consolidándose como una herramienta poderosa en el contexto empresarial y académico. En las próximas secciones, se presentarán los distintos modelos de aprendizaje automático y se analizarán tanto las técnicas clásicas que los precedieron como aquellas que llevaron al desarrollo de arquitecturas más complejas y precisas, como las redes neuronales.

1.2.2.1 Modelos de Aprendizaje

Existen distintas técnicas o metodologías que permiten a los modelos procesar datos y extraer patrones para realizar predicciones o tomar decisiones de manera autónoma. La elección de un modelo de aprendizaje depende fundamentalmente del tipo de datos disponibles y de la naturaleza del problema que se busca resolver.

El proceso de entrenamiento es una etapa fundamental en el aprendizaje automático. Durante esta fase, el modelo analiza grandes volúmenes de datos conocidos y ajusta sus parámetros internos para identificar patrones significativos. El objetivo es que el modelo logre transformar los datos de entrada en respuestas precisas, optimizando su capacidad para generalizar lo aprendido a situaciones nuevas. A medida que el entrenamiento progresa, el modelo evalúa el rendimiento de sus predicciones y ajusta sus parámetros para reducir los errores y mejorar su precisión.

Dependiendo de la naturaleza de los datos y del objetivo del modelo, existen diferentes enfoques de aprendizaje que permiten organizar el proceso de entrenamiento de manera eficiente. A continuación, se presentan los cuatro tipos principales de aprendizaje automático: supervisado, no supervisado, semi-supervisado y por refuerzo.

Aprendizaje Supervisado

El aprendizaje supervisado es el enfoque más común dentro del Machine Learning y se basa en entrenar el modelo utilizando datos etiquetados, es decir, conjuntos de ejemplos en los que la relación entre las variables de entrada y la salida esperada está claramente definida. Durante el entrenamiento, el modelo aprende a identificar patrones que relacionan los datos de entrada con los resultados conocidos, lo que le permite generar predicciones precisas cuando se enfrenta a datos nuevos (Kotsiantis, 2007).

Por ejemplo, en un problema de clasificación de imágenes, el modelo recibe fotografías de animales junto con la etiqueta correspondiente a cada especie (gato, perro, caballo). Durante el entrenamiento, la red neuronal analiza las características visuales de cada imagen y ajusta sus parámetros internos para aprender a distinguir entre las diferentes clases. Una vez entrenado, el modelo puede recibir una nueva imagen sin etiqueta y predecir a cuál de las clases pertenece, utilizando los patrones aprendidos previamente.

Aprendizaje No Supervisado

A diferencia del aprendizaje supervisado, el aprendizaje no supervisado trabaja con datos sin etiquetas, lo que implica que el modelo debe descubrir patrones o estructuras ocultas en los datos sin contar con una referencia previa sobre el resultado esperado. El objetivo es identificar agrupamientos o relaciones subyacentes que permitan comprender mejor la estructura de la información.

Un ejemplo clásico es el análisis de agrupamiento de clientes en un supermercado. El modelo recibe datos como el comportamiento de compra o las preferencias, pero no sabe de antemano cómo clasificar a los clientes. A través de algoritmos de agrupamiento, el modelo identifica grupos con características comunes, permitiendo segmentar a los consumidores en categorías similares sin haber definido previamente los grupos.

Aprendizaje Semi-Supervisado

El aprendizaje semi-supervisado combina aspectos del aprendizaje supervisado y no supervisado, aprovechando tanto datos etiquetados como no etiquetados para mejorar el rendimiento del modelo. Es particularmente útil cuando se dispone de una gran cantidad de datos sin etiquetar y solo una pequeña parte está correctamente identificada. Al integrar ambos conjuntos, el modelo puede mejorar su precisión sin requerir un etiquetado exhaustivo de todos los datos.

Por ejemplo, en la clasificación de correos electrónicos como spam o no spam, el modelo puede contar con un conjunto reducido de correos etiquetados manualmente, mientras que la mayoría de los correos aún no están clasificados. El modelo aprovecha los correos etiquetados para aprender patrones y luego utiliza esos patrones para clasificar el resto, logrando un buen rendimiento con un esfuerzo de etiquetado mínimo.

Aprendizaje por Refuerzo

El aprendizaje por refuerzo presenta un enfoque distinto, en el que el modelo toma decisiones de manera secuencial mientras interactúa con un entorno dinámico. En lugar de entrenarse con un conjunto de datos estático, el modelo aprende a partir de la retroalimentación que recibe en forma de recompensas o penalizaciones según las decisiones que toma. El objetivo es maximizar la recompensa acumulada a lo largo del tiempo, ajustando su estrategia a partir de la experiencia adquirida (Sutton & Barto, 2018).

Un ejemplo simple de este enfoque es el entrenamiento de un agente para jugar al ajedrez. El modelo aprende jugando partidas contra sí mismo o contra otros jugadores, recibiendo una recompensa positiva al ganar y una penalización al perder. A medida que acumula experiencia, el agente ajusta su estrategia para aumentar sus posibilidades de éxito en partidas futuras.

Estos cuatro enfoques representan la base conceptual del aprendizaje automático y permiten abordar una gran variedad de problemas en contextos muy diversos. La elección de la técnica adecuada depende del tipo de datos disponibles, la complejidad del problema y los objetivos específicos que se buscan alcanzar con el modelo.

1.2.2.2 Técnicas Clásicas de Machine Learning

Antes del auge de las redes neuronales, el aprendizaje automático ya contaba con una serie de técnicas que permitían resolver problemas complejos de manera efectiva. Estas metodologías, desarrolladas en un contexto limitado por el poder computacional de la época, lograron establecer los cimientos del análisis de datos moderno y siguen siendo fundamentales en muchos casos prácticos. Aunque hoy en día las redes neuronales han

alcanzado una notable precisión en tareas complejas, las técnicas clásicas siguen vigentes gracias a su simplicidad, eficiencia y capacidad de interpretación, especialmente en situaciones donde el volumen de datos es moderado o se requiere transparencia en el modelo (Alpaydin, 2020).

La **regresión lineal** es una técnica de aprendizaje supervisado que permite estimar un resultado numérico a partir de múltiples variables mediante una función lineal. Puede utilizarse, por ejemplo, para predecir el valor de una vivienda considerando su superficie, el número de habitaciones, la ubicación y el estado de conservación. La **regresión logística**, en cambio, se aplica a problemas de clasificación binaria, como estimar la probabilidad de que un cliente realice una compra según su edad, nivel de ingresos, historial de interacciones y frecuencia de uso del servicio.

Los **árboles de decisión** son modelos supervisados que representan un proceso de clasificación o regresión mediante una secuencia jerárquica de decisiones. En cada paso, el modelo selecciona automáticamente la variable que mejor separa los datos hasta llegar a un resultado final. Esta lógica permite, por ejemplo, predecir si un cliente abandonará un servicio en función de características como el tiempo de suscripción o la frecuencia de uso. El modelo **Random Forest** amplía este enfoque combinando múltiples árboles construidos sobre subconjuntos aleatorios de datos, y luego promedia o vota los resultados individuales para obtener una predicción conjunta más robusta.

También dentro del aprendizaje supervisado, las **máquinas de soporte vectorial (SVM)** son técnicas de clasificación que buscan separar dos categorías mediante una frontera que maximice la distancia con los casos más cercanos de cada clase. Esta estrategia ofrece buenos resultados incluso cuando los datos presentan superposición o ruido. Un ejemplo típico de uso es la detección de transacciones financieras sospechosas a partir de variables como el monto, la frecuencia y la ubicación de los movimientos.

En el campo del aprendizaje no supervisado, el algoritmo **K-Means** permite agrupar datos en clústeres según su similitud. Parte de una cantidad de grupos predefinida y ajusta la asignación de cada punto minimizando la distancia respecto al centroide del clúster correspondiente. Se utiliza, por ejemplo, para segmentar clientes en función de sus patrones de compra, identificando perfiles como compradores frecuentes, ocasionales o impulsivos.

El **análisis de componentes principales (PCA)** es una técnica que reduce la dimensionalidad de los datos transformando las variables originales en un conjunto reducido de componentes que concentran la mayor parte de la variabilidad. Es útil, por ejemplo, para simplificar bases financieras complejas —que incluyen ingresos, gastos, rentabilidad y volumen de operaciones— en un número menor de dimensiones más manejables.

Si bien estas técnicas clásicas han sido fundamentales para el desarrollo del aprendizaje automático y continúan utilizándose en una amplia variedad de aplicaciones, presentan limitaciones frente a problemas complejos, especialmente aquellos que involucran

relaciones no lineales o grandes volúmenes de datos no estructurados. La aparición de las redes neuronales representó un salto cualitativo, al introducir una arquitectura capaz de aprender representaciones más profundas y adaptarse a contextos más desafiantes. En la próxima sección exploraremos cómo funcionan estos modelos, cuáles son sus características principales y por qué marcaron un cambio de paradigma en el abordaje de tareas cada vez más exigentes (Goodfellow et al., 2016).

1.2.2.3 Redes Neuronales

Las redes neuronales surgieron como una respuesta a la necesidad de abordar problemas complejos que los modelos tradicionales no podían resolver de manera efectiva. Inspiradas en el funcionamiento del cerebro humano, están compuestas por unidades llamadas neuronas artificiales que se organizan en capas y se interconectan entre sí (Haykin, 2009).

Cada neurona recibe señales de la capa anterior, las procesa mediante cálculos matemáticos y transmite el resultado a la siguiente capa. A lo largo de la red, los datos fluyen desde la capa de entrada hasta la capa de salida, pasando por capas intermedias que ajustan y transforman la información en cada paso. Durante este recorrido, las conexiones entre las neuronas están ponderadas por valores numéricos llamados **pesos (weights)**, que determinan la influencia que cada señal tiene sobre el resultado final.

Aunque el funcionamiento de cada neurona puede comprenderse de manera aislada, el resultado final surge de la combinación de muchos pasos sucesivos e interrelacionados a lo largo de la red. Esta acumulación de cálculos hace que el proceso completo sea difícil de rastrear y entender en su totalidad. Por esta razón, es conveniente pensar a la red como un sistema cerrado o una caja negra que recibe datos en la entrada y genera un resultado en la salida, sin necesidad de comprender cada cálculo intermedio.

Los pesos de las conexiones se asignan inicialmente de manera aleatoria, lo que provoca que ante una señal de entrada la respuesta generada sea imprecisa o incoherente. Esto ocurre porque la red no ha aprendido aún a interpretar los datos de manera significativa, y sus conexiones no están ajustadas para capturar relaciones útiles entre la entrada y la salida.

Para que la red neuronal logre generar respuestas precisas, es necesario someterla a un proceso de entrenamiento que le permita aprender de los datos conocidos. Durante este proceso, la red recibe ejemplos con entradas y salidas conocidas, realiza una predicción y compara el resultado obtenido con el valor real. La diferencia entre ambos, conocida como error, indica cuánto se desvía la respuesta de lo esperado.

Con el fin de reducir este error y mejorar progresivamente la precisión, el modelo modifica los pesos de las conexiones entre neuronas, buscando que el próximo intento esté más cerca del resultado correcto. Este ciclo de predicción, cálculo del error y ajuste de pesos se repite una y otra vez, atravesando múltiples rondas llamadas epochs.

Durante cada epoch, la red procesa el conjunto completo de ejemplos de entrenamiento, ajustando los pesos en función de los errores acumulados.

El conjunto de datos utilizado durante esta etapa se divide en tres subconjuntos: training data, validation data y test data. El training data es el conjunto principal que la red utiliza para ajustar sus parámetros, realizando múltiples epochs para mejorar su capacidad de identificar patrones complejos. Sin embargo, el hecho de que la red logre generar respuestas precisas sobre los ejemplos de entrenamiento no garantiza que pueda hacerlo sobre datos nuevos. El verdadero desafío es lograr que el modelo no memorice casos específicos, sino que adquiera la capacidad de aplicar lo aprendido a situaciones diferentes.

Para monitorear el rendimiento del modelo y evitar que simplemente memorice los ejemplos específicos, se utiliza un segundo conjunto llamado validation data. Este conjunto permite evaluar cómo se desempeña la red ante datos que no ha visto durante el entrenamiento directo. El rendimiento en el conjunto de validación ayuda a detectar problemas de sobreajuste (overfitting), donde el modelo pierde capacidad de generalización y solo responde bien ante ejemplos específicos.

Finalmente, una vez que el entrenamiento ha concluido y el modelo ha alcanzado un rendimiento satisfactorio en el conjunto de validación, se evalúa su precisión final utilizando el test data. Este conjunto permanece completamente aislado durante todo el proceso anterior y se utiliza exclusivamente al final para medir la capacidad real de la red de enfrentar situaciones nuevas. El rendimiento en el test data proporciona una evaluación objetiva sobre la capacidad del modelo para aplicar lo aprendido en contextos no previamente conocidos (Goodfellow et al., 2016).

1.2.2.4 Aplicaciones y Desafíos de las Redes Neuronales

Las redes neuronales han demostrado ser herramientas eficaces para abordar tareas complejas que otros modelos tradicionales no lograban resolver con precisión, como el reconocimiento de voz, la clasificación de imágenes, el análisis de series temporales y el procesamiento del lenguaje natural.

Sin embargo, su adopción ha enfrentado varios desafíos que limitaron su uso. Uno de los mayores obstáculos fue el costo computacional asociado al entrenamiento de modelos complejos. Las redes neuronales requieren grandes volúmenes de datos y un procesamiento intensivo que demanda recursos significativos tanto en tiempo como en capacidad de cómputo. Otro desafío fundamental es el riesgo de sobreajuste (overfitting). Esto ocurre cuando la red aprende demasiado los detalles específicos del conjunto de entrenamiento, perdiendo la capacidad de generalizar frente a datos nuevos.

Además, las redes neuronales presentan limitaciones en términos de interpretabilidad. A diferencia de modelos clásicos como la regresión lineal o los árboles de decisión, donde la relación entre variables es clara y comprensible, las redes neuronales funcionan como

sistemas cerrados. Esto significa que, aunque los resultados puedan ser precisos, el razonamiento detrás de cada predicción no siempre es evidente, lo que puede generar incertidumbre en aplicaciones donde la transparencia es fundamental, como en contextos médicos o financieros.

Estos desafíos impulsaron el desarrollo de arquitecturas más sofisticadas que mejoraron tanto la eficiencia computacional como la capacidad de generalización. Fue en este contexto que surgió el Deep Learning, una evolución natural de las redes neuronales que permitió aprovechar al máximo los avances tecnológicos y computacionales, dando lugar a soluciones más precisas y eficientes.

1.2.3 La Revolución del Deep Learning y Transformers

El desarrollo del Deep Learning marcó una nueva etapa en la evolución de la inteligencia artificial, catalizado por los avances en hardware y el aumento exponencial en la capacidad de procesamiento de datos. Tecnologías como las unidades de procesamiento gráfico (GPU) y, más tarde, las unidades de procesamiento tensorial (TPU), permitieron implementar y escalar modelos con millones de parámetros que, aunque habían sido conceptualizados en décadas anteriores, resultaban inalcanzables hasta ese momento (Raina et al., 2009). Este progreso técnico abrió las puertas a la aplicación de diferentes modelos de redes neuronales profundas que buscaron resolver problemas complejos como el reconocimiento de imágenes, el procesamiento del lenguaje natural o la predicción de series temporales.

Con un poder de cálculo mucho mayor, las primeras arquitecturas con las que se comenzó a experimentar fueron los Feedforward Networks (FFN) profundas, también conocidos como Perceptrones Multicapa (MLP). Estos modelos, contruidos con varias capas de neuronas conectadas entre sí, buscaban abordar problemas como la clasificación de imágenes y la predicción de patrones en datos complejos, aprovechando el incremento en capacidad computacional y la mejora en los algoritmos de entrenamiento. Un ejemplo de su aplicación fue en el campo del reconocimiento de voz y la identificación de patrones en datos financieros, donde grupos de investigación, como el de Geoffrey Hinton, profesor en la Universidad de Toronto y uno de los pioneros en el campo del Deep Learning, comenzaron a utilizar estas redes para clasificar señales y series temporales. Sin embargo, aunque los FFN mostraban potencial en tareas específicas, su adopción fue limitada debido a su incapacidad para capturar relaciones temporales de manera eficiente.

Aunque los Feedforward Networks (FFN) permitieron abordar problemas de clasificación estática, se encontraban limitados en tareas donde el contexto temporal era fundamental. Esto impulsó el desarrollo de arquitecturas especializadas en el manejo de secuencias, dando lugar a las Redes Neuronales Recurrentes (RNN). Estas redes emergieron como una solución clave para capturar relaciones temporales y contextuales entre los datos, gracias a su capacidad de mantener un estado interno que incorporaba la información de entradas pasadas. A diferencia de las FFN, que operaban de manera

independiente en cada capa, las RNN mantenían un estado continuo que facilitaba tareas como la transcripción de voz a texto o la generación de texto (Elman, 1990). Sin embargo, a pesar de su capacidad para retener información del pasado, las RNN enfrentaban dificultades para capturar dependencias a largo plazo, lo que limitaba su efectividad en tareas que requerían recordar eventos distantes en el tiempo o en secuencias largas.

Para resolver esta limitación, se introdujeron variantes como las Redes LSTM (Long Short-Term Memory), que incorporaron mecanismos específicos para retener información relevante durante períodos prolongados, permitiendo que la red aprendiera cuándo recordar y cuándo olvidar (Hochreiter & Schmidhuber, 1997). Aun así, el enfoque secuencial de las RNN seguía siendo un cuello de botella en tareas extensas.

En el campo del reconocimiento de imágenes y el análisis de datos visuales, surgieron las Redes Neuronales Convolucionales (CNN), con una arquitectura diseñada específicamente para procesar datos que presentan una estructura espacial. Mediante la aplicación de filtros de convolución, estas redes extraen características de manera jerárquica, identificando patrones locales como bordes, texturas y formas, que luego se combinan para reconocer objetos más complejos. Este enfoque, que emula el proceso visual humano, permitió avances significativos en tareas como la clasificación de imágenes. Un ejemplo clave de su éxito fue el caso de ImageNet, una competencia internacional en la que se evaluaba la capacidad de los modelos para clasificar imágenes en miles de categorías. En 2012, AlexNet, un modelo de CNN desarrollado en la Universidad de Toronto, ganó dicha competencia con una mejora notable en el rendimiento, alcanzando una precisión sin precedentes en el reconocimiento de imágenes a gran escala (Krizhevsky et al., 2012).

Un evento clave que ilustró los avances de la inteligencia artificial en esa época fue la victoria de AlphaGo sobre el campeón mundial de Go, Lee Sedol, en 2016. Desarrollado por DeepMind, una subsidiaria de Alphabet, AlphaGo fue un hito en el uso de aprendizaje por refuerzo (reinforcement learning) y redes neuronales profundas para abordar un juego de estrategia considerado extremadamente complejo debido a su enorme espacio de posibles movimientos (Silver et al., 2016).

Sin embargo, si de avances tecnológicos se trata, el 2017 nos sorprendería con la presentación de un modelo revolucionario: los Transformers. Desarrollado por un equipo de investigadores de Google Brain, liderado por Ashish Vaswani y sus colaboradores, el paper titulado Attention is All You Need marcaría un hito en el campo de la inteligencia artificial (Vaswani et al., 2017). Este trabajo se centraba principalmente en la mejora de los sistemas de traducción automática, un área en la que los modelos previos, como las redes neuronales recurrentes (RNN), presentaban grandes limitaciones. Los modelos tradicionales luchaban para manejar secuencias largas de texto debido a la dificultad de capturar dependencias a largo plazo en los datos. Los Transformers, por el contrario, resolvieron este problema mediante un mecanismo de atención que permitía procesar toda la secuencia de entrada simultáneamente, logrando identificar las relaciones clave entre palabras sin necesidad de procesarlas de manera secuencial.

Este enfoque innovador transformó la traducción automática y abrió un abanico de posibilidades en el procesamiento del lenguaje natural, lo que marcó un antes y un después en la evolución de la IA. Los Transformers no solo revolucionaron la traducción automática, sino que también sentaron las bases para una amplia gama de aplicaciones en el procesamiento del lenguaje natural (NLP). Con su capacidad para capturar contextos complejos y mantener relaciones de largo alcance, los Transformers se convirtieron en la columna vertebral de los modelos más avanzados de la actualidad, como BERT o GPT. Estos modelos de lenguaje a gran escala, que se entrenan con enormes volúmenes de datos, son ahora capaces de realizar tareas complejas como la generación de texto, la respuesta a preguntas y la comprensión de contextos más amplios, con una precisión sin precedentes. Gracias a su arquitectura flexible y potente, los Transformers han dejado atrás las limitaciones de los enfoques anteriores y se han consolidado como la base para el desarrollo de modelos de IA cada vez más sofisticados, dando paso a la era de los Large Language Models (LLM), que continúan moldeando el futuro de la inteligencia artificial (Bommasani et al., 2021).

1.2.4 Los Grandes Modelos LLM

La presentación de los Transformers en 2017 marcó el inicio de una revolución en la inteligencia artificial que promete reconfigurar la vida de los seres humanos en los próximos años. En muy poco tiempo, la evolución de los Modelos de Lenguaje de Gran Escala (LLM, por sus siglas en inglés) ha sido tan vertiginosa que resulta difícil dimensionar su impacto total (Brown et al., 2020). Lo que comenzó como una innovación en el procesamiento del lenguaje natural (NLP) rápidamente se convirtió en una carrera por desarrollar modelos cada vez más sofisticados, capaces de abordar tareas complejas que hasta hace poco parecían inalcanzables.

Estos modelos han transformado la manera en que interactuamos con la tecnología y abierto nuevas posibilidades para empresas, organizaciones e individuos. Con millones o incluso miles de millones de parámetros, han logrado comprender y generar texto con una fluidez y precisión sin precedentes. Lo que realmente distingue a los LLM es su versatilidad: desde la generación de contenido automatizado hasta la asistencia conversacional y la traducción de idiomas, su potencial disruptivo parece no tener límites.

Lo que hace que esta evolución sea tan asombrosa no es solo la capacidad técnica de los modelos, sino también la velocidad con la que se han desarrollado e integrado en la vida cotidiana y el entorno laboral. En apenas unos años, pasamos de algoritmos experimentales a modelos comerciales que impactan directamente en millones de usuarios. Este avance acelerado refleja no solo el progreso en la arquitectura de modelos, sino también en la infraestructura computacional que los hace posibles, especialmente con el uso de GPU y TPU para el procesamiento masivo de datos.

Sin embargo, el desarrollo de los LLM también ha generado tensiones y debates sobre sus implicaciones éticas y sociales. Mientras algunos destacan los beneficios económicos

y la eficiencia que traen consigo, otros advierten sobre los riesgos relacionados con la generación de desinformación, la pérdida de empleos y los sesgos inherentes en los modelos de entrenamiento (Bender et al., 2021). Empresas y gobiernos están comenzando a abordar estas preocupaciones, intentando equilibrar el avance tecnológico con una implementación ética y responsable.

A medida que los modelos se vuelven más sofisticados, la competencia entre empresas ha intensificado la innovación en busca de mayor precisión, eficiencia y capacidad de integración. En este contexto, actores como Google, DeepMind, OpenAI, Meta, Anthropic y organizaciones colaborativas como BigScience y Mistral AI han impulsado desarrollos que desafían los límites de lo posible, liderando una carrera donde la capacidad de procesamiento, la eficiencia energética y la alineación ética juegan roles decisivos (Dans, 2023).

El futuro inmediato de los LLM parece orientarse hacia modelos aún más complejos, capaces de abordar tareas multimodales con un grado de comprensión contextual que rivaliza con la inteligencia humana. Las mejoras continuas en el rendimiento y la reducción de sesgos seguirán siendo objetivos prioritarios, ya que los usuarios demandan modelos más precisos y éticamente responsables. La velocidad de avance sugiere que en pocos años podríamos estar frente a modelos capaces de generar contenido complejo en tiempo real y asistir en la toma de decisiones estratégicas de manera altamente personalizada.

En última instancia, la evolución de los LLM no solo representa un avance técnico, sino también un cambio de paradigma en la forma en que entendemos la inteligencia artificial y su impacto en la sociedad moderna. La capacidad de estos modelos para aprender, adaptarse y generar contenido plantea interrogantes sobre el papel de la tecnología en nuestras vidas y el equilibrio entre innovación y responsabilidad. En este contexto, la competencia entre empresas no solo es una lucha por liderar el mercado, sino también una búsqueda continua de soluciones que permitan aprovechar el poder transformador de la IA de manera ética y sostenible.

A continuación, realizaremos un recorrido por las principales empresas que lideran esta carrera tecnológica, explorando sus modelos más emblemáticos, las estrategias adoptadas y los aportes específicos que cada una ha realizado al campo de los modelos de lenguaje de gran escala.

1.2.4.1 Google

Google fue pionero en el desarrollo de modelos de lenguaje de gran escala (LLM) desde la presentación de BERT (2018), que transformó el procesamiento del lenguaje natural al introducir la comprensión contextual bidireccional, estableciendo un nuevo estándar en precisión y capacidad de interpretación de textos (Devlin et al., 2019). Este avance permitió abordar tareas complejas como la clasificación y la respuesta a preguntas con un enfoque mucho más efectivo que los modelos previos.

A BERT le siguió T5 (2019), un modelo diseñado para enfrentar múltiples tareas de NLP bajo un único esquema de entrada-salida, como resúmenes, traducciones, respuestas a preguntas y clasificación de textos. Luego llegó GLaM (2021), que adoptó un enfoque eficiente al activar solo los parámetros necesarios para cada tarea, maximizando el rendimiento sin comprometer la precisión. PaLM (2022) se enfocó en el razonamiento lógico y el procesamiento multilingüe, mientras que Chinchilla (2023) optimizó el uso de datos para equilibrar precisión y eficiencia computacional.

Pero el mayor salto cualitativo llegó con la familia Gemini, que representa la estrategia de Google para consolidar su liderazgo en el desarrollo de modelos de última generación. Gemini 1 (2023) inauguró esta línea al ofrecer comprensión avanzada y enfoque multitarea. Posteriormente, Gemini 1.5 (2024) mejoró la eficiencia en la generación de texto, reduciendo tiempos de respuesta y mejorando la coherencia. Finalmente, Gemini 2.0 (2024) consolidó la apuesta más ambiciosa de Google al incorporar capacidades multimodales, permitiendo procesar texto, imágenes y datos estructurados en una arquitectura unificada (Gemini Team, 2024).

1.2.4.2 Open AI

La primera gran revolución de OpenAI llegó con GPT-2 en 2019, un modelo que logró generar texto coherente y fluido en tareas complejas gracias a sus 1.5 mil millones de parámetros, sentando las bases para el desarrollo de modelos de lenguaje más avanzados. A partir de allí, la evolución fue rápida y sostenida.

Con el lanzamiento de GPT-3 en 2020, consolidó su liderazgo al introducir un modelo con 175 mil millones de parámetros que llevó la generación de texto a un nuevo nivel de precisión y contextualización. Con gran capacidad para realizar tareas complejas y generar contenido convincente lo convirtió en un referente absoluto en el ámbito de los modelos generativos (Brown et al., 2020). Dos años después, con la versión GPT-3.5, se mejoraron aspectos clave como la precisión y el razonamiento, optimizando la interacción conversacional en aplicaciones como ChatGPT.

Luego llegó GPT-4 (2023), que rompió el paradigma al integrar capacidades multimodales, procesando tanto texto como imágenes en una arquitectura unificada. Este avance permitió mejorar significativamente el razonamiento lógico y la comprensión contextual, estableciendo un nuevo estándar en la generación de contenido automatizado. Posteriormente, la serie Omni (2024) amplió estas capacidades con modelos como GPT-4-o1 y GPT-4-o1mini, que optimizaron la eficiencia computacional y lograron una respuesta más rápida y precisa en entornos dinámicos (OpenAI, 2024).

1.2.4.3 META

Entre los primeros desarrollos de META se encuentran BART (2019), un modelo diseñado para tareas como la generación de resúmenes y la traducción automática, y RoBERTa (2019), una variante de BERT optimizada para tareas de comprensión de texto, que mejoró significativamente el rendimiento al extender el tiempo de entrenamiento y utilizar conjuntos de datos más amplios (Lewis et al., 2020).

Posteriormente, presentó RAG (2020), que combinó modelos generativos con mecanismos de recuperación de información, permitiendo generar respuestas fundamentadas en grandes volúmenes de datos. En 2022 lanzó OPT, un modelo de lenguaje autoregresivo que destacó por su enfoque en la generación coherente de textos largos, con una arquitectura eficiente para tareas de completado de secuencias.

Pero el mayor salto cualitativo llegó con la familia LLaMA, que representa el esfuerzo más ambicioso de Meta en el campo de los LLM. Desarrollados bajo un esquema de código abierto, LLaMA (2023) y su evolución LLaMA 2 (2023) se destacan por su enfoque en el uso eficiente de los recursos computacionales, logrando un equilibrio entre rendimiento y accesibilidad. Este enfoque permitió a la comunidad investigativa y empresarial aprovechar sus capacidades avanzadas, impulsando la innovación en el procesamiento del lenguaje natural y consolidando a Meta como un referente en la democratización de la inteligencia artificial (Touvron et al., 2023).

1.2.4.4 Anthropic

Anthropic ha centrado sus esfuerzos en el desarrollo de modelos de lenguaje orientados a la seguridad y la alineación ética, destacándose como una de las empresas más comprometidas en abordar los riesgos asociados con el uso de LLM. Su enfoque se ha basado en crear modelos que minimicen sesgos y generen respuestas seguras, evitando los problemas comunes de otros sistemas generativos.

El primer gran avance fue Claude 1 (2021), un modelo diseñado específicamente para priorizar la seguridad y la coherencia en las respuestas generadas, estableciendo un estándar en términos de alineación ética. Posteriormente, Claude 2 (2022) mejoró la capacidad de generar respuestas más precisas y controladas, optimizando tanto el rendimiento como la mitigación de sesgos.

La evolución continuó con Claude 3 y Claude 3.5 (2024), que introdujeron mejoras significativas en el procesamiento del lenguaje natural, consolidándose como herramientas versátiles capaces de responder a tareas complejas sin comprometer la seguridad. Estos desarrollos posicionaron a Anthropic como un referente en la creación de modelos alineados éticamente, capaces de enfrentar los desafíos contemporáneos del uso responsable de la IA (Anthropic, 2024).

1.2.4.5 BigScience

BigScience es una iniciativa colaborativa que agrupa a investigadores de diversas instituciones y empresas con el objetivo de desarrollar modelos de lenguaje de gran escala bajo un enfoque abierto y accesible. Su filosofía se basa en democratizar el acceso a tecnologías avanzadas de IA, promoviendo prácticas transparentes y éticas en la investigación y el desarrollo.

El mayor logro de esta iniciativa fue BLOOM (2022), un modelo de lenguaje de 176 mil millones de parámetros que se destacó por ser completamente de código abierto, permitiendo a la comunidad científica utilizarlo y mejorarlo sin restricciones. BLOOM fue diseñado para abordar tareas multilingües y generación de texto, demostrando un rendimiento competitivo frente a modelos comerciales cerrados. Esta propuesta estableció un precedente importante en la industria al fomentar la colaboración abierta y la responsabilidad compartida en el desarrollo de modelos de IA (BigScience Research Workshop, 2022).

El éxito de BLOOM consolidó a BigScience como un referente en la creación de modelos de gran escala accesibles para todos, abriendo nuevas posibilidades para la investigación académica y el desarrollo de aplicaciones prácticas en múltiples contextos.

1.2.4.6 Mistral

Mistral AI se posicionó rápidamente en el campo de los modelos de lenguaje de gran escala gracias a su enfoque en la eficiencia y el acceso abierto. Su estrategia estuvo marcada por el lanzamiento de modelos con arquitectura optimizada, priorizando el rendimiento computacional sin sacrificar precisión.

En 2023, presentó Mistral 7B, un modelo de 7 mil millones de parámetros diseñado para tareas de generación de lenguaje y comprensión contextual. Poco después, lanzó Mistral 12B, con 12.9 mil millones de parámetros, mejorando la capacidad de generación de texto con un enfoque abierto que fomentó su adopción por parte de comunidades de desarrolladores e investigadores (Mistral AI, 2023).

El compromiso de Mistral con el código abierto no solo democratizó el acceso a modelos avanzados, sino que también impulsó una comunidad colaborativa que sigue explorando aplicaciones innovadoras en diversos contextos.

1.2.4.7 Otras Iniciativas Relevantes

En paralelo a las grandes compañías que lideran el desarrollo de modelos de lenguaje de gran escala, existe una vasta diversidad de iniciativas que han contribuido significativamente al avance de la inteligencia artificial en los últimos años. Estas propuestas, impulsadas por gigantes tecnológicos, empresas emergentes y comunidades

open source, reflejan un ecosistema en constante evolución donde la innovación y la accesibilidad se combinan para ofrecer soluciones cada vez más sofisticadas.

La democratización del acceso a modelos de lenguaje ha permitido que múltiples actores desarrollen propuestas originales y competitivas, ampliando el horizonte de posibilidades en el uso práctico de la IA. Desde modelos diseñados para el análisis de grandes volúmenes de datos en China hasta alianzas estratégicas que integran capacidades generativas en herramientas de oficina, cada iniciativa aporta una perspectiva particular en la carrera por maximizar el potencial de los LLM.

Uno de los casos más relevantes es el de Microsoft, que a partir de su alianza con OpenAI creó Copilot, un asistente inteligente incorporado en herramientas como Word, Excel y PowerPoint. Copilot (2023) y, más tarde, su evolución Copilot X (2024), permiten generar contenido, resumir textos, automatizar tareas operativas, realizar análisis de datos y brindar asistencia contextual en tiempo real, todo dentro del flujo habitual de trabajo (Microsoft, 2023). Estas funciones buscan mejorar la eficiencia en el uso cotidiano de herramientas de oficina, sin requerir conocimientos técnicos por parte del usuario.

Anteriormente, Microsoft había colaborado con Nvidia en el desarrollo del modelo Megatron-Turing NLG (2021), con 530 mil millones de parámetros, orientado a tareas de generación de lenguaje natural a gran escala (Smith et al., 2022). Aunque no está integrado directamente en productos comerciales, representa un hito en la capacidad técnica de la compañía para construir y experimentar con modelos de gran escala en entornos empresariales.

China ha consolidado un ecosistema propio de desarrollo en inteligencia artificial, impulsado por grandes compañías tecnológicas que apuestan a construir modelos de lenguaje con estándares globales y aplicaciones concretas en el ámbito empresarial. Este enfoque combina inversiones estratégicas, acceso a grandes volúmenes de datos y un marco de desarrollo independiente de los principales actores occidentales.

Huawei fue una de las primeras en introducir modelos de gran escala con la serie PanGu, lanzada en 2021 y actualizada en 2023 con PanGu-Sigma, orientada a mejorar la precisión en tareas complejas, especialmente en sectores como finanzas e investigación (Zeng et al., 2021). Alibaba presentó en 2021 el modelo M6, de carácter multimodal (Lin et al., 2021), y más recientemente amplió su línea con la familia Qwen, cuyos últimos lanzamientos en 2025 continúan la evolución hacia tareas más avanzadas de generación de texto, programación y análisis de información. Baidu, por su parte, desarrolla la serie Ernie desde 2019, enfocada en comprensión semántica y generación de lenguaje, y en su versión más reciente, Ernie 4.5, incorporó capacidades multimodales para procesar texto, imágenes, audio y video en un único modelo (Sun et al., 2019). Finalmente, DeepSeek, una iniciativa emergente dentro del ecosistema chino, ha lanzado modelos como DeepSeek-V3 y DeepSeek-R1, orientados a ofrecer respuestas precisas en contextos complejos, con foco en aplicaciones empresariales (DeepSeek-AI, 2025).

Más allá de los grandes desarrolladores corporativos, el ecosistema de modelos de lenguaje se ha visto enriquecido por iniciativas de código abierto y propuestas colaborativas que buscan ampliar el acceso a estas tecnologías. Entre ellas, EleutherAI ha contribuido con modelos como GPT-Neo, GPT-J y GPT-NeoX, desarrollados entre 2021 y 2022 como alternativas abiertas a los modelos propietarios (Black et al., 2022). Estas propuestas han sido adoptadas por la comunidad investigadora y por proyectos independientes que requieren soluciones adaptables. En esta misma línea, Stability AI ha promovido el desarrollo de modelos de texto abiertos orientados a fomentar la innovación en entornos comunitarios y académicos.

También han surgido nuevos actores empresariales que apuntan a resolver desafíos específicos dentro del procesamiento de lenguaje natural. Cohere, con su serie de modelos Command R, se ha enfocado en optimizar tareas como generación, clasificación y extracción de texto, priorizando la eficiencia computacional (Cohere, 2025). Por su parte, AI21 Labs, una compañía con base en Israel, desarrolla la familia Jurassic, orientada a la generación de textos extensos y coherentes para aplicaciones comerciales y académicas (AI21 Labs, 2021).

Finalmente, la empresa xAI, fundada por Elon Musk en 2023, se propone integrar modelos de lenguaje dentro de un ecosistema tecnológico propio, con foco en aplicaciones empresariales y de consumo masivo. Aunque su desarrollo aún se encuentra en expansión, representa una apuesta estratégica por incorporar capacidades avanzadas de comprensión y generación de texto en plataformas tecnológicas ya consolidadas.

Estas iniciativas, tanto corporativas como independientes, muestran que el desarrollo de modelos de lenguaje no responde a un único enfoque tecnológico ni a un número limitado de actores. Por el contrario, conforman un ecosistema diverso y dinámico, donde confluyen estrategias empresariales, colaboración abierta e innovación aplicada. Esta variedad de propuestas permite ampliar los escenarios de uso de la inteligencia artificial, adaptándola a distintos contextos productivos, niveles de acceso y necesidades organizacionales.

1.2.5 Tendencias Futuras y Evolución de la IA

La inteligencia artificial avanza rápidamente y sigue ampliando sus capacidades, tanto en términos técnicos como en la manera en que se integra a distintos entornos. Este desarrollo no solo mejora lo que la tecnología ya puede hacer, sino que modifica la forma en que se construyen, distribuyen y utilizan los sistemas inteligentes.

En los próximos años, se espera una evolución que va más allá del rendimiento: se transforman los modelos, las formas de interacción con las personas, los marcos que regulan su uso y las condiciones para acceder a estas herramientas. Algunas tendencias ya están en marcha, otras empiezan a consolidarse.

En los apartados siguientes se presentan algunos de los principales cambios que se observan en el horizonte cercano, con foco en su impacto estructural y en los desafíos que plantean para las organizaciones que busquen incorporar estas tecnologías.

1.2.5.1 Tendencias Tecnológicas

El desarrollo de la inteligencia artificial no solo se ha caracterizado por su expansión en términos de aplicación, sino también por una transformación profunda en las tecnologías que la sustentan. Una de las principales tendencias es la evolución hacia modelos más pequeños y eficientes, capaces de ofrecer resultados comparables a los de modelos de gran escala, pero con menores requerimientos de procesamiento y consumo energético. Entre las técnicas utilizadas para lograrlo se destacan la destilación (distillation), que consiste en transferir el conocimiento de un modelo grande a uno más compacto sin perder precisión; la cuantización (quantization), que reduce la complejidad numérica de los datos procesados para mejorar la velocidad y disminuir el consumo de recursos; y el diseño de arquitecturas optimizadas, enfocadas en mantener el rendimiento con menor complejidad estructural (Wang & Jia, 2025).

Esta eficiencia ha facilitado el avance del procesamiento local o en el borde, conocido como edge computing, donde los modelos pueden ejecutarse directamente en dispositivos como teléfonos, sensores o terminales industriales. Esto reduce la dependencia de centros de datos, disminuye la latencia y mejora la privacidad, al mantener los datos cerca de su fuente de origen.

En paralelo, la IA generativa se ha consolidado como un punto de inflexión tecnológico. Más allá de su capacidad para crear textos, imágenes o código, representa un cambio en la forma en que las personas interactúan con las máquinas, delegando no solo tareas operativas, sino también funciones relacionadas con la toma de decisiones y la producción de conocimiento. Este tipo de sistemas ya no se limitan a responder a una instrucción específica, sino que comienzan a operar de manera más abierta y flexible, participando activamente en procesos creativos, analíticos y de planificación.

Este avance ha dado lugar al surgimiento de agentes de IA (AI Agents), sistemas capaces de razonar, planificar y ejecutar secuencias de acciones de forma autónoma. Estos agentes no solo generan contenido o respuestas, sino que son capaces de operar con múltiples objetivos, tomar decisiones en contextos complejos y actuar sobre diferentes entornos digitales sin intervención humana constante (Deloitte, 2024). Si bien todavía se encuentran en etapas tempranas, representan una dirección clara en la evolución de la autonomía de los sistemas inteligentes.

Otro aspecto central es la creciente sofisticación de los modelos multimodales, que combinan distintos formatos, como texto, imágenes, audio y video, en una única arquitectura. Esta convergencia tecnológica permite interpretar y generar información compleja de manera integrada, ampliando significativamente el alcance de los modelos para enfrentar tareas que antes requerían múltiples sistemas especializados.

Al mismo tiempo, se observa una tendencia hacia modelos que pueden adaptarse o personalizarse de manera dinámica, ajustándose a los datos o necesidades particulares de cada usuario o entorno sin requerir reentrenamiento completo. Estas capacidades de aprendizaje incremental y fine-tuning localizado abren nuevas posibilidades para contextos donde se requiere adaptación constante o mayor privacidad en el tratamiento de datos.

Finalmente, el ecosistema técnico también ha evolucionado hacia estructuras más abiertas. La proliferación de modelos de código abierto y de interfaces estandarizadas ha ampliado el acceso a estas tecnologías, permitiendo que distintos actores (empresas, gobiernos y comunidades), puedan experimentar, adaptar e implementar soluciones sin depender exclusivamente de proveedores cerrados. Esta apertura promueve la interoperabilidad, estimula la innovación y sienta las bases para una adopción más democrática de la inteligencia artificial (Microsoft News, 2025).

1.2.5.2 Colaboración, Autonomía y Confianza

La evolución de la inteligencia artificial está redefiniendo la forma en que se toman decisiones en entornos organizacionales, técnicos y sociales. En lugar de actuar como herramientas puntuales, los sistemas de IA se están consolidando como asistentes cognitivos, capaces de participar en la resolución de problemas complejos, ofrecer recomendaciones estratégicas o detectar patrones que antes pasaban desapercibidos. Esta transformación impulsa un nuevo modelo de interacción, donde humanos y máquinas colaboran en la construcción de conocimiento y la gestión de tareas.

Este enfoque, conocido como IA aumentativa (augmented intelligence), no busca reemplazar a las personas, sino potenciar sus capacidades. En contextos como la medicina, el derecho o la ingeniería, la IA puede analizar grandes volúmenes de información y presentar alternativas que complementen la experiencia del profesional. Del mismo modo, en procesos administrativos o de gestión, los sistemas inteligentes permiten automatizar decisiones rutinarias y liberar tiempo para tareas de mayor valor agregado (Davenport & Ronanki, 2018).

Sin embargo, a medida que los sistemas ganan autonomía, también se vuelve central el debate sobre la confianza. La aparición de modelos capaces de actuar con mayor independencia, como los agentes de IA (AI agents), plantea el desafío de entender y controlar cómo y por qué toman decisiones. Esto ha dado lugar a un campo creciente de investigación en IA explicable (explainable AI o XAI), que busca desarrollar mecanismos para que los modelos puedan justificar sus resultados de forma comprensible para los usuarios (Gunning & Aha, 2019). Esta capacidad no solo es clave en términos técnicos, sino también éticos y legales, especialmente cuando las decisiones afectan directamente a personas.

La colaboración efectiva entre humanos y sistemas inteligentes requerirá, en adelante, no solo capacidad tecnológica, sino también marcos de supervisión, diseño responsable y construcción de confianza. En este escenario, la inteligencia artificial ya no es solo una herramienta operativa, sino que se convierte en un actor más dentro de los procesos de análisis, decisión y acción.

1.2.5.3 Gobernanza, Riesgos y Regulación

A medida que los sistemas de IA se integran en procesos críticos, desde decisiones financieras hasta sistemas de salud, justicia o seguridad, emergen preocupaciones vinculadas a la gobernanza (AI governance), entendida como el conjunto de principios, marcos y mecanismos necesarios para guiar su desarrollo y aplicación de manera segura, ética y responsable.

Uno de los principales riesgos es la opacidad de los modelos (black-box models), que dificulta entender cómo se toman ciertas decisiones, especialmente en sistemas complejos como las redes neuronales profundas. Esto puede comprometer la rendición de cuentas cuando los resultados afectan directamente a personas o instituciones. Además, el uso de grandes volúmenes de datos conlleva riesgos de violación de la privacidad (privacy breaches) y sesgos algorítmicos (algorithmic bias), que pueden amplificar desigualdades existentes si no se abordan adecuadamente en el diseño y entrenamiento de los modelos (Smuha, 2021).

Frente a estos desafíos, distintos organismos internacionales, gobiernos y comunidades técnicas han comenzado a desarrollar marcos regulatorios que buscan establecer límites claros al uso de la IA. La Unión Europea, por ejemplo, ha impulsado una propuesta integral con el AI Act, centrada en una clasificación de riesgos y en la exigencia de transparencia, supervisión humana y trazabilidad (European Commission, 2021). Otras iniciativas, como las promovidas por la UNESCO o el G7, apuntan a establecer principios globales que articulen innovación tecnológica con derechos humanos y equidad (UNESCO, 2021).

En este contexto, el concepto de regulación proactiva (proactive regulation) se vuelve clave: no se trata solo de limitar los usos indebidos, sino de crear condiciones estructurales que orienten el desarrollo de la IA hacia el bien común. Para las organizaciones que adoptan estas tecnologías, el desafío será operar en un entorno donde la confianza, la trazabilidad y la responsabilidad no sean opcionales, sino condiciones necesarias para su legitimidad y sostenibilidad.

1.2.5.4 Acceso, Equidad y Sostenibilidad

El crecimiento exponencial de la inteligencia artificial ha generado oportunidades sin precedentes, pero también ha puesto en evidencia desigualdades de acceso que podrían profundizar las brechas existentes entre organizaciones, países y sectores productivos.

La posibilidad de implementar soluciones basadas en IA depende, en muchos casos, de contar con infraestructura adecuada, capacidades técnicas, disponibilidad de datos y recursos económicos suficientes. En este sentido, existe un riesgo real de que la IA, lejos de democratizar el acceso a la tecnología, consolide una nueva forma de concentración si no se diseñan estrategias inclusivas (Vinuesa et al., 2020).

