

**Integración de Business Intelligence, Machine Learning y Big Data en la Industria 4.0:  
Impacto en la administración estratégica y la toma de decisiones empresariales**

Luis Alberto Pallares Vega

Deysi Yulieth Acevedo Duran

Asesor

Andrés Felipe Hernández Giraldo

Universidad Nacional Abierta y a Distancia UNAD  
Escuela de Ciencias Básicas, Tecnología e Ingeniería  
Especialización en Ciencia de Datos y Analítica

2025

## Resumen

En un entorno empresarial marcado por la transformación digital, la integración de Business Intelligence, Machine Learning y Big Data representa un eje clave para la competitividad en la Industria 4.0. Esta monografía analiza cómo estas tecnologías, más allá de su uso individual, se potencian mutuamente al abordar temáticas como la automatización, la personalización, la visualización de datos y la predicción de tendencias, elementos esenciales en la toma de decisiones estratégicas.

El estudio emplea un enfoque cualitativo y documental, sustentado en una revisión sistemática de literatura y casos reales en sectores como manufactura, salud, retail y finanzas. Se identifican y comparan las técnicas y herramientas más relevantes, al tiempo que se profundiza en los principales retos —como la resistencia al cambio y la integración de datos heterogéneos— y los beneficios obtenidos, tales como la eficiencia operativa y la mejora en la toma de decisiones basada en datos.

La monografía ofrece una perspectiva actualizada y crítica, dirigida a profesionales y estudiantes interesados en ciencia de datos y gestión organizacional, con el propósito de facilitar la adopción efectiva de estas tecnologías y aportar valor a la transformación digital empresarial.

**Palabras claves:** Industria 4.0, Internet de las Cosas, Big Data, Business Intelligence, Machine Learning.

## Abstract

In a business environment shaped by digital transformation, the integration of Business Intelligence, Machine Learning, and Big Data is a key driver of competitiveness in Industry 4.0. This monograph analyzes how these technologies, beyond their individual applications, reinforce each other when addressing topics such as automation, personalization, data visualization, and trend prediction—essential elements for strategic decision-making.

The study adopts a qualitative and documentary approach, based on a systematic literature review and real-world cases in sectors such as manufacturing, healthcare, retail, and finance. It identifies and compares the most relevant techniques and tools, while examining the main challenges—such as resistance to change and integration of heterogeneous data—and the benefits achieved, including operational efficiency and improved data-driven decision-making.

This monograph offers an updated and critical perspective, aimed at professionals and students interested in data science and organizational management, with the goal of facilitating the effective adoption of these technologies and contributing value to business digital transformation.

**Keywords:** Industry 4.0, Internet of Things, Big Data, Business Intelligence, Machine Learning.

## Tabla de Contenido

Introducción .....	9
Descripción del Problema .....	11
Planteamiento del Problema .....	11
Justificación .....	13
Objetivos .....	14
Objetivo General .....	14
Objetivos Específicos.....	14
Marco de Referencial .....	15
Marco Conceptual.....	15
Marco Teórico .....	16
Metodología .....	20
Temáticas Empresariales más Abordadas .....	23
Técnicas, Medios y Herramientas más Utilizados en la Industria 4.0 .....	41
Business Intelligence (BI).....	41
Machine Learning (ML) .....	46
Big Data .....	51
Desarrollo de un Análisis Comparativo para Identificar Herramientas Tecnológicas por Sector Empresarial .....	56
Validación de Hallazgos Basados en Casos Documentados .....	58
Retos y Beneficios en la Integración Estratégica.....	64
Análisis Comparativo.....	101
Conclusiones.....	107

Recomendaciones .....	110
Referencias Bibliográficas .....	112
Apéndices.....	120

## Lista de Tablas

<b>Tabla 1</b> <i>Combinaciones de Búsqueda Claves</i> .....	23
<b>Tabla 2</b> <i>Distribución por Sector</i> .....	31
<b>Tabla 3</b> <i>Resumen Revisión de Estudios</i> .....	35
<b>Tabla 4</b> <i>Comparativo Contribución de Temáticas</i> .....	37
<b>Tabla 5</b> <i>Tecnologías, Herramientas y Modelos por Sector</i> .....	56
<b>Tabla 6</b> <i>Beneficios de la Integración</i> .....	103
<b>Tabla 7</b> <i>Retos de la Integración</i> .....	105

## Lista de Figuras

<b>Figura 1</b> <i>Metodología</i> .....	20
<b>Figura 2</b> <i>Diagrama Flujo Prisma</i> .....	25
<b>Figura 3</b> <i>Criterios Evaluación Bibliográfica</i> .....	29
<b>Figura 4</b> <i>Participación Revisión Sistemática de Estudios</i> .....	36
<b>Figura 5</b> <i>Tendencias Temáticas</i> .....	65
<b>Figura 6</b> <i>Predicción de Khan (2020) en una Empresa Retail</i> .....	71

**Lista de Apéndice**

**Apéndice A** *Puntuación de Referencias por Tipología* ..... 120

**Apéndice B** *Matriz Revisión Sistemática de Estudios* ..... 120

## Introducción

La irrupción de la cuarta revolución industrial ha redefinido profundamente la forma en que las empresas gestionan la información y abordan las decisiones estratégicas en un entorno cada vez más competitivo. Las sucesivas revoluciones industriales han marcado hitos que han obligado a las organizaciones a adaptarse a nuevas realidades tecnológicas y culturales. Hoy, inmersas en una era digital caracterizada por la hiperconectividad y la explosión de datos, las empresas enfrentan el reto ineludible de incorporar tecnologías emergentes como Business Intelligence, Machine Learning y Big Data para sostener y potenciar su competitividad.

Esta monografía responde a esa necesidad, analizando cómo la integración de estas tres tecnologías —más allá de su uso individual— potencia la capacidad de las organizaciones para transformar grandes volúmenes de datos en ventajas estratégicas. Mediante un enfoque cualitativo y documental, se realizó una revisión exhaustiva de literatura especializada, complementada con el análisis de casos prácticos en sectores como manufactura, salud, comercio minorista, finanzas y telecomunicaciones. Ello permitió identificar tanto los beneficios concretos de integrar estas herramientas, como los desafíos principales: la resistencia cultural al cambio, la integración de sistemas heterogéneos y la escasez de personal calificado.

El documento también enfatiza la relevancia de promover una cultura organizacional orientada al análisis de datos, lo que habilita decisiones más rápidas, certeras y adaptables. En este sentido, se reconoce al factor humano como pilar fundamental del éxito en cualquier proceso de transformación tecnológica, y se subraya la importancia de prácticas éticas y responsables en el manejo de información, en ámbitos como la privacidad, la seguridad y la transparencia de los procesos analíticos.

Mediante la exposición de experiencias reales y ejemplos tangibles, este trabajo se plantea como una fuente de conocimiento actualizado y como una guía estratégica para profesionales, estudiantes y personas tomadoras de decisiones que buscan capitalizar las oportunidades de la Industria 4.0. Su objetivo principal es acompañar la transición hacia organizaciones más inteligentes, ágiles y centradas en los datos, capaces de anticiparse a las exigencias del futuro y convertir los desafíos en ventajas competitivas sostenibles. Asimismo, la monografía aspira a inspirar nuevas investigaciones sobre el impacto de estas tecnologías, especialmente en pequeñas y medianas empresas, fortaleciendo así su capacidad de innovación y crecimiento en el escenario global.