Frente a este escenario, se ha intensificado el desarrollo de modelos de código abierto (open-source models) y herramientas accesibles que permitan a organizaciones más pequeñas, incluidas las Pymes, incorporar capacidades de IA sin depender de plataformas cerradas o inversiones desproporcionadas. La expansión de modelos más eficientes y ejecutables localmente contribuye en esta dirección, reduciendo la barrera de entrada y favoreciendo una adopción más equitativa.

En paralelo, la sostenibilidad ambiental se ha convertido en un aspecto crítico del debate. El entrenamiento de modelos de gran escala implica un consumo energético elevado y una huella de carbono significativa (Strubell et al., 2019). Este problema ha llevado a la comunidad técnica a trabajar en técnicas de optimización, reutilización de modelos e infraestructuras más eficientes. Al mismo tiempo, la IA también se está utilizando para abordar desafíos ambientales, como la gestión inteligente de energía, la agricultura de precisión o el monitoreo del cambio climático, lo que abre un doble frente de acción: reducir su impacto y contribuir activamente a soluciones sostenibles.

Garantizar que la IA sea una herramienta al servicio de un desarrollo más inclusivo y sostenible será uno de los desafíos centrales en los próximos años. Para ello, no solo se requerirá innovación técnica, sino también voluntad política, marcos de colaboración y un compromiso real con la equidad.

1.2.6 Conclusiones

La inteligencia artificial ha evolucionado con rapidez y sigue avanzando a un ritmo que pone en tensión la capacidad de adaptación de las organizaciones, los marcos normativos y los equipos de trabajo. Lo que hasta hace pocos años se encontraba en el ámbito de la investigación especializada hoy forma parte de herramientas que se usan en contextos cotidianos, tanto en empresas como en servicios públicos o en el consumo personal. Esta expansión no responde solo al progreso técnico, sino también a cambios en la forma en que se produce, se accede y se utiliza la tecnología.

En este capítulo se presentó un recorrido general sobre el desarrollo de la inteligencia artificial, desde sus primeras aproximaciones formales hasta los modelos actuales y las principales tendencias que definen su evolución. Cada etapa trajo consigo nuevos enfoques: desde las primeras reglas explícitas hasta los modelos capaces de aprender con grandes volúmenes de datos, y más recientemente, los modelos generativos y multimodales que amplían el tipo de tareas que la IA puede abordar.

La inteligencia artificial actual no se limita a ejecutar instrucciones. Interviene en la toma de decisiones, colabora con las personas en procesos de análisis y planificación, y permite automatizar operaciones que antes requerían intervención humana directa. Esto plantea oportunidades, pero también obliga a revisar cómo las organizaciones diseñan sus estructuras, desarrollan capacidades y toman decisiones sobre la adopción tecnológica.

Uno de los desafíos más importantes es la velocidad con la que se producen los cambios. Esta aceleración supera en muchos casos los tiempos habituales de actualización institucional, de formación profesional y de adopción tecnológica. Esto no solo afecta a las empresas, sino también a los marcos legales, a las políticas públicas y a las expectativas de la sociedad en relación con el uso responsable de estas herramientas.

La evolución técnica también plantea nuevas exigencias. El avance de modelos más autónomos, el uso combinado de múltiples formatos de información y la incorporación de la IA en sistemas críticos hacen que la transparencia, la trazabilidad y la supervisión humana sean elementos cada vez más relevantes. A esto se suman preocupaciones sobre la equidad en el acceso a estas tecnologías y sobre su impacto ambiental, especialmente en lo que respecta al uso intensivo de recursos y a la concentración de capacidades en pocos actores.

El futuro de la inteligencia artificial se perfila como un escenario en el que convergen posibilidades de transformación y desafíos estructurales. Más allá de los avances técnicos, lo que está en juego es la capacidad de las organizaciones, y de la sociedad en su conjunto, para incorporar estas tecnologías de manera efectiva, responsable y sostenible.

En el próximo capítulo se abordará el contexto específico de las pequeñas y medianas empresas en Argentina, su rol económico, las condiciones estructurales que enfrentan y el estado actual de su transformación digital. Esta caracterización permitirá entender en qué medida las PYMEs están preparadas para incorporar tecnologías basadas en IA y qué desafíos deben superar para hacerlo de manera efectiva y sostenible.

CAPÍTULO 2: LAS PYMES EN EL CONTEXTO TECNOLÓGICO ACTUAL

2.1. Panorama Actual de las Pymes en Argentina

Las Pequeñas y Medianas Empresas (Pymes) cumplen un rol fundamental en la economía y sociedad argentina. Representan más del 99% de las empresas del país, generan alrededor del 65% del empleo privado registrado y aportan cerca del 42% del Producto Interno Bruto (PIB) (Secretaría de la Pequeña y Mediana Empresa, los Emprendedores y la Economía del Conocimiento [SPMEEEDC], 2024; Rojo et al., 2022). Su importancia económica y social es indiscutible.

A pesar de esto, el número total de PYMEs se ha mantenido prácticamente estancado en las últimas dos décadas, en un rango de entre 520 y 600 mil unidades. Cada año nacen cerca de 70 mil nuevas empresas, pero una cantidad similar desaparece, anulando cualquier intento de crecimiento.

Para reforzar esta tendencia, los datos del Banco Mundial muestran que la tasa de creación de nuevas empresas en Argentina es considerablemente baja en comparación con otros países de la región. El indicador de Densidad de Nuevas Empresas (registros nuevos por cada 1.000 habitantes de entre 15 y 64 años) (Banco Mundial, 2024) posiciona a Argentina con 0,2 nuevas empresas por cada 1.000 habitantes (dato de 2018), muy por debajo de Brasil (5,1 en 2022), Colombia (2,3 en 2022) y Chile (10,3 en 2022). A la fecha de elaboración de este documento, estos son los últimos datos publicados por el Banco Mundial, destacándose especialmente el rezago de Argentina en 2018. Esta información está en línea con la presentada por la Fundación Observatorio PyME en su conferencia Biental 2022 (Fundación Observatorio PyME [FOP], 2022).

A su vez, las PYMEs enfrentan brechas estructurales significativas en comparación con las grandes empresas. Entre ellas, se destacan menores niveles de productividad, menor capacidad de innovación y mayores dificultades para acceder a financiamiento y mercados internacionales. Mientras que las grandes compañías cuentan con recursos para invertir en tecnología e infraestructura, las PYMEs operan con limitaciones que restringen su crecimiento y competitividad.

Además, el sector PyME es altamente heterogéneo. Mientras algunas empresas muestran un fuerte dinamismo e innovación, otras luchan por mantenerse operativas, lo que en gran medida explica las fluctuaciones en las tasas de aperturas y cierres mencionadas.

A pesar de estos desafíos, las PYMEs cuentan con ventajas competitivas clave. Su menor tamaño y estructura les otorgan una gran flexibilidad, permitiéndoles adaptarse con rapidez a los cambios del entorno, tomar decisiones ágiles y responder eficientemente a nuevas oportunidades. Este dinamismo, sumado a su cercanía con clientes y

proveedores, les facilita establecer relaciones más personalizadas y explorar nichos de mercado que suelen quedar fuera del alcance de las grandes corporaciones.

Este capítulo tiene como objetivo ofrecer una visión actualizada de las PYMEs en Argentina y su evolución en las últimas dos décadas, en un contexto donde han debido enfrentar un escenario desafiante para su desarrollo, reflejado en los indicadores analizados previamente.

2.1.1. Definiciones y Clasificación

La clasificación de las PYMEs no es unívoca, ya que existen distintos criterios según el contexto del análisis que se trate.

De acuerdo con la Secretaría de la Pequeña y Mediana Empresa, los Emprendedores y la Economía del Conocimiento (SPMEEEDC, 2024), se define como empresa a toda unidad económica, ya sea persona humana o jurídica, con fines de lucro y que contrate personal. Según esta definición, una empresa deja de ser considerada parte del universo PYME si deja de tener empleados, aunque esto no signifique necesariamente que haya cesado sus operaciones.

Desde una perspectiva operativa y económica, se suele adoptar el criterio propuesto por Rojo et al. (2022), que clasifica a las empresas según su cantidad de empleados de la siguiente manera:

- Microempresa: 1 a 9 empleados
- Pequeña empresa: 10 a 49 empleados
- Mediana empresa: 50 a 199 empleados
- Gran empresa: 200 empleados o más

Sin embargo, a nivel legal y administrativo, una empresa es considerada PYME cuando está inscrita en el Registro MiPyME, creado por la Resolución N° 220 de la ex Secretaría de Emprendedores y de la Pequeña y Mediana Empresa (12 de abril de 2019) (RegistroPyme, 2024) .

Para su inscripción en este registro, las empresas deben clasificarse primero según su actividad principal, dentro de los siguientes sectores:

- ✓ Construcción
- ✓ Servicios
- ✓ Comercio
- ✓ Industria y Minería
- ✓ Agropecuario

A su vez, cada uno de estos sectores se subdivide en actividades más específicas, lo que determina el rubro detallado en el que la empresa debe registrarse.

En este marco normativo, las PYMEs se clasifican principalmente según sus niveles de facturación, cuyos montos se actualizan periódicamente para reflejar la inflación y la realidad económica. Sin embargo, en algunos casos específicos y dentro de ciertos subgrupos de actividad, la clasificación no se realiza por niveles de facturación sino por cantidad de empleados o por activos de la empresa (RegistroPyme, 2024).

Esta categorización tiene un impacto directo en la aplicación de beneficios fiscales, acceso a financiamiento y políticas públicas diseñadas para el sector PYME.

A diciembre de 2024, el cuadro de clasificación de PYMEs según nivel de facturación es el siguiente (RegistroPyme, 2024)

Categoría	Construcción	Servicios	Comercio	Industria y Minería	Agropecuario
Micro	208.401.000	91.494.000	599.483.000	435.869.000	316.630.000
Pequeña	1.236.557.000	551.596.000	4.270.323.000	3.256.865.000	1.166.340.000
Mediana Tramo1	6.899.145.000	4.565.365.000	20.297.829.000	23.180.330.000	6.863.946.000
Mediana Tramo2	10.347.579.000	6.520.009.000	28.997.100.000	46.835.799.000	10.886.680.000

Estos valores se actualizan periódicamente para reflejar las variaciones inflacionarias, lo que permite mantener una clasificación acorde con la realidad económica del país.

Con el objetivo de facilitar comparaciones internacionales y obtener un valor referencial en moneda estable, se construyó una tabla con los montos expresados en dólares estadounidenses (USD), utilizando un tipo de cambio promedio de 1.200 \$/USD (diciembre 2024).

Categoría	Construcción	Servicios	Comercio	Industria y Minería	Agropecuario
Micro	173.668	76.245	499.569	363.224	263.858
Pequeña	1.030.464	459.663	3.558.603	2.714.054	971.950
Mediana Tramo1	5.749.288	3.804.471	16.914.858	19.316.942	5.719.955
Mediana Tramo2	8.622.983	5.433.341	24.164.250	39.029.833	9.072.233

2.1.2. Contexto Pyme: 2007-2023



Como mencionamos anteriormente, entre 2007 y 2023, la cantidad de empresas PYMEs en Argentina no mostró una tendencia clara de crecimiento. A lo largo de estos casi 20 años, el stock de empresas se mantuvo fluctuando dentro de un rango acotado, entre 520.000 y 600.000 unidades, sin lograr un avance sostenido en el tiempo.

Si bien pueden identificarse ciclos de crecimiento, estancamiento y caída, la tendencia predominante en el largo plazo es la del estancamiento estructural del sector.

En 2007, el stock de PYMEs se situaba en 545,9 mil unidades. A partir de ese momento, se observa un período de crecimiento sostenido hasta 2013, cuando se alcanzó el máximo histórico de 595,6 mil empresas. Esto representa un aumento neto del 9% en seis años, equivalente a un crecimiento promedio anual del 1,5% acumulativo.

A partir de 2013, se inicia una etapa de estancamiento, con valores prácticamente constantes hasta 2017. Sin embargo, a partir de ese año, la cantidad de empresas comenzó un declive sostenido, alcanzando su nivel más bajo en 2021, con 518,3 mil unidades. En los dos años siguientes, se produjo una recuperación parcial, cerrando 2023 con 549,1 mil PYMEs, un valor casi idéntico al de 2007.

Esta evolución se puede observar con mayor detalle en los siguientes gráficos, que permiten visualizar claramente las fluctuaciones del stock de PYMEs a lo largo del período analizado:



Si bien a lo largo del período pueden identificarse tendencias de corto plazo de entre cuatro y cinco años con variaciones positivas o negativas, el aspecto más relevante desde


el punto de vista del desarrollo económico nacional es la ausencia de una tendencia clara de crecimiento en el largo plazo.

Dada la importancia de las PYMEs en la economía argentina, esta evolución está estrechamente relacionada con el desempeño económico del país en el mismo período.

2.1.3. Dinámica Demográfica

Además de analizar la evolución del stock total de PYMEs, resulta clave comprender la dinámica de creación y destrucción de empresas a lo largo del período, es decir, qué tan dinámico ha sido el ecosistema empresarial en Argentina. Para ello, es fundamental observar métricas como la cantidad de aperturas y cierres de empresas, así como la proporción de nuevas empresas sobre el total del universo PYME.

El siguiente gráfico (SPMEEEDC, 2024) muestra la evolución trimestral de aperturas y cierres de empresas PYMEs entre 2008 y 2023, junto con el saldo neto resultante.




Como se observa, los flujos de aperturas y cierres explican los movimientos del stock de empresas analizados en la sección anterior. Se pueden identificar cuatro grandes etapas:

- ✓ 2008-2013: Predominio de aperturas sobre cierres, con un saldo neto positivo.
- ✓ 2014-2017: Etapa de estabilidad, donde los nacimientos de empresas apenas logran compensar los cierres.
- ✓ 2018-2021: Período de crisis, donde los cierres superan ampliamente a las aperturas, generando un saldo neto negativo. En 2020 se alcanza el peor registro de destrucción de empresas del período.

- ✓ 2022-2023: Recuperación parcial con saldo neto positivo, aunque sin una tendencia clara de crecimiento sostenido.

Complementariamente, resulta útil examinar el peso relativo de las nuevas empresas sobre el total de PYMEs. El siguiente gráfico (SPMEEEDC, 2024) muestra la evolución de la cantidad de empresas nuevas cada año y su proporción respecto al stock total de empleadoras.



En 2018, el 15,3% del total de PYMEs eran empresas creadas ese mismo año, lo que equivale a 87.000 nuevas empresas. Durante el período de estabilidad 2012-2017, la creación de nuevas empresas se mantuvo en torno a 70.000 por año, representando aproximadamente el 12% del stock total.

Sin embargo, a partir de 2018, comienza un fuerte descenso, primero en la cantidad de aperturas y luego en los cierres. Esto generó el saldo negativo que explicamos anteriormente. La caída más pronunciada se dio en 2020, reflejando el impacto de la crisis económica y la pandemia.

En 2021-2023, se observa una recuperación parcial, alcanzando en 2023 un 12,3% de nuevas empresas, aunque aún por debajo de los niveles previos al declive.

Esta dinámica, sin una tendencia clara de crecimiento a lo largo del tiempo, ha llevado a Argentina a una posición desventajosa frente a otros países en términos de densidad empresarial. La siguiente tabla (FOP, 2022) muestra el stock de empresas por cada 100.000 habitantes en distintos países seleccionados.

País	Stock Empresas	Fuente
Australia	9.984	Australian Bureau of Statistics (Australia, 2021)
Países Bajos	7.978	EuroStat (Países Bajos, 2020)
Chile	6.696	Servicio de Impuestos Internos (Chile, 2020)
Uruguay	5.032	Instituto Nacional de Estadística (Uruguay, 2020)
México	3.763	Instituto Nacional de Estadística y Geografía (México, 2019)
Brasil	2.219	Instituto Brasileiro de Geografia e Estatística (Brasil, 2019)
Argentina	1.195	Observatorio de Empleo y Dinámica Empresarial (Argentina, 2021)

Como se observa, Argentina se encuentra rezagada en comparación con economías regionales y globales, lo que refuerza la necesidad de generar un entorno más propicio para la creación y sostenibilidad de nuevas empresas.

2.1.4. Escenario Actual: Año 2023

La estructura de las PYMEs argentinas se caracteriza por una marcada predominancia de las microempresas, como muestran las últimas estadísticas publicadas por la SPMEEDC (2024). De las 549.062 empresas registradas en el país en el año 2023, un 85,2% corresponden a microempresas (alrededor de 467.721 unidades), mientras que un 12,3% son pequeñas empresas (67.740 unidades) y apenas un 2,5% son empresas medianas (13.601 unidades).

La siguiente tabla muestra la cantidad de empresas PYMEs en cada categoría, desagregada por los principales sectores de actividad, medida en miles de unidades. Como se observa, en todos los rubros las microempresas representan la gran mayoría de los establecimientos productivos.

Categoría	Servicio	Comercio	Industria y Minería	Agro-pecuario	Cons-trucción	Total
Micro	178,3	165,8	46,7	56,3	20,6	467,7
Pequeña	23,1	18,4	15,2	5,1	6,0	67,8
Mediana	5,4	2,4	3,8	0,6	1,4	13,6
TOTAL	206,8	186,6	65,7	62,0	28,0	549,1

Si bien estos datos permiten dimensionar el volumen de empresas en cada sector, resulta interesante analizar qué participación tienen cada tipo de empresa dentro de su rubro. La siguiente tabla muestra la distribución relativa, permitiendo visualizar con mayor claridad la preponderancia de las microempresas en cada sector y la presencia relativa de pequeñas y medianas empresas en actividades más capital-intensivas.

Categoría	Servicio	Comercio	Industria y Minería	Agro-pecuario	Cons-trucción	Total
Micro	86,2%	88,9%	71,1%	90,8%	73,6%	85,2%
Pequeña	11,2%	9,9%	23,1%	8,2%	21,4%	12,3%
Mediana	2,6%	1,3%	5,8%	1,0%	5,0%	2,5%

Como se puede observar, las microempresas representan la gran mayoría en todos los sectores, pero su peso es particularmente alto en los rubros de Servicios y Comercio, donde superan ampliamente el 80% del total de empresas registradas. En contraste, en los sectores de Industria y Minería y Construcción, la participación de empresas pequeñas y medianas es relativamente mayor, reflejando estructuras productivas que requieren mayores niveles de inversión.

Al analizar la composición sectorial de las PYMEs, se observa que los sectores de Servicios y Comercio concentran más del 71% del total de empresas en Argentina. Esta concentración es aún más pronunciada en el caso de las microempresas, mientras que en las categorías de pequeñas y medianas empresas, el peso de los sectores de Industria y Minería, Construcción y Agropecuario es algo mayor.

La siguiente tabla refleja esta distribución sectorial y permite ver cómo la concentración en determinados sectores varía según la categoría de empresa.

Categoría	Servicio	Comercio	Industria y Minería	Agro-pecuario	Cons-trucción	Total
Micro	38,1%	35,5%	10,0%	12,0%	4,4%	100,0%
Pequeña	34,1%	27,1%	22,4%	7,5%	8,8%	100,0%
Mediana	39,7%	17,6%	27,9%	4,4%	10,3%	100,0%
TOTAL	37,7%	34,0%	12,0%	11,3%	5,1%	100,0%

La distribución territorial de las PYMEs en Argentina muestra una marcada concentración en las principales provincias del país. En 2023, cuatro jurisdicciones concentraban cerca del 70% del total de unidades productivas, con una presencia destacada en la provincia de Buenos Aires (32,3%), seguida por la Ciudad Autónoma de Buenos Aires (17,2%), Córdoba (10,4%) y Santa Fe (9,5%).

Esta fuerte centralización del empleo y la actividad productiva resalta el peso económico de estas regiones y las disparidades territoriales en el desarrollo empresarial del país.

2.1.5. Resumen y Perspectivas

A lo largo de este capítulo hemos explorado la evolución y la estructura actual de las PYMEs en Argentina, analizando su comportamiento en las últimas dos décadas. El

diagnóstico es claro: el ecosistema PYME en el país se encuentra en un estado de estancamiento estructural, con períodos de crecimiento y contracción, pero sin una tendencia sostenida que impulse su desarrollo a largo plazo.

Más allá de los números, este análisis revela una realidad más profunda. Las PYMEs son el motor de la economía nacional, pero su expansión se ve condicionada por un entorno desafiante. La dinámica de aperturas y cierres de empresas refleja la fragilidad de un sector que, pese a su resiliencia, encuentra dificultades para consolidarse y crecer.

Además, la estructura del tejido empresarial argentino está marcada por una fuerte predominancia de las microempresas, cuya alta concentración en sectores como Servicios y Comercio sugiere una economía orientada hacia actividades de menor escala productiva. Al mismo tiempo, la distribución territorial de las PYMEs pone en evidencia una centralización del empleo y la actividad productiva en pocas regiones, lo que profundiza las desigualdades en el desarrollo empresarial del país.

Si bien estos desafíos presentan obstáculos evidentes, también trazan el camino de lo que será clave para el futuro del sector. En este contexto de estancamiento y dificultades estructurales, la transformación digital surge como una oportunidad para que las PYMEs fortalezcan su competitividad y superen muchas de las barreras que históricamente han limitado su crecimiento. A través de la adopción de nuevas tecnologías, muchas empresas han logrado optimizar procesos, ampliar su alcance y mejorar su eficiencia, demostrando que la digitalización no es solo un cambio operativo, sino una herramienta estratégica para la sostenibilidad y expansión del sector.

En el próximo capítulo exploraremos la madurez digital de las PYMEs en Argentina, entendiendo su nivel actual de adopción tecnológica y las oportunidades que la digitalización puede ofrecerles para fortalecer su competitividad y sostenibilidad en el mercado.

2.2 La Transformación Digital en las PYMEs

En un mundo cada vez más interconectado, la transformación digital se ha convertido en un factor decisivo para la competitividad de las empresas. Desde pequeñas startups hasta grandes corporaciones, la digitalización ha permitido automatizar procesos, optimizar costos, mejorar la relación con clientes y ampliar mercados de manera exponencial.

Las herramientas digitales, como los sistemas de gestión (ERP y CRM), el comercio electrónico, la analítica de datos y la inteligencia artificial, han redefinido la manera en que las empresas operan. La posibilidad de tomar decisiones basadas en datos en tiempo real, mejorar la eficiencia operativa y alcanzar audiencias globales ha sido clave en la evolución del sector productivo.

Para las PYMEs, la digitalización representa una gran oportunidad para competir en igualdad de condiciones con empresas más grandes. En sectores como el comercio minorista, la incorporación de plataformas de venta online permitió que pequeños negocios pudieran expandir su alcance sin necesidad de contar con grandes estructuras físicas. En la industria manufacturera, la automatización de procesos ha logrado reducir costos y aumentar la productividad. En el sector agroindustrial, la digitalización ha permitido la aplicación de tecnologías de monitoreo de cultivos y optimización de recursos.

Sin embargo, el proceso de transformación digital no ocurre de manera uniforme en todas las empresas. Mientras que algunas han logrado adaptarse con rapidez, otras enfrentan barreras estructurales que dificultan su integración tecnológica. La falta de financiamiento, la escasez de talento digital y las desigualdades en infraestructura tecnológica son algunos de los factores que explican por qué muchas PYMEs aún operan bajo esquemas tradicionales.

Este capítulo analiza el estado actual de la digitalización en las PYMEs argentinas, identificando los principales desafíos que enfrentan, los factores que impulsan su transformación y las oportunidades que ofrece la tecnología. A lo largo de las siguientes secciones, se explorará qué empresas logran digitalizarse, cómo se compara Argentina con otros países de la región y qué estrategias pueden acelerar este proceso.

2.2.1. Panorama actual: barreras y oportunidades

Si bien la transformación digital ha sido una herramienta clave para mejorar la productividad y competitividad de las empresas en todo el mundo, su adopción en las PYMEs argentinas ha sido dispar. Mientras que algunas han logrado integrar tecnología con éxito en sus procesos, muchas otras aún enfrentan barreras que dificultan su digitalización.

Según la FOP (2021), más del 50% de las PYMEs del país han intensificado o iniciado el uso de herramientas digitales en los últimos años, aunque el grado de adopción varía según el sector, la región y el tamaño de la empresa. Mientras que algunas han incorporado automatización, comercio electrónico o software de gestión, otras aún operan con esquemas tradicionales.

A nivel regional, Argentina se encuentra en una posición intermedia en digitalización de PYMEs. De acuerdo con la CEPAL (2020), países como Chile y Uruguay han implementado estrategias de digitalización más estructuradas, con marcos regulatorios sólidos y programas de financiamiento específicos. Si bien Argentina ha avanzado en conectividad y digitalización gubernamental, el sector productivo aún enfrenta desafíos estructurales que condicionan la adopción tecnológica, lo que abre el debate sobre cómo facilitar este proceso y acelerar su impacto en la economía

2.2.1.1 Principales barreras para la digitalización en las PYMEs

A pesar del potencial de la digitalización, las PYMEs argentinas aún enfrentan obstáculos que dificultan su transformación tecnológica.

1. Falta de financiamiento

El acceso al crédito sigue siendo una de las principales dificultades. Mientras que las grandes empresas pueden acceder a líneas de financiamiento específicas para innovación y tecnología, muchas PYMEs no tienen recursos suficientes para invertir en digitalización. Según el Banco Mundial (2023), la falta de acceso a crédito es una de las principales causas del rezago tecnológico en el sector.

2. Brecha de talento digital

Muchas PYMEs no cuentan con empleados capacitados en herramientas digitales ni con acceso a formación en nuevas tecnologías. Según la CAF (2023), menos del 25% de las PYMEs ha implementado programas de capacitación digital en los últimos dos años, lo que limita su capacidad de competir con empresas más avanzadas tecnológicamente.

3. Desigualdad en acceso a conectividad e infraestructura digital

El acceso a internet de alta velocidad y servicios tecnológicos es desigual en Argentina. Mientras que en los principales centros urbanos la mayoría de las empresas cuentan con buena conectividad, en las regiones del interior la cobertura es deficiente y más costosa. Según la CEPAL (2024), el 95% de las PYMEs en grandes ciudades tiene acceso a internet de calidad, mientras que en zonas rurales este porcentaje cae por debajo del 55%.

4. Resistencia al cambio y cultura organizacional

Más allá de los factores externos, uno de los principales obstáculos es la mentalidad de muchas PYMEs hacia la transformación digital. Muchas empresas siguen viendo la digitalización como un costo en lugar de una inversión, lo que las lleva a posponer la adopción de herramientas digitales. En sectores más tradicionales o en empresas familiares, la falta de una cultura orientada a la innovación ralentiza los procesos de modernización.

2.2.1.2 Los beneficios de la digitalización en las PYMEs

Si bien las barreras mencionadas siguen limitando la adopción de tecnología en muchas empresas, las PYMEs que logran superar estos obstáculos obtienen beneficios significativos en términos de rentabilidad, eficiencia operativa y expansión de mercado.

El uso de herramientas digitales permite optimizar costos, reducir tiempos de producción y mejorar la toma de decisiones. La implementación de software de gestión, por ejemplo,

permite automatizar tareas administrativas, evitando errores y optimizando la planificación de recursos. En el sector manufacturero, la digitalización de procesos productivos ha demostrado incrementar la eficiencia y reducir desperdicios.

Un ejemplo de esto es Premecol, una empresa argentina del sector de la construcción que logró aumentar un 20% su producción tras digitalizarse. Implementó un sistema de automatización industrial que conectó sus máquinas a internet para mejorar la eficiencia y reducir costos operativos (Somos PYMEs, 12 de febrero de 2024). Sin embargo, su proceso de transformación no fue inmediato: enfrentó dificultades para acceder a financiamiento y tuvo que invertir en capacitación de su equipo para aprovechar las nuevas herramientas digitales.

Por otro lado, en sectores como el comercio y los servicios, la digitalización ha permitido expansión de ventas y mayor cercanía con los clientes. Social Lunch, una plataforma de gestión de pedidos en el sector gastronómico, logró automatizar sus procesos administrativos y optimizar la logística de entrega, reduciendo costos y mejorando su nivel de servicio (Somos PYMEs, 14 de febrero de 2024).

Incluso en mercados más tradicionales, las PYMEs que logran incorporar herramientas de análisis de datos y automatización han visto mejoras sustanciales. En la industria textil, por ejemplo, empresas que han integrado gestión de inventario digital y plataformas de e-commerce han logrado expandir su alcance a clientes fuera del país, superando barreras geográficas y accediendo a nuevos mercados.

Estos casos demuestran que la digitalización no solo es un factor de modernización, sino una estrategia clave para el crecimiento sostenible de las PYMEs.

2.2.1.3 Oportunidades para el futuro

A pesar de las dificultades, el avance de la transformación digital es inevitable. En un entorno cada vez más competitivo y tecnológico, las PYMEs que logren adaptarse tendrán más oportunidades de crecimiento, mientras que aquellas que posterguen su digitalización corren el riesgo de quedar rezagadas.

Para aprovechar este cambio, es clave superar las barreras estructurales mediante:

- ✓ Mayor acceso a financiamiento para digitalización.
- ✓ Programas de capacitación en herramientas digitales.
- ✓ Mejor infraestructura tecnológica y conectividad en todo el país.

El impacto de la digitalización en las PYMEs ya es evidente en varios sectores. La clave para acelerar este proceso es fortalecer las condiciones que permitan su adopción masiva, generando un ecosistema donde la innovación no sea una excepción, sino una norma.

En las siguientes secciones, analizaremos qué factores marcan la diferencia entre las PYMEs que logran digitalizarse y las que no, cómo se compara Argentina con otros países de la región, y qué estrategias pueden acelerar la transformación digital en el país.

2.2.2. Factores que marcan la diferencia

Mientras que algunas PYMEs han logrado incorporar tecnología con éxito, muchas otras siguen operando con modelos tradicionales. La digitalización no solo depende de factores externos, como el acceso a financiamiento o la infraestructura tecnológica, sino también de factores internos dentro de cada empresa. La visión estratégica del liderazgo, la cultura organizacional y la capacidad de adaptación al cambio son elementos clave que determinan el grado de digitalización de una PYME.

A su vez, el ecosistema en el que opera la empresa juega un papel fundamental. La presión del mercado, las exigencias de los clientes y proveedores, y la integración en redes empresariales pueden acelerar o frenar el proceso de transformación digital.

El rol del liderazgo y la cultura organizacional

Uno de los principales diferenciadores entre las PYMEs que avanzan en digitalización y las que no es la mentalidad de sus líderes. Empresas con una dirección estratégica que ve la tecnología como una inversión y no como un gasto tienden a adoptar herramientas digitales con mayor facilidad.

Según el Banco Interamericano de Desarrollo (BID, 2023), las PYMEs cuyos dueños o gerentes tienen una mentalidad innovadora tienen un 60% más de probabilidades de digitalizarse que aquellas con un enfoque más conservador. Esto se debe a que los empresarios con mayor visión estratégica:

- ✓ Están dispuestos a asumir riesgos tecnológicos.
- ✓ Priorizan la capacitación de su equipo en herramientas digitales.
- ✓ Evalúan la digitalización como un elemento central de su competitividad.

Un claro ejemplo es Terragene, una empresa argentina del sector biotecnológico. Su liderazgo apostó fuertemente por la automatización y el uso de machine learning en sus procesos productivos, lo que le permitió optimizar el control de calidad y mejorar sus tiempos de producción. Gracias a esta apuesta digital, la compañía logró escalar su negocio y posicionarse a nivel internacional (Somos PYMEs, 12 de febrero de 2024).

En contraste, muchas PYMEs familiares siguen operando con estructuras rígidas y procesos manuales, postergando la digitalización por temor a los costos o la complejidad del cambio. La resistencia al cambio dentro de la cultura organizacional es una barrera tan importante como la falta de recursos económicos.

Talento digital

Más allá del liderazgo y la cultura organizacional, otro factor que marca la diferencia en la digitalización de las PYMEs es la capacidad de su equipo para adaptarse y operar con nuevas herramientas tecnológicas. Las empresas que invierten en la formación de su personal logran integrar con mayor éxito la digitalización en sus procesos, mientras que aquellas que no priorizan el desarrollo de competencias digitales suelen enfrentar mayores dificultades para adoptar tecnología de manera efectiva.

En muchas PYMEs, la digitalización no avanza únicamente por la falta de inversión en infraestructura tecnológica, sino porque el equipo no está preparado para sacarle el máximo provecho a las herramientas disponibles. La adopción de software de gestión, plataformas de comercio electrónico o soluciones de automatización requiere más que solo instalar tecnología: demanda un proceso de aprendizaje y adaptación que solo es posible a través de la capacitación.

Un caso representativo es el de Social Lunch, una empresa del sector gastronómico que, tras capacitar a su equipo en la gestión digital de pedidos y automatización de procesos administrativos, logró optimizar su operativa, reducir costos y mejorar la experiencia de sus clientes (Somos PYMEs, 14 de febrero de 2024). El impacto de la digitalización en esta empresa no se limitó a la implementación de nuevas tecnologías, sino a la capacidad de su equipo para utilizarlas de manera efectiva.

El talento digital no solo facilita la adopción de tecnología, sino que también reduce la resistencia al cambio dentro de las organizaciones. Muchas veces, la falta de capacitación genera desconfianza o temor ante nuevas herramientas, lo que lleva a una subutilización de las mismas. En cambio, cuando los empleados se sienten preparados para trabajar con tecnología, la adopción digital se vuelve más fluida y efectiva.

La presión del mercado y los clientes

En muchos casos, la digitalización no es una elección interna de la empresa, sino una respuesta a la presión del mercado. En sectores con alta competencia, las PYMEs se ven obligadas a adoptar herramientas digitales para mantenerse competitivas y no perder participación de mercado.

Un caso representativo es el de Todomoda-Isadora, que transformó su modelo de ventas con una estrategia digital. La empresa integró comercio electrónico, automatización de inventarios y estrategias de marketing digital basadas en datos, lo que le permitió multiplicar su facturación y expandirse a nuevos mercados (Somos PYMEs, 12 de febrero de 2024).

En el sector del comercio minorista, la digitalización ya no es una opción, sino una necesidad. Empresas que han incorporado plataformas de venta online y estrategias de omnicanalidad han logrado expandir su alcance, mientras que aquellas que no han dado

este salto ven reducido su margen de acción y pierden clientes frente a competidores más digitalizados.

El mismo fenómeno ocurre en la industria manufacturera y en el sector servicios. Los clientes exigen cada vez más procesos eficientes, trazabilidad digital y respuestas rápidas, lo que obliga a las PYMEs a incorporar tecnología para no quedar fuera del mercado.

El papel de los proveedores y las redes empresariales

Otro factor que influye en la digitalización de las PYMEs es su integración en redes empresariales y la relación con sus proveedores. Empresas que trabajan con grandes compañías suelen estar forzadas a modernizarse para cumplir con los estándares de sus clientes o integrarse en cadenas de valor más digitalizadas.

Por ejemplo, en la industria manufacturera, muchos proveedores de grandes empresas han tenido que adoptar software de gestión para optimizar la cadena de suministro. Este fenómeno también se da en la agroindustria, donde el acceso a datos y la trazabilidad digital son cada vez más demandados por exportadores y distribuidores internacionales.

Además, formar parte de clusters tecnológicos, cámaras empresariales o hubs de innovación puede acelerar la transformación digital de las PYMEs. Según la OCDE (2024), las PYMEs que forman parte de redes empresariales tienen un 35% más de probabilidades de adoptar herramientas digitales que aquellas que operan de manera aislada.

Un caso relevante es el de Zavia BIO, una startup argentina del sector agroindustrial que ha utilizado herramientas de Big Data para optimizar la producción agrícola y mejorar el rendimiento de los cultivos. Gracias a su participación en redes de innovación, pudo acceder a financiamiento y conocimientos especializados para potenciar su digitalización (Somos PYMEs, 12 de febrero de 2024).

Conclusión: ¿qué diferencia a las PYMEs que logran digitalizarse?

Las empresas que logran avanzar en su digitalización tienen en común:

- ✓ Un liderazgo con visión estratégica y disposición a asumir riesgos tecnológicos.
- ✓ Un equipo capacitado en herramientas digitales o con acceso a formación especializada.
- ✓ Un ecosistema favorable, con clientes y proveedores que impulsan la digitalización.
- ✓ Pertenencia a redes empresariales o clusters que facilitan el acceso a tecnología y financiamiento.

En cambio, las PYMEs que enfrentan más dificultades para digitalizarse suelen presentar:

- × Resistencia al cambio dentro de la cultura organizacional.
- × Falta de recursos para invertir en tecnología.

- × Escasa capacitación interna en herramientas digitales.
- × Operación en mercados con poca presión para innovar.

Las empresas que entienden la digitalización como un elemento central de su competitividad logran adaptarse más rápido y capturar nuevas oportunidades de negocio. En las próximas secciones, exploraremos cómo se compara Argentina con otros países de la región y qué estrategias pueden ayudar a cerrar la brecha digital en las PYMEs.

2.2.3. Argentina y la región

El proceso de digitalización de las PYMEs no ha sido uniforme en América Latina. Mientras que en algunos países la incorporación de tecnología ha avanzado con rapidez, en otros ha sido un camino más fragmentado y lento. Las diferencias no responden solo a la infraestructura tecnológica o a la conectividad, sino también a la existencia de políticas claras que acompañen la transformación digital de las pequeñas y medianas empresas.

En este contexto, Argentina se encuentra en una posición intermedia en la región. Si bien las PYMEs argentinas han logrado avances en digitalización en los últimos años, estos progresos han sido más impulsados por la necesidad de adaptación a cambios de mercado que por estrategias deliberadas de modernización. Otros países han implementado medidas que facilitaron la adopción tecnológica con mayor rapidez y profundidad, generando impactos más significativos en la competitividad de sus empresas.

Si observamos lo ocurrido en países como Chile, Brasil y México, y en otros casos de América Latina, podemos identificar estrategias y enfoques que han favorecido la transformación digital y que ofrecen aprendizajes relevantes para Argentina.

Según el informe de la Comisión Económica para América Latina y el Caribe (CEPAL, 2020), algunos países de la región han logrado avances importantes en digitalización a través de políticas específicas que buscan mejorar la competitividad de las PYMEs mediante el acceso a tecnología, financiamiento y capacitación. En los siguientes apartados se describen algunas de estas experiencias.

Chile: Digitalización como pilar del crecimiento

Chile ha sido uno de los países con mayor avance en digitalización de las PYMEs, impulsado por la fuerte integración de tecnología en su sector productivo. A diferencia de otros países, donde la digitalización se dio de manera más espontánea, Chile estableció un enfoque más estructurado que permitió a muchas pequeñas empresas adoptar herramientas digitales con menor resistencia y mayores incentivos.

Una de las claves del avance chileno ha sido la combinación de acceso a financiamiento, capacitación y asesoramiento. No solo se brindaron herramientas para que las PYMEs

accedieran a tecnología, sino que también se las acompañó en su implementación y uso efectivo. Este enfoque permitió que sectores como el comercio minorista y los servicios avanzaran rápidamente en la digitalización de sus procesos, incluyendo el comercio electrónico y la gestión digital de clientes.

Además, la integración tecnológica ha favorecido una mayor competitividad en el sector exportador. Muchas PYMEs han podido modernizar su operativa y mejorar sus oportunidades en mercados internacionales gracias a la adopción de soluciones digitales.

México: La transformación impulsada por el mercado

En México, el avance de la digitalización en las PYMEs ha estado estrechamente ligado a la presión del mercado y la necesidad de modernización para sostener su competitividad.

A diferencia de otros países donde el acceso a tecnología estuvo más impulsado por el sector público o el financiamiento dirigido, en México muchas PYMEs se vieron forzadas a digitalizarse debido a las exigencias del comercio internacional y de grandes clientes que demandaban integración digital en sus procesos.

Esta tendencia se hizo evidente en sectores como el comercio minorista, la manufactura y los servicios. Las empresas que lograron adaptarse rápidamente lograron expandirse y mejorar su rentabilidad, mientras que aquellas que resistieron la digitalización perdieron mercado frente a competidores más ágiles.

Un caso particularmente notable en México ha sido la digitalización del sistema de pagos y facturación electrónica, que permitió que un gran número de PYMEs pudiera integrarse al ecosistema digital y operar con mayor eficiencia.

Brasil: La integración de PYMEs en cadenas de valor digitalizadas

Brasil ha desarrollado un modelo diferente, donde la transformación digital de las PYMEs ha estado impulsada en gran medida por su integración en cadenas de valor más grandes.

En sectores como la agroindustria y la manufactura, muchas PYMEs han adoptado herramientas digitales no solo por iniciativa propia, sino porque sus clientes y proveedores más grandes las han obligado a modernizarse para seguir siendo parte del ecosistema productivo.

Este proceso ha llevado a que muchas pequeñas empresas incorporen herramientas como sistemas de trazabilidad digital, plataformas de automatización de pedidos y soluciones de inteligencia de datos. El sector agroindustrial, en particular, ha sido uno de los más dinámicos en la adopción de tecnologías digitales, permitiendo mejorar la eficiencia en el uso de recursos y optimizar la producción.

Otros países de la región

Además de los casos de Chile, Brasil y México, el resto de la región también ha avanzado en la digitalización de sus PYMEs, aunque con estrategias más focalizadas en sectores específicos y con distintos niveles de impacto según la estructura productiva de cada economía. En algunos casos, el foco ha estado en la modernización de la infraestructura tecnológica y el comercio digital, mientras que en otros, es temas más puntuales como la digitalización de servicios financieros o la mejora en la gestión administrativa de las empresas.

En Colombia, la digitalización de las PYMEs ha crecido de la mano del comercio electrónico y la modernización de los servicios financieros. En los últimos años, muchas empresas han integrado herramientas digitales para la gestión de pagos, ventas en línea y automatización de procesos administrativos, lo que les ha permitido mejorar su eficiencia operativa y acceder a nuevos mercados. Además, el acceso a financiamiento digital ha sido un factor clave en el crecimiento de las pequeñas empresas, facilitando créditos y soluciones bancarias a través de plataformas tecnológicas. Si bien aún enfrenta desafíos en términos de brecha digital y capacitación, Colombia ha logrado avances significativos en la modernización empresarial.

En Perú, el crecimiento del comercio digital ha impulsado la digitalización en sectores como el comercio minorista y los servicios, aunque la infraestructura sigue siendo una barrera en las regiones del interior.

Uruguay y Costa Rica han desarrollado ecosistemas tecnológicos más avanzados, con especial énfasis en la digitalización industrial y el crecimiento del sector fintech. En Uruguay, la incorporación de pagos electrónicos y software de gestión ha sido clave para mejorar la administración de las PYMEs, mientras que en Costa Rica las soluciones digitales han optimizado la eficiencia operativa en sectores productivos estratégicos.

Ecuador y El Salvador han seguido un camino distinto, priorizando la digitalización de trámites administrativos y servicios financieros. La implementación de plataformas gubernamentales para la gestión de permisos, impuestos y registros ha permitido agilizar la formalización de las PYMEs y reducir algunas barreras burocráticas. Sin embargo, la integración de herramientas digitales en sectores productivos sigue siendo un desafío, especialmente para las pequeñas empresas que aún operan con modelos tradicionales.

A pesar de las diferencias entre estos países, hay tendencias comunes que han impulsado la transformación digital en la región. La expansión del comercio electrónico, la mejora en la conectividad y la incorporación de herramientas digitales en las PYMEs más innovadoras han sido factores clave en este proceso. Sin embargo, la ausencia de políticas estructuradas y el acceso desigual a tecnología continúan marcando diferencias en la velocidad y profundidad de la digitalización en América Latina.

Argentina: Avances y Desafíos

Si bien Argentina enfrenta desafíos en la digitalización de sus PYMEs, se encuentra en una posición más avanzada en comparación con muchos países de la región. La alta penetración de internet y el crecimiento sostenido del comercio digital han facilitado la incorporación de herramientas tecnológicas en distintos sectores, aunque la adopción de soluciones avanzadas sigue siendo desigual.

Uno de los factores que ha impulsado la digitalización en Argentina es la expansión del ecosistema emprendedor y tecnológico, que ha permitido a muchas PYMEs acceder a plataformas digitales, soluciones de gestión y modelos de negocio basados en tecnología. En sectores como el comercio, los servicios financieros y la logística, la transformación digital ha sido más dinámica, con una mayor integración de pagos electrónicos, plataformas de venta online y herramientas de automatización. Sin embargo, en otras industrias más tradicionales, como la manufactura y la agroindustria, la adopción de tecnología sigue siendo más lenta y depende en gran medida de la disponibilidad de financiamiento y capacitación.

A diferencia de otros países que han implementado estrategias nacionales estructuradas para digitalizar sus PYMEs, en Argentina el proceso ha sido más fragmentado y ha dependido en gran medida de iniciativas sectoriales, esfuerzos individuales de las empresas y la presión del mercado. Si bien existen programas de apoyo y líneas de financiamiento para fomentar la modernización empresarial, su alcance ha sido limitado y no han logrado generar un cambio estructural en la digitalización del sector productivo.

A pesar de estas dificultades, las PYMEs argentinas tienen un gran potencial para consolidar su digitalización en los próximos años. La demanda del mercado, la evolución tecnológica y la necesidad de aumentar la competitividad serán factores clave en este proceso. En la siguiente sección se analizarán los principales desafíos que enfrentan las pequeñas y medianas empresas para expandir su digitalización y qué estrategias pueden implementarse para cerrar la brecha tecnológica y potenciar su desarrollo.

2.2.4. La Inteligencia Artificial: Un paso al futuro

La transformación digital ha sido un proceso complejo y desafiante para las PYMEs argentinas. A lo largo de este capítulo, hemos analizado cómo algunas empresas han logrado integrar herramientas digitales con éxito, mientras que otras han quedado rezagadas por diversas barreras. También hemos explorado cómo Argentina se encuentra en un punto intermedio dentro de la región: con avances significativos, pero aún lejos de los modelos más desarrollados.

Uno de los aspectos más reveladores de este proceso es que, en gran medida, las empresas que han logrado avanzar en Argentina lo han hecho más por iniciativa propia que por el impulso de políticas públicas o incentivos gubernamentales. Si bien existen programas de apoyo y financiamiento, la mayoría de los casos de éxito responden a

decisiones estratégicas internas, donde los empresarios comprendieron la urgencia de innovar y decidieron dar el paso.

Esto demuestra que la digitalización no es un privilegio exclusivo de quienes cuentan con respaldo externo, sino una oportunidad abierta para cualquier empresa que asuma el desafío de transformar su modelo de negocio. No se trata de esperar condiciones ideales, sino de comprender que la tecnología es una herramienta accesible para aquellas PYMEs dispuestas a adaptarse.

Digitalización: oportunidad y estrategia

La digitalización ha demostrado ser un factor clave y diferenciador para la competitividad de las empresas. Sin embargo, no todas las PYMEs han transitado este camino con la misma velocidad ni con la misma profundidad. Algunas han encontrado en la tecnología una vía para optimizar su gestión, mejorar su rentabilidad y expandirse a nuevos mercados, mientras que otras han preferido mantener estructuras tradicionales, confiando en modelos de negocio ya consolidados.