## Descripción del Problema

### Planteamiento del Problema

La realidad de las empresas atravesó por grandes cambios tras el final de la Segunda Guerra Mundial, con el inicio del llamado proceso de la globalización, donde las economías internacionales comenzaron a cooperar, con lo cual también se inició una revolución tecnológica que llevó a las empresas a darse cuenta de las grandes ventajas competitivas que la información les daba frente a las demás organizaciones, como un pilar para la toma de decisiones (García-Jiménez et al., 2021). En este contexto emergió también el proceso de adopción de tecnologías de información y comunicaciones (ICT) en los procesos productivos, fenómeno que más recientemente ha sido reconocido bajo el nombre de Industria 4.0 (Silva et al., 2021).

La Industria 4.0 representa un nuevo paradigma basado en el uso intensivo de tecnologías digitales para adquirir y procesar datos en tiempo real, generando así información valiosa o *insights* para optimizar decisiones estratégicas (Alshahrani, 2023). En este marco emergen tecnologías como Business Intelligence (BI), Machine Learning (ML) y Big Data Analytics, las cuales han sido objeto de numerosas revisiones científicas respecto a su implementación en distintos sectores de la economía (Alqhatani et al., 2022). Sin embargo, a pesar de este creciente interés, aún son escasos los estudios que analizan su interrelación práctica, su complementariedad tecnológica y, sobre todo, su impacto conjunto en la administración estratégica y la toma de decisiones organizacionales (Bordeleau et al., 2020).

Ante esta carencia, la presente monografía busca consolidar, de forma estructurada y crítica, el conocimiento disponible en torno a la relación entre BI, ML y Big Data, identificando cómo se implementan, cuáles son sus componentes, medios, ventajas, retos y las industrias donde su aplicación es más frecuente. De esta manera, se pretende ofrecer una visión amplia

pero rigurosa que permita a organizaciones, estudiantes e interesados comprender la integración de estas herramientas en la dinámica empresarial contemporánea.

Existe, pues, una necesidad latente de revisar, clasificar y sintetizar la evidencia académica y aplicada que explore cómo estas tres tecnologías se integran de forma articulada en entornos reales. Esta falta de integración conceptual y operativa limita el verdadero aprovechamiento de su potencial analítico y predictivo. Por ello, el propósito de esta investigación no es solo describir el estado del arte, sino también generar una visión unificada, aplicable y estratégica que sirva como guía para investigadores, empresas y tomadores de decisión que deseen diseñar estrategias más inteligentes, basadas en datos y ajustadas a los desafíos de la Industria 4.0.

## Justificación

Los ambientes empresariales se han tornado más complejos en el contorno de la industria 4.0 y para dar pronta respuesta a estos mercados dinámicos, las empresas requieren de la innovación y la tecnología (Tavera Romero et al., 2021). Adicional, a través del uso de estas tecnologías emergentes se logra ver una mejora en la competitividad y el desempeño de los procesos, además de lograr productos innovadores, nuevos servicios y cambios en los modelos de negocio tradicionales (Bordeleau et al., 2020).

En la reciente era de avances tecnológicos e hipercompetitividad los sistemas de Business Intelligence han atraído atención significativa de los ejecutivos (Ain et al., 2019), además de la importancia que toma el Big Data para muchas organizaciones con la masiva cantidad de datos que se generaran cada día (Amalina et al., 2020) y la concepción del Machine Learning como uno de los tres pilares de la analítica (Raghupathi & Raghupathi, 2021a), sientan un precedente de importancia suficiente para dedicar el esfuerzo de abordar estos temas en la presente monografía, donde los principales beneficiados serán las organizaciones que están en proceso de adhesión a esta nueva realidad.

Como lo expresa Bordeleau et al. (2020), a pesar de que existe literatura sobre estos temas, poca de esta se enfoca en la aplicación para la administración estratégica y la toma de decisiones orientada en datos por medio de estas tecnologías. Adicional, algunos tipos de empresas se encuentran poco representadas en estas revisiones, con lo cual, con la presente monografía se busca la generación del conocimiento que facilite la correcta aplicación de los temas tratados para todos los tipos de organizaciones, y a su vez el entendimiento y comprensión de estos para la generación de más conocimiento a partir de nuevos trabajos futuros.

## **Objetivos**

### **Objetivo General**

Analizar la relación e integración entre Business Intelligence, Machine Learning y Big Data en el contexto de la Industria 4.0, con el fin de comprender su impacto en la administración estratégica y en la toma de decisiones empresariales.

### **Objetivos Específicos**

Identificar las temáticas empresariales más-abordadas mediante la aplicación de Inteligencia de Negocios, Machine Learning y Big Data en la industria 4.0, relacionadas con la toma de decisiones estratégicas.

Determinar las técnicas y herramientas utilizadas en la implementación de la Inteligencia de Negocios, Machine Learning y Big Data en procesos de análisis y gestión empresarial.

Establecer los principales retos y beneficios que enfrentan las organizaciones al integrar estas tecnologías en su gestión estratégica.

## Marco de Referencial

### Marco Conceptual

Variable dependiente. De acuerdo con lo que plantea Granados (2016), se entiende que la variable independiente es aquella que se encuentra al lado izquierdo de la igualdad y cuyo valor es el que se pretende determinar por medio de las variables independientes presentes en el lado izquierdo de la igualdad.

Variable independiente. De acuerdo con lo que plantea Granados (2016), se entiende que la variable dependiente es aquella, o aquellas, que se encuentra(n) al lado derecho de la igualdad y cuyo valor es el que permite determinar el valor de la variable dependiente.

Gradiente. De acuerdo con Raschka & Mirjalili (2017), el gradiente de una función es el resultado de derivar parcialmente cada una de las variables de la función.

Array. VanderPlas (2023) establece que los arrays de NumPy son semejantes a las listas de Python, pero estos tienen una mayor eficiencia en almacenamiento y operaciones de datos a medida que el array se va haciendo más grande. Además, los arrays son el núcleo de casi todo el ecosistema de las herramientas de ciencia de datos de Python.

Series. Para McKinney (2022) las series de pandas son objetos unidimensionales similares a los arrays que contienen una secuencia de valores del mismo tipo y que se encuentran asociados a un array con etiquetas denominado como índice. Además, VanderPlas (2023) menciona que estos objetos combinan una secuencia de valores con una secuencia explícita de índices, a los cuales se puede acceder con los valores almacenados en la serie o con su respectivo índice.

DataFrame. Para McKinney (2022) un DataFrame representa una tabla de datos rectangular que contiene una colección de columnas ordenadas y con nombre, las cuales pueden

ser cada una de un tipo de valor diferente. También menciona que tanto filas y columnas poseen un índice y puede interpretarse como un diccionario de series de pandas que comparten el mismo índice.

**Algoritmo.** Procedimiento computacional que comienza en un valor o valores con un estado inicial, el cual lleva a una solución tras ejecutar una serie de pasos definidos y finitos. (Garate, 2022)

**Aprendizaje supervisado.** Son algoritmos que tienen un aprendizaje previo basado en un sistema de etiquetas que les permite tomar decisiones o predicciones. (Iberdorla, 2022)

**Aprendizaje no supervisado.** Son algoritmos No tienen ningún conocimiento previo. Están tratando de encontrar patrones que les permitan organizarse de alguna manera. (Iberdorla, 2022)

**Aprendizaje por refuerzo.** Se trata de algoritmos que aprenden de su experiencia, lo que les permite tomar la mejor decisión en diferentes situaciones según un proceso de prueba y error, donde las decisiones correctas son recompensadas. (Iberdorla, 2022)

**Base de datos.** Es un conjunto organizado de información o datos estructurados, generalmente almacenados electrónicamente en un sistema informático. (Oracle, 2013)

**KPI.** Es un valor medible cualitativa o cuantitativamente, que suele expresarse en porcentajes o proporciones, con ayuda del cual se puede evaluar el progreso en la consecución de los objetivos marcados en la empresa. (Lanza Cruz, 2016)

## **Marco Teórico**

La industria 4.0, de acuerdo con lo expresado por Alshahrani (2023), es un término que también es utilizado para referirse a la llamada cuarta revolución industrial, además de mencionar que esta es un nuevo paradigma que se basa en el uso de las tecnologías digitales para

adquirir y procesar datos en tiempo real y alimentar los sistemas de manufactura con información. Adicional, Alshahrani establece al internet de las cosas (IoT), la computación en la nube y la analítica del Big Data como las tecnologías críticas que permiten habilitar la industria 4.0.

Agregado a lo anterior, Silva et al. (2021) menciona que el origen del término Industria 4.0 se da en el año 2011 en Alemania, donde el Ministerio de Educación e Investigación la definió como la flexibilidad que existe en las redes de creación de valor y su incremento por la aplicación de sistemas de producción ciber físicos. Adicional también menciona que el término también se ha utilizado para caracterizar una gran cantidad de adopciones de las tecnologías de la información y comunicación (ITC) en los procesos de producción, como por ejemplo el IoT.

En medio de todo esto, Silva et al. mencionan una de las grandes ITC, como lo es la Analítica de Negocios, la cual incluye métodos de procesamiento de datos para toma de decisiones como la optimización, los pronósticos, el modelamiento predictivo y el análisis estadístico, cuyo objetivo principal es la extracción de conocimiento útil y práctico de datos históricos.

En la analítica de negocios, Silva et al. (2021a) menciona al Grupo Gartner, que en 2013 definió 4 tipos de analítica: descriptiva (“¿Qué sucedió?”), diagnóstica (“¿Por qué sucedió?”), predictiva (“¿Qué sucederá?”) y prescriptiva (“¿Cómo podemos hacer que suceda?”), para las cuales, la analítica descriptiva y diagnóstica se vale de herramientas como la inteligencia de negocios y los sistemas de big data para dar respuesta a sus interrogantes, mientras que la analítica prescriptiva y predictiva responde las suyas por medio del análisis estadístico y el machine learning.

Paradza & Daramola (2021) hablan del surgimiento de la analítica de negocios cerca del

inicio de la década de los 2000, como una herramienta centrada en el análisis, surgida a partir de la evolución de la inteligencia de negocios, que tuvo su introducción en la década de los 90, la cual es definida por Tavera Romero et al. (2021) como un proceso de toma de decisiones basado en la integración y análisis de las fuentes de datos de las organizaciones, que con la constitución de los datos como un nuevo tipo de activo económico para las organizaciones, está jugando un rol crítico en muchos tipos de compañías, como el medio para el desarrollo de este nuevo tipo de activo económico.

De acuerdo con Srivastava et al. (2022), la inteligencia de negocios es principalmente utilizada para almacenar y compartir información de las organizaciones, apoyando y desarrollando las prácticas empresariales de estas, con decisiones impecables en todos los aspectos. Adicional, Srivastava et al. mencionan que entre los recursos que la inteligencia de negocios tiene a su disposición, se encuentran los almacenes de datos, los procesos ETL (Extracción, Transformación y Carga) y el OLAP (Procesamiento Analítico en Línea).

Retomando la idea anterior, se observa que los datos juegan un papel muy importante para la inteligencia de negocios, por lo cual resulta coherente que Paradza & Daramola mencionen que el término más reciente en evolucionar a partir de la inteligencia de negocios sea el de big data, el cual se refiere a grandes y complejos volúmenes de conjuntos de datos que requieren de herramientas dedicadas para sintetizar la información que contienen. Amalina et al. (2020) menciona que el Big Data es la combinación de varios factores como el tiempo el tipo de datos y consiste en grandes volúmenes, a alta velocidad, complejidad y variabilidad, los cuales requieren métodos y tecnologías avanzados para lograr capturar, almacenar, distribuir, administrar y analizar la información.

Por otro lado, el machine learning, según Rachman et al. (2021), es una parte de la


inteligencia artificial (AI) que le permite al sistema aprender de los datos en lugar de ser programado de manera explícita para esto, utilizando una gran cantidad de algoritmos repetitivos para mejorar, describir los datos y predecir resultados.

## Metodología

La metodología empleada en esta monografía se fundamenta en un enfoque cualitativo, con alcance exploratorio y diseño documental, buscando ofrecer una visión integral y sistemática sobre la integración de Business Intelligence, Machine Learning y Big Data en el contexto de la Industria 4.0. El proceso metodológico se estructuró en una secuencia lógica de etapas interrelacionadas que permitieron abordar los objetivos de investigación desde diferentes perspectivas y niveles de profundidad, de esta manera:

### Figura 1

#### *Metodología*



*Nota.* En la figura 1, en primer lugar, se llevó a cabo una exhaustiva revisión sistemática de literatura científica y académica, guiada por el protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), reconocido internacionalmente por su rigor y transparencia en la síntesis de evidencia científica (Moher et al., 2009). Esta revisión abarcó publicaciones comprendidas entre los años 2018 y 2025, seleccionando artículos en bases de datos especializadas como Scopus, ScienceDirect, IEEE Xplore y Google Scholar.

Para garantizar la pertinencia y calidad de las fuentes, se definieron criterios estrictos de inclusión y exclusión, considerando aspectos como la actualidad de los documentos, la relevancia temática para los objetivos propuestos, el tipo de fuente (artículos revisados por pares, libros académicos y reportes técnicos), el idioma, y el rigor académico evidenciado en la

metodología de los textos. Adicionalmente, se diseñó y aplicó una matriz de evaluación para calificar cada fuente en cuatro dimensiones: actualidad, pertinencia temática, claridad metodológica y aplicabilidad práctica, asignando un puntaje que permitió identificar aquellas referencias con mayor potencial para contribuir significativamente a la investigación.