No se trata de una receta única ni de una obligación ineludible. Cada empresa debe evaluar qué herramientas pueden potenciar su crecimiento y en qué medida pueden integrarse a su estrategia empresarial. Lo que sí es evidente es que la tecnología cambia las reglas del juego y que, en muchos sectores, la adopción digital es un diferencial competitivo cada vez más marcado.

Las PYMEs que han avanzado en su transformación digital ya están capturando ventajas competitivas. Son más ágiles en la toma de decisiones, reducen costos operativos, acceden a nuevos mercados y optimizan su relación con clientes y proveedores. En contraste, aquellas que aún no han dado este paso pueden comenzar a enfrentar dificultades para sostener su posición en el mercado.

Por ejemplo, un comercio minorista que adopta plataformas de venta online puede multiplicar su base de clientes y mejorar la experiencia de compra, mientras que otro que sigue dependiendo exclusivamente del punto de venta físico ve su participación de mercado reducirse progresivamente. Una empresa manufacturera que automatiza procesos y optimiza su cadena de suministros mejora su rentabilidad y eficiencia, mientras que otra que sigue operando con métodos tradicionales se enfrenta a costos crecientes y menor flexibilidad.

La digitalización no es simplemente una herramienta para mejorar la eficiencia operativa, sino una decisión estratégica que puede determinar el futuro de una empresa en el mercado. En un entorno cada vez más digitalizado, postergar la transformación tecnológica puede significar quedar relegado frente a competidores más preparados para enfrentar los desafíos del futuro.

Si bien la digitalización ha representado un cambio profundo en la forma en que las PYMEs operan, lo que viene a continuación es una transformación aún mayor. La

Inteligencia Artificial no es solo una herramienta más dentro del proceso de modernización tecnológica, sino una disrupción que redefinirá la manera en que las empresas compiten, toman decisiones y generan valor.

Hasta ahora, las tecnologías digitales han permitido mejorar la eficiencia y ampliar el alcance de las empresas. La IA, en cambio, introduce la posibilidad de analizar grandes volúmenes de datos, anticipar tendencias y automatizar procesos con un nivel de precisión y autonomía sin precedentes.

Este cambio de paradigma representa un desafío aún mayor para las PYMEs. Mientras que muchas aún están en proceso de integrar herramientas digitales básicas, la Inteligencia Artificial ya está modificando las dinámicas del mercado a nivel global. Las empresas que logren adaptarse a esta nueva realidad no solo optimizarán su competitividad, sino que también accederán a oportunidades impensadas, expandirán su alcance y mejorarán su eficiencia.

En el próximo capítulo exploraremos el impacto de la Inteligencia Artificial en el mundo de las PYMEs y las estrategias que pueden adoptar para no quedar rezagadas en esta nueva era de transformación tecnológica.

CAPÍTULO 3: APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LAS EMPRESAS

A lo largo de la historia, las nuevas tecnologías suelen ser incorporadas en primer lugar por las grandes corporaciones, que con recursos financieros sustanciales pueden experimentar, evaluar su impacto e implementar innovaciones a gran escala. Estas organizaciones no solo validan su utilidad, sino que también optimizan su funcionamiento y reducen los costos asociados a su adopción. Con el tiempo, este conocimiento se extiende a las pequeñas y medianas empresas (PYMEs), que pueden incorporar estas herramientas de manera adaptada a sus necesidades y posibilidades.

La inteligencia artificial no ha sido la excepción a esta dinámica. Desde sus primeras implementaciones, ha logrado optimizar procesos en distintos sectores, permitiendo mejoras en productividad, eficiencia y toma de decisiones. Lo que en un principio parecía exclusivo de grandes corporaciones, hoy es cada vez más accesible para organizaciones de todos los tamaños, con herramientas que pueden ser adoptadas incluso sin grandes inversiones en infraestructura o conocimiento técnico avanzado.

En los capítulos anteriores se abordaron la evolución tecnológica de la IA y su impacto como fuerza transformadora, así como el contexto estructural en el que operan las pymes en Argentina. Este capítulo propone analizar cómo la IA ha sido implementada en el mundo empresarial, describiendo ejemplos concretos que ilustran su aplicación en distintas funciones y sectores. El recorrido incluye tanto las primeras soluciones basadas en aprendizaje automático como las herramientas más avanzadas de inteligencia artificial generativa, mostrando cómo estas tecnologías ya están transformando las operaciones cotidianas de muchas organizaciones.

Este análisis servirá como base para el capítulo siguiente, en el que se presentará una metodología propia para identificar oportunidades de aplicación de la IA en pequeñas y medianas empresas, considerando sus particularidades, limitaciones y fortalezas.

3.1. Primeras Aplicaciones de IA

La inteligencia artificial ha logrado insertarse de manera progresiva en prácticamente todos los procesos clave de las organizaciones: marketing y ventas, atención al cliente, producción, supply chain, administración y finanzas, entre otros. Su capacidad para procesar grandes volúmenes de datos, identificar patrones ocultos, generar predicciones y automatizar procesos y decisiones ha convertido a la IA en una herramienta estratégica con impacto real en los resultados del negocio.

El verdadero potencial de la inteligencia artificial va mucho más allá de la mejora de la eficiencia. Las empresas líderes no solo están optimizando sus operaciones, sino que están redefiniendo el diseño mismo de sus procesos de negocio. La IA ya no se incorpora

como una herramienta periférica que mejora funciones aisladas, sino como un componente estructural que transforma la forma en que se organiza el trabajo, se toman decisiones y se crea valor. En estas organizaciones, la tecnología no se adapta a los procesos existentes: son los procesos los que se rediseñan para aprovechar al máximo sus capacidades. Allí donde la IA se integra de forma transversal y estratégica, no solo mejora los resultados: impulsa nuevas formas de operar, colaborar y competir, convirtiéndose en el eje de una transformación organizacional profunda (McKinsey & Company, 2025; Boston Consulting Group, 2024).

En este contexto, esta sección presenta una serie de casos que ilustran cómo la inteligencia artificial ha sido aplicada de manera concreta en distintos procesos clave del negocio. Se analizarán soluciones representativas en áreas como marketing, producción, logística y atención al cliente, mostrando cómo fueron implementadas, qué desafíos abordaron y qué impacto generaron. Lejos de ser experiencias aisladas, estos ejemplos permiten comprender de forma tangible cómo la IA está transformando el funcionamiento de las organizaciones y ofrecen insumos valiosos para pensar su adopción en otros contextos empresariales.

3.1.1 Supply Chain: Gestión Dinámica del Inventario

La gestión de inventarios ha sido históricamente un desafío dentro de la cadena de suministro. Un manejo ineficiente puede generar sobrecostos, pérdidas de ventas y problemas operativos que afectan la rentabilidad de una empresa. Tradicionalmente, las empresas han gestionado sus inventarios mediante métodos estáticos como el punto de reorden fijo (ROP, Reorder Point) y la cantidad económica de pedido (EOQ, Economic Order Quantity), que determinan cuándo y cuánto reabastecer. Sin embargo, estos enfoques son rígidos ante las variaciones del mercado, lo que puede provocar sobrestocks o quiebres de inventario. (Waters, 2003).

La eficiencia en la gestión de inventarios depende de múltiples factores como el lead time, el stock de seguridad y la rotación de productos. Las variaciones en el lead time, es decir, los cambios en el tiempo que transcurre entre la emisión de un pedido y su recepción, pueden afectar la disponibilidad de productos si los niveles de stock no se ajustan adecuadamente. Por su parte, el stock de seguridad funciona como una reserva ante variaciones en la demanda o retrasos en los proveedores, mientras que una adecuada gestión de la rotación de inventario minimiza productos inmovilizados y optimiza el uso del capital. Empresas que optimizan estos parámetros pueden reducir costos y mejorar su competitividad.

El machine learning optimiza estos procesos analizando datos históricos y en tiempo real, detectando patrones en la demanda y ajustando dinámicamente los niveles de stock. Para la predicción de demanda, los modelos de series temporales, como ARIMA y SARIMA, permiten anticipar fluctuaciones estacionales y tendencias de consumo. En escenarios más complejos, donde múltiples factores afectan la demanda, se han integrado redes neuronales artificiales y árboles de decisión como Random Forest y

Gradient Boosting, que analizan variables como promociones, eventos externos y patrones de compra en distintos mercados. (Chopra & Meindl, 2016).

Cuando la demanda es volátil y difícil de predecir, los modelos tradicionales pueden fallar, por lo que el aprendizaje por refuerzo ha ganado protagonismo. Este enfoque ajusta los niveles de inventario y los pedidos a proveedores en tiempo real, aprendiendo continuamente a mejorar sus decisiones sin intervención manual. Algunas empresas han combinado técnicas estadísticas con redes neuronales recurrentes y Transformers, que han demostrado ser más efectivas en la identificación de cambios abruptos en los patrones de compra. Estos avances han convertido la gestión de inventarios en un proceso autónomo, minimizando costos operativos, reduciendo desperdicio y mejorando la disponibilidad de productos sin generar sobrestocks innecesarios. (Ünal et al., 2022).

El impacto de la inteligencia artificial en la optimización de inventarios no solo se limita a modelos de predicción, sino que también ha transformado la logística y la distribución de productos. Empresas como Amazon y Walmart han integrado IA en sus sistemas de planificación para anticipar la demanda y optimizar la asignación de productos en distintos centros de distribución. Hoy, plataformas SaaS permiten que empresas de cualquier tamaño accedan a estos algoritmos para optimizar su planificación de inventarios y reducir costos de almacenamiento, haciendo que la IA en la gestión de stock sea una realidad accesible.

3.1.2 Marketing y Publicidad: Segmentación de Clientes y Optimización de Campañas

El marketing y la publicidad han sido herramientas esenciales para el crecimiento y la competitividad de las empresas, definiendo su capacidad para atraer clientes, posicionar sus marcas y maximizar sus ingresos. De la comunicación masiva orientada a alcanzar al mayor número posible de consumidores, el marketing evolucionó hacia un enfoque basado en la segmentación y la personalización. La capacidad de identificar y comprender a distintos grupos de clientes se convirtió en un factor determinante para la efectividad de cualquier acción comercial. Así, la segmentación de clientes permite a las empresas diseñar estrategias más precisas, alineadas con los intereses, necesidades y comportamientos de cada audiencia, transformando la relación entre marcas y consumidores (Kotler & Armstrong, 2012).

La llegada de Internet y el comercio electrónico impulsó el marketing digital, transformando la manera en que las empresas interactúan con sus clientes. Plataformas como Google Ads y Facebook Ads permitieron una segmentación más precisa basada en intereses, búsquedas y comportamiento en línea. Esto les permitió orientar su publicidad a grupos específicos según edad, ubicación o género. Sin embargo, este enfoque seguía siendo rígido, ya que dependía de reglas estáticas impuestas por los anunciantes, sin considerar la evolución del comportamiento del consumidor en tiempo real. Para optimizar las campañas, era necesario realizar ajustes manuales mediante pruebas A/B (un método que compara diferentes versiones de un anuncio para determinar cuál tiene

mejor rendimiento) y analizar métricas como costo por clic y tasas de conversión. Esto, sumado a la rigidez de la segmentación, limitaba la capacidad de adaptación a los cambios rápidos del mercado. (Kohavi & Longbotham, 2017; Quin et al., 2022).

La inteligencia artificial transformó este proceso al eliminar las limitaciones de la segmentación estática. Modelos de aprendizaje automático como K-Means y DBSCAN identifican patrones ocultos en grandes volúmenes de datos, agrupando clientes según su comportamiento real y ajustando los segmentos en tiempo real. Una tienda online, por ejemplo, puede modificar sus estrategias publicitarias en función de cambios en los hábitos de compra, asegurando que cada usuario reciba anuncios personalizados basados en sus interacciones más recientes (Kasem et al., 2023).

El análisis predictivo llevó la optimización publicitaria a otro nivel. Algoritmos como Random Forest y Gradient Boosting analizan campañas pasadas para predecir qué anuncios generarán mayor impacto en cada segmento. En la publicidad programática, la IA automatiza la compra y optimización de espacios publicitarios en tiempo real, ajustando anuncios según el perfil del usuario, el contexto de navegación y el rendimiento esperado. Esto maximiza el retorno sobre la inversión sin intervención manual, permitiendo campañas más efectivas y eficientes (Wei et al., 2024).

Hoy, las empresas integran la inteligencia artificial en todas las fases del marketing. Desde la captación de clientes hasta la personalización del contenido, los sistemas de IA analizan datos de múltiples fuentes y ajustan dinámicamente las estrategias. Plataformas como Amazon y Netflix utilizan redes neuronales para anticipar qué productos o contenidos interesarán a cada usuario, adaptando la experiencia en tiempo real. Estas tecnologías no solo optimizan la publicidad, sino que fortalecen la relación entre marcas y consumidores, mejorando la retención y el engagement.

3.1.3 Producción: Mantenimiento Predictivo

La disponibilidad y el rendimiento óptimo de los equipos industriales son pilares fundamentales para la producción. Las empresas han gestionado este problema a través de estrategias de mantenimiento correctivo y preventivo. En el mantenimiento correctivo, las reparaciones se realizan únicamente cuando el equipo deja de operar, lo que genera tiempos de inactividad elevados y costos imprevistos. Por otro lado, el mantenimiento preventivo establece calendarios de inspección y sustitución de componentes en función de estimaciones generales de desgaste, sin considerar la condición real de cada máquina. Aunque este enfoque reduce la probabilidad de fallas graves, también genera gastos innecesarios al reemplazar piezas que aún pueden estar operativas. (Higgins & Mobley, 2002)

En el campo del mantenimiento predictivo, la incorporación de sensores de IoT (Internet of Things, dispositivos que recopilan y transmiten datos en tiempo real sobre el estado de los equipos) ha permitido capturar información sobre variables clave como vibración, temperatura y consumo de energía. Estos datos proporcionan la base para entrenar

modelos de machine learning, los cuales permiten anticipar fallas y mejorar la eficiencia operativa.

Dependiendo del tipo de datos y de la problemática específica, se seleccionan diferentes modelos de machine learning. En entornos donde no se dispone de datos etiquetados, los modelos no supervisados permiten identificar anomalías en tiempo real. Técnicas como Isolation Forest, One-Class SVM y Análisis de Componentes Principales (PCA) detectan desviaciones inusuales en el comportamiento de los equipos sin necesidad de registros históricos de fallas. Estos modelos resultan especialmente útiles en industrias donde los fallos son poco frecuentes y los datos disponibles son limitados (Iftikhar et al., 2022).

Cuando el objetivo es predecir el tiempo restante antes de una falla (Remaining Useful Life - RUL), se emplean modelos supervisados como Random Forest, Support Vector Machines (SVM) y Artificial Neural Networks (ANN). Estos algoritmos analizan grandes volúmenes de datos históricos y establecen relaciones entre las condiciones operativas y el desgaste de los componentes, permitiendo estimar con mayor precisión el momento óptimo para intervenir antes de que ocurra una falla crítica (Hamaide et al., 2022).

En sistemas donde las variables operativas tienen una fuerte dependencia temporal, como el monitoreo continuo de turbinas, motores y maquinaria rotativa, se utilizan modelos de series temporales como Recurrent Neural Networks (RNN) y arquitecturas más avanzadas como Long Short-Term Memory (LSTM). Estas técnicas permiten identificar patrones de degradación progresiva en los equipos, anticipando tendencias de falla con mayor precisión. Estudios recientes han demostrado que el uso de redes neuronales profundas basadas en LSTM puede mejorar significativamente la capacidad de diagnóstico al capturar relaciones complejas en los datos de sensores (Maheshwari et al., 2024).

Gracias a estas herramientas, las empresas pueden intervenir de manera proactiva, reduciendo costos de mantenimiento, evitando interrupciones en la producción y maximizando la vida útil de los equipos. La combinación de IoT, machine learning y análisis avanzado de datos ha convertido al mantenimiento predictivo en una pieza fundamental en la optimización de procesos industriales.

3.1.4 Control de Calidad en las líneas de manufactura y producción

Históricamente, las empresas han implementado controles de calidad en sus líneas de producción para garantizar estándares, evitar defectos en los productos y proteger el valor de su marca. Esto permitió minimizar desperdicios, optimizar recursos y garantizar la uniformidad en la producción, factores clave para la competitividad y la satisfacción del cliente. (Juran & Gryna, 1993)

En sus primeras etapas, el control de calidad se basó en inspecciones manuales y muestreos estadísticos, donde operarios especializados evaluaban visualmente los productos o realizaban pruebas sobre un subconjunto de la producción. Sin embargo, este método dependía de la experiencia del personal, que no siempre identificaba fallas en tiempo real y no garantizaba la detección de todos los defectos antes de que los productos llegaran al mercado. (Grant & Leavenworth, 1996).

A mediados del siglo XX, el Control Estadístico de Procesos (SPC) introdujo gráficos de control y herramientas matemáticas para detectar defectos. Si bien ayudó a mejorar la detección de defectos, no evitaba su aparición, sino que permitía corregir problemas una vez generados. Desde los años 80, el uso de sensores avanzados y sistemas de medición computarizados mejoró la precisión de la inspección y redujo la variabilidad en la producción. A partir de finales de siglo, la visión computarizada automatizó la inspección visual con cámaras de alta resolución y software de análisis de imágenes. Estos sistemas dependían de reglas predefinidas y requerían programación manual para determinar qué parámetros constituían un defecto. Cualquier variación en la producción o en los tipos de defectos exigía reconfigurar el sistema, lo que los volvía inflexibles y poco adaptables. (Oakland, 2007).

Si bien estos avances optimizaron los sistemas de control de calidad, su rigidez ante cambios en los procesos de manufactura y su dependencia de reglas estáticas seguían limitando su efectividad. La inteligencia artificial permitió superar estas restricciones, ya que los modelos de machine learning pueden procesar grandes volúmenes de datos, detectar patrones complejos y aprender continuamente a partir de ejemplos previos. Esta capacidad ha transformado la inspección visual, el análisis de datos de sensores y la detección de anomalías en tiempo real, brindando mayor precisión y adaptabilidad a los procesos de manufactura.

Uno de los principales avances ha sido la implementación de Convolutional Neural Networks (CNN) en la inspección visual automatizada. Las CNN, diseñadas para el análisis de imágenes, han optimizado la detección de defectos en líneas de producción al automatizar la inspección visual y mejorar la precisión del control de calidad. Estas redes pueden analizar grandes volúmenes de imágenes y aprender a reconocer irregularidades con una precisión superior a la del ojo humano en la detección de fallas de superficies industriales como aceros, textiles, etc. (Khanam et al., 2024)

Además del análisis de imágenes, los modelos basados en Random Forest y Gradient Boosting han demostrado ser eficaces en la evaluación de datos de sensores para optimizar procesos de calidad. Estos algoritmos permiten detectar variaciones en parámetros operativos y predecir cuándo un producto podría presentar fallas, ajustando automáticamente los procesos de manufactura para minimizar defectos. (Alshraideh et al., 2020; Moldovan et al., 2017).

Por otro lado, los modelos no supervisados como Isolation Forest y One-Class SVM han sido fundamentales en la detección de anomalías en líneas de producción sin necesidad de contar con datos etiquetados de fallas previas. Estos modelos identifican desviaciones

en patrones normales de operación y alertan sobre posibles defectos antes de que se vuelvan recurrentes. (Chen et al., 2020).

Su capacidad de aprendizaje continuo y adaptabilidad permite a las empresas elevar los estándares de calidad, reducir desperdicios y optimizar la eficiencia operativa, posicionando la IA como un pilar clave en la transformación digital de la manufactura.

3.1.5 Finanzas y Banca: Detección de Fraudes

El fraude financiero es un desafío constante para bancos, plataformas de pago y comercios electrónicos, con ataques cada vez más sofisticados que van desde el uso indebido de tarjetas hasta la manipulación de cuentas bancarias. Para combatir este problema, las instituciones financieras desarrollaron sistemas de detección basados en reglas predefinidas que evaluaban criterios como montos elevados, ubicaciones inusuales o intentos fallidos de autenticación.

Este método resultó insuficiente frente a un fraude en constante evolución. A medida que los atacantes encontraban nuevas formas de eludir los controles, las reglas debían modificarse manualmente, un proceso lento que dejaba expuestos a los sistemas durante largos períodos. Mientras tanto, muchas transacciones fraudulentas seguían pasando desapercibidas, y un número creciente de operaciones legítimas eran bloqueadas por error, afectando tanto a los clientes como a las instituciones financieras (Wells, 2020).

La inteligencia artificial permitió superar estas limitaciones al detectar fraudes de manera más precisa y adaptativa. A diferencia de los sistemas tradicionales, los modelos de machine learning pueden analizar simultáneamente miles de transacciones y detectar fraudes con una precisión mucho mayor. En lugar de simplemente rechazar una transacción por realizarse en un país inusual, la IA evalúa múltiples variables, como el historial del usuario, la velocidad de conexión y la correlación con compras previas, permitiendo identificar fraudes sin afectar transacciones legítimas. Con la capacidad de aprender de cada operación, estos sistemas evolucionan constantemente, ajustándose a nuevas tácticas sin necesidad de intervención manual. Esto no solo ha mejorado la efectividad en la detección de fraudes, sino que también ha reducido la cantidad de transacciones legítimas bloqueadas por error, optimizando la seguridad sin afectar la experiencia del usuario.

Por un lado, los modelos supervisados utilizan datos históricos de transacciones etiquetadas como fraudulentas o legítimas para aprender a clasificar nuevas operaciones. Estos modelos entrenan sobre una amplia gama de variables, como montos de transacción, frecuencia de pagos, ubicación geográfica, dispositivo utilizado, historial de compras y conexiones entre cuentas. Algoritmos como Random Forest, Gradient Boosting y Redes Neuronales Artificiales han demostrado ser altamente efectivos en este contexto, ya que pueden manejar grandes conjuntos de datos con múltiples variables y generar predicciones en tiempo real (Al-Hashedi & Magalingam, 2020).

Por otro lado, los modelos no supervisados no requieren datos etiquetados de fraude, sino que detectan anomalías en las transacciones analizando desviaciones respecto al comportamiento normal del usuario o del sistema. Isolation Forest, One-Class SVM y Autoencoders son algunas de las técnicas más utilizadas en este enfoque. Un Isolation Forest puede analizar miles de transacciones y detectar aquellas que son estadísticamente atípicas en función de variables como el tiempo entre compras, la distancia entre ubicaciones y los patrones de gasto. Los Autoencoders, basados en redes neuronales, reconstruyen transacciones normales y marcan aquellas que presentan desviaciones significativas como potencialmente fraudulentas (Nassif et al., 2022).

La combinación de modelos supervisados y no supervisados ha demostrado ser la estrategia más efectiva en la detección de fraudes financieros. Un enfoque híbrido permite utilizar modelos supervisados para detectar fraudes ya conocidos con alta precisión, mientras que los no supervisados complementan el análisis al identificar transacciones atípicas que podrían representar nuevas amenazas. Implementaciones recientes han integrado redes neuronales con mecanismos de detección de anomalías, mejorando la capacidad de respuesta ante tácticas fraudulentas en evolución (Carcillo et al., 2019; Hilal et al., 2022). Este enfoque combinado no solo reduce las pérdidas económicas, sino que también optimiza la seguridad del sistema al minimizar la cantidad de transacciones legítimas bloqueadas erróneamente.

3.1.6 Salud y Diagnóstico Médico: Análisis de Imágenes

El análisis de imágenes médicas es una herramienta fundamental en el diagnóstico de enfermedades, permitiendo a los especialistas detectar patologías a partir de estudios como radiografías, tomografías computarizadas, resonancias magnéticas y microscopía digital. La precisión en la interpretación de estas imágenes es crucial, ya que un diagnóstico tardío o incorrecto puede afectar gravemente el pronóstico del paciente. Sin embargo, este proceso enfrenta múltiples desafíos. La alta demanda de estudios genera una sobrecarga en los especialistas, lo que puede ralentizar el diagnóstico y aumentar la posibilidad de errores. Además, la variabilidad en la interpretación entre distintos médicos y la dificultad de identificar ciertas anomalías en etapas tempranas hacen que la detección de enfermedades dependa en gran medida de la experiencia y disponibilidad de los profesionales. En enfermedades críticas como el cáncer o afecciones neurológicas, esta variabilidad puede traducirse en falsos negativos que retrasan el tratamiento o falsos positivos que generan procedimientos innecesarios.

Para enfrentar estos desafíos, se desarrollaron sistemas de análisis de imágenes médicas basados en técnicas de procesamiento digital. Estos métodos aplicaban algoritmos de segmentación, filtrado y realce de contrastes para mejorar la visualización de estructuras anatómicas y ayudar a los especialistas en la detección de anomalías. En particular, técnicas como la segmentación basada en umbrales, la transformada de Fourier y los métodos de filtrado espacial fueron ampliamente utilizadas para mejorar la calidad de las imágenes médicas y facilitar su interpretación. (Dhawan, 2011). Sin embargo, estos sistemas dependían de reglas predefinidas y requerían que el especialista interpretara

los resultados, lo que limitaba su capacidad para detectar patrones complejos o adaptarse a variaciones en las imágenes médicas (Ritter et al., 2011).

La inteligencia artificial permitió superar estas limitaciones al procesar imágenes médicas de manera más precisa y autónoma. A diferencia de los métodos tradicionales, que dependían de parámetros definidos manualmente, los modelos de machine learning aprenden directamente de grandes volúmenes de datos, identificando patrones en los estudios médicos y mejorando la capacidad de detección de enfermedades. Las redes neuronales convolucionales (CNNs) han sido el avance más significativo en este campo, ya que están diseñadas específicamente para analizar imágenes médicas. Estas redes procesan las imágenes en diferentes capas, donde las primeras detectan bordes y texturas básicas, mientras que las capas más profundas extraen patrones de mayor complejidad, como anomalías específicas en tejidos. Modelos como AlexNet, VGG, ResNet y DenseNet han demostrado ser altamente efectivos en la identificación de estructuras anatómicas y la clasificación de imágenes médicas (Anwar et al., 2019).

El uso de deep learning en el análisis de imágenes ha demostrado su eficacia en la detección de enfermedades como cáncer de mama en mamografías, neumonía y tuberculosis en radiografías de tórax, melanoma en imágenes dermatológicas y retinopatía diabética en oftalmología. Gracias a bases de datos médicas etiquetadas como NIH Chest X-ray, LIDC-IDRI para cáncer de pulmón y el conjunto de imágenes dermatológicas ISIC, los modelos han sido entrenados con millones de casos clínicos, lo que ha permitido mejorar su precisión y reducir los errores de diagnóstico. Sin embargo, la efectividad de estos modelos depende de grandes volúmenes de datos anotados, lo que representa un desafío en entornos clínicos donde la disponibilidad de imágenes etiquetadas es limitada (Ker et al., 2017).

Para abordar esta limitación, se han desarrollado técnicas como Transfer Learning, que permite reutilizar modelos entrenados en grandes conjuntos de datos para aplicaciones específicas con menos datos. Además, modelos generativos como GANs (Generative Adversarial Networks) han sido utilizados para sintetizar imágenes médicas realistas y aumentar la cantidad de datos disponibles para entrenamiento, mejorando el rendimiento de los modelos de diagnóstico en situaciones con pocos datos etiquetados (Suganyadevi et al., 2021).

Uno de los principales avances en la integración de IA en imágenes médicas es la capacidad de los modelos para generar explicaciones visuales mediante herramientas como heatmaps y Grad-CAM, que permiten a los especialistas interpretar por qué el sistema ha marcado una región como sospechosa. Estas técnicas han demostrado ser valiosas en el diagnóstico médico, ya que resaltan las áreas más relevantes para la clasificación del modelo, facilitando la validación por parte de los médicos (Chien et al., 2022). Además, los enfoques más recientes han aplicado ensemble learning (aprendizaje por ensamble), combinando predicciones de múltiples redes neuronales para mejorar la precisión del diagnóstico. Asimismo, se ha explorado la integración de datos multimodales, fusionando imágenes médicas con información clínica del paciente para obtener diagnósticos más robustos (Tsuneki, 2022). Estos avances han permitido no solo

mejorar la precisión del diagnóstico, sino también optimizar su implementación en entornos clínicos, facilitando su adopción en hospitales y sistemas de diagnóstico asistido por computadora.

3.2 La Revolución de la IA Generativa

A medida que la inteligencia artificial se consolidó en el mundo empresarial, sus capacidades fueron evolucionando más allá del análisis de datos y la optimización de procesos. Si bien la IA tradicional demostró ser una herramienta poderosa para predecir tendencias, automatizar decisiones y mejorar la eficiencia operativa, sus aplicaciones estaban limitadas a tareas donde el conocimiento podía extraerse de datos históricos y estructurados. Sin embargo, en muchos ámbitos de negocio, la generación de contenido, el razonamiento complejo y la interpretación del lenguaje seguían siendo terrenos exclusivos de la inteligencia humana.

La llegada de la IA Generativa representó un salto cualitativo. Por primera vez, los modelos no solo aprendían de datos previos, sino que eran capaces de crear información nueva y estructurada de manera autónoma. Esto permitió la automatización de procesos que antes requerían intervención humana, como la redacción de documentos, la creación de imágenes, la programación de código o la personalización de contenido en tiempo real. Lo que antes era solo posible a través de reglas programadas o modelos entrenados para tareas específicas, hoy se logra con herramientas flexibles que pueden adaptarse a distintos contextos sin necesidad de reentrenamiento continuo.

El impacto de esta evolución no radica únicamente en la velocidad o la automatización, sino en la capacidad de comprender y generar información con una precisión sin precedentes. Modelos de lenguaje avanzados pueden procesar grandes volúmenes de texto, identificar patrones semánticos y generar respuestas contextualizadas en función de la situación. En sectores donde el lenguaje y la creatividad juegan un rol central, esto ha cambiado radicalmente la manera en que las empresas operan.

Otro aspecto clave de la IA Generativa es su accesibilidad. Mientras que las primeras soluciones de IA requerían infraestructura costosa y talento altamente especializado, las nuevas plataformas permiten que cualquier empresa pueda aprovechar estos modelos sin necesidad de desarrollos propios. Esto ha democratizado su adopción y ha abierto oportunidades para que organizaciones de todos los tamaños experimenten con aplicaciones antes impensadas.

Para ilustrar estas capacidades en acción, analizaremos dos ejemplos concretos donde la IA Generativa está transformando la manera en que se gestionan procesos clave en el ámbito empresarial. A través de estos casos, podremos visualizar no solo cómo funcionan estas nuevas herramientas, sino también qué oportunidades pueden representar para distintos sectores y cómo podrían adaptarse a realidades más específicas, como la de las PYMEs.

3.2.1 Atención al Cliente: Chatbots y Automatización de Respuestas

Para muchas empresas, la atención al cliente es un componente central de su operación. Abarca desde la orientación en la compra hasta el seguimiento posventa, la gestión de reclamos y la resolución de problemas técnicos o administrativos. La eficiencia en estas interacciones impacta directamente en la satisfacción del cliente y en la continuidad de la relación comercial. Sin embargo, manejarlas a gran escala presenta múltiples desafíos. Una consulta puede ir desde una pregunta simple sobre el precio o la disponibilidad de un producto hasta casos más complejos, como la devolución de un artículo, el reclamo por un error en la facturación o la reactivación de un servicio suspendido. En cada situación, la predisposición del cliente varía según la urgencia del problema y su experiencia previa con la empresa. Mientras algunos buscan información y están abiertos a sugerencias, otros llegan con un alto nivel de frustración o enojo. En estos escenarios, el tiempo de respuesta y la claridad en la comunicación son claves. Un proceso confuso o una demora innecesaria pueden agravar la situación y escalar el reclamo, afectando no solo la relación con ese cliente, sino también la reputación de la empresa.

Inicialmente, la atención presencial y telefónica permitía resolver problemas de manera directa, brindando respuestas inmediatas y personalizadas, pero su escalabilidad era limitada, ya que cada interacción requería un agente disponible. Con el crecimiento de la demanda, los costos operativos aumentaron y los tiempos de espera se volvieron un problema recurrente. Para mitigar esto, surgieron centros de contacto centralizados con agentes especializados, lo que mejoró la eficiencia operativa, aunque seguía sujeto a limitaciones horarias y a la necesidad de una amplia fuerza laboral. Con la digitalización, aparecieron canales asincrónicos como el correo electrónico y los formularios web, que reducían la presión sobre los equipos de atención en tiempo real, pero la falta de inmediatez generaba frustración en clientes con problemas urgentes, ya que las respuestas podían tardar horas o días (McLean & Wilson, 2016).

Para agilizar la atención, las empresas incorporaron sistemas automatizados, como los menús de respuesta de voz interactiva (IVR) y los primeros chatbots basados en reglas predefinidas (Saber et al., 2017). Estos permitieron resolver consultas simples, como verificar el estado de un pedido o restablecer una contraseña, sin intervención humana. Sin embargo, cuando la consulta no coincidía exactamente con las opciones programadas, el sistema se convertía en una barrera, obligando a los usuarios a navegar por múltiples opciones antes de hablar con un agente o, en muchos casos, dejándolos sin resolver su problema.

La incorporación de la IA Generativa transformó radicalmente la atención al cliente al ofrecer respuestas inmediatas, flexibles y disponibles las 24 horas. A diferencia de los chatbots tradicionales, que operaban con respuestas predefinidas, los nuevos modelos de IA comprenden el lenguaje natural, ajustan su tono a la situación y gestionan interacciones más complejas con fluidez similar a la conversación humana. Un asistente basado en IA Generativa no solo responde preguntas frecuentes, sino que también

resuelve problemas específicos consultando bases de datos en tiempo real y adaptando sus respuestas según el estado de ánimo del cliente. Esto permite atender con la misma precisión desde una consulta simple hasta un reclamo delicado, brindando información clara y solucionando casos sin desvíos innecesarios. (Ferraro et al., 2024).

La implementación de una solución de atención al cliente con IA Generativa comienza con la elección del modelo de lenguaje y su integración en los sistemas de la empresa. La mayoría de las soluciones operan en la nube, lo que permite escalabilidad, actualización continua y acceso a modelos avanzados sin infraestructura propia. Sin embargo, algunas organizaciones con altos requerimientos de seguridad optan por modelos on-premise alojados en servidores propios. (Goswami, 2021).

Las empresas pueden utilizar modelos preentrenados como GPT-4, Claude o Gemini, que ofrecen alta precisión sin entrenamiento adicional, o modelos open-source como LLaMA o Mistral, que permiten mayor personalización. La integración de modelos preentrenados se realiza mediante APIs conectadas a sistemas de gestión de clientes (CRM), bases de datos y plataformas de mensajería. Si se requiere ajuste, se emplea fine-tuning con datos históricos o técnicas de prompt engineering para guiar respuestas sin modificar el modelo base. (Trad & Chehab, 2024).

Para optimizar su rendimiento, los asistentes combinan múltiples fuentes de información en tiempo real. Acceden a bases de conocimiento estructuradas como FAQs y manuales internos, pero también a datos transaccionales para respuestas personalizadas. Los sistemas más avanzados usan retrieval-augmented generation (RAG), que permite consultar documentos internos y generar respuestas contextualizadas (Xu et al., 2024). Además, incluyen mecanismos de moderación para evitar respuestas incorrectas, con filtros de seguridad y modelos de evaluación de confianza.

En términos de integración, estas soluciones se conectan con chat en vivo, correo electrónico, WhatsApp y call centers. En interacciones por voz, se combinan con modelos de síntesis y reconocimiento de voz para asistentes totalmente automatizados. También se diseñan para ser escalables y gestionar altos volúmenes de consultas sin afectar la calidad de la respuesta.

Las soluciones de IA Generativa han alcanzado un nivel de madurez significativo, pero siguen evolucionando. Los modelos actuales pueden gestionar conversaciones complejas, personalizar respuestas y operar en múltiples canales con tiempos de respuesta instantáneos. Sin embargo, persisten desafíos en precisión, control de sesgos e interpretación de situaciones especializadas. (Alqudah & Muradkhanli, 2024). A pesar de los avances, la interacción humana sigue siendo necesaria en casos sensibles o que requieren criterio profesional, por lo que la combinación de IA y agentes humanos sigue siendo la estrategia más efectiva.

A futuro, estos sistemas mejorarán en razonamiento y autonomía. Se espera que comprendan mejor el contexto a largo plazo, recuerden interacciones previas y generen respuestas más coherentes en conversaciones extensas. (Nah et al., 2023). La

integración con herramientas avanzadas de voz y video permitirá interacciones más naturales, mientras que los modelos multimodales facilitarán la comprensión de imágenes y documentos. Además, con la llegada de agentes autónomos, estos sistemas no solo responderán consultas, sino que ejecutarán tareas proactivamente, como gestionar reembolsos o coordinar servicios sin intervención humana.

A medida que la tecnología avanza, la personalización será aún mayor, permitiendo experiencias de atención completamente adaptadas a cada cliente. La combinación de modelos de lenguaje con análisis de datos en tiempo real permitirá interacciones predictivas, anticipando problemas y ofreciendo soluciones antes de que el cliente las solicite. La IA Generativa no solo está redefiniendo la atención al cliente, sino que marca el inicio de una nueva era de interacciones automatizadas más intuitivas, fluidas y eficientes.

3.2.2 Legal y Compliance: Análisis de Contratos

El análisis de contratos es una tarea esencial en empresas, estudios jurídicos e instituciones que gestionan acuerdos legales y normativos. Este proceso es clave en sectores como el financiero, tecnológico, gubernamental, de salud y otros, donde la correcta interpretación de cláusulas y el cumplimiento regulatorio pueden tener un impacto crítico en la operación y gestión de riesgos. Las diferencias en la redacción de los contratos, la complejidad de las regulaciones y la necesidad de evaluar grandes volúmenes de documentos hacen que este trabajo sea demandante y propenso a errores. En organizaciones con una alta carga contractual, la revisión manual retrasa negociaciones, incrementa costos y puede generar riesgos legales si se omiten términos clave o no se detectan inconsistencias a tiempo.

Para abordar estos desafíos, las organizaciones comenzaron a buscar soluciones tecnológicas que les permitieran agilizar la gestión de contratos y reducir la carga operativa. Uno de los primeros avances fue la implementación de software de gestión documental, herramientas que permiten digitalizar y centralizar los contratos en bases de datos estructuradas. Estas plataformas permitían clasificar documentos, realizar búsquedas avanzadas y gestionar versiones, lo que facilitaba el seguimiento de modificaciones y la colaboración entre equipos legales. Si bien estas soluciones ayudaron a mejorar la organización de la información, su alcance era limitado, ya que no podían interpretar el contenido legal, detectar riesgos ni evaluar la coherencia entre cláusulas, tareas que seguían en manos de los especialistas.

Más adelante, surgieron soluciones basadas en los primeros modelos de inteligencia artificial, que incorporaban algoritmos de procesamiento de lenguaje natural (NLP) para identificar cláusulas específicas dentro de los contratos. Estos sistemas representaron un avance, ya que automatizaban la detección de términos clave y alertaban sobre disposiciones críticas, agilizando la primera etapa del análisis contractual. Sin embargo, su análisis se basaba en patrones predefinidos, lo que les dificultaba interpretar el contexto legal completo, detectar inconsistencias entre cláusulas o adaptarse a

variaciones en la redacción. Además, no podían ajustar su análisis a marcos normativos específicos ni reconocer automáticamente cambios legislativos, lo que los hacía poco confiables en entornos con regulaciones dinámicas. (Moreno-Schneider et al., 2020).

La llegada de la IA Generativa revolucionó la manera en la que se analizan los contratos a partir de una capacidad disruptiva: la de comprender e interpretar el lenguaje en profundidad. Muchas de las tareas que antes dependían exclusivamente del análisis humano ahora pueden ser automatizadas con un alto grado de precisión, permitiendo reducir tiempos de revisión y minimizar errores. Estos modelos son capaces de analizar cláusulas en su totalidad, interpretando su alcance dentro del contrato y en relación con normativas vigentes. Pueden detectar contradicciones entre términos, señalar posibles riesgos en la redacción y evaluar si el documento está alineado con marcos regulatorios. Además, al conectarse con bases de datos normativas y jurídicas, pueden contrastar automáticamente los términos contractuales con la legislación aplicable y advertir sobre posibles incumplimientos. De esta manera, la IA Generativa no solo agiliza el análisis contractual, sino que redefine el flujo de trabajo legal, permitiendo que los especialistas se concentren en la validación y en decisiones estratégicas más complejas. (Martin et al., 2024).

Existen distintas estrategias para implementar estas soluciones, dependiendo del nivel de personalización requerido, la sensibilidad de los datos y la infraestructura disponible. Algunas empresas optan por modelos comerciales que operan en la nube, mientras que otras prefieren herramientas especializadas o soluciones de código abierto que les permitan mayor control sobre el análisis contractual.

Los modelos comerciales como GPT-4, Claude y Gemini permiten analizar contratos a través de APIs en la nube, ofreciendo rapidez de implementación, escalabilidad y acceso a modelos de última generación. Estos modelos han demostrado un alto rendimiento en la interpretación del lenguaje, lo que los hace útiles para automatizar el análisis contractual. Sin embargo, no fueron entrenados específicamente en derecho, por lo que su precisión puede verse afectada en el análisis de términos jurídicos complejos o interpretaciones normativas específicas. Para mejorar su desempeño, suelen combinarse con bases de datos jurídicas externas o integrarse con sistemas de gestión documental que permitan validar la información con marcos regulatorios específicos. No obstante, uno de los mayores desafíos de estas soluciones es la seguridad y confidencialidad de los datos, ya que al operar en la nube, la información contractual es procesada fuera de la infraestructura de la empresa. Esto implica una pérdida de control sobre el manejo de datos sensibles, lo que puede ser un factor crítico para organizaciones con estrictos requisitos de privacidad y cumplimiento normativo.

Para lograr mayor precisión en el análisis legal, surgieron herramientas especializadas entrenadas con grandes volúmenes de documentos jurídicos. A diferencia de los modelos generalistas, han sido ajustadas mediante fine-tuning con datos legales, lo que les permite identificar cláusulas críticas, evaluar riesgos contractuales y generar reportes alineados con normativas vigentes de una manera mucho más efectiva. Plataformas como Harvey AI, Kira Systems y Luminance, entre otros, destacan por su precisión en el

análisis de contratos estándar y su capacidad para procesar grandes volúmenes de documentos de manera eficiente. Operan en entornos cloud privados, lo que facilita escalabilidad y actualizaciones constantes con cambios regulatorios, pero también implica desafíos de confidencialidad similares a los modelos comerciales, lo que puede ser una barrera para empresas con estrictos requisitos de privacidad. Además, al estar entrenadas con datos jurídicos generalistas, no pueden ser ajustadas por el usuario para adaptarse a normativas internas o análisis de contratos altamente especializados. Esto puede ser una desventaja para empresas que manejan contratos con estructuras únicas o regulaciones en constante cambio, donde la flexibilidad en el análisis es clave.

Para organizaciones que requieren mayor control sobre la información y la capacidad de personalizar el análisis contractual según normativas internas, los modelos open-source como LLaMA, Mistral y Falcon representan una alternativa viable. A diferencia de las soluciones comerciales o especializadas, estos modelos permiten entrenar modelos propios mediante fine-tuning, ajustándolos con contratos internos y regulaciones específicas para mejorar su precisión en entornos legales concretos. Además, la integración con retrieval-augmented generation (RAG) les permite consultar bases de datos jurídicas en tiempo real, asegurando que el análisis se base en información actualizada. Si bien esta opción requiere mayor inversión y conocimientos técnicos, es la única que permite un control absoluto sobre el modelo y su entrenamiento, adaptándolo de manera precisa a las necesidades de la organización. (Siino et al., 2025).

Además de entrenar modelos desde cero, también existen modelos open-source preentrenados específicamente para el ámbito legal, como LegalBERT y LexGPT, disponibles en plataformas como Hugging Face. (Jayakumar et al., 2023). Estos modelos han sido ajustados con grandes volúmenes de datos jurídicos y permiten realizar tareas como clasificación de cláusulas, análisis de cumplimiento normativo y generación de resúmenes legales con mayor precisión que los modelos generalistas. Al igual que los modelos open-source generalistas, pueden ser ajustados mediante fine-tuning para adaptarse a necesidades específicas.

3.3 Riesgos, Limitaciones y Buenas Prácticas

La inteligencia artificial ha demostrado un potencial transformador en múltiples áreas del negocio, como se ha visto a lo largo de este capítulo. Sin embargo, su implementación no está exenta de desafíos. Adoptar soluciones de IA sin un análisis riguroso puede derivar en errores costosos, decisiones sesgadas o efectos no deseados sobre la operación, los equipos o los clientes. Por eso, tan importante como conocer las oportunidades que ofrece esta tecnología es comprender sus limitaciones y riesgos, así como las condiciones necesarias para su uso responsable.

Las pequeñas y medianas empresas, en particular, deben tener presente que la IA no es una solución mágica ni universal. Si bien existen herramientas cada vez más accesibles, la efectividad de su aplicación depende de múltiples factores, entre ellos la

calidad de los datos disponibles, la claridad del problema a resolver, la capacidad de interpretar los resultados y la madurez digital de la organización.

A continuación se presentan los principales riesgos asociados a la implementación de IA en entornos empresariales, junto con las limitaciones técnicas y organizacionales que pueden condicionar su desempeño. Se incluye también un conjunto de buenas prácticas que permiten mitigar estos desafíos. El objetivo no es desalentar su adopción, sino ofrecer un marco realista que ayude a evaluar con mayor criterio cuándo, cómo y para qué incorporar esta tecnología en el proceso de transformación empresarial.

3.3.1 Limitaciones Tecnológicas

La inteligencia artificial es una tecnología poderosa, pero no está exenta de restricciones técnicas que deben ser comprendidas antes de su implementación. Estas limitaciones pueden afectar la precisión de los modelos, su capacidad de adaptación y su aplicabilidad en distintos contextos. En esta sección se abordan los principales factores que condicionan el rendimiento de las soluciones de IA desde el punto de vista técnico, con foco en aquellos aspectos que suelen pasar desapercibidos en los discursos más entusiastas.

3.3.1.1 Sesgos de información

Una de las limitaciones más importantes en el desarrollo de soluciones de inteligencia artificial es la presencia de sesgos en los datos. En términos estadísticos, esto se produce cuando los datos utilizados para entrenar un modelo no representan adecuadamente el fenómeno que se busca analizar o predecir. La falta de representatividad puede deberse a errores de muestreo, a la omisión de variables relevantes o a la presencia de correlaciones espurias que inducen al modelo a aprender patrones incorrectos.