Posteriormente, los artículos seleccionados fueron sometidos a un proceso de análisis temático y de variables, el cual consistió en la identificación, codificación y agrupación de los principales hallazgos según categorías clave establecidas previamente, tales como automatización, visualización, predicción, personalización y eficiencia operativa. Esta etapa fue fundamental para detectar patrones comunes, así como diferencias relevantes en el uso y el impacto de las tecnologías analizadas, permitiendo establecer relaciones entre sectores económicos, áreas funcionales y tipos de herramientas aplicadas. El análisis de variables, inspirado en metodologías comparativas como la empleada por García Meza & Lázaro Barrera (2025), permitió un abordaje más profundo sobre cómo cada tecnología y técnica contribuye de manera específica a la toma de decisiones y la gestión organizacional en diferentes contextos.

A continuación, se realizó un análisis comparativo y una validación de los hallazgos obtenidos mediante la inclusión de casos documentados. Para ello, se seleccionaron experiencias reales de organizaciones que han implementado soluciones de Business Intelligence, Machine Learning o Big Data en sectores como manufactura, salud, retail, finanzas y telecomunicaciones. Estos casos, extraídos tanto de la literatura revisada como de estudios sectoriales y reportes técnicos, fueron analizados de manera crítica para contrastar la evidencia teórica con la práctica, tomando en cuenta criterios como la aplicabilidad, el impacto real y la replicabilidad de las soluciones implementadas. Esta triangulación metodológica, al confrontar teoría y práctica, contribuyó a fortalecer la validez de los resultados y a extraer aprendizajes transferibles a otros

entornos empresariales.

Finalmente, se incorporó una reflexión crítica sobre las principales limitaciones metodológicas encontradas durante el desarrollo del estudio, tales como la posible existencia de sesgos en la selección y disponibilidad de literatura, la dificultad para comparar resultados entre sectores o países debido a la heterogeneidad de contextos, y los desafíos derivados de la rápida evolución tecnológica que caracteriza el ámbito de la Industria 4.0. Esta sección no solo reconoce los alcances reales del trabajo realizado, sino que también propone recomendaciones y líneas de mejora para investigaciones futuras, enfatizando la necesidad de mantener una actitud abierta a la actualización continua y a la integración de nuevos enfoques metodológicos.

En síntesis, la metodología de la presente monografía se distingue por su estructura integral, el uso de herramientas reconocidas para la revisión y el análisis, y la articulación entre diferentes métodos que garantizan la robustez, relevancia y aplicabilidad de los resultados obtenidos. Todo esto asegura que los hallazgos y conclusiones sean pertinentes tanto para el ámbito académico como para la práctica profesional en el contexto de la transformación digital y la gestión de datos en las organizaciones modernas.

### Temáticas Empresariales más Abordadas

Como parte del proceso de búsqueda, se definieron términos específicos y combinaciones clave para asegurar la recuperación de información relevante en las principales bases de datos académicas, como Scopus, Web of Science, IEEE Xplore, ScienceDirect y Google Scholar. Estos términos incluyeron conceptos relacionados como "Business Intelligence", "Machine Learning", "Big Data", "Industry 4.0" y "Data Analytics", entre otros. La selección cuidadosa de estas palabras clave permitió dirigir las búsquedas hacia estudios de alta calidad y con un enfoque preciso en las áreas de interés del proyecto. Esta estrategia aseguraba la inclusión de publicaciones pertinentes y científicamente rigurosas, mejorando la profundidad y representatividad del análisis final.

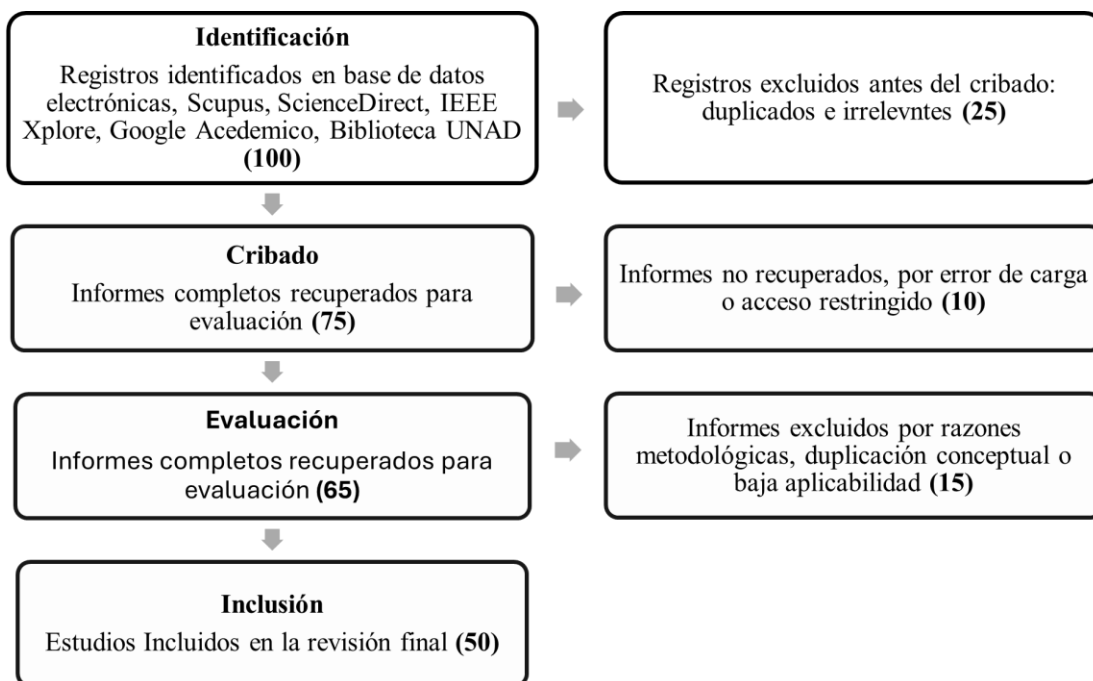
**Tabla 1**

*Combinaciones de Búsqueda Claves*

	Business Intelligence	Machine Learning	Big Data	Industry 4.0	Data Analytics	Predictive Analytics
BI	-	Business Intelligence + Machine Learning	Business Intelligence + Big Data	Business Intelligence + Industry 4.0	Business Intelligence + Data Analytics	Business Intelligence + Predictive Analytics
ML	Machine Learning + Business Intelligence	-	Machine Learning + Big Data	Machine Learning + Industry 4.0	Machine Learning + Data Analytics	Machine Learning + Predictive Analytics

	Business Intelligence	Machine Learning	Big Data	Industry 4.0	Data Analytics	Predictive Analytics
Big Data	Big Data + Business Intelligence	Big Data + Machine Learning	-	Big Data + Industry 4.0	Big Data + Data Analytics	Big Data + Predictive Analytics
Industry 4.0	Industry 4.0 + Business Intelligence	Industry 4.0 + Machine Learning	Industry 4.0 + Big Data	-	Industry 4.0 + Data Analytics	Industry 4.0 + Predictive Analytics
Data	Data + Business Intelligence	Data + Machine Learning	Data + Big Data	Data + Industry 4.0	-	Data + Predictive Analytics
Analytics	Analytics + Business Intelligence	Analytics + Machine Learning	Analytics + Big Data	Analytics + Industry 4.0	Analytics + Data Analytics	Analytics + Predictive Analytics
Predictive	Predictive + Business Intelligence	Predictive + Machine Learning	Predictive + Big Data	Predictive + Industry 4.0	Predictive + Data Analytics	-
Analytics	Analytics + Business Intelligence	Analytics + Machine Learning	Analytics + Big Data	Analytics + Industry 4.0	Analytics + Data Analytics	

La tabla 1 muestra todas las posibles combinaciones entre los conceptos clave mencionados. Estas combinaciones sirvieron como base para identificar investigaciones, propuestas de proyectos o modelado de relaciones entre tecnologías y enfoques estratégicos en diversos contextos industriales que pudieran ser de utilidad para el desarrollo del proyecto.