En modelos de aprendizaje automático, esto puede generar predicciones sesgadas o inestables cuando el modelo se aplica en entornos distintos a aquellos utilizados para su entrenamiento. Por ejemplo, un sistema de recomendación comercial entrenado con información histórica de clientes frecuentes podría ignorar sistemáticamente a nuevos perfiles que no cumplen con ese patrón, limitando su capacidad de captación o personalización. En modelos generativos, el sesgo se expresa en la forma en que los sistemas completan textos, generan imágenes o responden preguntas, replicando patrones dominantes en los datos de entrenamiento, que muchas veces arrastran errores, estereotipos o vacíos estructurales.

El problema no reside solamente en los algoritmos, sino en la información que les da forma. Un modelo que aprende a partir de datos incompletos, homogéneos o desactualizados difícilmente podrá ofrecer resultados relevantes, robustos y generalizables. Esto no solo afecta la calidad de las decisiones, sino también la confianza en el sistema, especialmente cuando los resultados son difíciles de auditar o interpretar.

Para mitigar este problema, es fundamental analizar críticamente la procedencia y composición de los datos utilizados. Las empresas que consideren implementar IA deberían preguntarse si los datos disponibles son suficientemente amplios, diversos y actualizados como para reflejar la realidad sobre la que se espera operar. Cuando eso no sea posible, es recomendable comenzar con proyectos acotados, donde se puedan controlar mejor las fuentes de información, y contar con asistencia técnica interna o externa que permita evaluar la calidad y los posibles sesgos de los datos. Existen técnicas específicas de análisis exploratorio, balanceo de clases, detección de anomalías en los datos o monitoreo posterior que ayudan a reducir el impacto de estos sesgos en el comportamiento del modelo.

Garantizar la calidad, diversidad y relevancia de los datos no es un aspecto secundario, sino una condición central para el éxito de cualquier proyecto de inteligencia artificial. Los modelos no operan en el vacío: su desempeño está directamente determinado por la información con la que fueron entrenados. Por eso, abordar de manera crítica y sistemática la composición de los datos es un paso imprescindible para asegurar que las soluciones de IA sean válidas, útiles y sostenibles en contextos reales.

3.3.1.2 Falta de transparencia y explicabilidad

Uno de los desafíos técnicos más relevantes en el uso de modelos de inteligencia artificial es la dificultad para comprender cómo se obtienen los resultados. Muchos de los algoritmos más potentes, especialmente aquellos basados en redes neuronales profundas, funcionan como cajas negras: producen respuestas precisas, pero no ofrecen explicaciones claras sobre el camino seguido para llegar a ellas. Esta falta de transparencia puede limitar la confianza en el sistema, dificultar su validación interna y generar resistencia a su adopción dentro de la organización.

En contextos donde las decisiones deben ser justificadas, como procesos financieros, evaluaciones legales o políticas de atención al cliente, no poder explicar por qué un modelo clasificó un caso de cierta manera puede convertirse en un problema serio. Incluso cuando el modelo acierta, la ausencia de criterios interpretables puede generar incertidumbre, especialmente entre quienes deben actuar en base a sus recomendaciones.

Este problema también se manifiesta en la IA generativa, donde los modelos pueden producir textos, imágenes o respuestas convincentes pero basadas en razonamientos difíciles de reconstruir o auditar. Esto puede dar lugar a respuestas técnicamente correctas pero desalineadas con los objetivos del negocio o con el contexto específico de aplicación.

Un buen enfoque consiste en comenzar con modelos simples, cuya lógica pueda ser validada por quienes conocen el negocio, y avanzar hacia soluciones más complejas solo cuando haya claridad sobre el problema, los datos disponibles y el uso que se le dará a

los resultados. La explicabilidad no es solo un atributo técnico, sino una condición clave para generar confianza, facilitar la adopción y garantizar que la inteligencia artificial se utilice como una herramienta efectiva y alineada con los objetivos de la empresa.

3.3.1.3 Generalización y Overfitting

Una de las capacidades fundamentales que debe tener un modelo de inteligencia artificial es la de generalizar, es decir, ofrecer resultados precisos no solo sobre los datos con los que fue entrenado, sino también frente a nuevos casos o situaciones reales. Cuando un modelo no logra este objetivo y muestra un rendimiento artificialmente alto durante la fase de entrenamiento pero bajo desempeño al aplicarse en la práctica, se dice que ha incurrido en un problema de sobreajuste u overfitting.

Este fenómeno ocurre cuando el modelo aprende en exceso los detalles del conjunto de entrenamiento, incluyendo ruido, errores o patrones circunstanciales que no se repiten en otros contextos. En lugar de captar regularidades generales útiles para la predicción, se ajusta demasiado a los casos particulares observados, perdiendo capacidad para adaptarse a variaciones. Esto puede suceder, por ejemplo, cuando se entrena un modelo con una cantidad limitada de datos, o cuando se utilizan algoritmos muy complejos para resolver problemas simples.

En el ámbito empresarial, un modelo sobreajustado puede generar decisiones erráticas, cambios abruptos en sus recomendaciones o predicciones poco confiables cuando cambian mínimamente las condiciones. Este comportamiento no solo reduce su utilidad práctica, sino que puede generar desconfianza en quienes lo utilizan o interpretan sus resultados.

Para minimizar este riesgo, es importante validar el modelo en datos distintos a los utilizados para su entrenamiento, mediante técnicas como la separación entre conjuntos de entrenamiento y prueba, o el uso de validación cruzada. También puede ser conveniente comenzar con modelos de menor complejidad y ajustarlos progresivamente solo si los resultados lo justifican. Más allá del tipo de algoritmo utilizado, lo esencial es evaluar su capacidad para funcionar correctamente en contextos reales, no solo en entornos de prueba controlados.

3.3.2 Desafíos Organizacionales y Regulatorios

Más allá de las limitaciones técnicas de los modelos de inteligencia artificial, existen barreras organizacionales, culturales y normativas que pueden dificultar su implementación efectiva. Estos desafíos no están vinculados al funcionamiento del algoritmo en sí, sino a las condiciones institucionales que rodean su adopción: desde la calidad de los procesos internos hasta el cumplimiento de marcos regulatorios en constante evolución.

En esta sección se abordan cinco dimensiones clave que deben ser consideradas al momento de incorporar inteligencia artificial en una organización. Primero, se analiza la gobernanza de los datos, entendida como el conjunto de responsabilidades, políticas y mecanismos que garantizan la calidad, trazabilidad y disponibilidad de la información. Luego, se explora cómo la cultura organizacional y la capacidad de gestionar el cambio inciden en la adopción de nuevas tecnologías. También se abordan los requerimientos vinculados a la privacidad y protección de datos, los riesgos legales y reputacionales asociados al uso de sistemas automatizados, y finalmente, los peligros que implica una dependencia excesiva de proveedores externos o plataformas cerradas que limitan la autonomía tecnológica de la empresa.

Identificar y anticipar estos desafíos no implica postergar la adopción de IA, sino abordarla con una visión más realista y estratégica. Solo reconociendo las condiciones necesarias para una implementación responsable es posible garantizar que esta tecnología se traduzca en una verdadera ventaja competitiva y no en una fuente de frustración o riesgo.

3.3.2.1 Gobernanza de datos y responsabilidad interna

La incorporación de inteligencia artificial en las organizaciones no puede desligarse de una gestión adecuada de los datos. Si los modelos son la maquinaria que procesa la información, los datos son el insumo crítico que define su rendimiento. En este sentido, la gobernanza de datos se convierte en un aspecto central: implica definir reglas claras sobre cómo se recopila, organiza, valida, actualiza y utiliza la información dentro de la empresa. Sin una estructura mínima de gobernanza, cualquier iniciativa basada en IA estará construida sobre una base inestable.

En muchas pequeñas y medianas empresas, la información clave se encuentra dispersa entre sistemas no integrados, archivos compartidos, planillas personales o incluso registros físicos. Esta fragmentación no solo dificulta la explotación de datos para entrenar modelos, sino que también genera incertidumbre sobre su calidad, trazabilidad y actualidad. En entornos así, las decisiones algorítmicas pueden apoyarse en datos incompletos, desactualizados o inconsistentes, con consecuencias directas sobre los resultados.

La gobernanza de datos también implica definir responsabilidades internas. ¿Quién valida la calidad de los datos? ¿Quién autoriza su uso? ¿Cómo se asegura la coherencia entre áreas? Sin respuestas claras, las iniciativas de IA quedan expuestas a errores operativos, conflictos entre sectores o problemas legales vinculados al uso indebido de información. Estos riesgos no dependen de la tecnología, sino de la ausencia de criterios compartidos dentro de la organización.

Para avanzar hacia un esquema mínimo de gobernanza, no es necesario implementar grandes estructuras ni invertir en soluciones costosas. En muchos casos, es suficiente con designar responsables para cada conjunto de datos, establecer buenas prácticas de

registro y validación, y mantener un inventario claro de qué información existe, dónde se encuentra y con qué nivel de confiabilidad se cuenta. Este tipo de acciones, aunque básicas, son fundamentales para sentar las bases de una adopción de IA más segura, sustentable y alineada con los objetivos del negocio.

3.3.2.2 Resistencia al cambio

Uno de los obstáculos más frecuentes en las pequeñas y medianas empresas frente a la incorporación de nuevas tecnologías no es técnico, sino humano. Muchas veces, las herramientas están disponibles, pero no se utilizan o se rechazan porque generan incomodidad, dudas o temor. La inteligencia artificial, por su nivel de sofisticación y su impacto potencial, suele amplificar estas reacciones, especialmente cuando no se comprende bien qué hace ni cómo puede integrarse al trabajo cotidiano.

En entornos de alta rotación operativa, con procesos poco documentados o con una fuerte dependencia de conocimientos informales, es común que los cambios tecnológicos generen resistencia. Algunos empleados temen que sus tareas se vuelvan obsoletas, otros desconfían de los resultados del sistema, y muchas veces los mismos dueños o directivos dudan de la utilidad real de estas herramientas. Esta resistencia no necesariamente se expresa como un rechazo explícito, sino que puede aparecer en forma de demoras, falta de seguimiento o uso parcial de las soluciones implementadas.

Superar estas barreras no requiere grandes inversiones ni programas de transformación cultural, pero sí implica acompañar el proceso. Es importante que las nuevas herramientas se introduzcan explicando claramente su objetivo, mostrando casos concretos de uso y escuchando activamente las preocupaciones del equipo. La participación del personal desde etapas tempranas, aunque sea en forma parcial, suele mejorar la apropiación y el uso efectivo de las soluciones.

En el caso de la inteligencia artificial, esto puede implicar comenzar con aplicaciones pequeñas, visibles y de impacto directo, como automatizar una tarea repetitiva o generar reportes que antes tomaban mucho tiempo. Estos primeros casos ayudan a desmitificar la tecnología, mostrar beneficios concretos y abrir el camino para una adopción más amplia. Sin este trabajo previo, incluso la mejor solución técnica puede fracasar por falta de adopción interna.

3.3.2.3 Privacidad, confidencialidad y protección de datos

El uso de inteligencia artificial implica trabajar con grandes volúmenes de información, y en muchos casos, esa información incluye datos sensibles, confidenciales o estratégicos para la empresa. Esto adquiere una relevancia particular cuando se utilizan modelos de IA generativa o agentes autónomos (AI Agents), ya que la información ingresada no siempre permanece dentro del entorno controlado de la organización.

Una de las principales preocupaciones surge cuando se utilizan plataformas comerciales basadas en la nube, como asistentes conversacionales, herramientas de generación de contenido o modelos integrados en aplicaciones de terceros. Los datos cargados, incluso si se trata de correos, documentos internos, precios o estrategias comerciales, pueden ser procesados en servidores externos sin que quede claro qué uso se hace de ellos. Esto plantea riesgos tanto desde el punto de vista de la confidencialidad como del cumplimiento legal.

En el caso de los agentes autónomos, que combinan modelos generativos con capacidad de acción automatizada, el riesgo se multiplica. Estos sistemas pueden interactuar con bases de datos, enviar mensajes, modificar contenidos o tomar decisiones sin supervisión directa, lo que aumenta la exposición a errores, filtraciones o accesos indebidos a información crítica.

Mitigar estos riesgos no requiere abandonar el uso de IA, pero sí implica tomar recaudos mínimos. Es fundamental saber qué tipo de información se está ingresando en cada herramienta, evitar compartir datos confidenciales en plataformas abiertas y, en lo posible, optar por soluciones que permitan mantener control local o privado sobre los modelos utilizados. En casos donde se trabaje con proveedores externos, es clave revisar los términos de uso, las políticas de almacenamiento y el destino final de los datos.

A medida que la IA se integra en más procesos del negocio, garantizar la privacidad y protección de la información no solo es una obligación legal, sino una condición básica para preservar la confianza en el uso de estas tecnologías.

3.3.2.4 Riesgos legales y regulatorios

A medida que las soluciones de inteligencia artificial se integran en más procesos empresariales, también crecen los riesgos vinculados a su uso, especialmente cuando afectan a clientes, empleados o terceros. Estos riesgos no se limitan al ámbito técnico: pueden derivar en conflictos legales, sanciones regulatorias o impactos negativos en la reputación de la empresa, incluso cuando no hubo intención de hacer un mal uso de la tecnología.

En muchos casos, las empresas implementan sistemas automatizados que toman decisiones o generan resultados sin haber definido con claridad quién es responsable por sus consecuencias. Por ejemplo, si un modelo genera una recomendación errónea que perjudica a un cliente, o si un agente automatizado realiza una acción fuera de contexto, ¿quién responde ante esa situación? Aunque la tecnología haya sido provista por un tercero, la empresa que la utiliza sigue siendo responsable por sus efectos.

Más allá del plano legal, también existen riesgos vinculados a la reputación de la empresa. Una decisión automatizada que afecte negativamente a un cliente, un contenido generado con errores, o el uso indebido de información pueden dañar la imagen de una empresa, incluso si el problema fue causado por una herramienta

externa. En contextos donde la confianza es un activo clave, como el comercio minorista, los servicios profesionales o la atención al cliente, este tipo de incidentes puede tener consecuencias más graves que el propio error técnico.

Para reducir estos riesgos, es importante definir límites claros al uso de la IA dentro de la empresa y mantener la capacidad de supervisión sobre sus resultados. También es recomendable evitar delegar decisiones críticas en sistemas que no se comprenden o no pueden ser auditados. Incorporar una mirada legal desde las etapas iniciales, aun de forma sencilla, permite anticipar posibles consecuencias no deseadas y reforzar la legitimidad del uso de estas tecnologías dentro y fuera de la organización.

3.3.2.5 Dependencia tecnológica

Muchas pequeñas y medianas empresas, al incorporar inteligencia artificial por primera vez, lo hacen a través de soluciones desarrolladas por terceros o integradas en plataformas externas. Si bien esto permite un acceso más rápido y sencillo a estas tecnologías, también puede generar una dependencia estructural que limite la autonomía de la empresa en el futuro. Este fenómeno se conoce como lock-in tecnológico y se produce cuando una organización queda atada a un proveedor, una arquitectura o un conjunto de herramientas que no puede reemplazar fácilmente sin perder datos, funcionalidades o inversiones realizadas.

Esto es especialmente relevante en el campo de la IA, donde los modelos, los datos y los flujos de trabajo suelen estar integrados dentro de entornos propietarios. Muchas veces, las empresas utilizan servicios que no permiten exportar los datos en formatos abiertos, ajustar los modelos según nuevas necesidades o migrar fácilmente a otras plataformas. Como consecuencia, cualquier cambio de proveedor, actualización del sistema o necesidad de escalar la solución puede implicar altos costos, riesgos operativos o directamente la imposibilidad de avanzar.

Además, en soluciones de IA generativa o agentes autónomos ofrecidos como servicio, es común que los términos de uso limiten el control sobre el modelo, los datos generados o las condiciones bajo las cuales la empresa puede usar la herramienta. En algunos casos, ni siquiera se garantiza la continuidad del servicio, lo que puede afectar la operación si la herramienta se vuelve crítica para el negocio.

Para reducir este riesgo, es recomendable evaluar desde el inicio el grado de dependencia que implica cada solución tecnológica. Siempre que sea posible, conviene optar por plataformas que utilicen estándares abiertos, permitan el acceso y resguardo local de los datos, y no condicionen la continuidad operativa a decisiones externas. También es útil mantener cierta documentación interna sobre cómo funciona la herramienta, qué procesos afecta y qué alternativas existen en caso de discontinuidad. Aunque estas medidas pueden parecer excesivas en un primer momento, son fundamentales para preservar la capacidad de adaptación de la empresa frente a cambios tecnológicos o estratégicos futuros.

3.3.3 Buenas prácticas para una implementación responsable

Luego de haber analizado las principales limitaciones tecnológicas y los desafíos organizacionales que conlleva la adopción de inteligencia artificial, esta sección propone un conjunto de buenas prácticas que pueden ayudar a reducir los riesgos y aumentar las probabilidades de éxito en su implementación. Se trata de criterios prácticos que pueden adaptarse a las capacidades y necesidades de cada empresa, especialmente en el contexto de las pequeñas y medianas organizaciones.

El objetivo es contar con ciertos lineamientos que permitan avanzar con mayor seguridad, orden y coherencia. La inteligencia artificial puede generar resultados concretos incluso en entornos simples, siempre que se respete una lógica progresiva, con foco en problemas bien definidos, datos confiables y decisiones razonadas. La experiencia muestra que muchas implementaciones fallan no por falta de tecnología, sino por expectativas desalineadas, falta de preparación o decisiones apresuradas.

A continuación, se presentan cuatro recomendaciones generales para orientar una adopción más efectiva y responsable: evaluar la factibilidad antes de iniciar un proyecto, avanzar de forma gradual y controlada, integrar distintas perspectivas desde el comienzo y establecer mecanismos de revisión continua que permitan aprender y corregir sobre la marcha.

3.3.3.1 Evaluar la factibilidad antes de implementar IA

Un error frecuente en la incorporación de inteligencia artificial es comenzar por la solución en lugar de comenzar por el problema. La disponibilidad de herramientas accesibles y las promesas de automatización generan a veces la ilusión de que cualquier empresa puede implementar IA con resultados inmediatos. Sin embargo, no toda necesidad empresarial puede resolverse con modelos inteligentes, y no todo modelo tiene sentido si no se cuenta con los datos adecuados, un objetivo claro o los recursos para sostenerlo.

Por eso, antes de iniciar cualquier proyecto de IA, es clave realizar una evaluación de factibilidad. Esto no requiere conocimientos técnicos avanzados, pero sí implica responder algunas preguntas básicas: ¿qué problema queremos resolver?, ¿por qué creemos que la IA puede ayudarnos?, ¿tenemos datos suficientes y de calidad para entrenar un modelo?, ¿quién va a usar los resultados?, ¿cómo vamos a medir si funciona?

En muchos casos, un análisis simple permite descartar iniciativas inviables antes de destinar tiempo y recursos a su desarrollo. Por ejemplo, si el problema no está bien definido, si los datos no existen o no pueden integrarse, o si la empresa no cuenta con personal que entienda los resultados, es probable que el modelo no tenga impacto real. En esas situaciones, puede ser más útil mejorar primero los procesos internos, ordenar

la información o explorar soluciones más simples que sienten las bases para una futura adopción de IA.

Evaluar la factibilidad no es una etapa burocrática, sino una práctica de madurez empresarial. Permite tomar decisiones más racionales, evitar frustraciones y construir un camino de adopción más sólido, con objetivos alcanzables y resultados medibles. En contextos como el de las PYMEs, donde los recursos son limitados y el tiempo escaso, esta etapa puede marcar la diferencia entre un experimento fallido y una solución realmente útil.

3.3.3.2 Enfoques graduales y controlados

La inteligencia artificial no requiere implementaciones disruptivas para generar valor. Por el contrario, una de las estrategias más efectivas, especialmente en pequeñas y medianas empresas, es avanzar de forma progresiva, con proyectos acotados que permitan probar, aprender y corregir antes de escalar. Este enfoque no solo reduce los riesgos técnicos, sino que también facilita la apropiación interna de las herramientas y permite construir confianza en sus resultados.

Una implementación gradual puede comenzar por tareas específicas que sean repetitivas, costosas en términos de tiempo o propensas a errores humanos. Automatizar una parte del proceso de análisis de datos, generar reportes a partir de información ya disponible, o incorporar un asistente virtual para responder consultas frecuentes son ejemplos concretos que no requieren transformar toda la operación, pero permiten mostrar resultados tangibles en poco tiempo.

Además de facilitar la validación de los modelos, este tipo de iniciativas sirve para alinear expectativas. Muchas veces, la percepción inicial sobre la IA está cargada de promesas irreales o temores infundados. Trabajar con casos puntuales, acotados en alcance y con impacto visible, permite que los equipos comprendan mejor cómo funciona la herramienta, qué puede aportar y qué limitaciones tiene.

Este enfoque también es útil desde el punto de vista organizacional. Permite identificar qué áreas están más preparadas para incorporar nuevas tecnologías, dónde surgen resistencias, y qué tipo de acompañamiento es necesario para sostener el cambio. A partir de estos aprendizajes, es posible planificar futuras implementaciones con mayor claridad, evitando errores y aprovechando lo que ya se ha construido.

Adoptar la IA en etapas no significa ser conservador, sino actuar con criterio. En contextos donde los recursos son escasos y el margen de error es bajo, avanzar paso a paso es muchas veces la forma más efectiva y rápida para generar resultados concretos y sostenibles.

3.3.3.3 Participación multidisciplinaria

El desarrollo e implementación de estas soluciones no debería ser una tarea exclusiva de especialistas en tecnología. Para que estas herramientas funcionen en la práctica, es necesario que distintos perfiles dentro de la empresa participen desde el inicio del proceso. Esto incluye no solo al área técnica o al proveedor externo, sino también a quienes conocen en profundidad el negocio, a quienes tomarán decisiones en base a los resultados y, cuando sea necesario, a quienes tienen una mirada legal, operativa o estratégica sobre el impacto del proyecto.

Cuando la IA se implementa sin esta diversidad de miradas, es común que los modelos estén bien programados pero mal orientados, que resuelvan problemas que no son prioritarios, o que sus resultados no puedan ser interpretados ni utilizados por quienes deberían beneficiarse de ellos. Por el contrario, cuando el conocimiento técnico se articula con el conocimiento del negocio, las soluciones tienden a ser más relevantes, más comprensibles y más útiles para la operación diaria.

Esta participación no implica que todos los involucrados deban saber de algoritmos o programación, sino que puedan contribuir con su experiencia para definir el problema, entender qué datos son relevantes, interpretar los resultados y anticipar posibles efectos no deseados. También permite detectar a tiempo errores de enfoque, riesgos regulatorios o impactos indirectos que podrían pasar desapercibidos si el proyecto queda en manos de un único perfil.

En el contexto de las PYMEs, donde muchas veces no existen áreas especializadas ni recursos sobrantes, esta participación puede darse de forma simple, pero debe estar presente. Un responsable de ventas que valida cómo se segmentan los clientes, un encargado de logística que analiza los resultados de una predicción de demanda, o un gerente que interpreta la recomendación de un modelo, son ejemplos de cómo se puede construir una implementación más robusta sin necesidad de grandes estructuras.

La inteligencia artificial, para ser efectiva, necesita combinar el poder del análisis automatizado con la comprensión profunda del contexto. Y eso solo es posible cuando se integran distintas perspectivas desde el primer momento.

3.3.3.4 Monitoreo, revisión y mejora continua

Implementar una solución de inteligencia artificial no es un evento puntual, sino el comienzo de un proceso que requiere seguimiento. Incluso cuando un modelo funciona bien en su etapa inicial, su desempeño puede degradarse con el tiempo si cambian las condiciones del entorno, los hábitos de los usuarios o los datos que alimentan su funcionamiento. Por eso, una parte esencial de cualquier implementación responsable es establecer mecanismos de monitoreo y revisión continua que permitan evaluar cómo se comporta la herramienta en la práctica y corregir desvíos a tiempo.

En las pequeñas y medianas empresas, donde los recursos suelen ser más limitados, esto no implica montar estructuras complejas de control, sino incorporar rutinas simples que permitan validar periódicamente si los resultados siguen siendo confiables y útiles. Por ejemplo, comparar las predicciones con los resultados reales, registrar cuándo el modelo falla o deja de ser relevante, o simplemente consultar con los usuarios si la herramienta sigue aportando valor.

Además del seguimiento técnico, también es importante revisar los efectos más amplios de la solución: cómo impacta en el trabajo diario, si genera fricciones internas, si produce efectos no deseados sobre clientes o procesos, o si hay nuevas variables que sería necesario incorporar. Este tipo de evaluación permite no solo sostener el rendimiento del modelo, sino también ajustarlo a medida que cambian las necesidades del negocio.

La mejora continua también requiere apertura. Muchas veces, los modelos no fallan por errores de cálculo, sino porque el contexto cambió y las reglas anteriores ya no aplican. En estos casos, es mejor ajustar o incluso abandonar una solución a tiempo que seguir operando con una herramienta que ya no responde al problema real.

Monitorear y mejorar no es una tarea extra: es parte del proceso de aprendizaje organizacional que la IA puede potenciar. Cuando se la acompaña con revisión crítica y capacidad de adaptación, la inteligencia artificial deja de ser una herramienta puntual y se convierte en un activo estratégico para la empresa.

3.4 Conclusiones

A lo largo de este capítulo se ha mostrado cómo la inteligencia artificial ha dejado de ser una promesa tecnológica para convertirse en un recurso estratégico capaz de transformar los procesos de negocio de las organizaciones. La revisión de casos concretos en supply chain, marketing y ventas, producción, control de calidad, finanzas y otros, permite observar que la IA no opera en la periferia de las organizaciones, sino que se ha integrado de manera estructural en sus procesos clave, modificando prácticas tradicionales y abriendo nuevas formas de crear valor.

En sus primeras aplicaciones basadas en modelos de machine learning y técnicas estadísticas avanzadas, la IA ha demostrado una gran capacidad para procesar grandes volúmenes de datos, detectar patrones ocultos, automatizar decisiones y optimizar procesos con una precisión que supera ampliamente las herramientas convencionales.

Con el desarrollo de la inteligencia artificial generativa se ha ampliado significativamente el alcance de la transformación digital. Ya no se trata solo de analizar datos existentes, sino de generar nuevo contenido, interpretar lenguaje complejo y automatizar tareas que hasta hace poco eran consideradas exclusivamente humanas. Esta evolución ha permitido, por ejemplo, automatizar la atención al cliente con sistemas que entienden el contexto emocional y operativo de cada consulta, generar documentos legales complejos en segundos o analizar contratos con precisión jurídica especializada. La IA generativa

ha introducido un nuevo paradigma en la interacción entre humanos y sistemas inteligentes, reduciendo la dependencia de programaciones rígidas y abriendo el camino a soluciones más adaptables, creativas y proactivas.

Sin embargo, esta transformación no está exenta de desafíos. La implementación efectiva de la inteligencia artificial exige no solo herramientas, sino también una revisión profunda de procesos, una cultura organizacional abierta a la experimentación y la capacidad de gestionar nuevos riesgos asociados, como la seguridad de los datos, la calidad de las predicciones o el impacto en los equipos humanos. La calidad de los datos, la capacidad de generalización de los modelos, la transparencia de los resultados y el cumplimiento normativo son factores que deben ser cuidadosamente considerados antes de implementar cualquier solución.

Las PYMEs, en particular, enfrentan barreras organizacionales, culturales y tecnológicas que requieren un abordaje realista y progresivo. Por eso, se han presentado también un conjunto de buenas prácticas que permiten reducir riesgos y aumentar las probabilidades de éxito en la adopción de estas tecnologías. Incorporar IA no se trata solo de acceder a nuevas herramientas, sino de hacerlo con criterio, alineado a los objetivos del negocio y con la madurez organizacional necesaria para sostener su implementación en el tiempo.

A continuación, se analizará cómo las pequeñas y medianas empresas pueden evaluar y adoptar la inteligencia artificial de manera concreta y realista, teniendo en cuenta sus propios contextos, recursos y necesidades. Para ello, se presentará una herramienta práctica que permite identificar las oportunidades de aplicación de estas tecnologías en distintos procesos del negocio. El objetivo es ofrecer un enfoque accesible que sirva de guía para aquellas empresas que, aun enfrentando limitaciones, tienen el potencial y la flexibilidad necesaria para dar sus primeros pasos en esta transformación.

CAPÍTULO 4: LA INTELIGENCIA ARTIFICIAL EN LAS PYMES

4.1 El Desafío de las Pymes frente a la IA

Las PYMES no operan bajo las mismas reglas que las grandes corporaciones. Sus dinámicas, prioridades y desafíos son distintos: deben competir con recursos limitados, tomar decisiones con rapidez y adaptarse constantemente a un entorno cambiante. Mientras que en una gran empresa la planificación estratégica puede extenderse por meses o años, con equipos especializados para cada área, en una PyME las decisiones deben tomarse con agilidad, con un margen de error reducido y una capacidad de reacción que puede definir su éxito o fracaso. (Aggity, s.f.)

En este contexto, la prioridad de las PYMES no es incorporar tecnología por sí misma, sino resolver problemas concretos, sostenerse en mercados cada vez más exigentes y encontrar oportunidades para crecer. No tienen margen para apuestas inciertas ni recursos para experimentos sin retornos claros. Mientras las grandes empresas cuentan con infraestructura y talento especializado para probar nuevas herramientas, las PYMES deben enfocarse en mantener el equilibrio del negocio, atender las necesidades diarias de sus clientes y optimizar su operación.

Por otro lado, el universo de las PYMES es amplio y diverso. En un extremo, encontramos pequeños comercios con estructuras mínimas, donde cada empleado cumple múltiples funciones y las decisiones se toman sobre la marcha, basándose en la experiencia y la intuición. En el otro, hay empresas con decenas o cientos de empleados, donde la estructura es más formal y los desafíos incluyen la gestión del talento, la optimización financiera y la expansión comercial. Y entre estos extremos hay una infinidad de realidades: emprendimientos digitales donde la tecnología es parte del ADN de la empresa, talleres industriales, empresas de servicios profesionales, negocios gastronómicos, distribuidoras mayoristas. Cada una con dinámicas únicas y necesidades específicas. (Hwang, 2025).

Ante esta diversidad de modelos de negocio, la manera en que cada PyME puede aprovechar la inteligencia artificial varía significativamente. No todas las empresas enfrentan los mismos desafíos ni tienen las mismas prioridades, por lo que la adopción de IA debe alinearse con su realidad operativa y estratégica. De esta manera, no todas las aplicaciones de IA generan el mismo impacto. Lo que para una empresa puede representar una solución clave, para otra puede ser irrelevante o difícil de aplicar. (IndesIA, 2024)

Las empresas industriales y manufactureras enfrentan desafíos como la eficiencia operativa, la optimización del uso de insumos y el mantenimiento de equipos. Para ellas, la IA puede aplicarse en el mantenimiento predictivo, anticipando fallas en la maquinaria antes de que ocurran; en el control de calidad con visión artificial, automatizando la

detección de defectos en productos; o en la optimización del abastecimiento, ajustando compras y stocks según la demanda proyectada.

En el sector de servicios profesionales, como estudios contables, agencias de marketing o consultoras, es más relevante la personalización en la atención al cliente o la eficiencia administrativa. La IA puede ayudarlas a automatizar tareas repetitivas, como la gestión de documentos y facturación, optimizar la relación con clientes mediante asistentes virtuales y sistemas de recomendación, o mejorar la planificación financiera con modelos de predicción de flujo de caja y detección de riesgos.

Los negocios minoristas y mayoristas deben gestionar clientes, ventas y logística con eficiencia. La IA aporta valor al personalizar ofertas, segmentando clientes y recomendando productos en función de su historial de compra; en la optimización de precios dinámicos, ajustando costos en función de la demanda y la competencia; y en la gestión eficiente del inventario, evitando quiebres de stock o sobreacumulación de productos.

En las empresas de logística y distribución, donde la eficiencia en el movimiento de productos es clave, la IA se aplica en la optimización de rutas, reduciendo costos de transporte y tiempos de entrega; en la automatización del seguimiento de envíos, mejorando la experiencia del cliente; y en el análisis de demanda y predicción de picos de actividad, optimizando la asignación de recursos.

Las empresas del sector gastronómico tienen un enfoque completamente diferente. Su desafío no es producir en masa ni distribuir productos a gran escala, sino gestionar la oferta y la demanda de manera eficiente, evitando desperdicio de insumos y maximizando la rentabilidad. La IA puede ayudar a predecir la demanda según el historial de pedidos y factores externos como el clima o eventos locales, automatizar la reposición de stock en función de patrones de consumo y ajustar dinámicamente los precios de ciertos productos en función de la demanda del momento.

También existen PYMEs tecnológicas y startups digitales, cuyo modelo de negocio ya parte de un entorno altamente digitalizado, pero que pueden beneficiarse de la IA para escalar más rápido. En estos casos, las aplicaciones van desde la automatización de la atención al cliente hasta el uso de IA para optimizar la captación de clientes en plataformas digitales, mejorar la recomendación de productos o acelerar procesos de desarrollo de software con algoritmos que optimizan el código.

No hay un único camino para la adopción de IA en PYMEs, sino múltiples formas de aprovecharla según la industria, el tamaño y la estructura de cada empresa. Cada PYME tiene sus propias necesidades, prioridades y recursos, por lo que las soluciones de IA no pueden abordarse con una receta única.

El potencial de la IA es innegable, pero para muchas PYMEs, su adopción puede venir acompañada de incertidumbre y dudas sobre cómo aplicarla de manera concreta en su negocio. La adopción de IA no es un camino lineal ni uniforme. Cada empresa enfrenta

su propio conjunto de oportunidades y limitaciones, y lo que para algunas puede ser una ventaja competitiva clara, para otras puede representar una barrera difícil de sortear.

En este escenario, muchas PYMEs se encuentran con una serie de dificultades comunes cuando evalúan incorporar IA en sus procesos. ¿Por dónde empezar? ¿Cómo diferenciar entre soluciones que pueden generar valor real y aquellas que no son aplicables a su modelo de negocio? ¿Cómo evitar invertir en herramientas que luego no se integran correctamente a su operación? ¿Cómo asegurarse de que la tecnología elegida realmente aporte mejoras sin generar costos innecesarios o complejidades difíciles de gestionar? (IBM, s.f.)

Además, a diferencia de las grandes empresas que pueden experimentar con nuevas tecnologías sin comprometer su estabilidad financiera, las PYMEs necesitan ser estratégicas en cada decisión que toman. No pueden darse el lujo de implementar soluciones sin un retorno claro ni de destinar recursos a tecnologías que no se alineen con su estructura y capacidades. Para ellas, la adopción de IA no es solo una cuestión de acceso a herramientas, sino de identificar con precisión dónde y cómo pueden generar el mayor impacto en su negocio. (Ng, 2020).

Ante estos desafíos, contar con una metodología que ayude a analizar el contexto y facilitar la toma de decisiones podría ser de gran utilidad. Con este propósito, desarrollamos una herramienta conceptual llamada Mapa de Oportunidades, diseñada para facilitar el análisis y la selección de soluciones de IA que aporten valor a su negocio. No se trata de un modelo estándar de la industria, sino de una guía práctica que permite a cada empresa identificar las aplicaciones más relevantes según su contexto. A través de este enfoque, cada PyME podrá explorar y evaluar distintas opciones en función de su nivel de digitalización, sus necesidades estratégicas y su capacidad de implementación.

El Mapa de Oportunidades está construido sobre una base amplia de aplicaciones de IA con potencial para generar valor en PYMEs de diversos sectores. Estas aplicaciones recorren distintos procesos de negocio, desde la optimización de la producción y la gestión de inventarios hasta la automatización de ventas y la mejora en la relación con los clientes. Al abarcar una variedad de soluciones aplicables en múltiples industrias, el mapa no solo permite visualizar oportunidades concretas, sino que también ayuda a cada empresa a reflexionar sobre dónde puede incorporar IA de manera estratégica. (Ng, s.f.)

A continuación, exploraremos una amplia base de aplicaciones en detalle, analizando cómo la IA puede aplicarse en distintos procesos del negocio y qué beneficios puede aportar en cada caso. Luego, abordaremos la metodología utilizada para evaluar estas soluciones, explicando los criterios clave que permiten a cada empresa analizar su viabilidad, su alineación con la estrategia de negocio y su potencial retorno de inversión.

Finalmente y para ilustrar cómo se puede aplicar esta herramienta en la práctica, llevaremos a cabo un ejercicio en el que aplicaremos el Mapa de Oportunidades a una PyME de un sector específico. A través de este caso, analizaremos un conjunto de

aplicaciones en su contexto real, permitiendo visualizar el proceso de evaluación y selección de soluciones de IA según las necesidades de la empresa y las características de su industria.

4.2 Aplicaciones de IA en las Pymes

La inteligencia artificial ofrece un potencial transformador para las pequeñas y medianas empresas, con aplicaciones que atraviesan todos sus procesos de negocio y permiten mejorar resultados de manera concreta. Las soluciones basadas en IA tienen la capacidad de generar un impacto tangible en la gestión empresarial, desde el aumento de ventas y la personalización de la oferta hasta la automatización de tareas operativas y la optimización del uso de recursos.

Pero este potencial no es estático. La IA es una tecnología en constante evolución, tanto en sus capacidades técnicas como en las formas en que puede aplicarse a los procesos de negocio. Por eso, el conjunto de aplicaciones que presentamos a continuación debe entenderse como una fotografía del momento: representativa y actual, pero no definitiva.

Este conjunto de soluciones constituye la base sobre la cual se apoya el Mapa de Oportunidades, nuestra guía práctica para evaluar qué aplicaciones pueden generar un mayor impacto en la realidad específica de cada empresa.

De esta manera, las aplicaciones fueron organizadas en tres grandes bloques que agrupan distintos procesos de negocio, en función de los ámbitos donde suelen generar mayor valor:

- ✓ Marketing, Ventas y Atención al Cliente, donde se incluyen soluciones para atraer y fidelizar clientes, personalizar la oferta y mejorar la experiencia del consumidor.
- ✓ Producción, Calidad y Supply Chain, con herramientas orientadas a aumentar la eficiencia operativa, mejorar la gestión de inventarios y optimizar el control de calidad y el mantenimiento de equipos.
- ✓ Administración y Finanzas, donde la IA permite automatizar tareas contables, optimizar la planificación financiera y reducir riesgos en la gestión económica.

Además de estas tres áreas principales, se incorpora un conjunto de soluciones basadas en inteligencia artificial generativa, de carácter transversal. Estas aplicaciones no se limitan a un proceso específico, sino que pueden integrarse de forma versátil en múltiples funciones dentro de la empresa. En particular, se destaca la figura del "Asistente GPT", pensado como un aliado estratégico para apoyar la gestión empresarial, automatizar tareas, facilitar la toma de decisiones y optimizar la productividad en distintos niveles del negocio.

Las aplicaciones que presentaremos han sido seleccionadas con un enfoque práctico, atendiendo a problemas específicos que suelen presentarse en las PYMEs. En lugar de abordar la IA desde una mirada generalista, se presentan soluciones alineadas con las particularidades operativas de cada empresa. Sin embargo, no todas las aplicaciones tienen el mismo grado de relevancia para todas las empresas. Algunas tendrán un impacto claro e inmediato, mientras que otras pueden ser menos aplicables dependiendo de la estructura, el momento y las necesidades de cada PyME.

A continuación, se detalla el conjunto de aplicaciones que conforman la base del Mapa de Oportunidades, organizado según los procesos de negocio mencionados, con una descripción de su propósito, su implementación y los beneficios que pueden aportar a distintas realidades empresariales.

4.2.1 Marketing, Ventas y Atención al Cliente

Este bloque está centrado en las aplicaciones de IA que ayudan a las PYMEs a optimizar sus procesos comerciales, desde la personalización de la experiencia de compra hasta la fidelización y el análisis de datos para mejorar la relación con los clientes (Shopify, 2024).

Las soluciones de IA no solo permiten personalizar la oferta de productos, sino también anticiparse a las necesidades de los consumidores, lo que aumenta la probabilidad de conversión y mejora la experiencia de usuario (Patma Digital, 2024).

La IA aplicada a la atención al cliente, mediante herramientas como los chatbots, permite a las empresas ofrecer soporte 24/7, reduciendo costos operativos y mejorando la satisfacción del cliente (Tidio, 2025; Darwin AI, 2024).

Además, las tecnologías de segmentación y recomendaciones personalizadas basadas en el análisis de datos históricos de compras, permiten mejorar la efectividad de las campañas comerciales, ajustándolas a las preferencias individuales de los consumidores, lo que facilita un enfoque más eficiente de ventas y marketing (Hayas Marketing, 2024).

1. Recomendación de productos basada en historial de compras y hábitos de consumo

Alinear las ofertas con los intereses del cliente es clave para mejorar la experiencia de compra y la tasa de conversión. Sin embargo, cuando las recomendaciones se basan en criterios generales, es posible que los productos sugeridos no sean relevantes para cada usuario, lo que reduce la efectividad de la estrategia comercial.

A través de modelos avanzados con IA, es posible analizar el historial de compras y los hábitos de consumo de cada cliente y así ofrecer recomendaciones más precisas sin necesidad de aplicar descuentos ni promociones. Un comercio de insumos para oficina, por ejemplo, puede detectar que un cliente compra papel y tinta cada dos meses y

sugerirle estos productos antes de su próxima compra esperada. De manera similar, una tienda de artículos deportivos puede identificar que un corredor ha comprado zapatillas para running y recomendarle nuevos modelos en función de su historial. Con este enfoque, la experiencia de compra se personaliza de manera precisa, aumentando la probabilidad de conversión de forma natural.

2. Estrategias de fidelización y retención mediante detección de abandono

Mantener una base de clientes activos es clave para la sostenibilidad del negocio. Sin embargo, no siempre es fácil identificar cuándo un cliente está en riesgo de abandonar, lo que puede llevar a pérdidas sin que se tomen medidas a tiempo. Sin una estrategia proactiva, las acciones de fidelización pueden aplicarse demasiado tarde o de manera indiscriminada, reduciendo su impacto.

Gracias a sistemas de predicción basados en IA, es posible detectar señales de abandono, como una menor frecuencia de compra o la falta de interacción con la marca. Estas herramientas no solo identifican clientes en riesgo de dejar de comprar, sino que también activan estrategias personalizadas para fortalecer su vínculo con la empresa. En función del historial y los patrones de comportamiento, se pueden enviar incentivos estratégicos o contenido relevante que ayude a recuperar su interés antes de que la relación se pierda por completo. Un gimnasio, por ejemplo, puede identificar clientes que llevan semanas sin asistir y enviarles un mensaje recordando su plan de entrenamiento o invitándolos a una clase especial. De manera similar, una tienda online puede detectar clientes que han dejado de comprar y contactarlos con contenido relevante o una atención personalizada para entender su desinterés y recuperar su actividad. Con este enfoque, la fidelización no depende únicamente de incentivos comerciales, sino de intervenciones estratégicas basadas en el comportamiento real del cliente.

3. Segmentación estratégica de clientes para personalizar acciones de venta

No todos los clientes tienen los mismos hábitos ni responden de la misma manera a las estrategias comerciales. Sin una segmentación adecuada, las empresas pueden aplicar campañas demasiado generales, sin aprovechar las diferencias clave en su base de clientes.

Aprovechando el análisis de patrones de comportamiento, la IA permite clasificar a los clientes en segmentos con características similares. Este enfoque facilita la adaptación de estrategias comerciales a distintos perfiles, priorizando a los clientes con mayor potencial de compra o diseñando campañas diferenciadas según sus hábitos. De esta manera, se optimizan los esfuerzos comerciales, logrando interacciones más relevantes y eficaces. Por ejemplo, una tienda de indumentaria puede identificar distintos grupos de clientes: aquellos que compren principalmente en cambio de temporada, los que

buscan novedades constantemente y los que realizan compras por grandes volúmenes en promociones. De la misma manera, una empresa de software puede detectar clientes que utilizan solo funciones básicas y diferenciarlos de quienes exploran herramientas avanzadas, permitiendo que su equipo de ventas ajuste su comunicación y enfoque en función de cada perfil. Con este enfoque, la IA no toma decisiones comerciales directamente, sino que estructura la información para que la empresa pueda desarrollar estrategias más efectivas.

4. Automatización de la gestión de reórdenes y compras recurrentes

Cuando los clientes realizan compras de manera frecuente, gestionar manualmente sus reabastecimientos puede ser ineficiente y generar olvidos que afecten la continuidad del negocio. Sin un sistema automatizado, el cliente debe recordar cuándo hacer su próximo pedido, lo que puede provocar pérdidas de ventas o compras tardías.

Analizando patrones de compra históricos, la IA automatiza la reposición de productos sin intervención manual, asegurando la disponibilidad en el momento adecuado. Un proveedor de productos de limpieza para empresas, por ejemplo, puede identificar clientes que reponen insumos cada mes y generar pedidos automáticos con la cantidad habitual, facilitando la reposición sin que el cliente deba solicitarlo. De manera similar, una veterinaria puede enviar recordatorios automáticos a dueños de mascotas cuando se acerca la fecha de la próxima compra de alimento balanceado.

5. Optimización de promociones personalizadas para incrementar ventas

Las promociones pueden mejorar las ventas, pero si se aplican sin un análisis preciso del cliente, pueden reducir márgenes innecesariamente o no generar el impacto esperado. Sin una estrategia personalizada, las ofertas pueden no alinearse con los hábitos de compra de cada cliente, disminuyendo su efectividad.

El uso de inteligencia artificial hace posible ajustar promociones de manera estratégica, alineándolas con los hábitos de compra de cada cliente. En lugar de aplicar descuentos masivos, la IA analiza datos de compras anteriores y preferencias individuales para determinar qué ofertas tienen mayor probabilidad de conversión. Este enfoque maximiza el impacto de las promociones sin comprometer la rentabilidad. Un supermercado, por ejemplo, puede identificar clientes que compran habitualmente determinados productos y ofrecerles descuentos específicos en esas categorías en lugar de aplicar promociones masivas. De manera similar, una librería online puede detectar qué géneros literarios consume cada usuario y enviarle ofertas en títulos relacionados con sus intereses. Con este enfoque, la IA optimiza las promociones para clientes activos, aumentando las ventas de manera eficiente sin generar incentivos innecesarios para quienes ya comprarían el producto.

6. Atención al cliente con chatbots conversacionales 24/7

Brindar una atención rápida y eficiente es clave para mantener una buena relación con los clientes. Sin embargo, responder consultas en tiempo real puede ser un desafío, especialmente fuera del horario comercial o cuando el volumen de interacciones es alto. Esto puede generar demoras, pérdida de oportunidades de venta y una mayor carga operativa para los equipos de atención.

Gracias a modelos de IA generativa, los chatbots conversacionales pueden comprender el contexto de cada interacción y generar respuestas más naturales y precisas. Esto permite gestionar consultas de clientes en WhatsApp, sitios web y email, respondiendo preguntas frecuentes, gestionando reservas y derivando casos complejos a representantes humanos. Un restaurante, por ejemplo, puede implementar un chatbot en WhatsApp para recibir pedidos y confirmar reservas sin intervención manual. De la misma manera, una tienda online puede automatizar respuestas sobre el estado de envíos y políticas de devolución, mejorando la experiencia del cliente y reduciendo la carga operativa.

7. Sentiment Analysis: Evaluación de la satisfacción del cliente a partir de comentarios y opiniones

Comprender la percepción que los clientes tienen sobre un producto o servicio es fundamental para mejorar la experiencia y fidelización. Sin embargo, analizar manualmente grandes volúmenes de reseñas, mensajes y opiniones puede ser complejo y demandar mucho tiempo, lo que dificulta la detección temprana de problemas o la identificación de oportunidades de mejora.

Mediante el análisis automático de textos, la inteligencia artificial identifica el tono emocional de los comentarios y clasifica las opiniones en categorías como positivas, neutras o negativas. Esta información permite a las empresas detectar patrones de insatisfacción de manera temprana y tomar acciones correctivas. Además, al procesar grandes volúmenes de reseñas en distintos canales, se obtiene una visión más precisa de la percepción del cliente sin necesidad de revisar manualmente cada comentario. Un hotel, por ejemplo, puede utilizar esta tecnología para analizar las reseñas de sus huéspedes y detectar quejas frecuentes sobre la limpieza de las habitaciones, lo que le permite tomar medidas correctivas de manera proactiva. De manera similar, una tienda online puede monitorear las opiniones en redes sociales y reconocer tendencias en la satisfacción del cliente, ajustando su servicio o productos en función de los comentarios recibidos.

8. Seguimiento posventa automatizado con personalización según comportamiento del cliente

El contacto con los clientes no termina con la compra; un buen seguimiento posventa puede mejorar la experiencia y fortalecer la fidelización. Sin embargo, gestionar estas interacciones de manera manual puede ser ineficiente, especialmente cuando el volumen de clientes es alto y sus necesidades varían.

Aplicando IA, las empresas pueden personalizar la comunicación posventa en función del comportamiento del cliente, enviando recordatorios, encuestas de satisfacción o asistencia proactiva cuando se detectan posibles inconvenientes. Estos sistemas permiten anticiparse a las necesidades del cliente y fortalecer la relación a largo plazo, optimizando la experiencia sin requerir intervención manual en cada contacto. Un concesionario de automóviles, por ejemplo, puede contactar a sus clientes tras la compra para recordarles su primer servicio de mantenimiento y solicitar una evaluación de la experiencia. De manera similar, una tienda de electrodomésticos puede detectar si un comprador ha consultado reiteradamente el centro de ayuda y enviarle asistencia proactiva para resolver cualquier problema con su producto. Con este enfoque, la relación con el cliente se fortalece a lo largo del tiempo, aumentando la satisfacción y la fidelización.

9. Personalización de la experiencia de compra con recomendaciones inteligentes

Cada cliente interactúa de manera diferente con una tienda online, explorando productos, comparando opciones y tomando decisiones según sus intereses. Sin personalización, la experiencia de compra puede parecer menos atractiva y reducir las posibilidades de compra.

A través de modelos predictivos, la IA ajusta dinámicamente la tienda online en función del comportamiento de navegación del usuario, mostrando productos relevantes en tiempo real. Esta personalización hace que la experiencia de compra sea más intuitiva y adaptada a los intereses del cliente, aumentando la probabilidad de conversión sin necesidad de aplicar descuentos indiscriminados. Un e-commerce de tecnología, por ejemplo, puede detectar que un usuario ha visitado varias veces la sección de notebooks y mostrarle ofertas específicas en su próxima visita. De manera similar, una tienda de moda puede sugerir productos basados en búsquedas recientes, generando una experiencia de compra más intuitiva y alineada con los intereses del cliente.

10. Optimización dinámica de precios según demanda y competencia

Fijar precios de manera estática puede generar desventajas competitivas, ya sea perdiendo oportunidades de aumentar la rentabilidad en momentos de alta demanda o quedando fuera del mercado frente a precios más atractivos de la competencia. Ajustar

manualmente los valores requiere tiempo y análisis constante, lo que dificulta reaccionar con rapidez ante cambios en las condiciones del mercado.

Mediante el análisis de demanda y la evaluación de precios de la competencia, la inteligencia artificial permite ajustar los valores de los productos de manera automática. Los modelos de IA ajustan los precios en función de la demanda y la competencia en tiempo real, asegurando que sean competitivos sin necesidad de intervención manual constante. Un e-commerce de productos electrónicos, por ejemplo, puede detectar que un artículo aumenta su demanda y ajustar su precio para maximizar el margen sin afectar las ventas. De la misma manera, una tienda de repuestos para autos puede monitorear los precios de la competencia y realizar ajustes automáticos para mantener su posicionamiento sin comprometer la rentabilidad. Con este enfoque, la estrategia comercial se vuelve más dinámica y alineada con las condiciones del mercado.

11. Recuperación automatizada de carritos abandonados

En el comercio digital, es común que los clientes agreguen productos al carrito y luego abandonen la compra sin completarla. Las razones pueden variar: distracciones, dudas sobre el precio, costos de envío inesperados o simplemente falta de urgencia en la decisión. Sin un seguimiento adecuado, estas oportunidades de venta pueden perderse sin que el negocio tenga una segunda oportunidad de conversión.

Gracias a la detección de carritos abandonados, los sistemas de IA pueden identificar patrones de compra inconclusos y activar recordatorios personalizados a través de email, WhatsApp o notificaciones push, incentivando al cliente a completar su compra. Un e-commerce de indumentaria, por ejemplo, puede identificar a quienes dejaron productos en el carrito y enviarles un mensaje destacando disponibilidad limitada o un pequeño descuento por tiempo limitado. Al reactivar el interés del cliente en un momento estratégico, esta tecnología mejora la tasa de conversión sin requerir intervención manual.

12. Automatización de estrategias de cross-selling y upselling en tiendas online

Muchas veces, una venta no termina en la simple elección del producto principal, sino que puede potenciarse con recomendaciones estratégicas. Sugerir productos complementarios o versiones mejoradas en el momento adecuado puede aumentar el valor del ticket promedio y mejorar la experiencia del cliente.

La inteligencia artificial optimiza estas estrategias al analizar el comportamiento de compra en tiempo real y detectar oportunidades para recomendar productos complementarios (cross-selling) o versiones superiores (upselling). Una tienda online de electrónica, por ejemplo, puede sugerir fundas y auriculares al momento de comprar un teléfono celular o recomendar un modelo más avanzado con mejor capacidad y

prestaciones. De esta manera, la IA impulsa compras adicionales sin interrumpir la experiencia del usuario, mejorando la rentabilidad sin necesidad de aplicar descuentos generalizados.

13. Creación automática de contenido para redes sociales

Mantener una presencia activa en redes sociales requiere una producción constante de contenido atractivo y relevante. Sin embargo, generar imágenes, textos y videos adaptados a cada plataforma puede demandar tiempo y recursos, dificultando la frecuencia y la coherencia en la comunicación.

Con herramientas de generación de contenido basadas en IA generativa, es posible producir textos, imágenes y videos optimizados para cada plataforma sin intervención manual. Estos modelos analizan tendencias y el comportamiento de la audiencia para adaptar los mensajes, asegurando una mayor relevancia y alcance en cada publicación. Un restaurante, por ejemplo, puede utilizar IA para generar imágenes con promociones del día y textos sugeridos con hashtags relevantes en función de la temporada. De manera similar, una tienda de ropa puede automatizar la producción de descripciones y videos cortos para mostrar nuevas colecciones en Instagram y TikTok. Con este enfoque, es posible mejorar el alcance orgánico y la interacción sin requerir una intervención manual constante.

14. Automatización de respuestas y gestión de consultas en redes sociales

Las redes sociales se han convertido en un canal clave para la interacción con clientes, pero gestionar consultas en tiempo real puede ser un desafío, especialmente cuando el volumen de mensajes y comentarios es alto. Responder con demoras o dejar preguntas sin atender puede afectar la percepción de la marca y generar oportunidades de venta perdidas.

Mediante sistemas de reconocimiento de preguntas frecuentes, la inteligencia artificial permite responder automáticamente comentarios y mensajes en redes sociales, manteniendo una comunicación fluida con los clientes. Estos modelos no solo identifican consultas comunes, sino que también pueden ajustar el tono y el estilo de las respuestas según el contexto, mejorando la interacción y optimizando la carga de trabajo del equipo de atención. Un local de venta de electrodomésticos, por ejemplo, puede utilizar IA para responder automáticamente consultas sobre precios y disponibilidad en los comentarios de sus publicaciones. De manera similar, una tienda de cosmética puede automatizar la gestión de mensajes directos, brindando información sobre tonos de maquillaje o ingredientes de productos sin necesidad de intervención humana. Con este enfoque, la empresa mantiene una comunicación fluida y eficiente en redes sociales, mejorando la experiencia del usuario y optimizando la conversión.

15. Programación inteligente de publicaciones en los mejores horarios

Publicar contenido en redes sociales en el momento adecuado puede marcar la diferencia en el alcance y la interacción. Sin embargo, determinar manualmente los horarios óptimos para cada plataforma y audiencia puede ser complejo, especialmente cuando los hábitos de consumo digital varían entre distintos segmentos de clientes.

A partir del análisis del comportamiento de los seguidores, los algoritmos de IA determinan los momentos óptimos para publicar contenido y maximizar su alcance. Estos modelos estudian la interacción previa con la marca y ajustan la estrategia de publicación en función de patrones detectados, asegurando que cada post llegue a la audiencia en el momento de mayor impacto. Un gimnasio, por ejemplo, puede identificar que sus publicaciones sobre entrenamientos tienen mayor engagement en la mañana y programarlas automáticamente en ese horario. De la misma manera, una tienda de productos para el hogar puede ajustar la difusión de promociones en función de los días y horarios en los que sus clientes suelen interactuar más. Con este enfoque, se maximiza el alcance del contenido sin necesidad de una gestión manual constante.

16. Identificación de clientes potenciales B2B a partir de bases de datos y redes profesionales

Encontrar nuevos clientes en el entorno B2B puede ser un proceso complejo cuando no se dispone de información clara sobre qué empresas tienen un alto potencial de compra. Contactar sin un análisis previo puede generar esfuerzos comerciales poco efectivos y una baja tasa de conversión.

Analizando grandes volúmenes de datos en bases comerciales y redes profesionales, la inteligencia artificial puede detectar prospectos con alto potencial de compra. Un proveedor de equipamiento industrial, por ejemplo, puede utilizar IA para identificar fábricas en expansión que podrían requerir nuevas maquinarias. Con esta capacidad, las empresas pueden enfocar sus esfuerzos comerciales en los contactos más prometedores, optimizando el uso de sus recursos sin perder oportunidades.

17. Automatización del contacto y seguimiento con clientes potenciales

No basta con identificar clientes potenciales, también es fundamental establecer y mantener una comunicación efectiva para convertir ese interés en una venta. Sin un proceso de seguimiento estructurado, muchas oportunidades pueden perderse por falta de contacto o demoras en la respuesta.

Con herramientas de automatización inteligente, las empresas pueden gestionar el contacto con prospectos, enviando mensajes personalizados y recordatorios sin intervención manual. Estos modelos ajustan la frecuencia y el contenido de los mensajes en función de la respuesta del cliente, asegurando un seguimiento eficiente sin resultar

invasivo. Un proveedor de software empresarial, por ejemplo, puede utilizar IA para contactar automáticamente a empresas interesadas en una demo, enviando información relevante y programando recordatorios si no hubo respuesta. Al mantener una comunicación proactiva y personalizada, esta tecnología ayuda a transformar leads en clientes sin requerir intervención manual constante.

4.2.2 Producción, Calidad y Supply Chain

La inteligencia artificial aplicada en la producción, calidad y la cadena de suministro permite a las PYMEs mejorar la eficiencia operativa y optimizar la gestión de recursos. (Foro Económico Mundial, 2024). Desde la predicción de la demanda hasta el mantenimiento predictivo de equipos, la IA facilita la toma de decisiones basadas en datos en tiempo real, lo que ayuda a reducir costos y minimizar los riesgos operativos (Datacamp, 2023).

Las herramientas de IA permiten anticipar las necesidades de stock, mejorar la planificación de la producción y reducir el desperdicio al predecir con precisión cuándo y cuántos insumos serán necesarios en función de patrones históricos y variables externas (IBM, 2024). Además, en el área de control de calidad, la IA aplicada a la visión artificial detecta defectos de producción con alta precisión, asegurando que solo los productos que cumplen con los estándares lleguen al cliente final (Cognex Corporation, 2023). Estas soluciones permiten no solo optimizar la eficiencia interna, sino también asegurar una calidad constante en los productos ofrecidos, mejorando la competitividad y satisfacción del cliente.

18. Predicción de demanda y planificación de abastecimiento

La proyección de la demanda es un proceso clave para cualquier negocio, ya que impacta directamente en diferentes áreas de la empresa. Una estimación precisa permite ajustar la capacidad de producción para evitar desperdicios y optimizar costos operativos, coordinar los niveles de inventario para minimizar excesos o faltantes, mejorar la planificación logística asegurando la disponibilidad de productos en los momentos adecuados y optimizar la contratación de personal en función de las necesidades del mercado. Un mal pronóstico de la demanda lleva indefectiblemente a ineficiencias y mayores costos para las empresas.

A través de modelos predictivos basados en inteligencia artificial, es posible analizar múltiples fuentes de información, internas y externas, para proyectar la demanda con mayor exactitud. Datos históricos de ventas, estacionalidad, tendencias del mercado, información macroeconómica, patrones climáticos u otros eventos externos pueden ser incorporados en los algoritmos de predicción. Un distribuidor de alimentos, por ejemplo, puede prever el aumento en la demanda de ciertos productos durante festividades y ajustar su stock con anticipación. De la misma manera, una tienda de artículos de ferretería puede detectar patrones de compra y programar reabastecimientos justo antes

de que los productos comiencen a escasear. Con este enfoque, se optimiza la planificación de inventario, reduciendo costos y asegurando la disponibilidad de productos en el momento adecuado.

19. Optimización del volumen y frecuencia de compras

Determinar el mejor momento para comprar insumos y la cantidad óptima a adquirir puede marcar una gran diferencia en los costos operativos. Sin un análisis preciso, las compras pueden realizarse de manera reactiva, sin considerar variaciones en los precios, los plazos de entrega o la capacidad de almacenamiento, lo que puede generar gastos innecesarios.

La inteligencia artificial permite optimizar la planificación de compras al analizar precios históricos, tiempos de reposición y costos logísticos, recomendando cuándo y cuánto comprar para maximizar la eficiencia. Un mayorista de productos de limpieza, por ejemplo, puede detectar períodos en los que los precios de determinados insumos tienden a bajar y anticipar sus compras para reducir costos. De manera similar, una cadena de restaurantes puede ajustar la frecuencia de sus pedidos según el flujo de clientes y la disponibilidad de proveedores, evitando compras excesivas o faltantes. Con este enfoque, la gestión de compras se vuelve más estratégica, mejorando la rentabilidad y reduciendo desperdicios.

20. Optimización del proceso de producción mediante análisis de datos operativos

La eficiencia en la producción depende de múltiples factores, como el uso adecuado de insumos, la optimización de tiempos y el rendimiento de la maquinaria. En muchos casos la planificación de la producción y los ajustes en la operación pueden depender de la experiencia e intervención humana. Esto puede dificultar la identificación de ineficiencias o variaciones del rendimiento, lo que a su vez puede generar desperdicios, tiempos improductivos y costos operativos innecesarios.

A través del análisis de datos operativos, es posible identificar patrones en la producción, detectar variaciones en el rendimiento y así recomendar ajustes para optimizar el proceso. Una fábrica de muebles, por ejemplo, puede utilizar IA para detectar cuellos de botella en la línea de ensamblaje y ajustar la distribución de tareas para mejorar los tiempos de producción. De la misma manera, una planta de alimentos puede analizar el rendimiento de sus hornos y programar ajustes automáticos en la temperatura y el tiempo de cocción, asegurando mayor uniformidad en la calidad del producto y reduciendo el consumo de energía. Con este enfoque, se optimiza la utilización de recursos, aumentando la productividad sin necesidad de grandes inversiones en infraestructura.

21. Control de calidad con visión artificial y alertas predictivas

El control de calidad es un aspecto clave en los procesos de producción, pero detectar fallas de manera manual puede ser un proceso lento y propenso a errores. Cuando los defectos no se identifican a tiempo, pueden generar desperdicio de materia prima, reprocesos costosos y retrasos en la entrega de productos.

Mediante visión artificial y algoritmos de aprendizaje automático es posible inspeccionar productos en tiempo real y detectar defectos con alta precisión. Sensores y cámaras conectados a sistemas de IA pueden identificar irregularidades en la producción y generar alertas predictivas antes de que los problemas se propaguen. En la industria alimenticia, por ejemplo, una planta procesadora puede detectar variaciones en el tamaño o color de los productos y retirar automáticamente aquellos que no cumplen con los estándares de calidad. Una fábrica de autopartes puede utilizar visión artificial para identificar piezas con imperfecciones y detener el proceso antes de que lleguen a la fase de ensamblaje.

22. Mantenimiento predictivo y prevención de fallas en equipos

Las fallas inesperadas en maquinaria y equipos pueden generar interrupciones en la producción, costos elevados de reparación y pérdida de eficiencia operativa. En algunas situaciones el mantenimiento suele realizarse de manera reactiva, cuando el problema ya ocurrió, o de forma programada sin considerar el estado real de los equipos, lo que puede generar gastos innecesarios.

A través del análisis de datos operativos y sensores en equipos es posible anticipar fallas mediante el análisis de patrones de funcionamiento y rendimiento de las máquinas en tiempo real. Algoritmos de predicción analizan variables como temperatura, vibraciones o consumo de energía para identificar señales tempranas de desgaste o mal funcionamiento. Al detectar anomalías antes de que se conviertan en problemas críticos, es posible programar mantenimientos preventivos en el momento óptimo, evitando tiempos de inactividad innecesarios. En la industria alimenticia, por ejemplo, una planta procesadora de lácteos puede monitorear la temperatura y presión en las líneas de pasteurización para anticipar fallas en los intercambiadores de calor y evitar cortes en la producción. En el sector energético, una central con generadores a gas puede analizar el consumo de combustible y la temperatura de combustión para detectar anomalías en los motores y programar mantenimientos antes de que una falla provoque una reducción en la capacidad de generación.

23. Gestión dinámica de inventarios

Mantener niveles de inventario adecuados es un desafío clave en la gestión de suministros. Un stock insuficiente puede generar quiebres y afectar la continuidad operativa, mientras que una acumulación excesiva puede aumentar costos de

almacenamiento y generar desperdicio. Sin herramientas avanzadas, definir estos niveles suele basarse en estimaciones manuales que no siempre reflejan con precisión la variabilidad en la demanda o los tiempos de reposición de los proveedores.

La inteligencia artificial permite calcular y ajustar dinámicamente los niveles óptimos de stock mínimo y de seguridad, considerando factores como la demanda histórica, la estacionalidad, los lead times de los proveedores y las variaciones en los plazos de entrega. En una distribuidora de alimentos, por ejemplo, la IA puede ajustar el stock de productos perecederos según la rotación y la demanda en cada punto de venta.

4.2.3 Administración y Finanzas

La inteligencia artificial está transformando la gestión financiera y administrativa en las PYMEs, permitiendo automatizar procesos y tomar decisiones informadas basadas en datos (SAP Concur, 2024). Desde la automatización de tareas repetitivas, como la carga de facturas y la conciliación bancaria, hasta la predicción de flujos de caja y la identificación de inconsistencias financieras, la IA reduce el tiempo dedicado a labores manuales y mejora la precisión en los registros (IBM, s.f.).

Además, los sistemas basados en IA ayudan a las empresas a gestionar el riesgo financiero al identificar patrones y prever eventos que podrían afectar la estabilidad económica, como la morosidad de clientes o fluctuaciones en el mercado (Yooz, 2024). Estas herramientas permiten a las PYMEs centrarse más en la toma de decisiones estratégicas, al tiempo que optimizan la administración de sus recursos y reducen riesgos operativos, mejorando la rentabilidad y la eficiencia general de la empresa (DocuSign, 2024).

24. Automatización del registro y carga de facturas y comprobantes con validación de inconsistencias

El registro manual de facturas y comprobantes puede ser un proceso tedioso y propenso a errores, especialmente cuando el volumen de documentos es alto. Errores en montos, impuestos o datos de proveedores pueden generar inconsistencias contables, retrasos en pagos y problemas en la conciliación financiera.

Con algoritmos avanzados de reconocimiento de texto y procesamiento de datos podemos automatizar este proceso mediante la extracción de datos desde facturas escaneadas o recibidas por email, validando montos, impuestos y datos clave antes de su registro en el sistema contable. Un comercio mayorista, por ejemplo, puede utilizar IA para procesar automáticamente facturas de múltiples proveedores, verificando que los montos coincidan con las órdenes de compra antes de aprobar el pago. De manera similar, un estudio contable puede detectar inconsistencias en los comprobantes recibidos de sus clientes y generar alertas para corregir posibles errores antes de su

imputación. Con este enfoque, se agiliza la gestión administrativa, se reducen los errores y se mejora el control financiero.

25. Conciliación bancaria automatizada y detección de inconsistencias

La conciliación bancaria es un proceso que, cuando se realiza de manera manual, puede resultar lento, sobre todo frente a un volumen alto de transacciones. Los errores más frecuentes incluyen pagos no registrados, montos ingresados incorrectamente, registros contables sin su correspondiente movimiento bancario y diferencias en los tiempos de acreditación. Esto genera desajustes financieros que afectan la precisión de los balances y dificulta la detección de irregularidades.

La inteligencia artificial permite automatizar la conciliación bancaria, comparando los registros contables con los movimientos de las cuentas bancarias con un nivel de productividad extremadamente alto. Al detectar discrepancias, genera alertas automáticas para su revisión antes de que impacten en la contabilidad. Un estudio contable, por ejemplo, puede procesar infinidad de transacciones diarias y detectar pagos recibidos que aún no han sido registrados o facturas pendientes de cobro. De manera similar, una empresa de comercio electrónico puede identificar cargos bancarios inesperados o cobros no acreditados de pasarelas de pago. Con este enfoque, se optimiza el control financiero, reduciendo tiempos de revisión y minimizando riesgos de errores o irregularidades.

26. Predicción de flujo de caja según ingresos, egresos y tendencias

El flujo de caja define la capacidad de una empresa para operar con estabilidad financiera y afrontar compromisos futuros. Las predicciones inexactas pueden generar déficits de liquidez, comprometer la capacidad de pago y dificultar la planificación de inversiones. Sin una estimación precisa de los ingresos esperados y las obligaciones financieras, el margen de maniobra para corregir desajustes es limitado.

Los modelos de machine learning permiten proyectar con mayor precisión el flujo de caja al analizar el historial de ingresos y egresos, identificar patrones de comportamiento financiero y anticipar variaciones en la disponibilidad de capital. Algoritmos avanzados procesan datos contables para detectar estacionalidad en los ingresos, evaluar los ciclos de pago de proveedores y estimar los momentos de mayor o menor liquidez. Además del análisis histórico, la IA proyecta la demanda futura y la cobranza asociada de acuerdo a los perfiles de pago de cada cliente. La integración de predicciones en la planificación financiera mejora la capacidad de respuesta ante cambios en la disponibilidad de capital, optimizando la estabilidad financiera del negocio.

27. Gestión automatizada del proceso de cobranzas y recordatorios de pago

La gestión eficiente de las cobranzas es clave para mantener un flujo de caja saludable, pero el seguimiento manual de facturas vencidas puede ser una tarea demandante y sujeta a omisiones. La falta de control en los pagos puede generar retrasos que afectan la liquidez y obligan a recurrir a acciones más costosas para recuperar deudas.

Los modelos de IA permiten automatizar el envío de recordatorios de pago, identificando facturas próximas a vencer o ya vencidas y ajustando la frecuencia de los avisos según la política de cobranzas de la empresa. Además, el análisis del historial de pagos y la detección de morosidad recurrente permiten reforzar las acciones de seguimiento con estrategias diferenciadas para clientes con mayor riesgo de incumplimiento, optimizando la previsibilidad del flujo de ingresos. Una distribuidora mayorista, por ejemplo, puede programar recordatorios automáticos antes del vencimiento de una factura y, al mismo tiempo, segmentar a sus clientes según su comportamiento de pago para tomar medidas más proactivas con aquellos que presentan antecedentes de retrasos. Con este enfoque, se reduce la morosidad, se mejora la planificación financiera y se minimiza la necesidad de intervención manual en el proceso de cobranzas.

28. Generación automatizada de informes financieros

Los informes financieros reúnen información clave sobre el desempeño económico de una empresa, consolidando datos de flujo de caja, rentabilidad, costos operativos, cuentas por cobrar y pagar, impuestos y otros indicadores relevantes. La recopilación de esta información desde múltiples fuentes contables y operativas puede ser un proceso complejo, ya que los datos pueden estar dispersos en distintos sistemas, reflejar diferentes períodos o requerir ajustes para garantizar su consistencia y comparabilidad. La falta de integración entre estos datos puede generar reportes incompletos o inconsistencias que dificultan el análisis financiero.

Los modelos de inteligencia artificial pueden automatizar la recopilación y procesamiento de datos financieros, accediendo a diversas fuentes de información y consolidando los registros en reportes estructurados y consistentes. A través de procesos de validación automática, la IA identifica discrepancias, cruza datos entre cuentas y asegura que la información refleje con precisión la realidad financiera de la empresa. Además, las herramientas de IA generativa permiten estructurar los informes según las necesidades de cada usuario, generando resúmenes explicativos y destacando métricas clave en función de tendencias recientes o desviaciones detectadas. Con este enfoque, las empresas acceden a información organizada y actualizada de manera ágil, eliminando fricciones en el proceso de generación de reportes.

29. Prevención de fraudes y errores en transacciones financieras

Las transacciones financieras pueden ser vulnerables a fraudes, pagos indebidos y desvíos de fondos que comprometen la estabilidad económica de una empresa. Errores contables, alteraciones en registros de pagos o intentos de manipulación en sistemas de facturación pueden generar pérdidas significativas si no son detectados a tiempo. En entornos con un alto volumen de operaciones, las irregularidades pueden pasar desapercibidas, dificultando la identificación temprana de anomalías.

Los modelos de inteligencia artificial pueden analizar patrones de pagos y cobros para detectar transacciones sospechosas en tiempo real. Algoritmos avanzados identifican comportamientos inusuales en montos, frecuencias y destinatarios, comparando cada operación con el historial financiero para reconocer posibles intentos de fraude. Además, la IA permite detectar pagos duplicados, inconsistencias entre facturas y registros bancarios, y operaciones que no se ajustan a los flujos habituales de una empresa. Con este enfoque, las organizaciones pueden generar alertas automatizadas, activar bloqueos preventivos y fortalecer la seguridad financiera sin necesidad de revisiones manuales extensivas.

4.2.4 Soluciones Transversales con IA Generativa

Las soluciones transversales basadas en IA generativa tienen el potencial de transformar las operaciones de las PYMEs, optimizando tareas en diversas áreas del negocio a través de la automatización inteligente. Estos sistemas pueden asistir en la creación de contenido, el análisis de datos, la toma de decisiones y la gestión de la comunicación interna y externa, brindando apoyo clave para mejorar la productividad general de la empresa (Microsoft, 2024).

La IA generativa no solo facilita la creación de contenido como textos, informes y campañas publicitarias, sino que también permite realizar simulaciones y escenarios predictivos para anticiparse a los resultados y optimizar estrategias a nivel empresarial (Stanford HAI, 2023). Además, la capacidad de estos sistemas para integrarse con otras herramientas de gestión empresarial y plataformas internas proporciona una ventaja significativa, al permitir una mayor personalización y adaptación a las necesidades específicas de cada PyME (Google AI, 2024). A través de estas aplicaciones transversales, las empresas pueden mejorar la eficiencia operativa, optimizar la planificación estratégica y generar valor en todos los niveles del negocio.

30. Mi Asistente GPT – Inteligencia Conversacional para Pymes

Las pequeñas y medianas empresas suelen operar con estructuras ajustadas, donde la toma de decisiones y la planificación estratégica recaen en pocos líderes o incluso en una sola persona. En este contexto, contar con un asistente de inteligencia artificial

generativa puede convertirse en una herramienta diferenciadora para mejorar la gestión del negocio, optimizar la productividad y apoyar la toma de decisiones en tiempo real.

A diferencia de otras aplicaciones de IA diseñadas para automatizar tareas específicas, un asistente GPT es una solución versátil que puede integrarse en diversas funciones dentro de la empresa (McKinsey & Company, 2023). Su implementación permite a los dueños de PyMEs disponer de una herramienta que los acompaña en la gestión del negocio, brindando apoyo en múltiples áreas (Accenture, 2023). Entre las soluciones que puede aportar un Asistente GPT en una PyME, se destacan:

✓ **Generación de contenido:**

- Puede elaborar planes de negocio detallados, estructurando objetivos, estrategias y análisis de mercado de manera clara y persuasiva.
- Redacta propuestas comerciales, ajustándolas a distintos clientes y contextos de negociación.
- Asiste en la creación de discursos y presentaciones ejecutivas, adaptando el tono y estilo según la audiencia.
- Genera materiales de marketing, como publicaciones para redes sociales, artículos de blog y campañas automatizadas.
- Puede estructurar manuales internos y guías de procesos, facilitando la documentación interna de la empresa.

✓ **Análisis y revisión de documentos:**

- Evalúa la coherencia y estructura de informes financieros, propuestas comerciales y planes estratégicos.
- Identifica errores o inconsistencias en datos, redacción y estructura de documentos clave.
- Sugiere mejoras en la presentación de la información para hacerla más efectiva y persuasiva.
- Optimiza documentos extensos, resumiendo contenido sin perder precisión ni claridad.

✓ **Apoyo en la toma de decisiones:**

- Analiza información financiera, evaluando rentabilidad, flujo de caja y tendencias del mercado.
- Genera escenarios predictivos y simulaciones, permitiendo evaluar diferentes estrategias antes de tomar decisiones.
- Sintetiza grandes volúmenes de datos en reportes ejecutivos, resaltando los insights más relevantes.

- Facilita la comparación de diferentes estrategias de inversión, expansión o reducción de costos, sugiriendo cursos de acción.

✓ **Automatización de la comunicación:**

- Redacta correos estratégicos para clientes, inversores y socios comerciales.
- Estructura informes de gestión, facilitando la presentación clara de resultados y métricas clave.
- Crea presentaciones empresariales, organizando la información de manera visual y persuasiva.
- Redacta resúmenes de reuniones y acuerdos, asegurando que se registren las decisiones tomadas y próximos pasos.

✓ **Acceso a información interna:**

- Responde preguntas sobre normativas, procedimientos internos y políticas empresariales de manera rápida y precisa.
- Permite realizar consultas sobre datos históricos de la empresa, sin necesidad de búsquedas manuales.
- Ayuda a la estructuración de bases de conocimiento internas, organizando documentos clave en formatos accesibles.
- Puede generar resúmenes de reuniones pasadas, decisiones estratégicas y registros importantes para referencia rápida.

✓ **Gestión de agenda y planificación:**

- Organiza reuniones, sugiriendo horarios óptimos según la disponibilidad de los participantes.
- Automatiza el seguimiento de tareas, recordando plazos y pendientes a los equipos de trabajo.
- Coordina agendas de trabajo para mejorar la productividad y reducir tiempos muertos en reuniones.
- Ayuda en la planificación de eventos, capacitaciones o actividades estratégicas, estructurando la logística y organización.

Si bien la implementación de un asistente GPT puede aportar múltiples beneficios a una PyME, su efectividad no depende únicamente de su disponibilidad, sino de cómo se utiliza y en qué condiciones se implementa. Para aprovechar al máximo sus capacidades, es fundamental desarrollar la gimnasia de uso, entendiendo no solo qué puede hacer, sino cómo interactuar con él de manera eficiente. Un equipo que aprende a estructurar consultas de forma clara, detallada y específica obtiene respuestas más precisas y útiles.

A su vez, la incorporación del asistente en la rutina diaria permite optimizar tiempos, reducir carga operativa y potenciar la toma de decisiones estratégicas (El País, 2025).

El proceso de adopción de esta tecnología dentro de la empresa suele comenzar en los niveles directivos. En un primer momento, los dueños y líderes de la organización pueden utilizar el asistente para fortalecer su planificación, mejorar su toma de decisiones y optimizar la comunicación estratégica. Una vez integrado en este nivel, su uso se expande naturalmente hacia otras áreas de la empresa, facilitando la automatización de tareas administrativas, la optimización de procesos internos y la mejora en la gestión del conocimiento. La clave está en que la dirección adopte la IA como una herramienta de apoyo real y fomente su incorporación en distintos sectores, asegurando una integración progresiva y efectiva.

Además del entrenamiento en su uso, existen ciertos requerimientos clave que pueden mejorar significativamente su rendimiento dentro de la empresa. La disponibilidad de información estructurada es uno de los factores más importantes: cuanto más organizados estén los datos dentro de la empresa, más precisas y relevantes serán las respuestas del asistente. Por otro lado, su integración con herramientas de gestión permite que se conecte a plataformas empresariales, bases de datos internas y sistemas de comunicación, facilitando su acceso a información clave y evitando la fragmentación de datos. En algunos casos, adaptar flujos de trabajo para incorporar la IA dentro de los procesos diarios también puede ser una estrategia útil para maximizar su impacto.

A pesar de sus ventajas, el uso de asistentes GPT presenta ciertas barreras y limitaciones que deben considerarse antes de su implementación. En primer lugar, la tecnología aún está en evolución y no siempre ofrece respuestas 100% certeras. Si bien su precisión mejora significativamente cuando las consultas son bien formuladas, sigue existiendo un margen de error en la generación de respuestas. Es posible que la IA interprete incorrectamente una solicitud, proporcione información desactualizada o genere contenido que, sin una revisión crítica, podría inducir a decisiones erróneas. Esto hace que la supervisión humana siga siendo esencial, especialmente en el análisis de información estratégica y en la automatización de procesos críticos dentro de la empresa.

Otro aspecto fundamental a considerar es la seguridad y privacidad de la información. Un asistente GPT puede procesar grandes volúmenes de datos, pero su uso debe estar regulado por políticas claras dentro de la empresa. La información sensible, como datos financieros, estrategias comerciales o registros internos, no debería compartirse sin un marco adecuado de control y gestión de acceso. Establecer límites en la interacción con la IA y definir protocolos de uso responsable es clave para evitar riesgos de filtración de información o exposición a potenciales vulnerabilidades de seguridad.

Cuando estos aspectos son abordados de manera adecuada y la empresa desarrolla un esquema sólido de uso, el asistente GPT se convierte en un verdadero aliado estratégico. Su impacto va más allá de la automatización de tareas y la optimización de procesos; su verdadero valor está en cómo se integra dentro de la estructura de trabajo y en la capacidad del equipo para utilizarlo como una herramienta de gestión e innovación. La

diferencia entre una empresa que simplemente tiene acceso a IA y una que realmente la aprovecha radica en la capacitación, la supervisión inteligente y la incorporación efectiva en los procesos clave del negocio.

Si bien en esta aplicación hemos utilizado el nombre "Mi Asistente GPT" debido a la popularidad de los modelos desarrollados por OpenAI, este no es el único enfoque disponible en el mercado. Existen diversas soluciones de inteligencia artificial generativa que pueden desempeñar funciones similares, como Claude de Anthropic, Gemini de Google DeepMind, Mistral de Mistral AI, Llama de Meta, entre otros. Cada uno de estos asistentes ha sido desarrollado con distintas prioridades tecnológicas: algunos ofrecen mayor precisión en la generación de texto, otros destacan por su enfoque en privacidad y seguridad, mientras que ciertos modelos están optimizados para integrarse con herramientas empresariales específicas.

Para una PyME, la elección del asistente adecuado dependerá en gran medida de la facilidad de uso, el costo de implementación y el tipo de soporte que ofrece cada solución. Por ejemplo, una empresa que ya utiliza herramientas de Google podría encontrar en Gemini una opción más integrada con su ecosistema, mientras que aquellas con mayores requerimientos de privacidad pueden optar por soluciones como Claude o Mistral, que están diseñadas con un enfoque más restrictivo en el manejo de datos. Mientras que algunos modelos requieren configuraciones más avanzadas y acceso a infraestructura específica, otros pueden ser utilizados de manera más sencilla con herramientas ya disponibles en el mercado. En este sentido, no se trata solo de acceder a la mejor tecnología, sino de encontrar el modelo que mejor se adapte a la realidad operativa de la empresa, asegurando que su incorporación sea viable y genere un impacto positivo en la productividad y la toma de decisiones.

CAPÍTULO 5: MAPA DE OPORTUNIDADES – UNA GUÍA PRÁCTICA

Hasta aquí hemos recorrido un amplio espectro de aplicaciones de inteligencia artificial aplicadas a diferentes áreas de negocios de las empresas. Pero bien vale preguntarnos: ¿qué hacemos ahora con todo esto?, ¿cómo logramos llevar este potencial a nuestra empresa?, ¿cómo podemos evaluar si resulta conveniente?, ¿por dónde empezamos?

Para responder a estos interrogantes, se ha desarrollado una herramienta práctica llamada Mapa de Oportunidades, diseñada para ayudar a las PYMEs a explorar, visualizar y priorizar distintas aplicaciones de inteligencia artificial según su realidad operativa. Su principal valor reside en traducir el universo amplio y muchas veces abstracto de la IA en un conjunto concreto de opciones evaluables, facilitando el análisis estratégico y la toma de decisiones informadas.

A diferencia de otros modelos existentes, el Mapa no busca ofrecer un diagnóstico técnico ni una solución estándar aplicable a todas las organizaciones. Por el contrario, se propone como una guía flexible que permite a cada empresa identificar aquellas soluciones de IA que podrían aportar mayor valor en función de su contexto, su nivel de madurez digital y sus prioridades estratégicas.

El Mapa de Oportunidades se concibe como un proceso estructurado en ocho etapas concretas, que permiten recorrer de manera ordenada el camino desde la identificación de aplicaciones hasta su análisis estratégico.

El proceso comienza con la identificación de un conjunto de aplicaciones relevantes para el negocio. Para analizar este universo de alternativas y su potencial para la empresa, se define un grupo de atributos estratégicos que sirven como base de evaluación.

Cada aplicación es calificada en función de estos atributos a través de una escala previamente determinada. Esta calificación cualitativa se traduce luego en un puntaje numérico, utilizando un sistema de puntuaciones y ponderaciones específicas.

Finalmente, el proceso concluye con la elaboración de un cuadro de evaluación y la construcción de un ranking de oportunidades, que permite priorizar las aplicaciones más convenientes en función de su viabilidad y su impacto estratégico.

En el gráfico siguiente se presenta el esquema general del proceso de trabajo.

Mapa de Oportunidades: Flujo de Proceso**Universo de Aplicaciones**

- ✓ Se define un conjunto de 30 Aplicaciones de IA en distintos procesos de negocio de la empresa.
- ✓ Este listado es flexible y puede ampliarse o adaptarse según el contexto de la empresa y evolución de la IA.

**Definición de 5 Atributos**

- ✓ Se definen cinco atributos clave (pueden ser más) para evaluar a cada aplicación:
 - Madurez Digital Requerida
 - Dificultad de Implementación
 - Costo de Implementación
 - Impacto en el Negocio
 - Tiempo de Retorno de Inversión


**Escala de Evaluación de los Atributos**

- ✓ Se define una escala de evaluación de tres niveles: Bajo, Medio o Alto.
- ✓ Para cada aplicación se evalúa cada atributo según la escala definida
- ✓ La evaluación de cada aplicación en cada atributo depende tanto de las características de la solución como de las características de la empresa.

**De la evaluación cualitativa al Puntaje**

- ✓ A cada nivel de la escala (Bajo, Medio, Alto) se le asigna un puntaje numérico:
 - Bajo = 0 Puntos
 - Medio = 1 Punto
 - Alto = 2 Puntos
- ✓ Esta conversión permite cuantificar la evaluación de cada aplicación en cada atributo.





En las próximas secciones, recorreremos cada una de estas etapas, explicando el método de evaluación, el sistema de puntuación y la construcción del Mapa de Oportunidades aplicado al universo de aplicaciones identificado.

5.1 Universo de Aplicaciones

En la sección 4.2 hemos presentado un conjunto de treinta aplicaciones de inteligencia artificial aplicables a diferentes áreas de negocio de Pymes. En esta tesis, trabajamos con esta selección de 30 aplicaciones prácticas como base para ilustrar el uso del Mapa de Oportunidades. Si bien este listado no es exhaustivo ni define un estándar, fue seleccionado para ser lo suficientemente amplio y representativo del potencial que tiene la IA en los distintos procesos de negocio de una PyME.

El objetivo de esta selección fue reflejar la diversidad de usos posibles, abarcando desde áreas comerciales y productivas hasta funciones administrativas y estratégicas, brindando así un punto de partida robusto para el análisis. No obstante, el Mapa de Oportunidades no está limitado a un número fijo de aplicaciones: cada empresa puede adaptar, ampliar o reducir este universo inicial en función de su contexto operativo, su nivel de madurez digital y sus prioridades estratégicas. Además, dado el ritmo acelerado de evolución de la inteligencia artificial, es esperable que constantemente surjan nuevas aplicaciones que amplíen el espectro de alternativas disponibles para las organizaciones.

Es importante señalar que cuanto mayor sea la cantidad y diversidad de aplicaciones consideradas en el análisis, mayor será también la riqueza de los resultados obtenidos. Un universo amplio de soluciones potencia las oportunidades de descubrimiento, permite identificar áreas de impacto menos evidentes y facilita una priorización más precisa y estratégica de las iniciativas de adopción de inteligencia artificial.

Una vez definido el universo de aplicaciones a analizar, el siguiente paso consiste en establecer los atributos estratégicos que permitirán evaluar cada alternativa de manera estructurada. En la próxima sección se detallarán los criterios seleccionados para guiar este proceso de evaluación.

5.2 Definición de Atributos

Para poder analizar de manera estructurada las distintas aplicaciones de inteligencia artificial identificadas, es necesario establecer un conjunto de atributos estratégicos que sirvan como criterios comunes de evaluación.

En esta tesis se definieron cinco atributos con el objetivo de balancear el enfoque estratégico y operativo de la empresa, permitiendo priorizar alternativas de manera práctica y accesible, sin requerir conocimientos técnicos especializados. Estos atributos fueron seleccionados no sólo por su relevancia individual, sino también por su capacidad para complementarse entre sí, generando una evaluación integral del impacto, la viabilidad y el tiempo de recuperación de la inversión asociado a cada aplicación.

Los cinco atributos considerados son:

- ✓ **Madurez digital requerida:** nivel de desarrollo digital necesario para implementar la solución con éxito.
- ✓ **Dificultad de implementación:** grado de complejidad técnica, organizacional y operativa del proceso de adopción.
- ✓ **Costo estimado de implementación:** inversión económica inicial o recurrente asociada a la puesta en marcha.
- ✓ **Impacto potencial en el negocio:** valor estratégico o económico que la aplicación puede generar en el contexto de la empresa.

- ✓ **Tiempo estimado de retorno:** plazo esperado para percibir beneficios concretos tras la implementación.

Estos atributos permiten construir una visión integral del potencial de cada aplicación, facilitando su priorización en función de la realidad y objetivos estratégicos de cada organización.

En la sección siguiente se detallará cómo se evalúan cualitativamente estos atributos para cada aplicación.

5.3 Evaluación de los Atributos

Para poder evaluar las aplicaciones en el Mapa de Oportunidades a través de los atributos que presentamos en la sección anterior, se define una Escala de calificación que está estructurada en tres niveles: BAJO, MEDIO y ALTO.

Con la elección de tres niveles se logra un equilibrio entre simplicidad y capacidad de diferenciación. Sin embargo, si quisiéramos tener un mayor nivel de detalle en el análisis, podríamos expandir la escala incorporando más niveles intermedios.

A través de este sistema, cada aplicación recibe una calificación cualitativa en cada uno de los atributos definidos. De esta forma, se establece un marco de evaluación estructurado que permite comparar las aplicaciones de manera homogénea y facilitar la visualización de diferencias significativas.


Por ejemplo, en el atributo Madurez Digital Requerida, aquellas aplicaciones que pueden implementarse con infraestructura tecnológica básica, utilizando herramientas de uso cotidiano como formularios online o gestores de correos electrónicos automatizados, serían calificadas con un nivel BAJO. Por el contrario, las aplicaciones que requieren que la empresa cuente con un nivel avanzado de digitalización, como el uso de sensores IoT, plataformas de análisis de datos en la nube o sistemas de machine learning integrados a la operación, serían calificadas con un nivel ALTO en este atributo.

En el caso del atributo Tiempo de Retorno de Inversión, si bien la lógica de progresión de conveniencia se mantiene, la terminología utilizada es LARGO, MEDIO y CORTO plazo. Así, una aplicación con tiempo de retorno CORTO generará beneficios casi inmediatos tras su implementación, mientras que una solución con tiempo de retorno LARGO requerirá un horizonte más extendido para alcanzar resultados concretos.

En las secciones siguientes, se analizará en mayor detalle cómo funciona el sistema de calificación para cada uno de los cinco atributos definidos, ilustrando su aplicación concreta a través de ejemplos prácticos.

El objetivo de esta clasificación no es ofrecer mediciones técnicas exactas, sino construir un marco de análisis práctico que permita visualizar rápidamente diferencias significativas entre las aplicaciones y orientar la toma de decisiones estratégicas.

El gráfico que se presenta a continuación sintetiza visualmente esta escala de evaluación, mostrando para cada atributo los niveles posibles y su progresión de menor a mayor conveniencia. Los colores asociados —rojo para la peor clasificación, amarillo para la intermedia y verde para la mejor— permiten identificar de forma inmediata el posicionamiento relativo de cada alternativa dentro del proceso de análisis.



Es clave entender que la calificación de cada aplicación no solo depende de sus características intrínsecas, sino también de factores propios de la PyME, como el rubro al que pertenece o el modelo de negocio que desarrolla dentro de ese sector.

En el caso de la Madurez Digital Requerida, la calificación depende mayoritariamente de las características técnicas intrínsecas de la aplicación. La infraestructura tecnológica necesaria para su funcionamiento está determinada más por las exigencias propias de la solución, y no varía tanto en función del sector o del tipo de empresa que la implemente. Una solución que requiere, por ejemplo, integración de sensores IoT o

procesamiento de datos en la nube, demandará siempre un nivel avanzado de madurez digital, independientemente del contexto en el que se aplique.