**Figura 2***Diagrama Flujo Prisma*

*Nota.* El proceso inicial recolectó 100 artículos, los cuales fueron sometidos a un exhaustivo proceso de evaluación basado en criterios de inclusión y exclusión rigurosamente definidos. Entre estos criterios se encontraban la pertinencia temática, que aseguraba que los estudios seleccionados respondieran a los enfoques clave de la investigación; la claridad metodológica, que garantizaba la precisión y validez de las metodologías empleadas; la actualidad, que verificaba la relevancia temporal de los artículos frente a los avances más recientes; y la aplicabilidad práctica, donde se evaluaba su potencial para ser implementados en escenarios empresariales o en organizaciones.

Este proceso de depuración se llevó a cabo con el objetivo de garantizar que cada artículo seleccionado aportara un valor significativo a la investigación, eliminando aquellos con limitaciones conceptuales o metodológicas. Como resultado, se seleccionaron 50 artículos de alta

calidad que no solo representaban un análisis y resultados profundos, sino que también cubrían de manera efectiva las áreas de interés definidas en el marco del estudio, estableciendo una base sólida para el desarrollo de la monografía.

Para lograr una mayor comprensión de los artículos trabajados, se procedió a una clasificación detallada basada en el sector industrial al que pertenecían, como manufactura, salud, retail, finanzas y telecomunicaciones. Además, se realizó una segmentación adicional según el área funcional, incluyendo logística, marketing, producción, finanzas y recursos humanos. Este enfoque permitió identificar patrones específicos y aplicaciones prácticas que enriquecieron significativamente el análisis, generando una visión integral y multifacética del impacto de las tecnologías en distintos contextos empresariales e industriales.

Para evaluar los artículos seleccionados, se implementó una matriz comprensiva de evaluación que permitió analizar cada estudio desde múltiples perspectivas clave. Este enfoque garantizó una valoración equilibrada y exhaustiva, considerando los siguientes criterios:

1. Actualidad: Se evaluó la relevancia temporal de cada artículo en relación con los avances más recientes en los campos de interés, asegurando que los documentos seleccionados reflejaran las tendencias y descubrimientos contemporáneos (Alasa, 2021; García Meza & Lázaro Barrera, 2025).

2. Pertinencia temática: Se verificó la alineación del contenido de los artículos con los enfoques fundamentales de la investigación, como Business Intelligence, Machine Learning, Big Data e Industria 4.0, garantizando que cubrieran temas esenciales para los objetivos del proyecto (Boulahia et al., 2024).

3. Claridad metodológica: Se consideró el rigor y la precisión de las metodologías empleadas en cada estudio. Este criterio permitió identificar investigaciones con enfoques bien

estructurados y detallados, favoreciendo la validez de los hallazgos (Sharma et al, 2021; Rane et al., 2024).

4.Aplicabilidad práctica: Se analizó el potencial de cada artículo para ser aplicado en escenarios empresariales o industriales reales, identificando aquellos trabajos que podían generar impactos tangibles y transferibles a contextos de la vida real (Figuroa-Donayre et al., 2023; Al-Zoubi et al., 2023).

Este enfoque multifacético no solo facilitó una evaluación robusta de las referencias trabajadas, sino que también ayudó a establecer una base documental que combina actualidad, pertinencia, profundidad metodológica y valor práctico, todos elementos clave para el desarrollo exitoso de la investigación.

Cada criterio fue evaluado utilizando una escala del 1 al 5, lo que permitió asignar un puntaje preciso según el grado de cumplimiento de cada artículo con los estándares definidos. El puntaje total máximo que un artículo podía alcanzar era de 20 puntos. De los estudios seleccionados, la mayoría obtuvo un promedio superior a 16 puntos, evidenciando no solo una alta calidad en los contenidos, sino también una alineación clara con los objetivos de la investigación. Este enfoque aseguró que los artículos retenidos no solo cumplieran con los requisitos metodológicos y temáticos, sino que también aportaran un valor significativo como base para el análisis y desarrollo del proyecto.

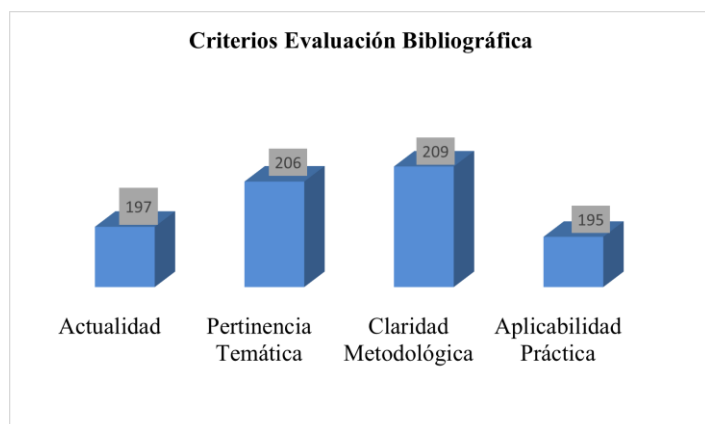
La implementación rigurosa del protocolo PRISMA desempeñó un papel fundamental en el proceso de selección de artículos, ya que permitió evitar sesgos que podrían haber comprometido la calidad de la investigación, garantizando una muestra representativa y sólida de literatura científica. Este protocolo no solo ofreció una estructura clara para documentar de manera transparente el flujo de selección de los estudios, fortaleciendo así la validez y la

replicabilidad de la revisión, sino que también facilitó una codificación temática eficiente, que fue clave para el análisis cuantitativo posterior. Además, su aplicación aseguró que cada etapa de la selección estuviera alineada con los objetivos del proyecto, maximizando la calidad y relevancia de los resultados obtenidos.

En el Apéndice 1 se presenta en detalle la clasificación tipológica de cada artículo identificado en la búsqueda exhaustiva realizada. A cada estudio se le asignó una calificación del 1 al 5, donde 5 representa el mayor grado de enfoque en el tema correspondiente. En este sentido, se destaca el artículo "**03. Khan et al., 2020**", que obtuvo la puntuación más alta (20 puntos), lo que lo posiciona como el estudio de mayor relevancia temática para el presente trabajo. Además, se distingue por su claridad metodológica, actualidad y nivel de aplicabilidad.

Continuando con el análisis del Apéndice 1, se presenta un resumen con los totales agrupados por criterios de evaluación. Este resumen permite identificar cuál es el enfoque predominante entre las investigaciones analizadas.

En la Figura 2, se muestra la suma total por criterio de todos los artículos que se les dio una puntuación en el Apéndice 1:

**Figura 3***Criterios Evaluación Bibliográfica*

*Nota.* De acuerdo con el análisis presentado en el gráfico de barras y la tabla previa, se evidencia que la mayoría de las referencias seleccionadas dentro de la muestra obtenida presentan una puntuación destacada en el criterio de Claridad Metodológica. Este resultado subraya la importancia de enfoques bien estructurados y transparentes para facilitar la comprensión de los conceptos clave y su aplicación en la resolución de problemas relacionados con la Industria 4.0. En términos cuantitativos, Claridad Metodológica lidera con un puntaje acumulado de 209, seguido de cerca por Pertinencia Temática con 206 puntos, lo que resalta que los estudios seleccionados abordan directamente las problemáticas y oportunidades vinculadas a esta área.

Por otro lado, el criterio de Actualidad obtuvo 197 puntos, un indicador de que la mayoría de los trabajos seleccionados se publicaron en años recientes, alineándose con la necesidad de contar con información contemporánea para analizar las tendencias emergentes en Business Intelligence, Machine Learning y Big Data. Finalmente, el criterio de Aplicabilidad en la Industria, con 195 puntos, refleja cómo estos estudios proveen ejemplos prácticos y casos de uso

concretos que pueden ser adaptados a distintos sectores dentro de la Industria 4.0, como manufactura, salud, retail, finanzas y telecomunicaciones.

Estos resultados no solo validan el rigor en la selección de los estudios incluidos, sino que también permiten establecer un marco confiable para su clasificación y análisis posterior, garantizando que los aportes de cada referencia puedan ser aprovechados al máximo en el contexto del proyecto. La información obtenida servirá como base para explorar cómo las tecnologías emergentes están transformando los procesos empresariales y las estrategias de toma de decisiones en un entorno cada vez más interconectado y digitalizado.

Para abordar de manera integral los estudios seleccionados, se estableció una taxonomía detallada que permitió clasificar los artículos en tres dimensiones principales. En primer lugar, se consideró el sector industrial al que cada investigación estaba orientada. Esto incluyó áreas clave como manufactura, salud, retail, finanzas y telecomunicaciones, reflejando la diversidad de aplicaciones de las tecnologías emergentes en distintos contextos económicos y sociales (Sandner et al., 2020, p. 8; Ain et al., 2019b, p. 115). Cada uno de estos sectores enfrenta desafíos únicos, y los estudios analizados contribuyen a proponer soluciones específicas que optimizan procesos, mejoran la eficiencia y amplían la capacidad de adaptación en entornos digitales.

En segundo lugar, se evaluaron las tecnologías aplicadas en cada artículo, destacando cinco pilares fundamentales: Business Intelligence (BI), Machine Learning (ML), Big Data, Internet de las Cosas (IoT) y Blockchain. Este enfoque permitió identificar si los estudios se centraban en una tecnología específica o si exploraban la convergencia entre ellas para abordar problemas complejos en la Industria 4.0 (Raghupathi & Raghupathi, 2021, p. 6; Paradza & Daramola, 2021, p. 14). La integración de estas tecnologías no solo impulsa la innovación, sino

que también permite adoptar enfoques multidisciplinarios que enriquecen las soluciones propuestas.

Finalmente, se examinó el área funcional de las investigaciones, que incluyó ámbitos como logística, marketing, producción, finanzas, recursos humanos y la toma de decisiones estratégicas. Este análisis permitió identificar cómo cada tecnología contribuye a optimizar funciones específicas dentro de las organizaciones, ofreciendo herramientas que fortalecen la competitividad en mercados globalizados y orientan las estrategias empresariales hacia un futuro más sostenible y eficiente (Niu et al., 2021, p. 5; Richards et al., 2019, p. 191).

Este esquema taxonómico no solo facilitó la organización de los artículos seleccionados, sino que también ayudó a visualizar con claridad las tendencias emergentes y los impactos concretos de las tecnologías analizadas en diversos aspectos de la Industria 4.0.

A continuación, se detalla la distribución de artículos clasificados por sector y las tecnologías aplicadas, señalando que algunos documentos abarcan múltiples categorías:

**Tabla 2**

*Distribución por Sector*

Sector	BI	ML	Big Data	IoT	Blockchain	Total
Manufactura	15	20	18	12	8	43
Salud	13	14	16	10	5	33
Retail	14	12	14	9	4	29
Finanzas	11	15	12	8	6	28
Telecomunicaciones	9	7	10	6	3	18

La tabla 2 se muestra cómo la manufactura y el sector salud concentran la mayor parte de la investigación, lo cual evidencia un interés creciente en digitalizar procesos y optimizar la toma de decisiones mediante la implementación de tecnologías emergentes como Business Intelligence (BI), Machine Learning (ML) e Internet de las Cosas (IoT) (Sandner et al., 2020; Ain et al., 2019). En el caso de la manufactura, estas tecnologías no solo buscan mejorar la eficiencia operativa, sino también optimizar cadenas de suministro, reducir desperdicios y aumentar la capacidad de respuesta frente a cambios en la demanda. Por su parte, en el ámbito de la salud, se destacan aplicaciones como la integración de análisis predictivo con historiales médicos electrónicos y la mejora en la precisión de diagnósticos clínicos, lo que contribuye a tratamientos más personalizados (Yin & Fernandez, 2020; Paradza & Daramola, 2021).

En el sector retail, la personalización de la experiencia del cliente y el análisis de su comportamiento mediante Big Data y herramientas de Business Intelligence son prácticas predominantes. Estas tecnologías permiten a las empresas anticiparse a las necesidades del consumidor, optimizar estrategias de marketing y gestionar inventarios de manera más eficiente. Además, el análisis en tiempo real de grandes volúmenes de datos facilita la identificación de patrones de compra, contribuyendo a una mayor fidelización del cliente. En este contexto, se resaltan también las iniciativas para integrar sistemas de recomendación automatizados y potenciar la experiencia de usuario a través de plataformas digitales (Niu et al., 2021).

En el ámbito financiero, se observa un enfoque aún más especializado en la detección de fraudes y la optimización de procesos financieros mediante tecnologías como Blockchain y Machine Learning. Estas innovaciones no solo incrementan la seguridad de las transacciones, sino que también mejoran la capacidad de prever riesgos y gestionar carteras de inversión. El uso de Blockchain ha permitido un avance significativo en la transparencia y trazabilidad de las

operaciones financieras, mientras que los algoritmos de ML están siendo utilizados para reconocer patrones sospechosos en grandes volúmenes de datos, reduciendo significativamente el tiempo de respuesta frente a posibles amenazas (Richards et al., 2019; Raghupathi & Raghupathi, 2021).