La Dificultad de Implementación depende tanto de la complejidad técnica como de los desafíos organizacionales que plantea la aplicación. Si bien el nivel de dificultad está determinado fundamentalmente por la naturaleza de la tecnología involucrada, en este atributo comienzan a influir también factores internos de la empresa, como su capacidad tecnológica, la experiencia previa en proyectos similares o la disponibilidad de equipos especializados. Por ejemplo, la implementación de un sistema de visión artificial puede representar un desafío considerable para una PyME que carece de personal técnico capacitado, mientras que para una empresa con un área consolidada de IT, el mismo proyecto puede ser abordado con menor dificultad.

Para evaluar el Costo de Implementación, las condiciones tecnológicas y organizacionales de la empresa influyen de manera mucho más significativa que en los casos anteriores. Aunque las características técnicas de la solución establecen un marco de referencia inicial, el esfuerzo económico real requerido dependerá en gran medida del contexto propio de la organización: la existencia o ausencia de sistemas compatibles, la calidad de los datos disponibles, el nivel de madurez de sus procesos, y la capacidad de integración con tecnologías existentes. Por ejemplo, la implementación de un sistema de predicción de demanda basado en IA puede representar un costo relativamente accesible si la empresa ya cuenta con bases de datos consolidadas, procesos de venta digitalizados y herramientas de gestión integradas. Por el contrario, el mismo proyecto puede volverse considerablemente más costoso si es necesario estructurar datos históricos, desarrollar sistemas de captura de información y adecuar los procesos internos para que permitan alimentar correctamente el modelo predictivo.

El Tiempo de Retorno de Inversión está influido en mayor medida por las condiciones técnicas y operativas de la propia solución. Aunque la dinámica específica de la empresa puede modificar en parte la velocidad del retorno, el plazo estimado responde en esencia a la naturaleza de la aplicación y a su forma de generar beneficios. Por ejemplo, una herramienta de optimización de campañas publicitarias puede ofrecer resultados en el corto plazo, mientras que un sistema de mantenimiento predictivo basado en IA puede requerir un horizonte de mediano a largo plazo para evidenciar mejoras.

El Impacto en el Negocio es el atributo que presenta mayor sensibilidad al sector y al modelo comercial de la empresa. Si bien cada solución de inteligencia artificial posee un potencial inherente de transformación, su efecto real sobre la competitividad y la generación de valor depende en gran medida del contexto en el que se aplique. Por ejemplo, un sistema de segmentación avanzada de clientes puede ser clave en una empresa de retail, mientras que su aporte será más limitado en una organización que comercializa productos industriales bajo contratos estables.

En las secciones siguientes, se analizarán en detalle los cinco atributos definidos, ilustrando su interpretación mediante ejemplos prácticos.

5.3.1 Madurez Digital Requerida

Cada solución de IA necesita cierto grado de digitalización previa para funcionar de manera efectiva, ya que su desempeño depende de la disponibilidad y calidad de los datos, la infraestructura tecnológica existente y la capacidad de integración con los sistemas en uso. Este criterio busca evaluar el nivel de madurez digital que debe tener una empresa antes de adoptar una aplicación de IA, permitiendo determinar si la organización está preparada para su implementación o si es necesario desarrollar primero otras capacidades tecnológicas.

Las aplicaciones clasificadas con un nivel BAJO en este criterio pueden incorporarse sin requerir una base tecnológica avanzada. Son soluciones que funcionan con herramientas de uso cotidiano y que pueden operar de manera independiente o con una configuración mínima. En general, no requieren que la empresa disponga de datos estructurados ni que tenga digitalizados sus procesos operativos. Ejemplos de este tipo incluyen asistentes virtuales para atención al cliente, sistemas de automatización de correos electrónicos o herramientas de generación de contenido con IA. Estas aplicaciones pueden implementarse en organizaciones que aún trabajan con procesos manuales y que buscan incorporar inteligencia artificial sin necesidad de realizar grandes cambios en su estructura digital.

Las aplicaciones que requieren un nivel MEDIO de madurez digital necesitan que la empresa cuente con cierta estructuración en la gestión de sus datos y procesos. En esta categoría se incluyen herramientas que dependen de información previamente digitalizada para generar valor, como los sistemas de segmentación de clientes basados en IA, los modelos de predicción de demanda o las soluciones de optimización de inventarios. Para que estas aplicaciones puedan funcionar de manera eficiente, es fundamental que la empresa tenga acceso a bases de datos organizadas y que utilice plataformas como CRM, ERP o herramientas de analítica de datos. Si la información clave de la empresa todavía está dispersa en documentos físicos o no estructurados, la implementación de estas soluciones puede ser limitada o ineficaz.

Las aplicaciones clasificadas con un nivel ALTO en este criterio están diseñadas para empresas que han alcanzado un grado avanzado de digitalización y que cuentan con tecnologías especializadas en su operación. Estas soluciones suelen depender de infraestructuras más complejas, como el uso de sensores IoT, sistemas de análisis en la nube o modelos de machine learning personalizados. Ejemplos de estas aplicaciones incluyen el mantenimiento predictivo basado en IA, la visión artificial para control de calidad en procesos industriales y los sistemas de pricing dinámico que ajustan precios en tiempo real según múltiples variables. En estos casos, la empresa debe haber superado una etapa inicial de digitalización y contar con la capacidad técnica para gestionar grandes volúmenes de datos en tiempo real.

En la evaluación de cada aplicación dentro del Mapa de Oportunidades, la clasificación en este criterio permite que una empresa identifique si está preparada para adoptar una

determinada solución de IA o si primero debe fortalecer su infraestructura digital antes de avanzar en este camino.

5.3.2 Dificultad de Implementación

La incorporación de inteligencia artificial en una empresa no solo depende de su grado de digitalización, sino también de la complejidad técnica y operativa que implica su adopción. Algunas aplicaciones pueden implementarse de manera sencilla con herramientas preconfiguradas, mientras que otras requieren desarrollos a medida, integración con sistemas existentes o la capacitación del equipo. Este criterio busca medir el nivel de dificultad asociado a la puesta en marcha de cada aplicación, permitiendo anticipar los recursos y esfuerzos necesarios para su correcta implementación.

Las aplicaciones clasificadas con un nivel BAJO en este criterio pueden adoptarse sin necesidad de conocimientos técnicos avanzados ni modificaciones en los procesos internos de la empresa. Son soluciones que suelen estar disponibles como herramientas listas para usar, con interfaces intuitivas y configuraciones simples. Ejemplos de estas aplicaciones incluyen chatbots básicos para atención al cliente, asistentes de redacción con IA o sistemas de automatización de publicaciones en redes sociales. Su implementación es rápida y no requiere la intervención de especialistas en inteligencia artificial o desarrolladores de software, lo que las hace accesibles para cualquier empresa sin importar su nivel de experiencia tecnológica.

Las aplicaciones con una dificultad de implementación MEDIA requieren ciertos ajustes técnicos o integración con plataformas utilizadas en la empresa. En esta categoría se encuentran herramientas que analizan datos internos y generan recomendaciones automatizadas, como los sistemas de segmentación de clientes o los modelos de predicción de demanda. Para que estas soluciones funcionen de manera efectiva, es necesario que la empresa disponga de información estructurada y que pueda integrarla con la IA mediante APIs o conexiones con sistemas de gestión como CRM o ERP. Además, su implementación puede requerir la capacitación del personal para interpretar los resultados y ajustar la estrategia empresarial en función de los datos generados.

Las aplicaciones clasificadas con un nivel ALTO en este criterio presentan una mayor complejidad en su implementación, ya que requieren una infraestructura tecnológica avanzada y un equipo especializado en inteligencia artificial, análisis de datos o integración de sistemas. Estas soluciones suelen implicar el desarrollo de modelos personalizados, la recopilación y procesamiento de grandes volúmenes de datos o la conexión con múltiples fuentes de información en tiempo real. Ejemplos de este tipo incluyen el mantenimiento predictivo en la industria, la visión artificial para control de calidad o los sistemas de pricing dinámico basados en machine learning. Su adopción no solo demanda recursos tecnológicos significativos, sino que también implica un proceso de ajuste y optimización para asegurar que la IA cumpla con los objetivos del negocio.

En la evaluación de cada aplicación dentro del Mapa de Oportunidades, este criterio permite que las empresas comprendan el esfuerzo necesario para adoptar una solución de IA y si cuentan con los conocimientos y la infraestructura adecuada para llevar adelante su implementación.

5.3.3 Costo de Implementación

La adopción de inteligencia artificial en una empresa implica una inversión que varía según la complejidad de la solución, la infraestructura tecnológica necesaria y los costos asociados a su integración y mantenimiento. Algunas aplicaciones pueden implementarse con herramientas de bajo costo o incluso gratuitas, mientras que otras requieren inversiones significativas en software, hardware o personal especializado. Este criterio no busca determinar si una aplicación es costosa en términos absolutos, sino más bien comparar el nivel de inversión relativo entre diferentes soluciones de IA, permitiendo identificar cuáles requieren mayores recursos para su implementación y operación.

Las aplicaciones clasificadas con un nivel BAJO en este criterio pueden implementarse con recursos mínimos o con herramientas accesibles en el mercado. Muchas de estas soluciones están disponibles bajo modelos SaaS (Software as a Service), lo que permite su uso mediante suscripciones mensuales o incluso en versiones gratuitas con funcionalidades limitadas. Ejemplos de estas aplicaciones incluyen chatbots básicos, sistemas de automatización de marketing y herramientas de análisis de texto con IA. En estos casos, la empresa no necesita realizar grandes inversiones en infraestructura ni en desarrollo tecnológico, ya que la solución puede ser utilizada de manera inmediata con una configuración sencilla.

Las aplicaciones con un costo de implementación MEDIO requieren una inversión moderada en software especializado, integración con los sistemas internos de la empresa o capacitación del equipo para su correcta utilización. En esta categoría se encuentran soluciones como los sistemas de predicción de demanda, los modelos de segmentación de clientes o la optimización de inventarios con IA. Aunque muchas de estas herramientas están disponibles en plataformas de terceros, su implementación puede implicar costos adicionales relacionados con la personalización del modelo, la recopilación y estructuración de datos o la necesidad de asistencia técnica externa.

Las aplicaciones clasificadas con un nivel ALTO en este criterio requieren inversiones significativas en infraestructura tecnológica, licencias de software avanzado o desarrollo de soluciones a medida. Estas soluciones suelen implicar costos elevados en términos de hardware, almacenamiento en la nube y contratación de personal especializado en inteligencia artificial y análisis de datos. Ejemplos de este tipo incluyen la visión artificial para control de calidad, el mantenimiento predictivo en la industria y los sistemas de IA generativa aplicados a la personalización de productos. En estos casos, la empresa debe considerar no solo el costo inicial de implementación, sino también los gastos asociados a la operación y mantenimiento de la solución a lo largo del tiempo.

En la evaluación de cada aplicación dentro del Mapa de Oportunidades, este criterio permite a las empresas comprender qué soluciones requieren una mayor inversión en relación con otras alternativas, ayudando a priorizar aquellas que se alinean mejor con sus capacidades financieras y expectativas de retorno.

5.3.4 Impacto en el Negocio

Si bien la dificultad y el costo de implementación son factores clave en la adopción de inteligencia artificial, el verdadero valor de una aplicación de IA radica en su capacidad para generar mejoras sustanciales en la empresa. Algunas soluciones aportan beneficios incrementales en eficiencia operativa, mientras que otras pueden transformar por completo la forma en que se gestionan los procesos o se toman decisiones estratégicas. Este criterio busca evaluar el impacto potencial de cada aplicación en la competitividad, la productividad y la rentabilidad de la empresa.

Las aplicaciones clasificadas con un nivel BAJO en este criterio generan mejoras operativas menores, generalmente relacionadas con la automatización de tareas repetitivas o la optimización de procesos administrativos. Son herramientas que aportan eficiencia y reducen carga operativa, pero cuyo efecto en la competitividad de la empresa es limitado. Ejemplos de estas aplicaciones incluyen chatbots básicos para responder consultas frecuentes, sistemas de generación de contenido con IA y herramientas de automatización de correos electrónicos. Aunque estas soluciones pueden optimizar la gestión interna, su adopción no supone un cambio sustancial en la estructura del negocio.

Las aplicaciones con un impacto MEDIO generan mejoras significativas en la eficiencia y la capacidad de toma de decisiones. Estas soluciones permiten optimizar procesos clave en la empresa, reducir costos operativos o mejorar la relación con los clientes. En esta categoría se encuentran los modelos de segmentación de clientes, las soluciones de predicción de demanda y los algoritmos de optimización de precios. La implementación de estas herramientas puede traducirse en un incremento en la rentabilidad, una mejor gestión de los recursos o una mayor efectividad en las estrategias comerciales, pero sin alterar fundamentalmente el modelo de negocio de la empresa.

Las aplicaciones clasificadas con un impacto ALTO tienen el potencial de transformar la empresa y proporcionar ventajas competitivas sustanciales. Son soluciones que permiten mejorar significativamente la productividad, acceder a nuevos mercados o redefinir la manera en que se ofrece un producto o servicio. Ejemplos de estas aplicaciones incluyen la inteligencia artificial aplicada a la personalización masiva de productos, la visión artificial para el control de calidad en manufactura y los sistemas de mantenimiento predictivo en la industria. Estas herramientas pueden modificar la estructura operativa de la empresa y proporcionar un diferencial clave en el mercado, permitiendo una mayor escalabilidad y eficiencia a largo plazo.

En la evaluación de cada aplicación dentro del Mapa de Oportunidades, este criterio permite identificar qué soluciones de IA pueden generar un impacto significativo en la empresa y cuáles aportan beneficios más limitados, ayudando a priorizar aquellas que pueden contribuir de manera más efectiva a la competitividad y el crecimiento del negocio.

5.3.5 Tiempo de Retorno de Inversión

Uno de los factores más relevantes en la adopción de inteligencia artificial en PYMEs es el tiempo que transcurre entre la implementación de una solución y la generación de beneficios tangibles. Mientras algunas aplicaciones pueden mostrar resultados casi inmediatos, otras requieren un período más prolongado de ajuste y optimización antes de generar un impacto positivo en la empresa. Este criterio busca estimar el horizonte temporal en el que una empresa podría percibir mejoras o recuperar la inversión realizada en una determinada aplicación de IA.

Las aplicaciones clasificadas con un tiempo de retorno CORTO generan beneficios rápidamente tras su implementación. Son soluciones que pueden optimizar procesos existentes sin necesidad de realizar cambios profundos en la empresa. Su adopción permite percibir mejoras casi de inmediato en términos de eficiencia, reducción de costos o incremento en la conversión de clientes. Ejemplos de estas aplicaciones incluyen la automatización de atención al cliente con chatbots, los sistemas de optimización de campañas publicitarias basados en IA y las herramientas de recomendación de productos en comercio electrónico.

Las aplicaciones con un tiempo MEDIO requieren un período más extenso antes de generar un impacto significativo en la empresa. En esta categoría se encuentran soluciones que implican ajustes en los procesos internos y que dependen de la acumulación de datos o del aprendizaje progresivo del sistema para alcanzar su máximo potencial. Ejemplos de estas aplicaciones incluyen los modelos de predicción de demanda, los sistemas de segmentación avanzada de clientes y las herramientas de optimización de inventarios basadas en IA. Aunque los beneficios pueden no ser inmediatos, una vez que la tecnología se integra plenamente en la operación, su impacto en la eficiencia y la rentabilidad puede ser considerable.

Las aplicaciones clasificadas con un tiempo LARGO requieren un período prolongado de implementación y maduración antes de generar beneficios perceptibles. Estas soluciones suelen implicar inversiones significativas en infraestructura tecnológica y requieren un tiempo de adaptación antes de comenzar a optimizar la operación. Ejemplos de este tipo incluyen el mantenimiento predictivo basado en IA, la visión artificial para control de calidad en la industria y los sistemas de pricing dinámico en sectores de alta competencia. En estos casos, la empresa debe evaluar cuidadosamente si está en condiciones de sostener la inversión durante el tiempo necesario para alcanzar un retorno positivo.

En la evaluación de cada aplicación dentro del Mapa de Oportunidades, este criterio permite que las empresas comprendan el tiempo estimado para recuperar su inversión y tomar decisiones informadas sobre la viabilidad de cada solución en función de sus recursos y expectativas de crecimiento.

4.3.3.6 Ejemplo Ilustrativo de Evaluación de Aplicaciones

Con el objetivo de mostrar de manera práctica cómo se aplica la escala de evaluación cualitativa a las distintas aplicaciones de inteligencia artificial, se presenta a continuación un ejemplo ilustrativo.

En este caso, se consideran tres aplicaciones genéricas, evaluadas según los cinco atributos definidos previamente: Madurez Digital Requerida, Dificultad de Implementación, Costo de Implementación, Impacto en el Negocio y Tiempo de Retorno.

Es importante señalar que el caso no refleja una evaluación real aplicada a una empresa específica, y está destinado a visualizar cómo se estructura el proceso de análisis dentro del Mapa de Oportunidades.

Como puede observarse en el cuadro siguiente, cada aplicación recibe una calificación cualitativa para cada atributo, utilizando la escala de tres niveles establecida previamente.

Aplicación	Madurez Digital Requerida	Dificultad de Implementación	Costo de Implementación	Impacto en el Negocio	Tiempo de Retorno
Chatbot para Atención al Cliente	BAJO	BAJO	BAJO	MEDIO	CORTO
Predicción de Demanda	MEDIO	MEDIO	MEDIO	MEDIO	LARGO
Conciliación Bancaria	MEDIO	MEDIO	MEDIO	ALTO	CORTO

A continuación, se explicará cómo este esquema cualitativo se transforma en un sistema de puntaje numérico, que servirá como base para realizar posteriormente la comparación cuantitativa entre las distintas aplicaciones.

5.4 Sistema de Puntaje de Atributos

Con el objetivo de avanzar en el proceso de evaluación de las aplicaciones, se establece un sistema de conversión de las calificaciones cualitativas en puntajes numéricos. Esta transformación permite cuantificar el análisis, facilitando la comparación estructurada

entre distintas soluciones y sentando las bases para construir posteriormente el Cuadro de Evaluación.

La lógica de puntuación asigna valores de la siguiente manera:

- ✓ Opción más favorable: 2 Puntos.
- ✓ Opción intermedia: 1 Punto.
- ✓ Opción menos favorable: 0 Puntos.

De esta manera los atributos quedan con los siguientes puntajes:

Madurez Digital Requerida	Dificultad de Implementación	Costo de Implementación	Impacto en el Negocio	Tiempo de Retorno
BAJO: 2 Puntos	BAJO: 2 Puntos	BAJO: 2 Puntos	ALTO: 2 Puntos	CORTO: 2 Puntos
MEDIO: 1 Punto	MEDIO: 1 Punto	MEDIO: 1 Punto	MEDIO: 1 Punto	MEDIO: 1 Punto
ALTO: 0 Puntos	ALTO: 0 Puntos	ALTO: 0 Puntos	BAJO: 0 Puntos	LARGO: 0 Puntos

Este esquema numérico permitirá, en el siguiente paso del proceso, calcular un puntaje global para cada aplicación a partir de la ponderación de los diferentes atributos, avanzando así en la construcción del Mapa de Oportunidades.

5.5 Ponderación de Atributos

No todos los atributos definidos para la evaluación de aplicaciones de inteligencia artificial tienen el mismo peso relativo a la hora de determinar la conveniencia de una solución. Algunos aspectos, como el impacto en el negocio, suelen ser determinantes para la estrategia de una empresa, mientras que otros, como la madurez digital requerida, pueden resultar menos críticos si la organización está dispuesta a invertir en el fortalecimiento de su infraestructura tecnológica.

Para reflejar esta diferencia de importancia, se establece un esquema de ponderación de atributos que permite ajustar la evaluación final, otorgando mayor influencia a los criterios más relevantes para el éxito de la implementación.

En este modelo, se propone la siguiente ponderación inicial:

- ✓ **Impacto en el Negocio (30%)** → Evalúa la transformación que puede generar la aplicación dentro de la empresa.
- ✓ **Costo de Implementación (25%)** → Considera el nivel de inversión relativo requerido.
- ✓ **Tiempo de Retorno de Inversión (20%)** → Mide qué tan rápido se pueden percibir beneficios tras la implementación.
- ✓ **Dificultad de Implementación (15%)** → Representa los desafíos técnicos y operativos involucrados en la adopción.
- ✓ **Madurez Digital Requerida (10%)** → Refleja la necesidad de contar con una infraestructura tecnológica mínima para su funcionamiento.

Es importante señalar que este esquema de ponderaciones puede ser adaptado por cada empresa según su contexto particular. Por ejemplo, una PyME con recursos financieros limitados podría asignar mayor peso al Costo de Implementación, priorizando soluciones de rápida adopción y bajo impacto económico. Del mismo modo, una empresa que opera en un mercado altamente competitivo podría optar por darle mayor importancia al Impacto en el Negocio, buscando aplicaciones que generen ventajas estratégicas sustanciales. En otros casos, organizaciones con baja madurez digital podrían considerar que este factor sea más crítico, debido a las inversiones adicionales que implicaría su adecuación tecnológica.

De esta manera, el modelo mantiene su flexibilidad, permitiendo que cada organización ajuste la ponderación de los atributos según su realidad operativa, su estrategia empresarial y sus capacidades financieras.

5.6 Puntaje Global de cada Aplicación

Una vez obtenidos los puntajes numéricos de cada aplicación en los cinco atributos evaluados, y definidas las ponderaciones relativas de cada atributo, es posible calcular el puntaje global de cada solución. Este puntaje resume de manera cuantitativa la conveniencia relativa de cada aplicación, considerando no sólo su desempeño en cada atributo, sino también la importancia asignada a cada uno de ellos dentro del modelo de evaluación.

El cálculo del puntaje global se realiza aplicando una fórmula de ponderación, en la que el puntaje obtenido por cada aplicación en cada atributo se multiplica por el peso asignado a dicho atributo, y luego se suman los resultados obtenidos.

La fórmula general para el cálculo del puntaje global es la siguiente:

Puntaje Global

$$\begin{aligned} &= (\text{Puntaje Madurez Digital Requerida} \times 10\%) \\ &+ (\text{Puntaje Dificultad de Implementación} \times 15\%) \\ &+ (\text{Puntaje Costo de Implementación} \times 25\%) \\ &+ (\text{Puntaje Impacto en el Negocio} \times 30\%) \\ &+ (\text{Puntaje Tiempo de Retorno de Inversión} \times 20\%) \end{aligned}$$

Cada uno de los términos de la fórmula corresponde al puntaje numérico obtenido por la aplicación en el atributo respectivo, multiplicado por el porcentaje de ponderación que refleja su importancia relativa dentro del modelo. En cada atributo se le asigna a la aplicación un puntaje entre 0 y 2, donde 0 representa el peor desempeño posible y 2 el mejor desempeño en ese criterio específico. Al aplicar las ponderaciones definidas para cada atributo y sumar los resultados obtenidos, se calcula el puntaje final de cada aplicación.

Dado que el puntaje máximo posible por atributo es 2 y que las ponderaciones en conjunto suman el 100% del total (o 1 en términos proporcionales), el puntaje global de una aplicación puede fluctuar entre 0 y 2. Una aplicación que obtuviera 0 puntos en todos los atributos alcanzaría un puntaje final de 0, mientras que una aplicación que lograra la máxima calificación en cada atributo alcanzaría un puntaje final de 2.

En términos prácticos, cuanto más cercano esté el puntaje global a 2, mayor será la conveniencia y el potencial de adopción de esa aplicación para la empresa. De manera inversa, un puntaje más bajo reflejará mayores barreras, dificultades o costos asociados a su implementación. Este puntaje final permitirá construir un ranking de aplicaciones, facilitando la comparación estructurada entre soluciones y ayudando a priorizar aquellas que representen una mayor oportunidad de incorporación.

Con este puntaje global calculado para cada aplicación, en la siguiente sección se avanzará en la construcción del Cuadro de Evaluación, consolidando los resultados obtenidos en un esquema comparativo integral.

5.7 Cuadro de Evaluación

A lo largo de las secciones anteriores, se presentó un proceso metodológico que permitió estructurar la evaluación de cada aplicación de inteligencia artificial de manera sistemática.

El análisis comenzó con la definición de cinco atributos estratégicos, a través de los cuales se calificaron cualitativamente todas las soluciones identificadas. Posteriormente, se diseñó un esquema de conversión que transformó las evaluaciones cualitativas en puntajes numéricos. Sobre esta base, se aplicó un sistema de ponderación que asignó diferentes niveles de importancia a cada criterio, reconociendo que no todos los factores inciden de igual manera en la decisión de adopción. Finalmente, combinando los puntajes numéricos y las ponderaciones, se calculó un puntaje global para cada aplicación, integrando en un solo valor su desempeño relativo dentro del modelo.

El universo analizado comprende un total de 30 aplicaciones, cada una evaluada bajo los mismos criterios y con la misma metodología, facilitando así la comparabilidad de los resultados. La construcción del Cuadro de Evaluación constituye la consolidación de todo este recorrido analítico, permitiendo visualizar de manera integrada la posición relativa de cada solución. A modo ilustrativo, se presenta a continuación un ejemplo reducido del Cuadro de Evaluación, en el que se incluyen algunas aplicaciones seleccionadas para mostrar la estructura general del análisis.

Aplicación	Madurez Digital Requerida	Dificultad de Implementación	Costo de Implementación	Impacto en el Negocio	Tiempo de Retorno	Puntaje Final
Chatbot para Atención al Cliente	BAJO (2)	BAJO (2)	BAJO (2)	MEDIO (1)	CORTO (2)	1,70
Predicción de Demanda	MEDIO (1)	MEDIO (1)	MEDIO (1)	MEDIO (1)	LARGO (0)	0,80
Conciliación Bancaria	MEDIO (1)	MEDIO (1)	MEDIO (1)	ALTO (2)	CORTO (2)	1,50

Con la construcción del Cuadro de Evaluación concluye el desarrollo metodológico del Mapa de Oportunidades. El proceso presentado permite calificar, ponderar y consolidar las distintas aplicaciones de inteligencia artificial de manera estructurada y comparativa, ofreciendo una base sólida para el análisis estratégico posterior. A partir del puntaje global obtenido para cada aplicación, es posible construir un ranking de prioridades, ordenando las soluciones desde las de mayor potencial de adopción hacia aquellas que presentan mayores barreras o dificultades.

El Cuadro de Evaluación no ofrece una respuesta automática, sino que constituye una herramienta de apoyo para la reflexión estratégica de cada empresa. A partir de esta matriz, cada organización puede analizar cuáles son las soluciones que mejor se alinean con su contexto particular, sus objetivos de negocio y su capacidad de implementación. El ranking de aplicaciones ofrece una primera aproximación al orden de prioridad, pero la decisión final sobre qué soluciones adoptar, en qué secuencia y bajo qué condiciones, depende de un análisis estratégico más profundo que debe considerar las dinámicas propias de cada empresa.

En el siguiente capítulo se presentará un caso práctico donde se ejemplificará la aplicación del modelo en una PyME concreta. Este ejercicio permitirá observar cómo se utiliza el Mapa de Oportunidades y el Cuadro de Evaluación como herramientas de apoyo para la toma de decisiones, aunque el análisis estratégico definitivo quedará reservado a cada situación empresarial particular.

CAPÍTULO 6: APLICACIÓN DEL MAPA EN UN CASO REAL

En el capítulo anterior, hemos analizado el impacto de la inteligencia artificial en las PYMEs y desarrollado un conjunto de 30 aplicaciones que pueden aportar valor en distintos sectores y procesos. Si bien no se trata de un listado exhaustivo, se buscó que fuera lo suficientemente abarcativo para reflejar el amplio espectro de soluciones que la IA puede ofrecer a las pequeñas y medianas empresas, considerando desde herramientas de automatización hasta modelos avanzados de predicción y personalización.

Con el propósito de evaluar estas aplicaciones de manera estructurada, se presentó el Mapa de Oportunidades, una herramienta metodológica diseñada para analizar la viabilidad y el impacto de cada solución en función del contexto específico de cada empresa. El mapa incorpora un Cuadro de Evaluación, en el que cada aplicación se evalúa desde 5 atributos definidos: la madurez digital requerida, la dificultad de implementación de la aplicación, el costo de implementación, el impacto en el negocio y el tiempo de retorno de inversión.

Cada atributo se clasifica en tres niveles (bajo, medio y alto), lo que permite diferenciar soluciones según su accesibilidad, su complejidad y su potencial de impacto. Aquí es importante destacar que la clasificación que recibe cada atributo depende por un lado de la aplicación puntual de IA que estamos tratando, pero también de la empresa concreta que estamos evaluando. Luego cada atributo recibe un puntaje numérico en función del nivel de clasificación determinado.

Posteriormente, estos valores son ponderados de acuerdo con la importancia relativa de cada atributo dentro del análisis. Por ejemplo, el impacto en el negocio tiene un peso mayor que la madurez digital requerida, ya que una solución que transforma significativamente la empresa es más prioritaria que otra cuya única barrera es la falta de digitalización. Finalmente, la suma ponderada de estos valores da como resultado un puntaje global para cada aplicación, lo que permite comparar soluciones de manera estructurada y priorizar aquellas con mayor potencial y menor dificultad de adopción.

Por esta razón, en esta sección se trabajará con un caso ilustrativo, donde una PYME con desafíos comerciales y operativos concretos aplicará el Mapa de Oportunidades para evaluar diferentes soluciones de IA. Dado que analizar la totalidad de las 30 aplicaciones resultaría extenso y poco práctico para los fines de la tesis, se seleccionarán cinco aplicaciones representativas que permitan demostrar la metodología en acción garantizando un análisis riguroso. Cada una será evaluada bajo los criterios establecidos en el Mapa de Oportunidades, mostrando cómo esta herramienta puede ser utilizada para tomar decisiones estratégicas informadas sobre la adopción de IA.

6.1 Presentación del Caso

Para ilustrar la aplicación del Mapa de Oportunidades, trabajaremos con un caso real de una librería familiar con varios años de trayectoria, que ha sabido adaptarse a los cambios del mercado incorporando herramientas digitales en su operación. A pesar de su evolución, el negocio enfrenta desafíos en la gestión de ventas y en su estrategia comercial, áreas donde la inteligencia artificial podría aportar mejoras significativas.

La librería es una empresa familiar con varias décadas de trayectoria en el sector comercial. Su historia y permanencia en el mercado le han permitido consolidarse como un negocio de referencia dentro de su comunidad, ofreciendo una amplia variedad de productos que incluyen artículos escolares, insumos de oficina, papelería y accesorios relacionados. A lo largo del tiempo, la empresa ha evolucionado para adaptarse a las nuevas demandas del mercado, incorporando herramientas de gestión y expandiendo su presencia a través de una tienda online.

El negocio maneja un catálogo extenso, con decenas de miles de SKUs, lo que implica una gestión compleja del inventario. Las compras de mercadería se realizan combinando información del ERP, que permite visualizar movimientos de stock e historial de ingresos de productos, con la experiencia y criterio de los dueños, quienes han sido los principales responsables de la toma de decisiones comerciales. Si bien los quiebres de stock no son un problema frecuente, sí ocurre que ciertos productos se acumulan sin rotación, generando costos innecesarios de almacenamiento.

La demanda presenta una marcada estacionalidad, con un fuerte pico de ventas al inicio del ciclo escolar, cuando la compra de listas de materiales escolares se convierte en el principal motor de facturación. Fuera de este período, las ventas son más estables y diversificadas, pero mantener el flujo de clientes y optimizar las promociones resulta un desafío clave para la rentabilidad del negocio.

Con el objetivo de expandir su alcance, la librería implementó una tienda online hace algunos años, la cual representa actualmente alrededor del 15% de las ventas totales. Sin embargo, no ha logrado aún explotar todo su potencial como canal de comercialización. Aunque permite a los clientes realizar compras y retirar en el local, no está integrada con el ERP para la gestión de stock en tiempo real, lo que limita su eficiencia operativa. Además, la empresa no ha desarrollado estrategias de captación digital, ya que la web se ha manejado más como un canal complementario que como un motor activo de ventas.

La interacción con los clientes se da principalmente en el local físico y a través de WhatsApp, redes sociales y correo electrónico. Si bien reciben muchas consultas por estos canales, no cuentan con herramientas que permitan automatizar respuestas ni hacer seguimiento a los clientes interesados. Tampoco tienen un CRM que registre el

historial de compras, aunque han podido construir una base de datos de clientes recurrentes, especialmente gracias a la venta de listas escolares.

En términos comerciales, la empresa realiza ajustes de precios de manera periódica, basándose en la inflación y en análisis manuales de costos y mercado. También ofrece descuentos y promociones, aunque estos se aplican de forma más generalizada, sin una segmentación inteligente basada en patrones de compra. La comunicación de estas promociones se realiza principalmente a través de cartelería en el local y publicaciones en Instagram, sin estrategias de marketing digital pagas ni automatización de campañas.

Desde el punto de vista tecnológico, la librería ha incorporado un ERP funcional para la gestión de stock y facturación, que permite obtener reportes sobre productos más vendidos y rotación de inventarios, pero no almacena datos de clientes ni está integrado con herramientas de marketing o automatización. No utilizan software externo para estrategias comerciales ni tienen experiencia en la implementación de inteligencia artificial en sus procesos.

A pesar de estas limitaciones, la empresa ha manifestado interés en ser más proactiva en la venta, invirtiendo en herramientas que permitan mejorar su conversión comercial. Sus principales áreas de oportunidad con IA se centran en ventas, promociones y captación de clientes, buscando optimizar la relación con sus compradores y aprovechar mejor la información que generan en sus distintos canales.

Para evaluar qué aplicaciones de IA pueden generar mayor impacto en este contexto, utilizaremos el Mapa de Oportunidades, aplicando su metodología de análisis. Dado que evaluar la totalidad de las 30 aplicaciones resultaría innecesario para los fines de este capítulo, se seleccionarán 5 soluciones representativas, garantizando un análisis riguroso y alineado con las necesidades concretas de la empresa.

6.2 Aplicación del Mapa de Oportunidades

Como mencionamos anteriormente, aplicaremos la metodología del Mapa de Oportunidades para evaluar distintas soluciones de inteligencia artificial en el contexto de la librería. Para este análisis, seleccionamos cinco aplicaciones provenientes del listado de 30 presentadas al inicio del capítulo, asegurando una muestra representativa de distintas posibilidades de adopción de IA. Algunas de estas aplicaciones demostrarán un alto potencial de impacto en el negocio, mientras que otras permitirán evidenciar por qué ciertas soluciones no resultan adecuadas para este caso.

Cada una de estas aplicaciones será evaluada en función de los cinco atributos definidos en el Cuadro de Evaluación, permitiendo una comparación objetiva y estructurada. A continuación, se presenta el análisis detallado de cada una de ellas.

1. Estrategias de fidelización y retención mediante detección de abandono - (Aplicada a la Tienda Online)

En la tienda online, la librería cuenta con un historial de compras por cliente, lo que permite aplicar inteligencia artificial para analizar patrones de comportamiento y detectar señales de abandono. Esta solución de IA puede identificar clientes que han dejado de comprar durante un período determinado y activar estrategias personalizadas para incentivar su regreso, como el envío de ofertas especiales, recordatorios o recomendaciones de productos basadas en su historial.

Evaluación de atributos y asignación de puntajes

Madurez Digital (BAJA - 2 Puntos): La tienda online ya cuenta con un registro de compras por cliente, lo que permite implementar esta solución sin necesidad de cambios estructurales en la digitalización del negocio. No se requiere desarrollar bases de datos adicionales ni incorporar herramientas complejas, ya que la información necesaria para detectar patrones de abandono está disponible dentro del sistema de comercio electrónico.

Dificultad de Implementación (MEDIA - 1 Punto): Aunque la IA puede analizar datos históricos de compra, la empresa debe definir qué criterios específicos indicarán que un cliente está en riesgo de abandono. Además, será necesario configurar un sistema de contacto automatizado, como correos electrónicos personalizados o mensajes en WhatsApp, para que la detección de abandono tenga un impacto real en la retención de clientes.

Costo de Implementación (BAJA - 2 Puntos): La empresa no necesita adquirir software adicional, ya que la tienda online almacena los datos requeridos y existen herramientas gratuitas o de bajo costo que pueden utilizarse para segmentar clientes y automatizar mensajes. Los costos estarán principalmente asociados a la configuración del sistema y a la generación de contenido para retención, lo que representa una inversión operativa moderada.

Impacto en el Negocio (MEDIA - 1 Punto): Si bien la mejora en la retención de clientes puede aumentar la recurrencia de compra y mejorar la rentabilidad, el impacto de esta solución es limitado porque la tienda online representa solo el 15% de las ventas totales. Aunque puede optimizar este canal, no tiene una influencia directa en el grueso de la facturación del negocio.

Tiempo de Retorno de Inversión (CORTO - 2 Puntos): Dado que la tienda online ya tiene los datos necesarios para que la IA detecte patrones de abandono, la empresa puede empezar a aplicar estrategias de retención casi de inmediato. Una vez configurado el sistema, los efectos pueden percibirse en pocos meses, ya que la automatización de

mensajes y la segmentación de clientes permiten intervenir rápidamente para recuperar compradores inactivos.

Cuadro de Evaluación:

Aplicación	Madurez Digital Requerida	Dificultad de Implementación	Costo de Implementación	Impacto en el Negocio	Tiempo de Retorno	Puntaje Final
Fidelización y Retención (Tienda Online)	BAJO (2)	MEDIO (1)	BAJO (2)	MEDIO (1)	CORTO (2)	1,55

La implementación de un sistema de detección de abandono mediante inteligencia artificial en la tienda online representa una oportunidad viable para la empresa con un puntaje global interesante de 1,55, aunque su impacto está limitado por el hecho de que este canal representa solo el 15% de las ventas totales.

2. Estrategias de fidelización y retención mediante detección de abandono - (Aplicada a la Tienda Física)

A diferencia de la tienda online, donde los clientes dejan un historial de compras registrado, en la tienda física la empresa no cuenta con un sistema que vincule las compras a clientes específicos, lo que dificulta la aplicación de una estrategia de detección de abandono basada en inteligencia artificial. Para que esta solución funcione correctamente, la empresa necesitaría implementar un sistema de fidelización o CRM que como mínimo permita registrar datos de compra asociados a cada cliente.

Evaluación de atributos y asignación de puntajes

Madurez Digital (ALTA - 0 Puntos): La empresa no cuenta con un CRM ni con un registro estructurado de clientes en la tienda física, lo que hace inviable la aplicación de esta solución en el corto plazo. Para que la IA pueda detectar patrones de abandono, sería necesario implementar un sistema de identificación de clientes al momento de la compra, lo que implica un cambio significativo en la operación actual del negocio.

Dificultad de Implementación (ALTA - 0 Puntos): Sin una base de datos de clientes en la tienda física, la implementación de esta solución requeriría una reestructuración operativa que incluya la identificación de compradores y la captura de datos en cada transacción. Además, sería necesario educar a los empleados y a los clientes sobre la importancia de registrarse para poder acceder a beneficios personalizados.

Costo de Implementación (ALTO - 0 Puntos): La empresa debería invertir en una plataforma de fidelización o CRM, integrarla con su ERP y diseñar una estrategia para incentivar el registro de clientes. Estos costos son significativos y no generan un beneficio

inmediato, ya que la efectividad de la IA dependerá de la cantidad de datos recopilados a lo largo del tiempo.

Impacto en el Negocio (MEDIO - 1 Punto): Si se lograra implementar un sistema de fidelización y la IA pudiera detectar clientes en riesgo de abandono, la empresa podría aumentar la recurrencia de compra y mejorar la retención. Sin embargo, el impacto sería progresivo y dependería de qué porcentaje de los clientes accede a registrarse y compartir sus datos de compra.

Tiempo de Retorno de Inversión (LARGO - 0 Puntos): La implementación de esta solución requeriría primero establecer un sistema de recolección de datos y, solo después de haber acumulado suficiente información, la IA podría comenzar a generar predicciones precisas. Este proceso tomaría meses o incluso años antes de generar un impacto medible en las ventas.

Cuadro de Evaluación:

Aplicación	Madurez Digital Requerida	Dificultad de Implementación	Costo de Implementación	Impacto en el Negocio	Tiempo de Retorno	Puntaje Final
Fidelización y Retención (Tienda Física)	ALTO (0)	ALTO (0)	ALTO (0)	MEDIO (1)	LARGO (0)	0,30

Con un puntaje de 0,30, la aplicación de inteligencia artificial para la detección de abandono en la tienda física no es viable en su estado actual, ya que la empresa no cuenta con un sistema de registro de clientes ni con la infraestructura necesaria para recopilar y analizar datos de compra. La implementación de esta solución requeriría primero la incorporación de un CRM o un sistema de fidelización.

3. Atención al cliente con chatbots conversacionales 24/7

La librería recibe consultas de clientes a través de varios canales digitales, incluyendo WhatsApp, redes sociales y correo electrónico. Actualmente, estas interacciones requieren intervención manual, lo que puede generar demoras en las respuestas y una carga operativa significativa para el equipo. La implementación de un chatbot conversacional con inteligencia artificial permitiría automatizar la atención al cliente, ofreciendo respuestas rápidas y precisas a preguntas frecuentes sobre disponibilidad de productos, horarios, métodos de pago y promociones.

Evaluación de atributos y asignación de puntajes:

Madurez Digital (BAJA - 2 Puntos): La empresa ya opera con canales digitales como WhatsApp e Instagram, por lo que la implementación de un chatbot no requiere cambios estructurales en su digitalización. No es necesario desarrollar infraestructura adicional,

ya que existen herramientas accesibles que permiten automatizar respuestas sin una integración compleja.

Dificultad de Implementación (MEDIA - 1 Punto): Si bien la instalación de un chatbot en WhatsApp o redes sociales es relativamente sencilla, la empresa deberá configurar correctamente las respuestas automatizadas para garantizar que la IA interprete correctamente las consultas. Además, se necesita establecer criterios de escalamiento para que los casos más complejos sean derivados a una persona real cuando sea necesario.

Costo de Implementación (BAJA - 2 Puntos): Existen soluciones gratuitas o de bajo costo para la automatización de mensajes en WhatsApp y redes sociales. Herramientas como ManyChat o WhatsApp Business API permiten configurar flujos de conversación sin necesidad de una inversión significativa. La mayor inversión podría estar en la personalización del chatbot y en el mantenimiento de su base de conocimientos.

Impacto en el Negocio (ALTO - 2 Puntos): Automatizar la atención al cliente reduciría significativamente el tiempo de respuesta y la carga operativa del equipo. Además, permitiría gestionar consultas fuera del horario comercial, mejorando la experiencia del cliente y potencialmente aumentando la conversión de ventas.

Tiempo de Retorno de Inversión (CORTO - 2 Puntos): La implementación de un chatbot puede generar beneficios inmediatos, ya que los clientes recibirían respuestas automáticas desde el primer día. Dado que no se requiere una fase prolongada de recolección de datos ni entrenamiento, el impacto puede percibirse en pocas semanas.

Cuadro de Evaluación:

Aplicación	Madurez Digital Requerida	Dificultad de Implementación	Costo de Implementación	Impacto en el Negocio	Tiempo de Retorno	Puntaje Final
Chatbot Atención al Cliente 24/7	BAJO (2)	MEDIO (1)	BAJO (2)	ALTO (2)	CORTO (2)	1,85

La implementación de un chatbot conversacional representa una solución altamente viable y recomendable para la librería, con un puntaje global de 1,85. La empresa ya cuenta con los canales digitales necesarios para implementar la automatización de respuestas sin requerir cambios estructurales en su infraestructura digital.

4. Creación automática de contenido para redes sociales

La librería actualmente mantiene una presencia en redes sociales, pero la generación de contenido es manual y depende de los recursos internos disponibles. Publicar de manera constante y con mensajes adaptados a cada plataforma puede ser un desafío, lo que

limita la frecuencia y el impacto de la comunicación. La implementación de inteligencia artificial permitiría automatizar la creación de imágenes, textos y videos optimizados para redes sociales, asegurando mayor coherencia y relevancia sin una intervención manual constante.

Evaluación de atributos y asignación de puntajes:

Madurez Digital (BAJO - 2): La empresa ya utiliza redes sociales para la comunicación con sus clientes, por lo que la implementación de IA para la generación automática de contenido no requiere una transformación digital significativa. No es necesario desarrollar infraestructura adicional, ya que la IA puede integrarse fácilmente con herramientas de gestión de redes.

Dificultad de Implementación (BAJO - 2): Existen múltiples herramientas accesibles que permiten generar contenido con IA sin requerir conocimientos técnicos avanzados. La implementación consiste en seleccionar una plataforma adecuada, definir parámetros de contenido y automatizar publicaciones según un calendario estratégico.

Costo de Implementación (BAJO - 2): Muchas soluciones de IA para la generación de contenido ofrecen versiones gratuitas o modelos de suscripción accesibles. La empresa no necesita invertir en hardware ni en desarrollos personalizados, por lo que la inversión es mínima en comparación con otras soluciones de IA.

Impacto en el Negocio (MEDIO - 1): Mejorar la presencia en redes sociales puede fortalecer la captación de clientes y aumentar la visibilidad de la empresa, pero su impacto en las ventas no es inmediato ni directamente medible. Aunque una estrategia de contenido optimizada puede generar mayor interacción y reconocimiento de marca, no garantiza un aumento directo en la facturación.

Tiempo de Retorno de Inversión (CORTO - 2): La implementación de la IA es rápida y los beneficios pueden percibirse en poco tiempo. Al reducir la carga de trabajo en la generación de contenido, la empresa puede mantener una presencia activa en redes sin esfuerzo adicional. Si bien el impacto en ventas es indirecto, la mejora en la comunicación con los clientes es inmediata.

Cuadro de Evaluación:

Aplicación	Madurez Digital Requerida	Dificultad de Implementación	Costo de Implementación	Impacto en el Negocio	Tiempo de Retorno	Puntaje Final
Creación de Contenido	BAJO (2)	BAJO (2)	BAJO (2)	MEDIO (1)	CORTO (2)	1,70

La implementación de herramientas de IA para la creación automática de contenido en redes sociales es una solución altamente viable y recomendable para la librería, con un puntaje global de 1.70. La empresa puede generar publicaciones de manera eficiente sin

una gran inversión y sin requerir una alta madurez digital o complejidad en la implementación.

5. Gestión dinámica de inventarios

La librería maneja un amplio catálogo de productos con miles de SKUs, lo que hace que la administración del inventario sea un desafío clave. Actualmente, los pedidos a proveedores se realizan combinando datos del ERP con la experiencia de los dueños, sin herramientas avanzadas que permitan ajustar dinámicamente los niveles de stock en función de la demanda, la estacionalidad o los tiempos de reposición. La implementación de inteligencia artificial permitiría optimizar el inventario, reduciendo el riesgo de quiebres y evitando la acumulación excesiva de productos de baja rotación.