Por último, en el sector de telecomunicaciones, aunque el volumen de investigación es menor en comparación con otros sectores, se está observando un interés creciente en integrar Big Data con tecnologías emergentes para la gestión de redes y servicios. Estas soluciones buscan optimizar el rendimiento de las infraestructuras, mejorar la experiencia del cliente y anticipar posibles fallos en los sistemas. Además, se destacan iniciativas para el despliegue de redes inteligentes que, mediante el uso de Big Data y herramientas analíticas, permiten una mayor eficiencia en la asignación de recursos y una respuesta más rápida a las demandas del mercado. Este sector también está explorando la implementación de 5G, que promete transformar la conectividad y abrir nuevas posibilidades para aplicaciones como la realidad aumentada y el Internet de las Cosas (Chen et al., 2022).

Para analizar de manera exhaustiva las temáticas empresariales tratadas en los estudios seleccionados, se desarrolló una matriz de codificación estructurada en cinco categorías principales: automatización, visualización, predicción, personalización y eficiencia operativa. Cada categoría fue seleccionada con base en su relevancia para la transformación digital y el impacto en los procesos organizativos.

La metodología empleada incluyó una codificación binaria (Ver Apéndice 2), donde cada categoría se evaluó en términos de presencia (1) o ausencia (0) dentro del contenido de los artículos revisados. Este enfoque permitió una cuantificación precisa y objetiva de las coincidencias temáticas, lo que a su vez facilitó la identificación de patrones y la comparación

entre diferentes estudios. Además, la matriz no solo ayudó a resumir y clasificar la información, sino que también proporcionó una base sólida para futuras investigaciones sobre tendencias en la adopción de tecnologías emergentes en diversos sectores empresariales.

Los resultados obtenidos de la revisión sistemática de estudios (Ver Apéndice 2) muestran que un significativo 60% de los documentos analizados aborda temáticas relacionadas con personalización. Este enfoque se centra en un enfoque en las necesidades personales de los clientes para mayor experiencia. También el 54% de los estudios se orienta hacia la visualización y como las organizaciones tienen un mayor enfoque en el business intelligence y en la presentación de sus datos para tener una mejor visión de negocio y en la mejora de la toma de decisiones estratégicas. Por otro lado, un 46% de los 50 artículos son predictivos, en los cuales se aprovechan herramientas y técnicas avanzadas para anticipar comportamientos, tendencias y eventos, particularmente en áreas como el análisis del consumidor y la gestión de riesgos financieros. de los estudios abordados, el 44% se orienta hacia la automatización, explorando cómo los procesos pueden ser optimizados mediante tecnologías como la Automatización Robótica de Procesos (RPA) y sistemas autónomos, lo que resulta crucial en sectores industriales y de manufactura (Dueñas-Ramírez et al., 2020). Asimismo, un 44% se enfoca en la eficiencia operativa, mostrando cómo tecnologías emergentes como IoT y Big Data pueden ser aplicadas para el mantenimiento predictivo y la optimización de recursos, reduciendo costos y aumentando la productividad (A. Sharma et al., 2021).

Cómo los procesos pueden ser optimizados mediante tecnologías como la Automatización Robótica de Procesos (RPA) y sistemas autónomos, lo que resulta crucial en sectores industriales y de manufactura (Dueñas-Ramírez et al., 2020). Asimismo, un 44% se enfoca en la eficiencia operativa, mostrando cómo tecnologías emergentes como IoT y Big Data pueden ser aplicadas

para el mantenimiento predictivo y la optimización de recursos, reduciendo costos y aumentando la productividad (A. Sharma et al., 2021).

**Tabla 3**

*Resumen Revisión de Estudios*

Tema	Q	% Part
Automatización	22	18%
Visualización	27	22%
Predicción	23	19%
Personalización	30	24%
Eficiencia Operativa	22	18%
Total	124	100%

La Tabla 3 muestra como Personalización tiene mayor puntuación en todas las investigaciones encontradas (30 puntos) sacados del Apéndice 1. A continuación, se grafica por medio de la Figura 4 dicha participación de criterios.

**Figura 4***Participación Revisión Sistemática de Estudios*

*Nota.* En términos de temas evaluados en la gráfica, la personalización destaca como el aspecto con mayor participación, representando un 24% del total. Este enfoque subraya la importancia de adaptar productos, servicios y experiencias a las necesidades y preferencias específicas de cada cliente, lo que no solo mejora la satisfacción del usuario, sino que también incrementa la lealtad hacia las empresas. Le sigue muy de cerca la visualización, con un 22%, lo que refleja el creciente interés en el uso de herramientas como Power BI y Tableau para transformar datos complejos en representaciones visuales claras y accionables, elevando la capacidad de los usuarios para tomar decisiones informadas (Araque González & Giampietro Torres, 2023).

Además, se pueden identificar ejemplos destacados según los temas evaluados anteriormente, que ilustran cómo estas áreas clave se aplican en contextos reales. En el caso de la automatización, la implementación de RPA en procesos de manufactura ha permitido una reducción significativa de tareas repetitivas, liberando recursos humanos para actividades de mayor valor añadido (Dueñas-Ramírez et al., 2020). En cuanto a la predicción, el uso de Machine Learning ha revolucionado el modelado del comportamiento del cliente y la evaluación

del riesgo financiero, ofreciendo soluciones más precisas y adaptativas a los desafíos del mercado (García Meza & Lázaro Barrera, 2025). Por otro lado, la visualización, mediante el uso de tableros interactivos con herramientas como Power BI y Tableau, ha demostrado ser esencial para la comprensión y el monitoreo de indicadores clave de rendimiento en tiempo real (Araque González & Giampietro Torres, 2023). Finalmente, en el ámbito de la eficiencia operativa, la integración de IoT y Big Data no solo permite un mantenimiento predictivo más eficiente, sino que también mejora significativamente la gestión de los recursos, minimizando tiempos de inactividad y costos operativos (A. Sharma et al., 2021).

El análisis de las 50 investigaciones más relevantes permitió identificar cinco grandes temáticas que se destacan de forma reiterativa en los contextos de adopción tecnológica dentro de la Industria 4.0: automatización, visualización, predicción, personalización y eficiencia operativa. Cada una de estas dimensiones representa no solo un uso técnico de las tecnologías emergentes, sino una palanca estratégica que transforma la manera en que las organizaciones deciden, planifican y se adaptan al cambio. A continuación, se muestra en la tabla como esto influye en la administración estratégica y en las decisiones de una compañía:

**Tabla 4**

*Comparativo Contribución de Temáticas*

Temática	Descripción General	Aplicación en la Industria 4.0	Contribución a la Administración Estratégica y Toma de Decisiones	Ejemplos Documentados
Automatización	Uso de tecnologías para ejecutar tareas sin intervención humana	RPA, mantenimiento predictivo, producción inteligente	Permite decisiones más ágiles, operativas y de reducción de costos, alineadas con objetivos de eficiencia	García & Meza (2021); Sharma et al. (2022)