Evaluación de atributos y asignación de puntajes:

Madurez Digital (MEDIA - 1): La empresa cuenta con un ERP que permite visualizar el historial de movimientos de stock y fechas de ingreso de productos, lo que facilita la integración de IA para la optimización de inventarios. Sin embargo, actualmente el sistema no está configurado para generar pronósticos automatizados, por lo que sería necesario estructurar mejor los datos y definir criterios para ajustar los niveles de stock dinámicamente.

Dificultad de Implementación (MEDIA - 1): Si bien existen herramientas accesibles para aplicar modelos de IA en la gestión de inventarios, la empresa deberá definir reglas específicas para la reposición y establecer integraciones con su ERP. La dificultad radica en la necesidad de ajustar parámetros operativos y garantizar que las recomendaciones de la IA sean interpretadas y aplicadas correctamente en la toma de decisiones.

Costo de Implementación (MEDIA - 1): No se requiere una inversión en hardware ni en recolección manual de datos, ya que la empresa ya cuenta con un ERP funcional. Sin embargo, integrar modelos de predicción de inventario implicará costos de configuración y posiblemente la contratación de herramientas externas, lo que justifica su clasificación en un nivel medio de inversión.

Impacto en el Negocio (ALTO - 2): La optimización del inventario puede generar beneficios significativos en la reducción de costos operativos y en la mejora de la disponibilidad de productos clave. Al evitar sobrestocks y ajustar la compra de productos con base en la demanda real, la empresa puede mejorar su rentabilidad y reducir pérdidas por acumulación innecesaria de productos de baja rotación.

Tiempo de Retorno de Inversión (MEDIO - 1): Si bien los ajustes en la gestión del inventario pueden generar beneficios en el mediano plazo, la empresa necesitará monitorear los resultados y ajustar progresivamente los parámetros del modelo de IA. Dependiendo de la complejidad del sistema implementado, el impacto financiero positivo puede tardar varios meses en consolidarse.

Cuadro de Evaluación:

Aplicación	Madurez Digital Requerida	Dificultad de Implementación	Costo de Implementación	Impacto en el Negocio	Tiempo de Retorno	Puntaje Final
Gestión de Inventarios	MEDIA (1)	MEDIA (1)	MEDIA (1)	ALTO (2)	MEDIO (1)	1,30

Con un puntaje de 1.3, la implementación de inteligencia artificial para la gestión dinámica de inventarios no revela una conveniencia significativamente alta, ya que implica ciertos desafíos operativos y de integración con el ERP. La relevancia de esta solución dependerá en gran medida de la gravedad de los sobrestocks que tenga la librería. Si el exceso de inventario representa un problema financiero considerable, optimizar la gestión de stock con IA puede ser una inversión estratégica. Sin embargo, si los niveles de sobrestock son manejables, la empresa podría optar por ajustes más simples antes de considerar una solución basada en inteligencia artificial.

6.3 Conclusiones del Caso

El análisis del caso de la librería familiar mediante el Mapa de Oportunidades permitió evaluar distintas soluciones de inteligencia artificial en función de su viabilidad e impacto potencial en el negocio. El Mapa fue construido a partir de un conjunto de 30 aplicaciones propuestas, abarcando áreas clave como marketing, ventas, atención al cliente, producción, calidad, administración y finanzas. Sin embargo, es importante recordar que este conjunto no representa un listado exhaustivo, ya que la inteligencia artificial está en continua evolución y existen múltiples herramientas que pueden tener relevancia según el contexto particular de cada PyME. Además, algunas empresas con características específicas pueden requerir aplicaciones de IA personalizadas, diseñadas para abordar problemas únicos o muy particulares, como por ejemplo una bodega boutique que utilice modelos de IA para análisis de calidad del suelo y predicción de cosechas, considerando variables climáticas y patrones históricos específicos de la región.

Para ilustrar la metodología de evaluación, seleccionamos cinco aplicaciones representativas que permiten ejemplificar cómo se aplica el Mapa en la práctica. No obstante, para una implementación completa se debería considerar la evaluación de todas las aplicaciones planteadas. El objetivo de esta selección es demostrar el potencial de la herramienta metodológica para orientar decisiones estratégicas sobre la adopción de IA en entornos PyME.

6.3.1 Síntesis de Resultados

El análisis mostró que, para este caso, las soluciones con mayor viabilidad y menor dificultad de implementación fueron el chatbot conversacional para atención al cliente y la generación automática de contenido para redes sociales. Ambas propuestas destacan por su bajo costo de implementación, su rápida puesta en marcha y el impacto directo en la mejora de la experiencia del cliente y la eficiencia operativa. Además, su retorno de inversión es prácticamente inmediato, ya que permiten gestionar consultas frecuentes y mantener una presencia digital activa sin necesidad de intervención constante por parte del equipo.

En contraste, se identificaron aplicaciones con mayores desafíos operativos y de implementación, como la gestión dinámica de inventarios y las estrategias de fidelización en tienda física. La complejidad radica en la falta de digitalización previa y en la necesidad de integrar soluciones avanzadas con sistemas ERP o CRM que la empresa aún no ha incorporado. Esto hace que el retorno de inversión sea incierto y el esfuerzo requerido para su adopción, considerable.

Un caso particularmente ilustrativo es el de la fidelización mediante detección de abandono, que resulta altamente efectiva en la tienda online, donde ya existen registros históricos de compras y una base de datos de clientes identificados. En este contexto, la IA permite identificar usuarios inactivos y activar estrategias personalizadas de retención mediante mensajes automatizados, mejorando la recurrencia de compras. Sin embargo, al intentar aplicar la misma solución en la tienda física, el resultado es completamente distinto. La falta de un sistema de fidelización o CRM hace que no exista un registro estructurado de clientes, lo que imposibilita detectar señales de abandono. Esto demuestra que la adopción de IA debe considerar el contexto específico de cada entorno, ya que la misma tecnología puede ofrecer grandes beneficios en un canal digital y no tener impacto en un entorno físico sin la estructura necesaria.

El Mapa de Oportunidades permitió estructurar este análisis de manera integral, proporcionando una herramienta útil para identificar soluciones viables y valorar su impacto antes de tomar decisiones de implementación. Esta metodología promueve un enfoque reflexivo y estratégico que evita inversiones innecesarias o proyectos que pueden no generar el retorno esperado. Además, evidencia que no todas las soluciones de IA son igualmente efectivas en todos los contextos, ya que una herramienta que ofrece grandes resultados en un entorno digital puede tener una aplicación limitada en un entorno físico si no cuenta con la infraestructura adecuada. Por lo tanto, el proceso de selección debe ser flexible y adaptarse a la realidad operativa de cada empresa, evitando la adopción indiscriminada de tecnologías que, aunque prometedoras, pueden no alinearse con la capacidad tecnológica o financiera actual.

6.3.2 Recomendaciones para la Adopción

Dada la naturaleza operativa de la librería y el estado actual de su digitalización, se recomienda comenzar con soluciones que ofrezcan rápido retorno de inversión y bajo costo de implementación. Esto incluye la automatización de respuestas a clientes mediante chatbots y la generación de contenido para redes sociales, lo que permitirá fortalecer la comunicación y reducir la carga operativa de atención.

En una segunda fase, y tras consolidar estas primeras implementaciones, la empresa podría considerar avanzar hacia proyectos de mayor envergadura como la gestión dinámica de inventarios, previa evaluación de la capacidad de integración con el ERP existente y la capacitación del equipo para utilizar la nueva tecnología de manera eficiente.

En cuanto a la fidelización en tienda física, sería recomendable implementar primero un sistema de identificación de clientes que permita crear una base de datos estructurada. Solo entonces podría considerarse una estrategia de detección de abandono que aproveche esta información, logrando un mayor impacto en la retención de compradores habituales.

CAPÍTULO 7: APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LAS EMPRESAS

7.1 Introducción y Propósito

Con el objetivo de validar y complementar los análisis realizados a lo largo de esta tesis, se llevó a cabo un estudio de campo dirigido a dueños, socios y ejecutivos de pequeñas y medianas empresas (PYMES) en Argentina. A través de una encuesta estructurada, se buscó comprender las percepciones actuales sobre la adopción de inteligencia artificial (IA) en sus organizaciones, identificar las principales oportunidades y barreras detectadas, y evaluar el nivel real de conocimiento y madurez digital.

A lo largo de los distintos capítulos, hemos visto que ciertas características estructurales propias del mundo pyme impactan de manera profunda en su forma de pensar y de decidir frente a la incorporación de nuevas tecnologías. Basta observar, por ejemplo, la diferencia de recursos que las separa de las grandes corporaciones: mientras estas últimas pueden funcionar como verdaderos laboratorios de innovación, impulsadas por grandes presupuestos y una alta tolerancia al riesgo, las pymes deben administrar sus recursos con mucha mayor prudencia. La inversión en nuevas tecnologías, en su caso, no puede estar basada en promesas de largo plazo ni en apuestas inciertas, sino que debe mostrar un retorno concreto y razonablemente previsible. Esta diferencia estructural explica en parte su tendencia a adoptar tecnologías en fases más avanzadas de maduración, cuando los riesgos son menores y los beneficios más tangibles.

Sin embargo, también hemos visto que las pymes cuentan con ventajas competitivas propias que las grandes estructuras corporativas no pueden igualar fácilmente. Su alta flexibilidad, su menor rigidez organizativa y su capacidad para tomar decisiones rápidas representan fortalezas clave en un entorno de cambio acelerado como el que plantea la inteligencia artificial. Este rasgo distintivo ofrece una oportunidad estratégica importante: si logran superar sus limitaciones de conocimiento y de recursos, las pymes pueden adoptar tecnologías emergentes con una agilidad que muchos grandes jugadores no tienen. ¿Están las pymes realmente en condiciones de capitalizar esa ventaja? ¿Lograrán traducir su flexibilidad en acciones concretas frente a una tecnología disruptiva como la IA? ¿Qué obstáculos siguen limitando esa capacidad de reacción? ¿Y qué factores podrían acelerar o frenar su adopción efectiva en el corto plazo?

Otro aspecto recurrente que se ha planteado a lo largo de esta tesis es que las pymes no suelen buscar la innovación por sí misma, sino como respuesta a problemas concretos que requieren soluciones claras y accesibles. La falta de equipos especializados, de estructuras de datos organizadas y de conocimiento técnico profundo constituye un obstáculo real, pero también define la forma en que estas empresas evalúan y priorizan sus decisiones de inversión tecnológica. ¿En qué medida estas limitaciones condicionan hoy su capacidad de incorporar inteligencia artificial? ¿Son capaces de visualizar

aplicaciones concretas que respondan a sus necesidades reales? ¿O la falta de recursos técnicos y estructurales sigue actuando como una barrera difícil de superar?

Las pymes, absorbidas por la gestión cotidiana, tienden a privilegiar las urgencias operativas sobre las decisiones estratégicas. Esta dinámica, centrada en la resolución del día a día, no solo limita la posibilidad de pensar en transformaciones de fondo, sino que también restringe el acceso a información actualizada sobre tecnologías emergentes como la inteligencia artificial. ¿Hasta qué punto el foco operativo permanente dificulta la identificación de nuevas oportunidades tecnológicas? ¿Cómo impacta esta falta de actualización en la capacidad de las pymes para anticiparse a los cambios del entorno competitivo? ¿Qué nivel de conocimiento tienen las pymes sobre la inteligencia artificial?

Este estudio de campo tiene por propósito contrastar estas observaciones teóricas con la realidad concreta que atraviesan las pymes en su proceso de incorporación de nuevas tecnologías. La encuesta busca validar hasta qué punto estas características condicionan hoy la forma en que perciben, valoran y proyectan la adopción de inteligencia artificial dentro de sus modelos de negocio.

7.2 Metodología de la Encuesta

El relevamiento de datos se realizó mediante una encuesta anónima, diseñada específicamente para dueños, socios y ejecutivos de pequeñas y medianas empresas argentinas. El cuestionario fue implementado a través de un formulario de Google y distribuido utilizando grupos de WhatsApp relevantes para el segmento objetivo, y se realizó entre Febrero y Marzo del 2025.

Se recibieron un total de 78 respuestas completas, todas correspondientes a perfiles de decisión dentro de empresas PYMEs.

La encuesta estuvo compuesta por diecisiete preguntas, de las cuales dieciséis fueron de opción múltiple y una de respuesta abierta. Algunas de las preguntas permitieron seleccionar más de una respuesta, mientras que otras requerían elegir una única opción. El cuestionario abarcó desde la caracterización básica de los encuestados y sus empresas, pasando por el nivel de digitalización y el uso de tecnologías, hasta percepciones específicas sobre el conocimiento, las barreras, las oportunidades y la disposición futura en relación con la adopción de inteligencia artificial.

El diseño de la encuesta priorizó la eficiencia en el tiempo de respuesta, estructurando la mayoría de las preguntas en formato de opción múltiple. Esta estrategia buscó minimizar la carga cognitiva de los encuestados, facilitar la participación y maximizar la tasa de respuesta. Solo una pregunta final se planteó en formato abierto, permitiendo a los participantes compartir ideas o reflexiones adicionales sobre el uso de la inteligencia artificial en sus organizaciones.

La encuesta abordó temas como el perfil de los encuestados y de sus empresas, el nivel de digitalización, el conocimiento y uso de herramientas de inteligencia artificial, las áreas de negocio donde perciben mayor potencial de impacto, las principales barreras de adopción, y las oportunidades futuras que vislumbran asociadas a la IA.

7.3 Resultados Obtenidos

7.3.1 Perfil de los Encuestados

El primer bloque de la encuesta estuvo orientado a relevar información básica sobre los encuestados y sus empresas. Compuesto por las primeras 6 preguntas, se consultó sobre la función o rol que desempeña el encuestado dentro de la empresa, datos personales (género y generación), e información propia de la empresa (sector de actividad, rango de facturación anual y la cantidad de empleados).

Tal como fue distribuida, la encuesta contó mayoritariamente con perfiles de alta responsabilidad en las pymes entrevistadas. De los 78 encuestados, el 65% fueron dueños o socios (51 casos), el 10% CEOs (8 casos), el 12% directores de Comercial, Marketing y Finanzas (9 casos) y el 13% restante (10 casos) corresponde a funciones de gerentes operativos, jefes de área y otros. La alta participación de dueños, socios y CEOs garantiza que los resultados reflejen una mirada estratégica y de toma de decisiones dentro de la muestra de empresas participantes.

Se relevaron características propias de los entrevistados en términos de género y edad, buscando contextualizar el perfil de quienes participaron en el estudio. Respecto al género, el 72% de los encuestados se identificó como masculino y el 28% como femenino, mostrando un claro predominio masculino en las posiciones de conducción dentro de las pymes relevadas. En cuanto a la edad, se utilizó una segmentación por generaciones para ordenar los perfiles. El 56% de los participantes corresponde a la Generación X (nacidos entre 1965 y 1981), el 31% a los Millennials o Generación Y (nacidos entre 1982 y 1994), el 12% a los Baby Boomers (nacidos entre 1945 y 1964) y el 1% a la Generación Z o Centennials (nacidos entre 1995 y 2009). Si bien más de la mitad de los entrevistados pertenecen a la Generación X, con edades de entre 44 y 60 años, ya comienzan a incorporarse nuevas generaciones al frente de las empresas, quienes probablemente aporten una mayor apertura hacia la innovación tecnológica y una aceleración en los procesos de transformación digital.

Respecto al sector de actividad, la muestra relevada presenta una fuerte concentración en empresas de servicios y comercio, que en conjunto representan aproximadamente el 60% del total de casos relevados. Este patrón resulta consistente con lo observado en el Capítulo 2, donde se destacó que más del 70% de las pymes argentinas se categorizan dentro de los rubros de servicios y comercio, con leves variaciones según el tamaño de la empresa. Más allá de esta concentración, la encuesta también captó una diversidad significativa de sectores como industria, construcción, agroindustria, logística, turismo y

salud, lo que aporta una visión amplia sobre los distintos perfiles de adopción tecnológica dentro del ecosistema pyme.

En el Capítulo 2 mostramos que, de acuerdo con las estadísticas oficiales, más del 80% de las pymes nacionales son microempresas, con facturaciones anuales de hasta 500.000 dólares. Por el contrario, en esta encuesta la participación de microempresas fue menor y se observó una distribución más equilibrada entre distintos niveles de facturación. Sólo el 16% de los encuestados declaró ingresos anuales entre 100.000 y 500.000 dólares, segmento que corresponde al universo tradicional de microempresas. En niveles superiores, el 22% reportó ingresos de entre 1 y 3 millones de dólares, y el 21% declaró facturar más de 10 millones. Esta composición más diversa permite captar percepciones no solo de microempresas tradicionales, sino también de organizaciones con mayores capacidades operativas y un potencial más elevado de adopción tecnológica, enriqueciendo así el análisis de oportunidades y desafíos en torno a la inteligencia artificial.

Los datos relevados sobre la cantidad de empleados también indican una participación más equilibrada entre diferentes tamaños de empresa. El 37% de los encuestados indicó tener menos de 10 empleados, el 31% se ubicó en el rango de entre 10 y 49 empleados, el 6% entre 50 y 99 empleados, el 6% entre 100 y 199 empleados, y el 15% reportó más de 200 empleados. Esta distribución también muestra que, si bien el universo relevado incluye microempresas, su participación no es mayoritaria, y existe una representación significativa de pequeñas y medianas empresas de mayor escala. Al igual que en los datos de facturación, esta diversidad en el tamaño organizacional enriquece el análisis posterior, permitiendo interpretar percepciones desde distintos niveles de complejidad operativa y capacidad de adopción tecnológica.

7.3.2 Nivel de Digitalización

El segundo bloque estuvo compuesto por 2 preguntas y buscó medir el nivel de digitalización de las empresas desde dos perspectivas complementarias. La primera pregunta apuntó a relevar de manera concreta qué herramientas digitales forman parte de los procesos de negocio de cada empresa, como indicador objetivo de su grado de digitalización. La segunda, en cambio, exploró la percepción subjetiva del encuestado sobre el nivel general de digitalización alcanzado en su organización.

Para el relevamiento de las herramientas se utilizaron las siguientes opciones, permitiendo seleccionar todas aquellas que aplicaran:


1. Herramientas básicas de oficina (correo electrónico corporativo, sitio web, Microsoft Office).
2. Software de gestión contable (sistemas de contabilidad y facturación).
3. Software de gestión empresarial (ERP, CRM).
4. Marketing digital y redes sociales.

5. Plataformas de e-commerce (tienda online o marketplaces).
6. Herramientas de trabajo colaborativo (Teams, Zoom, Meet).
7. Sistemas en la nube (almacenamiento o servicios de cloud computing).
8. Soluciones de análisis de datos y business intelligence (como Power BI o Tableau).
9. Otra.

El gráfico siguiente muestra el resultado de las encuestas:

7.- ¿Qué herramientas digitales utiliza tu empresa como parte de sus procesos de negocio?
(Selecciona todas las que correspondan)

78 respuestas



Tal como era de esperar, una amplia mayoría de las empresas encuestadas declaró utilizar herramientas básicas de oficina, como correo electrónico corporativo, sitio web y software de productividad, alcanzando un nivel de adopción cercano al 92%. Aunque en menor medida, también se registra una presencia importante de sistemas administrativos-contables, utilizados por aproximadamente el 70% de los encuestados, lo que refleja que las funciones básicas de facturación y registro financiero han sido ampliamente digitalizadas en el ecosistema pyme.

Un dato significativo que surge del relevamiento es que apenas el 32% de los encuestados indicó utilizar un sistema de gestión empresarial (CRM o ERP), lo cual evidencia que la digitalización de procesos integrados de negocio aún no ha alcanzado un nivel de adopción masivo entre las pymes.

Por otra parte, resulta destacable la alta adopción de herramientas en la nube y de trabajo colaborativo, utilizadas por alrededor del 65% de las empresas, un fenómeno que puede atribuirse en parte a los cambios de paradigma impulsados por la pandemia de COVID-19, que aceleró la necesidad de trabajo remoto y flexibilidad operativa.

Finalmente, el aspecto más llamativo es el bajo nivel de uso de soluciones de análisis de datos y business intelligence, reportado por apenas un 26% de los encuestados. Este

dato sugiere que, si bien las empresas avanzaron en digitalizar operaciones básicas y herramientas de comunicación, todavía existe una brecha considerable en el aprovechamiento estratégico de los datos como activo clave para la toma de decisiones y el crecimiento.

La segunda pregunta del bloque buscó relevar cuál es el nivel de percepción que tienen los encuestados sobre el grado de digitalización y utilización de herramientas tecnológicas en sus empresas, ofreciéndoles cinco opciones de respuesta: "Muy bajo", "Bajo", "Medio", "Alto" y "Muy alto". Este planteo permite contrastar la percepción interna de las organizaciones con el nivel real de adopción tecnológica relevado en la primera pregunta, y analizar el grado de coherencia entre ambos resultados.

Se observa que un 16% de los encuestados percibe que su empresa tiene un nivel de digitalización bajo o muy bajo, mientras que un 49% piensa en un nivel medio y un 35% en niveles alto y muy alto. Esta distribución valida en buena medida los resultados obtenidos en la primera pregunta del bloque: la mayoría de las empresas ha incorporado herramientas digitales básicas y algunas soluciones más avanzadas, pero aún persiste un margen importante para evolucionar hacia esquemas de digitalización más integrados y estratégicos. La fuerte concentración de respuestas en el nivel medio refleja una percepción realista respecto al estado actual de la transformación digital en el universo pyme relevado.

7.3.3 Conocimiento y uso personal de IA

Este bloque de la encuesta estuvo orientado a relevar el nivel de conocimiento y de uso personal de herramientas de inteligencia artificial por parte de los encuestados. El objetivo fue comprender cómo la familiaridad individual con la tecnología, tanto a nivel conceptual como práctico, podría influir en su capacidad para extrapolar decisiones relacionadas con la adopción de IA en el ámbito empresarial. Para ello, se plantearon tres preguntas específicas:

- ✓ ¿Cómo calificarías tu conocimiento sobre inteligencia artificial?
- ✓ ¿Utilizas ChatGPT u otra herramienta de IA en tu vida cotidiana?
- ✓ ¿De dónde obtienes información sobre IA?

Las preguntas fueron diseñadas para capturar tanto el nivel de comprensión que los tomadores de decisión tienen sobre los conceptos de IA, como sus experiencias prácticas de uso y las fuentes a través de las cuales acceden a información sobre esta tecnología.

Los resultados muestran que un 58% de los encuestados se autodefine con un nivel de conocimiento "Bajo" sobre inteligencia artificial, mientras que un 32% se ubica en un nivel "Medio". Apenas un 7% considera que posee un conocimiento "Alto", y un 3% declara no estar seguro respecto a su nivel de conocimiento. Esta distribución refleja

una brecha importante entre el interés creciente por la IA y la comprensión real de sus fundamentos técnicos y aplicaciones estratégicas.

Como se analizó en el Capítulo 2, particularmente en la sección sobre el rol del liderazgo, esta brecha no es solo un desafío técnico, sino un factor estratégico que puede condicionar el proceso de transformación digital en las pymes. El bajo nivel de conocimiento de los propios dueños, socios y ejecutivos limita su capacidad de visualizar las oportunidades que la IA podría aportar a sus negocios, retrasando la adopción de soluciones tecnológicas más avanzadas.

Dado que la visión estratégica de los líderes es uno de los principales motores para la incorporación de tecnología, el hecho de que más de la mitad de los encuestados reconozca limitaciones en su comprensión de la IA refuerza la necesidad de iniciativas que no solo promuevan la accesibilidad tecnológica, sino también la capacitación y sensibilización de los niveles directivos sobre el valor estratégico de estas herramientas.

A pesar de las limitaciones en el conocimiento declarado sobre inteligencia artificial, el alto porcentaje de uso cotidiano de herramientas como ChatGPT entre los encuestados ofrece una señal alentadora. Ante la pregunta sobre su utilización personal de herramientas de IA, el 37% de los participantes indicó que las usa de manera regular, un 32% señaló que las utiliza ocasionalmente, un 26% manifestó no utilizarlas pero mostró interés en aprender más, y sólo un 5% declaró no usarlas o no conocerlas.

En conjunto, estos datos muestran que cerca del 70% de los encuestados tiene experiencias habituales u ocasionales con la IA. Esta familiaridad práctica, enfocada principalmente en herramientas accesibles, demuestra que la inteligencia artificial ya forma parte de la vida cotidiana de muchos líderes pyme. Esta base cultural y operativa constituye un terreno fértil para que, con la capacitación y la estrategia adecuadas, las empresas puedan evolucionar hacia una adopción más profunda y alineada con sus objetivos de negocio.

Otro dato positivo es que los resultados muestran un interés genuino de los encuestados por acceder a contenidos de IA desde diversos medios. El 68% se informa a través de noticias y artículos en línea, el 60% utiliza redes sociales, el 41% recurre a recomendaciones de colegas, el 24% ha participado en cursos o capacitaciones formales, y apenas el 9% obtiene información a través de proveedores de tecnología.

Esta diversidad de canales refleja que existe una búsqueda activa de conocimiento sobre IA dentro del ecosistema pyme, aunque predominantemente apoyada en fuentes informales o de fácil acceso. Esto representa una oportunidad concreta para complementar el interés existente mediante propuestas de formación más estructuradas y especializadas, capaces de ofrecer un enfoque más profundo, estratégico y orientado a las necesidades reales de las empresas.

7.3.4 Percepciones Empresariales sobre la Inteligencia Artificial

Finalmente, el cuarto bloque del relevamiento estuvo orientado a captar las percepciones específicas de los empresarios y directivos respecto al impacto potencial de la inteligencia artificial en sus organizaciones. A través de cinco preguntas, se buscó relevar en qué procesos consideran que la IA podría aportar mayor valor, cuál es su percepción sobre la adopción futura de estas tecnologías, qué barreras identifican como principales obstáculos para su implementación, qué oportunidades visualizan a mediano plazo, y cuál es su disposición a invertir en soluciones de IA en el corto plazo.

Estas preguntas permiten comprender no sólo el nivel de conocimiento o uso actual de la IA, sino también la actitud estratégica que las empresas muestran frente a su posible incorporación en sus modelos de negocio.

Las preguntas formuladas en este bloque fueron las siguientes:

- ✓ ¿En qué procesos de tu empresa crees que la inteligencia artificial podría generar mayor impacto o valor?
- ✓ ¿Cómo percibes la incorporación de la inteligencia artificial en tu empresa en el futuro cercano?
- ✓ ¿Cuáles consideras que son los principales desafíos o barreras para implementar IA en tu empresa?
- ✓ ¿Qué oportunidades crees que la inteligencia artificial generará para tu empresa en los próximos 5 años?
- ✓ ¿Estarías dispuesto a invertir en soluciones de IA para tu empresa en los próximos 12 meses?

A diferencia de los bloques anteriores vamos a revisar los resultados de estas 5 preguntas de manera individual, dada la relevancia que tienen en cuanto a las aplicaciones de IA para las empresas.


7.3.4.1 Procesos de mayor impacto de IA

En este bloque se buscó relevar cuáles son las áreas o procesos internos en que las pymes visualizan mayor potencial de impacto mediante la incorporación de soluciones basadas en inteligencia artificial. Esta pregunta resulta clave para comprender no solo el nivel de conocimiento sobre las aplicaciones prácticas de la IA, sino también para identificar cuáles son las prioridades estratégicas percibidas por los líderes empresariales a la hora de pensar en su adopción.

Para ello, se ofrecieron múltiples opciones de respuesta que reflejan el amplio espectro de aplicaciones prácticas de inteligencia artificial, en sintonía con las presentadas en el Mapa de Oportunidades del Capítulo 4. Las alternativas contemplan procesos vinculados

a la generación y crecimiento de ventas, la captación y retención de clientes, la optimización de precios y promociones, la automatización de tareas administrativas, la gestión de compras y proveedores, la gestión financiera, el análisis de datos de recursos humanos, y la mejora de operaciones y producción, entre otros aspectos críticos de la gestión empresarial.

Los resultados obtenidos en la encuesta se muestran en el siguiente gráfico



Los resultados muestran una marcada concentración en torno a la automatización de procesos administrativos, señalada por casi el 75% de los encuestados. Este dato refleja la fuerte prioridad que las pymes otorgan a la mejora de la eficiencia operativa y a la reducción costos.

En segundo término, las aplicaciones vinculadas a la generación de nuevos clientes, el crecimiento de ventas y la optimización de campañas de marketing reunieron cerca del 50% de las respuestas, evidenciando que la expansión comercial y la captación de nuevos mercados constituyen otro eje estratégico central para las empresas relevadas.

Esta distribución confirma que, al momento de pensar en la adopción de IA, las pymes priorizan iniciativas orientadas tanto a la eficiencia interna como al fortalecimiento de su posición comercial.

Estas respuestas resultan consistentes con lo desarrollado en el Capítulo 2, donde se vio que las pequeñas y medianas empresas priorizan aquellas iniciativas tecnológicas que prometen retornos rápidos y tangibles, dadas sus restricciones habituales de recursos y su necesidad de minimizar el riesgo de inversión.

7.3.4.2 Percepción de adopción futura


En el Capítulo 2 analizamos cómo el proceso de adopción tecnológica en las pequeñas y medianas empresas está condicionado por múltiples barreras, entre ellas la falta de financiamiento, la escasez de talento digital, las desigualdades de acceso a infraestructura y la resistencia cultural al cambio. También vimos que, allí donde existen liderazgo estratégico, capacidades internas fortalecidas y presiones competitivas adecuadas, las PYMEs logran superar estos obstáculos y avanzar en sus procesos de transformación.

En paralelo a estas limitaciones, identificamos una característica estructural que les juega a favor: su mayor flexibilidad y capacidad de reacción frente a los cambios, en comparación con las grandes corporaciones. Esta agilidad en la toma de decisiones representa una ventaja competitiva clave, especialmente frente a tecnologías emergentes que todavía no han alcanzado un nivel de estandarización o adopción masiva.

Sobre esta base, esta pregunta busca entender cómo se posicionan actualmente los empresarios pymes frente a la incorporación de una tecnología disruptiva como la inteligencia artificial. ¿Aprovechan su flexibilidad para adelantarse y ganar terreno, o permanecen a la espera, arriesgándose a quedar rezagados? ¿Observan la IA como una palanca de transformación para su negocio, o la perciben aún como un fenómeno ajeno, distante o riesgoso? ¿Se están moviendo hacia el cambio, o se están quedando en la cola de la innovación?

En función de esto, se propusieron cinco opciones de respuesta que buscaban capturar distintos niveles de conocimiento, exploración e interés concreto en torno a la adopción de inteligencia artificial. En el gráfico siguiente se muestran los resultados con las opciones propuestas.

13.- ¿Cómo percibes la incorporación de la inteligencia artificial en tu empresa en el futuro cercano?
78 respuestas



Los resultados de esta pregunta reflejan una dinámica muy significativa en la actitud de las pymes frente a la inteligencia artificial. Más de la mitad de los encuestados (51%) declaró conocer el tema, pero aún no haber comenzado a aplicar IA en su empresa. Esta

mayoría silenciosa revela una barrera no necesariamente tecnológica, sino de acción: el conocimiento existe, pero no se traduce en iniciativas concretas. ¿Estamos frente a un caso de resistencia cultural, de procrastinación, o simplemente de parálisis frente a un cambio percibido como incierto?

Si a este grupo le sumamos el 14% que manifiesta estar evaluando la incorporación de IA pero aún sin decisiones tomadas, se alcanza un 65% de empresarios que reconocen la existencia y la importancia potencial de la inteligencia artificial, pero que no han comenzado a avanzar en su implementación. Esta cifra pone en evidencia una de las actitudes más características del ecosistema pyme: la cautela extrema frente a las tecnologías disruptivas, aun cuando su valor estratégico es conocido.

En contraste, apenas el 25% de los encuestados afirmó haber dado los primeros pasos hacia la adopción de IA, ya sea explorando, implementando o utilizando activamente estas herramientas en varios procesos clave. Esta brecha marca una enorme oportunidad: el conocimiento ya está instalado en buena parte del universo pyme, pero la acción todavía no. Los datos sugieren que el desafío no pasa por la falta de información, sino por transformar ese conocimiento latente en estrategias concretas de adopción tecnológica que permitan a las pymes adelantarse y capitalizar las ventajas competitivas que la inteligencia artificial ofrece.

7.3.4.3 Barreras para implementar IA

Como vimos anteriormente, la mayor parte de las pymes entrevistadas identificó áreas donde la inteligencia artificial podría aportarle valor a su negocio, principalmente en la automatización de procesos administrativos, en la generación de nuevos clientes, en el crecimiento de ventas y en la atención y retención de clientes. Por otro lado, más de la mitad de los encuestados admitió conocer el tema pero no haber comenzado a aplicar soluciones basadas en IA en su empresa y otro porcentaje relevante se encuentra evaluando alternativas pero sin decisiones firmes hacia la implementación.


Si las empresas identifican oportunidades concretas para aplicar inteligencia artificial y reconocen su potencial de impacto en áreas clave del negocio, ¿por qué no logran avanzar en su implementación? ¿Qué factores explican la distancia entre el reconocimiento del valor de la IA y la falta de acción efectiva? Para intentar entender mejor esta brecha, se relevó cuáles son las principales barreras que los propios empresarios perciben como obstáculos a la hora de adoptar soluciones de inteligencia artificial en sus organizaciones.

Las opciones que se le presentaron a los encuestados fueron las siguientes:

1. Desconocimiento sobre la utilidad para mi negocio
2. Falta de tiempo y recursos
3. Costos elevados para mi empresa

4. Resistencia al cambio dentro de mi equipo
5. No veo una necesidad real para que invirtamos en IA
6. Otra... (respuesta abierta)

Las respuestas permitían elecciones múltiples y en la opción 6 se permitió el encuestado podía agregar otras opciones no contempladas. Los resultados se muestran en el siguiente gráfico.



Los resultados obtenidos muestran datos contundentes: el 53% de los empresarios señaló el desconocimiento sobre la utilidad de la inteligencia artificial para su negocio como una barrera principal, mientras que otro tanto identificó la falta de tiempo y recursos como otro obstáculo clave. Ambas limitaciones, combinadas, explican buena parte de la brecha entre el interés declarado en las soluciones de IA y su baja adopción efectiva. Esta situación plantea una enorme oportunidad: la demanda latente ya existe, pero se encuentra frenada por problemas que son, en su mayoría, superables mediante estrategias adecuadas de sensibilización, capacitación y acompañamiento técnico. No se trata de un rechazo estructural a la IA, sino de una falta de comprensión práctica sobre cómo aplicarla y de dificultades operativas que podrían resolverse con apoyos relativamente accesibles.

En un nivel intermedio de incidencia aparece la resistencia al cambio dentro de los equipos de trabajo, mencionada por el 27% de los encuestados. Si bien esta barrera no es la más mencionada, sigue teniendo un peso relevante, especialmente considerando que la transformación digital no depende únicamente de inversiones tecnológicas, sino también de la voluntad y capacidad de las personas para adoptar nuevas herramientas y formas de trabajo. La resistencia cultural puede ralentizar significativamente los procesos de implementación, y su gestión debe ser parte de cualquier estrategia que busque introducir IA en el ecosistema pyme.

Otro dato interesante es que apenas el 17% de los encuestados señaló los costos como un obstáculo principal. Este resultado es especialmente alentador, ya que sugiere que, a diferencia de otras tecnologías más intensivas en inversión, la inteligencia artificial comienza a ser percibida como una solución accesible para el segmento pyme. La reducción de barreras económicas podría acelerar, en los próximos años, la adopción de herramientas de IA si se logra superar las otras limitaciones detectadas.

Finalmente, sólo el 6% de los empresarios afirmó no ver necesidad de invertir en inteligencia artificial para su negocio. Este porcentaje mínimo refuerza la idea de que existe una conciencia generalizada sobre la importancia estratégica de la IA, incluso en empresas que todavía no han iniciado su proceso de adopción. El desafío no pasa, entonces, por convencer sobre el valor de la tecnología, sino por facilitar su implementación de manera práctica, cercana y adaptada a las realidades específicas de cada pyme.

7.3.4.4 Oportunidades futuras con IA


Luego de relevar las barreras que hoy limitan la adopción de inteligencia artificial en las pequeñas y medianas empresas, el siguiente paso fue indagar cómo visualizan los propios empresarios el potencial transformador que esta tecnología puede tener en sus organizaciones a mediano plazo. No se buscó identificar procesos específicos que podrían optimizarse, sino de comprender de qué manera imaginan que la incorporación de la IA puede redefinir la forma en que operan, compiten y evolucionan en su entorno de negocios.

Esta mirada busca entender no solo el nivel de conocimiento actual sobre la inteligencia artificial, sino también el grado de apertura estratégica que existe frente a las transformaciones más profundas que esta tecnología puede habilitar. La forma en que las pymes perciben estas oportunidades ofrece indicios sobre su capacidad de adaptación futura, su disposición a innovar y su comprensión de los cambios estructurales que se están gestando en el tejido empresarial.

Para ello, se presentaron múltiples dimensiones de impacto potencial, permitiendo a los encuestados seleccionar todas aquellas transformaciones que consideran que la IA generará en sus empresas en el horizonte de los próximos cinco años. En el gráfico siguiente se muestran los resultados.

15.- ¿Qué oportunidades crees que la inteligencia artificial generará para tu empresa en los próximos 5 años? (Selecciona todas las que apliquen)

78 respuestas



Para una mayoría del 59%, el mayor impacto de la IA en sus negocios será la aceleración de la digitalización empresarial. Este resultado refleja que existe una percepción extendida de que la inteligencia artificial no será simplemente una herramienta para mejorar tareas específicas, sino un impulsor de cambios profundos en la estructura operativa de las organizaciones. Tal como se analizó en el Capítulo 2, las tecnologías disruptivas no solo permiten optimizar procesos, sino que alteran de manera estructural la forma en que las empresas producen, se organizan y compiten en el mercado. La digitalización aparece así no como una opción, sino como un eje inevitable de transformación para aquellas pymes que buscan sostener su competitividad en los próximos años. La inteligencia artificial, dentro de este fenómeno, funciona como un acelerador natural de esa transición hacia entornos más automatizados, interconectados y basados en el procesamiento intensivo de información.

En segundo lugar, un 58% de los encuestados señaló que la inteligencia artificial cambiará la forma de trabajar dentro de sus empresas. Esta visión conecta directamente con las tendencias globales que analizan el futuro del trabajo, donde la automatización de tareas, la transformación de los perfiles profesionales, la convivencia entre humanos y sistemas inteligentes y la demanda de nuevas habilidades digitales son ya fenómenos observables. Que una porción significativa del universo pyme reconozca esta dimensión del cambio muestra una madurez incipiente en la lectura de los desafíos organizacionales que plantea la IA. El impacto no se limitará a optimizar puestos de trabajo existentes: redefinirá roles, competencias y modalidades de colaboración, exigiendo a las empresas una capacidad de adaptación cultural y formativa mucho más dinámica que en etapas anteriores de transformación tecnológica.

También se destaca la mejora en la toma de decisiones estratégicas, con un 45%. Esto indica que, más allá de las funciones operativas, una proporción significativa de empresarios percibe que la inteligencia artificial puede actuar como un soporte crítico para la gestión del negocio, facilitando decisiones más rápidas, informadas y alineadas a contextos cada vez más dinámicos.

La transformación de la experiencia del cliente y la promoción de la innovación interna también alcanzaron un 40 % de menciones cada una, lo que sugiere que las pymes reconocen que la inteligencia artificial no solo impactará en los procesos internos, sino también en la forma en que se relacionan con sus clientes y en su capacidad para desarrollar nuevas propuestas de valor.

Un 36% de los empresarios visualiza que la inteligencia artificial abrirá nuevas oportunidades de negocio. Este dato refuerza la percepción de la IA no solo como un habilitador de eficiencia, sino también como un catalizador para explorar nuevos mercados, servicios o modelos comerciales.

En el extremo opuesto, apenas un 5% de los encuestados consideró que la IA no generará nuevas oportunidades para su empresa. Esta baja incidencia confirma que la mayoría del ecosistema pyme reconoce el potencial de transformación asociado a estas tecnologías, aunque, como vimos anteriormente, todavía enfrenta desafíos importantes para su adopción efectiva.

5.3.4.5 Disposición a invertir en IA

A lo largo de las preguntas anteriores quedó claro que la mayoría de las pymes reconoce el potencial de la inteligencia artificial para transformar su negocio. Si bien muchos aún no han iniciado procesos concretos de implementación, la identificación de oportunidades estratégicas, el interés por acelerar la digitalización y la conciencia sobre los cambios que traerá la IA en la forma de trabajar son señales positivas que reflejan una apertura progresiva hacia esta tecnología.

Sin embargo, el reconocimiento teórico del valor de la IA plantea ahora una pregunta más concreta y desafiante: ¿están dispuestos los empresarios pymes a respaldar esa visión con decisiones de inversión en el corto plazo? Esta pregunta permite cerrar el recorrido conceptual iniciado en este bloque, llevando el análisis del terreno de las percepciones al terreno de los compromisos reales.

Para ello, se ofrecieron cuatro opciones de respuesta: Sí, No, Tal vez, y Depende del costo y la rentabilidad esperada. Los resultados se muestran en el siguiente gráfico.

16.- ¿Estaría dispuesto a invertir en soluciones de IA para tu empresa en los próximos 12 meses?

78 respuestas



Los datos relevados muestran que el 33 % de los empresarios manifestó estar dispuesto a invertir en soluciones de inteligencia artificial en los próximos doce meses. Este porcentaje representa un núcleo firme de adopción potencial inmediata, que podría comenzar a movilizar la incorporación de IA en el ecosistema pyme en el corto plazo.

Por otro lado, un 31 % de los encuestados respondió que "Tal vez" invertiría, lo cual indica que existe una proporción significativa de empresarios que visualiza el valor de la IA, pero que todavía necesita condiciones adicionales para transformar esa percepción en una decisión concreta.

El 24 % expresó que su disposición a invertir dependerá del costo y de la rentabilidad esperada, reflejando una actitud típicamente pragmática en el universo pyme: la inversión no está descartada, pero será evaluada bajo estrictos criterios de viabilidad económica.

Finalmente, apenas un 12 % de los encuestados afirmó que no está dispuesto a invertir en IA. Este porcentaje relativamente bajo refuerza la conclusión general de que, aunque persistan barreras de implementación y necesidades de acompañamiento, existe una base de interés y de apertura a la transformación tecnológica que puede ser aprovechada estratégicamente en los próximos años.

En conjunto, estos resultados reflejan un escenario de oportunidad, pero también de desafíos claros. Si bien uno de cada tres empresarios ya manifiesta una disposición concreta a invertir en inteligencia artificial, existe un universo aún mayor, integrado por quienes dudan o condicionan su decisión a criterios de costo-beneficio, que puede ser movilizad mediante estrategias adecuadas de sensibilización, acompañamiento y demostración de valor tangible.

El hecho de que solo una minoría excluyente descarte la posibilidad de inversión refuerza la idea de que la inteligencia artificial ya no es percibida como una tendencia lejana, sino como una opción real en el horizonte estratégico de las pymes. La transición de este interés potencial hacia acciones concretas dependerá en gran medida de la capacidad

de los actores del ecosistema —proveedores, consultores, organismos de apoyo— para facilitar el acceso, reducir la incertidumbre y mostrar resultados concretos de implementación.

7.3.5 Comentarios adicionales sobre las respuestas abiertas

Si bien la cantidad de respuestas abiertas fue moderada, el contenido de las mismas refleja de manera consistente la percepción generalizada de que la inteligencia artificial representa una oportunidad transformadora para las pequeñas y medianas empresas. La mayoría de los empresarios que dejaron su comentario reconoce que la IA puede ser un factor clave para mejorar la eficiencia, potenciar la creatividad, optimizar procesos administrativos y abrir nuevas oportunidades comerciales.

Sin embargo, también queda en evidencia una necesidad profunda de acompañamiento. Algunos empresarios manifestaron que todavía no conocen en profundidad las aplicaciones posibles de la IA, que necesitan capacitación específica para entender cómo aplicarla en sus negocios, y que requieren ayuda para traducir las posibilidades teóricas en proyectos concretos. Esta demanda de apoyo técnico y estratégico es un mensaje claro: el interés existe, pero no es suficiente. Para que la inteligencia artificial se convierta en un recurso efectivo para el ecosistema pyme, será fundamental construir puentes que acerquen el conocimiento, faciliten la implementación y acompañen el proceso de cambio cultural que la transformación digital exige.

Las respuestas también reflejan cierta tensión interna: si bien se reconoce la urgencia de incorporar IA para no quedar rezagados, la resistencia cultural, la falta de visión en algunos líderes empresariales y el difícil contexto económico son factores que siguen condicionando el ritmo de adopción. En conjunto, los comentarios abiertos no hacen más que reforzar el diagnóstico trabajado a lo largo de este capítulo: la inteligencia artificial es percibida como una oportunidad concreta, pero su implementación efectiva dependerá en gran medida de la capacidad del ecosistema de brindar apoyo, capacitación y soluciones adaptadas a la realidad de las pequeñas y medianas empresas.

7.4 Conclusiones

El estudio de campo realizado a lo largo de este capítulo permitió contrastar las observaciones teóricas desarrolladas en la tesis con la realidad concreta que atraviesan las pequeñas y medianas empresas argentinas en su proceso de incorporación de inteligencia artificial. Los resultados obtenidos validan en líneas generales los principales supuestos planteados: existe una conciencia creciente sobre el potencial transformador de la IA, pero también persisten limitaciones estructurales, culturales y operativas que condicionan su adopción efectiva.

Entre los hallazgos más relevantes se destaca que una amplia mayoría de empresarios reconoce el valor estratégico de la inteligencia artificial y vislumbra oportunidades

concretas en áreas como la eficiencia operativa, el crecimiento comercial, la toma de decisiones y la transformación organizacional. Sin embargo, esta percepción positiva convive con una brecha significativa entre el conocimiento teórico y la acción concreta: más de la mitad de los encuestados admite conocer la temática, pero aún no ha iniciado procesos de implementación. Las principales barreras detectadas —desconocimiento práctico, falta de tiempo y recursos, y resistencia cultural— refuerzan la necesidad de un acompañamiento específico que permita traducir el interés latente en estrategias de adopción realistas y sostenibles.

El análisis de las percepciones empresariales revela que el desafío no es exclusivamente tecnológico ni financiero. La adopción de inteligencia artificial en el ecosistema pyme exige abordar dimensiones estratégicas más profundas: sensibilizar a los equipos directivos sobre el valor tangible de la IA, facilitar el acceso a capacitación adaptada a sus necesidades, y construir soluciones accesibles que minimicen la complejidad operativa. Superar estas barreras no solo permitirá acelerar la incorporación de inteligencia artificial en las pymes, sino también fortalecer su capacidad competitiva en un entorno de transformación acelerada.

La inteligencia artificial, lejos de ser una promesa lejana, ya constituye una herramienta concreta para impulsar la evolución digital de las pequeñas y medianas empresas. Si bien el contexto externo puede facilitar o dificultar el camino, el verdadero motor de cambio reside en la propia decisión de cada pyme de asumir el desafío. Aquellas empresas que logren tomar la iniciativa, adaptarse, aprender y actuar sin esperar condiciones ideales, serán las que construirán organizaciones más resilientes, innovadoras y preparadas para liderar en un mercado en permanente transformación.

CONCLUSIONES Y RECOMENDACIONES

La inteligencia artificial ya no es una promesa lejana, sino una realidad concreta que está transformando, de manera silenciosa pero constante, la forma en que las empresas operan, compiten e innovan. Su presencia no siempre es evidente en el trabajo cotidiano, pero sus efectos se hacen cada vez más visibles en múltiples dimensiones de la actividad empresarial. La pregunta ya no es si la IA impactará en los negocios, sino cómo cada organización decidirá posicionarse frente a este cambio.

A lo largo de este trabajo hemos visto que la inteligencia artificial está atravesando todos los procesos de negocio de las empresas. Desde ventas y marketing, atención al cliente, supply chain, producción, finanzas hasta desarrollo de productos y otros, las aplicaciones de IA se expanden de manera transversal, integrándose de formas cada vez más diversas en la estructura de los negocios. No son soluciones aisladas en sectores específicos, sino que representan una fuerza transformadora que modifica la manera en que operamos, nos organizamos e incluso cómo nos vinculamos dentro y fuera de las organizaciones. La IA no solo mejora procesos: redefine prácticas, acelera dinámicas de trabajo y abre nuevas formas de interacción entre las personas y la tecnología.

A diferencia de otras disrupciones tecnológicas, donde los cambios se desplegaban de manera más gradual y previsible, la evolución de la inteligencia artificial avanza a un ritmo acelerado y continuo. Su capacidad para aprender, adaptarse y retroalimentarse a partir de nuevos datos genera un proceso de innovación constante, donde cada incorporación multiplica la velocidad de cambio. En este escenario, las organizaciones deben adaptarse en plazos cada vez más breves para no quedar rezagadas.

Desde la aparición de BERT en 2018, que resolvía aspectos avanzados del procesamiento de lenguaje natural, la evolución de los modelos de inteligencia artificial ha sido vertiginosa. En muy pocos años, en 2022, la inteligencia artificial generativa se popularizó masivamente a través de modelos como GPT, capaces de dialogar, interpretar contextos y generar contenido original con niveles de coherencia que antes parecían inalcanzables. Actualmente, surgieron los Agentes de IA, sistemas que combinan múltiples modelos de lenguaje, módulos de planificación y componentes de ejecución para interactuar de manera dinámica con su entorno, con capacidades de planificar secuencias de acciones, tomar decisiones autónomas y adaptarse a los resultados obtenidos.

Sin embargo, aunque el avance tecnológico se despliega a un ritmo vertiginoso, su adopción en el tejido empresarial no es homogénea. Un aspecto que quedó de manifiesto a lo largo del trabajo es la diferencia estructural entre las grandes corporaciones y las pequeñas y medianas empresas. Las primeras suelen contar con recursos financieros, capacidades técnicas y equipos humanos que les permiten experimentar, testear y ajustar nuevas tecnologías en un entorno controlado. En muchos casos, funcionan como verdaderos laboratorios de innovación, donde el margen de error está contemplado como parte del proceso.

La realidad pyme, en términos generales, es muy distinta. Cada decisión que se toma o cada inversión que se realiza requieren mostrar resultados concretos en plazos relativamente cortos. No hay demasiado margen para ensayos fallidos, lo que obliga a priorizar soluciones que puedan integrarse de manera sencilla, generar valor tangible y ser sostenibles en el tiempo.

Este escenario, donde cada decisión debe ser meditada y generar resultados visibles, encuentra hoy un contexto más favorable gracias a la evolución de las propias soluciones tecnológicas. El desarrollo de soluciones SaaS, plataformas accesibles y herramientas modulares ha democratizado, en buena medida, el acceso a tecnologías avanzadas. En particular, la aparición de APIs especializadas permite integrar funciones de inteligencia artificial en procesos existentes sin necesidad de desarrollar modelos propios, abriendo nuevas puertas incluso para organizaciones que no cuentan con equipos técnicos internos. Hoy, pequeñas y medianas empresas pueden explorar estas aplicaciones sin realizar grandes inversiones ni depender de estructuras tecnológicas complejas.

Más allá del acceso creciente a soluciones tecnológicas, es importante reconocer la diversidad de situaciones que conviven dentro del mundo pyme. Existen empresas en las que la tecnología constituye el núcleo mismo del modelo de negocio, mientras que en otras, las soluciones tecnológicas operan como herramientas de soporte, utilizadas en mayor o menor medida según las características propias de cada organización. Esta heterogeneidad obliga a comprender que no existe un único punto de partida ni un recorrido estándar hacia la adopción de inteligencia artificial. Cada pyme tiene una realidad única, marcada por su historia, su estructura, su sector de actividad y su cultura interna, lo que exige pensar estrategias de adopción distintas y ajustadas a cada caso.

Esta diversidad interna del mundo pyme, lejos de ser un obstáculo, encuentra hoy un correlato en el amplísimo abanico de aplicaciones de inteligencia artificial que analizamos a lo largo de esta tesis. Tal como vimos en los capítulos 3 y 4, existen soluciones adaptables a múltiples áreas, escalas y necesidades: desde herramientas para optimizar procesos administrativos y mejorar la atención al cliente, hasta desarrollos más complejos en logística, producción o análisis predictivo. Esta amplitud de opciones permite que cada empresa pueda encontrar, en función de su realidad y objetivos, una vía concreta de incorporación tecnológica que agregue valor de manera progresiva y sostenible.

En este contexto, donde la variedad de caminos posibles es tan amplia como las realidades empresariales existentes, resultaría conveniente contar con herramientas que ayuden a pensar sobre la adopción de inteligencia artificial de manera estructurada y estratégica.

Con ese propósito se desarrolló el Mapa de Oportunidades, una guía práctica y flexible que permite a cada empresa interpretar su punto de partida, visualizar caminos de incorporación tecnológica viables y priorizar aquellas iniciativas que mejor se alineen con sus capacidades actuales y su visión de crecimiento.

El Mapa de Oportunidades y la tesis en su conjunto, buscan también inspirar, invitar a la reflexión y ampliar la mirada sobre las oportunidades que hoy ofrece la inteligencia artificial. No se trata sólo de trazar recorridos posibles, sino de alentar una actitud consciente, crítica y estratégica frente a un escenario de cambio que ya está en marcha.

Sin embargo, esta propuesta de reflexión y construcción de caminos posibles no se basó únicamente en un análisis conceptual o en la revisión de tendencias globales. Para comprender más de cerca la realidad concreta de las pequeñas y medianas empresas, se realizó un estudio de campo dirigido a empresarios y directivos, buscando relevar sus percepciones sobre la irrupción de la inteligencia artificial, las barreras que enfrentan, las oportunidades que identifican y su disposición real a avanzar en procesos de adopción tecnológica.

Escuchar directamente a los protagonistas permitió enriquecer el análisis general, validar algunos de los planteos teóricos y, sobre todo, descubrir matices que no siempre surgen de los estudios globales: las tensiones, las dudas, las aspiraciones y las realidades cotidianas del mundo pyme frente a la IA.

Una de las conclusiones más relevantes del estudio de campo es que la mayoría de los empresarios pymes reconoce la importancia estratégica que la inteligencia artificial tiene para el futuro de sus negocios. Hay una conciencia creciente sobre el potencial de estas tecnologías para mejorar procesos, optimizar decisiones y abrir nuevas oportunidades. Sin embargo, ese reconocimiento no siempre se traduce en acciones concretas. Una parte significativa del universo relevado aún no ha dado los primeros pasos efectivos hacia la incorporación de soluciones de inteligencia artificial.

Esta brecha entre la comprensión del fenómeno y la acción efectiva constituye, probablemente, la conclusión de fondo más importante de la tesis. El desconocimiento sobre cómo aplicar la inteligencia artificial en el propio negocio, junto con la falta de tiempo y recursos disponibles para explorar nuevas soluciones, emergen como las barreras más relevantes.

Y frente a esta realidad, resulta inevitable preguntarnos: ¿Qué decisiones podríamos tomar hoy para acercarnos, aunque sea un paso, hacia ese futuro que ya intuimos como necesario? ¿Qué acciones podríamos priorizar para transformar la comprensión en avance real?

Frente a este panorama, el camino más razonable no sería buscar transformaciones rápidas o profundas, sino promover procesos graduales, realistas y sostenibles. Una forma efectiva de avanzar podría ser identificar espacios puntuales donde una aplicación concreta de inteligencia artificial genere un beneficio tangible: mejorar la experiencia del cliente, optimizar la gestión de datos o automatizar procesos repetitivos, entre otras posibilidades.

Dar un primer paso pequeño pero significativo permitiría construir aprendizajes valiosos, fortalecer la confianza organizacional y confirmar que la incorporación de IA puede desarrollarse como un proceso controlado y progresivo, capaz de abrir nuevas oportunidades a medida que se consolida.

En este recorrido, resulta especialmente valioso apoyarse en redes de colaboración. Proveedores tecnológicos, consultores especializados, cámaras empresariales y comunidades de práctica pueden ser aliados estratégicos para acercar conocimiento, compartir experiencias y facilitar la implementación de soluciones adaptadas a cada realidad particular. No se trata de enfrentar el proceso de transformación en soledad, sino de construirlo en diálogo con otros.

Asimismo, resulta esencial asumir que el camino hacia la adopción de inteligencia artificial no será lineal ni libre de obstáculos. El aprendizaje continuo, la apertura a revisar y ajustar decisiones, y la resiliencia frente a los desafíos serán cualidades clave para sostener una evolución efectiva a lo largo del tiempo. La IA no necesita perfección sino que exige disposición a explorar, cuestionar y evolucionar.

El futuro no es una promesa distante. Es una construcción que empieza con las decisiones que tomemos hoy. La inteligencia artificial no viene a reemplazar la esencia de las empresas, sino a potenciarlas, a liberar su capacidad de adaptarse, innovar y crecer en un entorno cada vez más dinámico. Avanzar no requiere certezas absolutas, sino la disposición a aprender, a explorar nuevas posibilidades y a dar los primeros pasos con visión estratégica.

El futuro no se espera: se construye desde el presente. El futuro no es mañana. El futuro es hoy.

REFERENCIAS

- Accenture. (2023). La IA generativa en los negocios. Accenture. Recuperado de <https://www.accenture.com/es-es/insights/technology/generative-ai>
- Aggity. (s.f.). Diferencias entre la transformación digital para pymes y grandes empresas. Recuperado de <https://aggity.com/transformacion-digital-para-pymes/>
- AI21 Labs. (2021). Jurassic-1: Technical Details and Evaluation. <https://www.ai21.com/blog/jurassic-1-technical-details>
- Al-Hashedi, K. G., & Magalingam, P. (2020). Financial fraud detection applying data mining techniques: A comprehensive review from 2009 to 2019. *Computer Science Review*, 38, 100402. <https://doi.org/10.1016/j.cosrev.2021.100402>
- Alpaydin, E. (2020). *Introduction to machine learning* (4th ed.). MIT Press.
- Alqudah, M. A., & Muradkhanli, L. (2024). The use of generative artificial intelligence for customer services. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4771265>
- Alshraideh, H., Del Castillo, E., & Gil Del Val, A. (2020). Process control via random forest classification of profile signals: An application to a tapping process. *Journal of Manufacturing Processes*, 58, 736–748. <https://doi.org/10.1016/j.jmapro.2020.08.043>
- Anthropic. (2024, 20 de junio). Claude 3.5 Sonnet: Raising the bar for intelligence, speed, and cost. <https://www.anthropic.com/news/claude-3-5-sonnet>
- Anwar, S. M., Majid, M., Qayyum, A., Awais, M., Alnowami, M., & Khan, M. K. (2018). Medical image analysis using convolutional neural networks: A review. *Journal of Medical Systems*, 42(11), 226. <https://doi.org/10.1007/s10916-018-1088-1>
- Banco Mundial. (2023). Conectados: Tecnologías digitales para la inclusión y el crecimiento. Informe Económico América Latina y el Caribe (Octubre 2023). Banco Mundial. DOI: 10.1596/978-1-4648-2039-7.
- Banco Mundial. (2024). Indicadores de desarrollo empresarial. Recuperado de <https://datos.bancomundial.org/indicador/IC.BUS.NDNS.ZS>
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* (pp. 610–623). <https://doi.org/10.1145/3442188.3445922>
- BID (Banco Interamericano de Desarrollo). (2023). Prioridades para la digitalización empresarial en América Latina y el Caribe. Banco Interamericano de Desarrollo.
- BigScience Research Workshop. (2022). BLOOM: A 176B-parameter open-access multilingual language model. arXiv preprint arXiv:2211.05100. <https://arxiv.org/abs/2211.05100>
- Black, S., Biderman, S., Hallahan, E., Anthony, Q., Gao, L., Golding, L., ... & Leahy, C. (2022). GPT-NeoX-20B: An Open-Source Autoregressive Language Model. arXiv preprint arXiv:2204.06745. <https://arxiv.org/abs/2204.06745>

- Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., ... & Liang, P. (2021). On the opportunities and risks of foundation models. arXiv preprint arXiv:2108.07258. <https://arxiv.org/abs/2108.07258>
- Boston Consulting Group. (2024). Where's the value in AI? BCG Global. <https://www.bcg.com/publications/2024/wheres-value-in-ai>
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877–1901. <https://arxiv.org/abs/2005.14165>
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877–1901. <https://arxiv.org/abs/2005.14165>
- Bughin, J., Seong, J., Manyika, J., Chui, M., & Joshi, R. (2019). Notes from the AI frontier: Modeling the impact of AI on the world economy. McKinsey Global Institute. <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/notes-from-the-ai-frontier-modeling-the-impact-of-ai-on-the-world-economy>
- CAF (Banco de Desarrollo de América Latina). (2023). Digitalización de las PYMEs en América Latina. CAF.
- Campbell, M., Hoane, A. J., & Hsu, F. (2002). Deep Blue. *Artificial Intelligence*, 134(1–2), 57–83. [https://doi.org/10.1016/S0004-3702\(01\)00129-1](https://doi.org/10.1016/S0004-3702(01)00129-1)
- Carcillo, F., Le Borgne, Y.-A., Caelen, O., Kessaci, Y., Oblé, F., & Bontemp, G. (2019). Combining unsupervised and supervised learning in credit card fraud detection. *Information Sciences*, 557, 317–331. <https://doi.org/10.1016/j.ins.2019.05.042>
- Castells, M. (2001). *The Internet galaxy: Reflections on the Internet, business, and society*. Oxford University Press.
- CEPAL (Comisión Económica para América Latina y el Caribe). (2020). Políticas de digitalización en América Latina: Avances y desafíos en el sector productivo. Naciones Unidas.
- CEPAL (Comisión Económica para América Latina y el Caribe). (2024). Superar las trampas del desarrollo de América Latina y el Caribe en la era digital: El potencial transformador de las tecnologías digitales y la inteligencia artificial. Naciones Unidas.
- Chen, H., Ma, H., Chu, X., & Xue, D. (2020). Anomaly detection and critical attributes identification for products with multiple operating conditions based on isolation forest. *Advanced Engineering Informatics*, 46, 101139. <https://doi.org/10.1016/j.aei.2020.101139>
- Chien, J.-C., Lee, J.-D., Hu, C.-S., & Wu, C.-T. (2022). The usefulness of gradient-weighted CAM in assisting medical diagnoses. *Applied Sciences*, 12(15), 7748. <https://doi.org/10.3390/app12157748>
- Chopra, S., & Meindl, P. (2016). *Supply chain management: Strategy, planning, and operation* (6ª ed.). Pearson.

Christensen, C. M. (1997). *The innovator's dilemma: When new technologies cause great firms to fail*. Harvard Business Review Press.

Christensen, C. M., Raynor, M. E., & McDonald, R. (2015). What is disruptive innovation? *Harvard Business Review*, 93(12), 44–53.

Cognex Corporation. (2023). Cómo la IA y la visión artificial mejoran la calidad y el rendimiento de los productos farmacéuticos. Recuperado de <https://www.cognex.com/es-mx/blogs/machine-vision/how-ai-and-machine-vision-improve-pharmaceutical-product-quality-and-yield>

Cohere. (2025). Command A: An Enterprise-Ready Large Language Model. <https://cohere.com/research/papers/command-a-technical-report.pdf>

Crevier, D. (1993). *AI: The tumultuous history of the search for artificial intelligence*. Basic Books.

Dans, E. (2023, 1 de febrero). Los modelos masivos de lenguaje y el problema de la escala. Enrique Dans. <https://www.enriquedans.com/2023/02/los-modelos-masivos-de-lenguaje-y-el-problema-de-la-escala.html>

Darwin AI. (2024, julio). IA en la atención al cliente: Mejora eficiencia y personalización. Recuperado de <https://blog.getdarwin.ai/es/content/ia-en-la-atencion-al-cliente>

Datacamp. (2023). La IA en la cadena de suministro: principales aplicaciones y casos de uso. Recuperado de <https://www.datacamp.com/es/blog/ai-in-supply-chain>

Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.

de procesos de transformación digital. Somos PYMES. <https://www.somospymes.com.ar/somos-pymes-tv/pymes-argentinas-destacadas-las-implementacion-procesos-transformacion-digital-n5394309>

DeepSeek-AI. (2025). DeepSeek-R1: Incentivizing Reasoning Capability in LLMs via Reinforcement Learning. arXiv preprint arXiv:2501.12948. <https://arxiv.org/abs/2501.12948>

Deloitte. (2024). Autonomous generative AI agents: Under development. Deloitte Insights. <https://www2.deloitte.com/us/en/insights/industry/technology/technology-media-and-telecom-predictions/2025/autonomous-generative-ai-agents-still-under-development.html>

Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of NAACL-HLT 2019* (pp. 4171–4186). <https://arxiv.org/abs/1810.04805>

Dhawan, A. P. (2011). *Medical Image Analysis* (2^a ed.). Wiley-IEEE Press. ISBN 978-0470622056.

DocuSign. (2024). Usos y ventajas de la IA para contabilidad y finanzas de una empresa. Recuperado de <https://www.docusign.com/es-mx/blog/ia-para-contabilidad-y-finanzas>

Domingos, P. (2015). *The Master Algorithm: How the quest for the ultimate learning machine will remake our world*. Basic Books.

- El País. (2025, 11 de febrero). Su compañero virtual le liberará del papeleo. El País. Recuperado de <https://elpais.com/economia/negocios/2025-02-11/su-companero-virtual-le-liberara-del-papeleo.html>
- Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211. https://doi.org/10.1207/s15516709cog1402_1
- European Commission. (2021). Proposal for a Regulation laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52021PC0206>
- Ferraro, C., Demsar, V., Sands, S., Restrepo, M., & Campbell, C. (2024). The paradoxes of generative AI-enabled customer service: A guide for managers. *Business Horizons*, 67(5), 549-559. <https://doi.org/10.1016/j.bushor.2024.04.013>
- Foro Económico Mundial. (2024, 4 de enero). 6 formas para liberar el poder de la IA en la manufactura. Recuperado de <https://es.weforum.org/stories/2024/01/es-asi-como-podemos-liberar-el-poder-de-la-ia-en-la-manufactura/>
- Gemini Team. (2024). Gemini 1.5: Unlocking multimodal understanding across millions of tokens of context. Recuperado de <https://arxiv.org/abs/2403.05530>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. <https://www.deeplearningbook.org>
- Goswami, M. J. (2021). Challenges and solutions in integrating AI with multi-cloud architectures. *International Journal of Enhanced Research in Management & Computer Applications*, 10(10), 67-73. <https://www.researchgate.net/publication/381280677>
- Grant, E. L., & Leavenworth, R. S. (1996). *Statistical quality control* (7ª ed.). McGraw-Hill.
- Grant, R. M., & Jordan, J. (2023). *Foundations of Strategy* (4th ed.). Wiley.
- Gunning, D., & Aha, D. W. (2019). DARPA's explainable artificial intelligence (XAI) program. *AI Magazine*, 40(2), 44–58. <https://doi.org/10.1609/aimag.v40i2.2850>
- Guttentag, D. (2015). Airbnb: Disruptive innovation and the rise of an informal tourism accommodation sector. *Current Issues in Tourism*, 18(12), 1192–1217. <https://doi.org/10.1080/13683500.2013.827159>
- Hamaide, V., Joassin, D., Castin, L., & Glineur, F. (2022). A two-level machine learning framework for predictive maintenance: Comparison of learning formulations. *arXiv Preprint*. <https://arxiv.org/abs/2204.10083>
- Hayas Marketing. (2024, abril). La Inteligencia Artificial (IA) y su aplicación en Marketing. Recuperado de <https://hayasmarketing.com/es/la-inteligencia-artificial-ia-y-su-aplicacion-en-marketing/>
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson.
- Hendler, J. (2008). Avoiding another AI winter. *IEEE Intelligent Systems*, 23(2), 2–4. <https://doi.org/10.1109/MIS.2008.26>

- Higgins, L. R., & Mobley, R. K. (Eds.). (2002). *Maintenance engineering handbook* (2^a ed.). McGraw-Hill.
- Hilal, W., Gadsden, S. A., & Yawney, J. (2022). Financial fraud: A review of anomaly detection techniques and recent advances. *Expert Systems With Applications*, 193, 116429. <https://doi.org/10.1016/j.eswa.2021.116429>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hwang, R. (2025, marzo 5). Amenazas, retos y oportunidades del mundo PyME en la era de la inteligencia artificial. *La Nación*. Recuperado de <https://www.lanacion.com.ar/videos/amenazas-retos-y-oportunidades-del-mundo-pyme-en-la-era-de-la-inteligencia-artificial-nid05032025/>
- IBM. (2024, 8 de julio). IA en ERP. Recuperado de <https://www.ibm.com/es-es/think/topics/ai-in-erp>
- IBM. (s.f.). ¿Qué es la inteligencia artificial (IA) en las empresas? Recuperado de <https://www.ibm.com/es-es/topics/artificial-intelligence-businessibm.com>
- IBM. (s.f.). ¿Qué es la inteligencia artificial en las finanzas? Recuperado de <https://www.ibm.com/es-es/topics/artificial-intelligence-finance>
- Iftikhar, N., Lin, Y.-C., & Nordbjerg, F. E. (2022). Machine learning-based predictive maintenance in manufacturing industry. En *Proceedings of the 14th International Conference on Agents and Artificial Intelligence (ICAART 2022)*. SCITEPRESS. <https://www.scitepress.org/Papers/2022/115373/115373.pdf>
- IndesIA. (2024). Informe del barómetro de la IA en las PYMEs españolas. Recuperado de <https://www.indesia.org/wp-content/uploads/2024/04/IndesIA.-Barometro-de-adopcion-de-la-inteligencia-artificial-en-las-pymes-espanolas-Edicion-2024.pdf>
- Jayakumar, T., Farooqui, F., & Farooqui, L. (2023). Large Language Models are legal but they are not: Making the case for a powerful LegalLLM. *arXiv*. <https://arxiv.org/abs/2311.08890>
- Juran, J. M., & Gryna, F. M. (1993). *Quality planning and analysis: From product development through use* (4^a ed.). McGraw-Hill.
- Kasem, M. S., Hamada, M., & Taj-Eddin, I. (2023). Customer profiling, segmentation, and sales prediction using AI in direct marketing. *arXiv Preprint*. <https://arxiv.org/abs/2302.01786>
- Ker, J., Wang, L., Rao, J., & Lim, T. (2018). Deep learning applications in medical image analysis. *IEEE Access*, 6, 9375-9389. <https://doi.org/10.1109/ACCESS.2017.2788044>
- Khanam, R., Zhang, Y., & Patel, S. (2024). A comprehensive review of convolutional neural networks for defect detection in industrial applications. *IEEE Access*, PP(99), 1-1. <https://doi.org/10.1109/ACCESS.2024.3425166>
- Kohavi, R., & Longbotham, R. (2017). Online controlled experiments and A/B tests. En D. Phung, V. S. Tseng, G. I. Webb, B. Biggio, M. J. Zaki, W. Dou, & H. Shi (Eds.),

Encyclopedia of machine learning and data science. Springer.
https://doi.org/10.1007/978-1-4899-7502-7_891-2

Kotler, P., & Armstrong, G. (2012). Fundamentos de marketing (14^a ed.). Pearson.

Kotsiantis, S. B. (2007). Supervised machine learning: A review of classification techniques. *Informatica*, 31(3), 249–268.
<https://www.informatica.si/index.php/informatica/article/view/148>

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
<https://doi.org/10.1038/nature14539>

Lewis, M., Liu, Y., Goyal, N., Ghazvininejad, M., Mohamed, A., Levy, O., ... & Zettlemoyer, L. (2020). BART: Denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics* (pp. 7871–7880).
<https://arxiv.org/abs/1910.13461>

Lin, J., Men, R., Zhang, Y., Chen, Y., Xu, B., & Sun, M. (2021). M6: A Chinese Multimodal Pretrained Language Model. *arXiv preprint arXiv:2103.00823*.
<https://arxiv.org/abs/2103.00823>

Maheshwari, S., Tiwari, S., Rai, S., & Singh, S. V. D. P. (2024). Comprehensive study of predictive maintenance in industries using classification models and LSTM model. *arXiv Preprint*. <https://arxiv.org/abs/2403.10259>

Marr, B. (2016). *Big data in practice: How 45 successful companies used big data analytics to deliver extraordinary results*. Wiley.

Martin, L., Whitehouse, N., Yiu, S., Catterson, L., & Perera, R. (2024). Better Call GPT: Comparing Large Language Models Against Lawyers. *Onit AI Center of Excellence*.
<https://arxiv.org/abs/2401.16212>

McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (1955). A proposal for the Dartmouth summer research project on artificial intelligence.
<http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133.
<https://doi.org/10.1007/BF02478259>

McDermott, J. (1982). R1: A rule-based configurer of computer systems. *Artificial Intelligence*, 19(1), 1–88. [https://doi.org/10.1016/0004-3702\(82\)90021-2](https://doi.org/10.1016/0004-3702(82)90021-2)

McGrath, R. G. (2013). *The end of competitive advantage: How to keep your strategy moving as fast as your business*. Harvard Business Review Press.

McKinsey & Company. (2023). *La organización del futuro: Habilitada por la IA generativa, impulsada por las personas*. McKinsey & Company. Recuperado de

<https://www.mckinsey.com/featured-insights/destacados/la-organizacion-del-futuro-habilitada-por-la-ia-generativa-impulsada-por-las-personas/es>

McKinsey & Company. (2025). The state of AI: How organizations are rewiring to capture value. McKinsey Digital. <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/a-generative-ai-reset-rewiring-to-turn-potential-into-value-in-2024>

McLean, G., & Wilson, A. (2016). Evolving the online customer experience: Is there a role for online customer support? *Computers in Human Behavior*, 60, 602-608. <https://doi.org/10.1016/j.chb.2016.02.084>

Microsoft News. (2025). 6 AI trends you'll see more of in 2025. Microsoft News Center. <https://news.microsoft.com/en-cee/2025/01/08/6-ai-trends-youll-see-more-of-in-2025/>

Microsoft. (2023). Introducing Microsoft 365 Copilot – your copilot for work. <https://blogs.microsoft.com/blog/2023/03/16/introducing-microsoft-365-copilot-your-copilot-for-work/>

Minsky, M., & Papert, S. (1969). *Perceptrons: An introduction to computational geometry*. MIT Press.

Mistral AI. (2023). Announcing Mistral 7B. Recuperado de <https://mistral.ai/news/announcing-mistral-7b>

Moldovan, D., Cioara, T., Anghel, I., & Salomie, I. (2017). Machine learning for sensor-based manufacturing processes. In 2017 13th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP) (pp. 27-34). IEEE. <https://doi.org/10.1109/ICCP.2017.8116997>

Moreno-Schneider, J., Rehm, G., Montiel-Ponsoda, E., Rodriguez-Doncel, V., Revenko, A., Karampatakis, S., Khvalchik, M., Sageder, C., Gracia, J., & Maganza, F. (2020). Orchestrating NLP Services for the Legal Domain. arXiv. <https://arxiv.org/abs/2003.12900>

Nah, F. F.-H., Zheng, R., Cai, J., Siau, K., & Chen, L. (2023). Generative AI and ChatGPT: Applications, challenges, and AI-human collaboration. *Journal of Information Technology Case and Application Research*, 25(3), 277–304. <https://doi.org/10.1080/15228053.2023.2233814>

Nassif, A. B., Abu Talib, M., Nasir, Q., & Dakalbab, F. M. (2022). Machine learning for anomaly detection: A systematic review. *IEEE Access*, 9, 1755-1763. <https://doi.org/10.1109/ACCESS.2021.3083060>

Ng, A. (2020). How AI could empower any business [Video]. TED. https://www.ted.com/talks/andrew_ng_how_ai_could_empower_any_business

Ng, A. (s.f.). Andrew Ng on the Democratization of AI. Evercopy AI Marketing Blog. Recuperado de <https://www.evercopy.ai/post/empowering-small-businesses-andrew-ng-on-the-democratization-of-ai> evercopy.ai+1

Nilsson, N. J. (1984). *Shakey the Robot*. *AI Magazine*, 5(2), 33–44.

Oakland, J. S. (2007). *Statistical process control* (6^a ed.). Routledge.

- Observatorio PyME. (2021). Informe Especial: Digitalización y desempeño empresarial pre y pospandemia. Fundación Observatorio PyME.
- Observatorio PyME. (2022). Informe Anual 2022: Convergencia productiva entre PYMES y grandes empresas. Fundación Observatorio PyME.
- OCDE (Organización para la Cooperación y el Desarrollo Económicos). (2024). Índice de Políticas para PYMES 2024. OCDE.
- OpenAI. (2024, May 15). Introducing GPT-4o. <https://openai.com/index/introducing-gpt-4o/>
- Patma Digital. (2024, agosto). El Impacto de la Inteligencia Artificial en el Marketing Digital. Recuperado de <https://www.patmadigital.com/el-impacto-de-la-inteligencia-artificial-en-el-marketing-digital-un-futuro-prometedor>
- Quin, F., Weyns, D., Galster, M., & Costa Silva, C. (2022). A/B testing: A systematic literature review. *The Journal of Systems & Software*, 211, 112011. <https://doi.org/10.1016/j.jss.2024.112011>
- Raina, R., Madhavan, A., & Ng, A. Y. (2009). Large-scale deep unsupervised learning using graphics processors. *Proceedings of the 26th International Conference on Machine Learning (ICML)*, 873–880. <https://doi.org/10.1145/1553374.1553486>
- Recuperado de <https://ai.stanford.edu/~nilsson/OnlinePubs-Nils/General%20Essays/Shakey-aimag-17.pdf>
- RegistroPyME. (2024). ¿Qué es una PyME? Recuperado de <https://www.argentina.gob.ar/produccion/registrar-una-pyme/que-es-una-pyme>
- Ries, E. (2011). *The lean startup: How today's entrepreneurs use continuous innovation to create radically successful businesses*. Crown Business.
- Ritter, F., Boskamp, T., Homeyer, A., Laue, H., Schwier, M., Link, F., & Peitgen, H. (2011). Medical image analysis. *IEEE Pulse*, 2(6), 60-70. <https://doi.org/10.1109/MPUL.2011.942929>
- Rogers, E. M. (2003). *Diffusion of innovations* (5th ed.). Free Press. (Obra original publicada en 1962)
- Rojo, S., Plummer, A., Laham, S., Lening, I., Bonanotte, E., Ferraro, C., Schteingart, D., & Benítez, N. (2022). Estructura y dinámica reciente de las MIPYMES empleadoras. Serie Investigaciones en Red, documento N° 7. Centro de Estudios para la Producción XXI, Secretaría de la Pequeña y Mediana Empresa, Ministerio de Desarrollo Productivo de la Nación.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>

- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Saberi, H., Tarokh, M. J., & Ebrahimipour, V. (2017). Contact centers performance evaluation: A systematic literature review. *Journal of Service Management*, 28(5), 919-946. <https://doi.org/10.1108/BPMJ-02-2015-0018>
- SAP Concur. (2024). Inteligencia artificial en la gestión financiera empresarial. Recuperado de <https://www.concur.com.ar/blog/article/inteligencia-artificial-en-la-gestion-financiera-empresarial>
- Secretaría de la Pequeña y Mediana Empresa, los Emprendedores y la Economía del Conocimiento (SPMEEEDC). (2024). *Las Pequeñas y Medianas Empresas, los Emprendedores y la Economía del Conocimiento en Argentina*.
- Shopify. (2024, 19 de octubre). IA en ecommerce: aplicaciones, beneficios y desafíos. Recuperado de <https://www.shopify.com/es/blog/ia-en-ecommerce>
- Shortliffe, E. H. (1976). *Computer-based medical consultations: MYCIN*. Elsevier.
- Siino, M., Falco, M., Croce, D., & Rosso, P. (2025). Exploring LLMs Applications in Law: A Literature Review on Current Legal NLP Approaches. *IEEE Access*, 13, 18253-18276. <https://doi.org/10.1109/ACCESS.2025.3533217>
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., ... & Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484–489. <https://doi.org/10.1038/nature16961>
- Smith, S., Patwary, M., Norick, B., LeGresley, P., Rajbhandari, S., Casper, J., ... & Tiwary, S. (2022). Using DeepSpeed and Megatron to Train Megatron-Turing NLG 530B, A Large-Scale Generative Language Model. arXiv preprint arXiv:2201.11990. <https://arxiv.org/abs/2201.11990>
- Smuha, N. A. (2021). From a “race to AI” to a “race to AI regulation”: Regulatory competition for artificial intelligence. *Law, Innovation and Technology*, 13(1), 57–84. <https://doi.org/10.1080/17579961.2021.1898300>
- Somos PYMEs. (2024, febrero 12). PYMEs argentinas destacadas en la implementación
- Somos PYMEs. (2024, febrero 14). Casos de éxito en la transformación digital de las PYMEs. Somos PYMEs. <https://www.somospymes.com.ar/somos-pymes-tv/casos-exito-la-transformacion-digital-las-pymes-n5394640>
- Strubell, E., Ganesh, A., & McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, 3645–3650. <https://doi.org/10.18653/v1/P19-1355>
- Suganyadevi, M., Geetha, A., Siva Sankari, R., & Kavitha, V. (2021). A review on deep learning approaches in medical image analysis. *Biomedical Signal Processing and Control*, 68, 102741. <https://doi.org/10.1007/s13735-021-00218-1>
- Sun, Y., Wang, S., Li, Y., Feng, S., Tian, H., Wu, H., ... & Wang, H. (2019). ERNIE: Enhanced Representation through Knowledge Integration. arXiv preprint arXiv:1904.09223. <https://arxiv.org/abs/1904.09223>

- Sutton, R. S., & Barto, A. G. (2018). Reinforcement learning: An introduction (2nd ed.). MIT Press. <http://incompleteideas.net/book/the-book-2nd.html>
- Tapscott, D., & Tapscott, A. (2016). Blockchain revolution: How the technology behind bitcoin and other cryptocurrencies is changing the world. Portfolio.
- Tidio. (2025, 11 de febrero). 10 Mejores Chatbots para Atención al Cliente en 2024. Recuperado de <https://www.tidio.com/es/blog/chatbot-atencion-cliente/>
- Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M.-A., Lacroix, T., ... & Scialom, T. (2023). LLaMA 2: Open foundation and fine-tuned chat models. arXiv preprint arXiv:2307.09288. <https://arxiv.org/abs/2307.09288>
- Trad, F., & Chehab, A. (2024). Prompt Engineering or Fine-Tuning? A Case Study on Phishing Detection with Large Language Models. Machine Learning and Knowledge Extraction, 6(1), 367–384. <https://doi.org/10.3390/make6010018>
- Tsuneki, M. (2022). Deep learning models for medical image analysis and clinical implementation challenges. Expert Systems with Applications, 202, 117209. <https://doi.org/10.1016/j.job.2022.03.003>
- Turing, A. M. (1950). Computing machinery and intelligence. Mind, 59(236), 433–460. <https://doi.org/10.1093/mind/LIX.236.433>
- Ünal, Ö. A., Erkeyman, B., & Usanmaz, B. (2022). Applications of artificial intelligence in inventory management: A systematic review of the literature. Archives of Computational Methods in Engineering. <https://doi.org/10.1007/s11831-022-09879-5>
- UNESCO. (2021). Recommendation on the Ethics of Artificial Intelligence. <https://unesdoc.unesco.org/ark:/48223/pf0000381137>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. Advances in Neural Information Processing Systems, 30, 5998–6008.
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., ... & Nerini, F. F. (2020). The role of artificial intelligence in achieving the Sustainable Development Goals. Nature Communications, 11(1), 233. <https://doi.org/10.1038/s41467-019-14108-y>
- Wang, X., & Jia, W. (2025). Optimizing Edge AI: A Comprehensive Survey on Data, Model, and System Strategies. arXiv preprint arXiv:2501.03265. <https://arxiv.org/abs/2501.03265>
- Waters, D. (2003). Inventory control and management (2nd ed.). John Wiley & Sons.
- Wei, C., Zelditch, B., Chen, J., Ribeiro, A. A. S. T., Tay, J. K., Ocejo Elizondo, B., Selvaraj, K., Gupta, A., & De Almeida, L. B. (2024). Neural optimization with adaptive heuristics for intelligent marketing system. arXiv Preprint. <https://arxiv.org/abs/2405.10490>
- Weizenbaum, J. (1966). ELIZA—a computer program for the study of natural language communication between man and machine. Communications of the ACM, 9(1), 36–45. <https://doi.org/10.1145/365153.365168>
- Wells, J. T. (2020). Corporate fraud handbook: Prevention and detection (6th ed.). Wiley.

Xu, Z., Cruz, M. J., Guevara, M., Wang, T., Deshpande, M., Wang, X., & Li, Z. (2024). Retrieval-Augmented Generation with Knowledge Graphs for Customer Service Question Answering. En Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR '24) (pp. 1-5). <https://doi.org/10.1145/3626772.3661370>

Yooz. (2024). Cómo usar la inteligencia artificial en las finanzas. Recuperado de <https://www.getyooz.com/es/blog/inteligencia-artificial-en-finanzas>

Zeng, G., Liu, X., Wang, J., Sun, Z., Zhu, Y., & Huang, X. (2021). PanGu- α : Large-scale Autoregressive Pretrained Chinese Language Models with Auto-parallel Computation. arXiv preprint arXiv:2104.12369. <https://arxiv.org/abs/2104.12369>

ANEXO I – ENCUESTA

El Impacto de la Inteligencia Artificial en las Pymes

Encuesta Anónima para el desarrollo de Tesis EMBA de la Universidad Di Tella - Dirigida a Dueños, Socios y Ejecutivos de Empresas Pymes. Duración estimada: 10 minutos.

** Indica que la pregunta es obligatoria*

1. 1.- ¿Qué función(es) o rol(es) desempeñas en tu empresa? (Selecciona todas las que correspondan)

Selecciona todos los que correspondan.

- ☐ Dueño/Socio
☐ CEO / Gerente General
☐ Director Comercial / Marketing
☐ Director Financiero / CFO
☐ Otro: _____

2. 2.- ¿A qué generación perteneces? *

Marca solo un óvalo.

- ☐ Generación Z o Centennials (nacidos entre 1995 y 2009)
☐ Generación Y o Millennials (nacidos entre 1982 y 1994)
☐ Generación X (nacidos entre 1965 y 1981)
☐ Baby Boomers (nacidos entre 1945 y 1964)
☐ Generación Silenciosa (nacidos antes de 1945)

3. 3.- ¿Con qué género te identificas? *

Marca solo un óvalo.

- ☐ Masculino
☐ Femenino
☐ Otro

4. 4.- ¿A qué rubro o sector pertenece tu empresa? *

Marca solo un óvalo.

- ☐ Comercio Minorista y Mayorista
- ☐ Construcción
- ☐ Agroindustria, Minería y Energía
- ☐ Industria y Manufactura
- ☐ Logística y Transporte
- ☐ Servicios Profesionales y Tecnología
- ☐ Finanzas y Seguros
- ☐ Seguridad, Limpieza y Mantenimiento
- ☐ Servicios de Salud y Educación
- ☐ Turismo, Gastronomía y Hotelería
- ☐ Otro: _____

5. 5.- ¿Cuántos empleados y/o contratados tiene tu empresa *

Marca solo un óvalo.

- ☐ Menos de 10
- ☐ Entre 10 y 49
- ☐ Entre 50 y 99
- ☐ Entre 100 y 199
- ☐ 200 o más

6. 6.- ¿Cuál es el rango de facturación anual de tu empresa, medido en dólares?

Marca solo un óvalo.

- ☐ Menos de 100.000
- ☐ Entre 100.000 y 500.000
- ☐ Entre 500.000 y 1.000.000
- ☐ Entre 1.000.000 y 3.000.000
- ☐ Entre 3.000.000 y 10.000.000
- ☐ Más de 10.000.000
- ☐ Prefiero no responder

7. 7.- ¿Qué herramientas digitales utiliza tu empresa como parte de sus procesos de negocio? (Selecciona todas las que correspondan)

Selecciona todas las que correspondan.

- ☐ Herramientas básicas de oficina (Email corporativo, Web, MS Office).
- ☐ Software de gestión contable (Sistemas de Contabilidad y Facturación).
- ☐ Software de gestión empresarial (ERP, CRM).
- ☐ Marketing digital y Redes Sociales
- ☐ E-commerce (Tienda Online o Plataformas).
- ☐ Herramientas de trabajo colaborativo (Teams, Zoom, Meet).
- ☐ Sistemas en la nube (Almacenamiento, Cloud Computing).
- ☐ Análisis de datos y Business Intelligence (PowerBI, Tableau)
- ☐ Otro: _____

8. 8.- ¿Cómo evaluarías el nivel de digitalización y utilización de herramientas tecnológicas en tu empresa?

Marca solo un óvalo.

- ☐ Muy bajo
- ☐ Bajo
- ☐ Medio
- ☐ Alto
- ☐ Muy alto

9. 9.- ¿Cómo calificarías tu conocimiento sobre inteligencia artificial? *

Marca solo un óvalo.

- ☐ Bajo
☐ Medio
☐ Alto
☐ No estoy seguro

10. 10.- ¿Utilizas ChatGPT u otra herramienta de IA en tu vida cotidiana? *

Marca solo un óvalo.

- ☐ Lo uso regularmente
☐ Lo uso sólo ocasionalmente
☐ No lo uso, pero me interesa aprender más.
☐ No lo uso y no veo utilidad en ello.
☐ No lo conozco

11. 11.- ¿De dónde obtienes información sobre IA? (Selecciona todas las que correspondan)

Selecciona todos los que correspondan.

- ☐ Cursos o capacitaciones
☐ Noticias o artículos en línea
☐ Proveedores de tecnología
☐ Redes sociales
☐ Recomendaciones de colegas
☐ Otro: _____

12. 12.- ¿En qué procesos de tu empresa crees que la inteligencia artificial podría generar mayor impacto o valor? (Selecciona todas las que consideres relevantes para tu negocio)

Selecciona todas las que correspondan.

- ☐ Generación de nuevos clientes (publicidad personalizada, captación de leads)
- ☐ Crecimiento de ventas (campañas de marketing segmentadas, recomendación de productos).
- ☐ Retención de clientes (detección de clientes en riesgo, programas de fidelización, seguimiento post-venta).
- ☐ Atención al cliente (chatbots, automatización de respuestas, análisis de satisfacción).
- ☐ Optimización de precios y promociones (ajuste automático de precios, descuentos personalizados).
- ☐ Automatización de procesos administrativos (reemplazo de carga manual de datos, detección de errores, generación automática de reportes).
- ☐ Gestión de compras y proveedores (comparación de precios, órdenes automatizadas).
- ☐ Gestión financiera y prevención de fraudes (análisis de flujo de caja, detección de pagos o actividades sospechosas).
- ☐ Gestión de recursos humanos (predicción de rotación, clima laboral).
- ☐ Optimización de producción y operaciones (mantenimiento predictivo, control de calidad).
- ☐ No creo que la IA pueda agregar valor a mi negocio

13. 13.- ¿Cómo percibes la incorporación de la inteligencia artificial en tu empresa en el futuro cercano?

Marca solo un óvalo.

- ☐ No vemos la necesidad de incorporar IA en nuestra empresa.
- ☐ Conocemos el tema, pero aún no hemos comenzado a aplicar IA.
- ☐ Estamos evaluando la incorporación de IA, pero aún no hemos tomado una decisión.
- ☐ Estamos comenzando a explorar e implementar IA.
- ☐ Ya utilizamos IA activamente en varios procesos clave.

14. 14.- ¿Cuáles consideras que son los principales desafíos o barreras para implementar IA en tu empresa? (Selecciona todas las que apliquen)

Selecciona todos los que correspondan.

- ☐ Desconocimiento sobre la utilidad para mi negocio
- ☐ Falta de tiempo y recursos
- ☐ Costos elevados para mi empresa
- ☐ Resistencia al cambio dentro de mi equipo
- ☐ No veo una necesidad real para que invirtamos en IA
- ☐ Otro: _____

15. 15.- ¿Qué oportunidades crees que la inteligencia artificial generará para tu empresa en los próximos 5 años? (Selecciona todas las que apliquen)

Selecciona todos los que correspondan.

- ☐ No creo que genere nuevas oportunidades
- ☐ Transformará la experiencia del cliente
- ☐ Mejorará la toma de decisiones estratégicas
- ☐ Fomentará la innovación en la empresa
- ☐ Cambiará la forma del trabajo
- ☐ Acelerará la digitalización empresarial
- ☐ Abrirá nuevas oportunidades de negocio
- ☐ Otro: _____

16. 16.- ¿Estaría dispuesto a invertir en soluciones de IA para tu empresa en los próximos 12 meses?

Marca solo un óvalo.

- ☐ Sí
- ☐ No
- ☐ Tal vez
- ☐ Depende del costo y la rentabilidad esperada.

17. 17.- ¿Qué otra idea o comentario tienes sobre el uso de IA en tu empresa?
(Respuesta abierta)

Este contenido no ha sido creado ni aprobado por Google.

Google Formularios

ANEXO II – RESULTADOS ENCUESTA

https://docs.google.com/spreadsheets/d/1hi5ILKc1gv3SeHUYdq-V0BN_nXIIMJ-jtGbnHq_OB_4/edit?usp=sharing