Temática	Descripción General	Aplicación en la Industria 4.0	Contribución a la Administración Estratégica y Toma de Decisiones	Ejemplos Documentados
Visualización	Representación gráfica de datos para facilitar su análisis y comprensión	Dashboards de BI (Power BI, Tableau), monitoreo en tiempo real	Mejora la toma de decisiones tácticas y estratégicas al dar visibilidad integral sobre métricas clave	Kumar & Singh (2020); Silva et al. (2021)
Predicción	Anticipación de comportamientos o eventos futuros mediante algoritmos	Forecasting de demanda, predicción de churn o riesgos financieros	Transforma decisiones reactivas en proactivas; fortalece la planificación a largo plazo y la resiliencia organizacional	Alshahrani (2023); Alqhatani et al. (2022)
Personalización	Adaptación de servicios, productos y experiencias a las necesidades del cliente	Segmentación dinámica, sistemas de recomendación, marketing personalizado	Impulsa decisiones centradas en el cliente, aumenta la fidelización y genera ventajas competitivas sostenibles	Tavera Romero et al. (2021); Ain et al. (2019)
Eficiencia Operativa	Optimización de recursos y procesos internos mediante uso de datos en tiempo real	Gestión de inventarios, reducción de desperdicios, optimización energética	Vincula operaciones con estrategia, permite decisiones de asignación de recursos más inteligentes y medibles	Bordeleau et al. (2020); Amalina et al. (2020)

La tabla 4 permite visualizar cómo cada temática no es aislada ni técnica, sino que constituye una pieza estratégica dentro de las industrias, cuyo objetivo es mejorar la competitividad, acelerar la transformación digital y sustentar decisiones informadas, dinámicas y

con foco en el cliente. Cada una de estas temáticas no debe entenderse como una aplicación aislada de tecnología, sino como una respuesta articulada a los desafíos estratégicos que enfrentan las organizaciones modernas. En conjunto, estas dimensiones construyen una arquitectura decisional más robusta, basada en datos, ágil, proactiva y centrada en el cliente. De este modo, se confirma que la integración de Business Intelligence, Machine Learning y Big Data en la Industria 4.0 no solo aporta valor tecnológico, sino que redefine los pilares de la administración estratégica.

La revisión sistemática desarrollada en este capítulo confirma que la integración de tecnologías como Business Intelligence, Machine Learning y Big Data ha consolidado cinco grandes temáticas que no solo dominan el discurso académico actual, sino que tienen una incidencia real y profunda en la estrategia organizacional moderna: automatización, visualización, predicción, personalización y eficiencia operativa.

Cada una de estas temáticas representa una respuesta tecnológica a una necesidad empresarial, pero su verdadero valor se manifiesta cuando se articulan con los objetivos estratégicos de la organización. Lejos de ser tendencias técnicas, estas dimensiones se convierten en habilitadores de decisiones inteligentes, capaces de transformar procesos, anticipar riesgos, reducir costos y, sobre todo, conectar con el cliente de forma más humana, personalizada y eficiente.

Además, los resultados muestran que la mayoría de los estudios analizados otorgan mayor protagonismo a la personalización y la visualización, lo que indica un giro claro hacia una administración estratégica centrada en el cliente y apoyada en la interpretación visual y dinámica de los datos. Este enfoque refleja un cambio de paradigma: la estrategia ya no se basa

únicamente en planes a largo plazo, sino en la capacidad de responder con agilidad, evidencia y precisión a un entorno altamente competitivo y digitalizado.

En resumen, estas temáticas no solo iluminan el camino para entender la transformación digital, sino que actúan como catalizadores de una nueva forma de administrar, decidir y competir. Su análisis, más allá del interés académico, constituye una herramienta valiosa para cualquier organización que desee construir ventajas sostenibles en el contexto de la Industria 4.0. La siguiente etapa de esta investigación buscará explorar las herramientas específicas que materializan estas temáticas dentro de los procesos organizacionales.

## **Técnicas, Medios y Herramientas más Utilizados en la Industria 4.0**

La transición hacia la Industria 4.0 marca una etapa en la que las tecnologías avanzadas no solo redefinen procesos, sino que también integran soluciones para enfrentar los desafíos modernos de gestión de datos y optimización. Este panorama pone de manifiesto la necesidad de un enfoque unificado que conecte la operacionalidad con la capacidad analítica y predictiva, facilitando la articulación entre estrategias clave como la automatización y la inteligencia de negocios.

### **Business Intelligence (BI)**

En el marco de la Industria 4.0, su valor radica en proporcionar una plataforma viva que conecta datos operativos con análisis avanzado para generar información accionable.

Herramientas como Power BI, Tableau, QlikView y SAP BusinessObjects son fundamentales en este proceso. Power BI destaca por su accesibilidad, integración directa con Excel y capacidad para visualización en dispositivos móviles, siendo especialmente útil en entornos industriales para monitorear indicadores clave de rendimiento relacionados con la eficiencia energética y la identificación de cuellos de botella operativos (Stalin et al., 2024).

Por otro lado, Tableau es conocida por su robustez en el análisis visual y su capacidad para explorar datos en tiempo real, mientras que QlikView ofrece un motor asociativo que facilita la detección de patrones de manera intuitiva sin necesidad de realizar consultas secuenciales. Estas herramientas no solo transforman datos crudos en información estratégica, sino que también optimizan procesos empresariales al permitir una visibilidad integral y una adaptabilidad ágil frente a los desafíos del mercado moderno (Srivastava et al., 2022b).

En lo que respecta a las plataformas tecnológicas, los estudios analizados identifican un uso predominante de arquitecturas cloud híbridas, como Azure y AWS, que proporcionan la

flexibilidad necesaria para manejar grandes volúmenes de datos de manera segura y eficiente. Estas arquitecturas no solo permiten el almacenamiento y procesamiento de datos a gran escala, sino también la integración de diversos sistemas empresariales en tiempo real. Paradza & Daramola (2021) destacan que los almacenes de datos o data warehouses desempeñan un papel crucial al centralizar la información organizacional, facilitando su acceso y análisis para convertirla en un activo estratégico clave para la toma de decisiones.

Además, Alqhatani et al. (2022) subrayan la importancia de los pipelines de datos, que actúan como un puente entre las herramientas de Business Intelligence (BI), sistemas de Machine Learning (ML) y plataformas como los sistemas ERP. Estos pipelines se construyen empleando servicios web y APIs, lo que asegura una integración rápida y adaptable frente a las necesidades cambiantes del mercado. Este enfoque permite combinar el análisis avanzado con la operación diaria, creando un ecosistema en el que las tecnologías interconectadas potencian la capacidad analítica y predictiva de las organizaciones.

A través de estas soluciones tecnológicas, las empresas logran no solo un mejor aprovechamiento de sus datos, sino también una alineación más efectiva entre sus estrategias operativas y analíticas, consolidando un entorno que fomenta la innovación y la eficiencia en la gestión de recursos y la planificación estratégica.

Dentro del repertorio de técnicas asociadas a la Inteligencia de Negocios (BI), destaca el proceso ETL (Extracción, Transformación y Carga), que es esencial para depurar, estructurar y consolidar grandes volúmenes de datos provenientes de diversas fuentes. Este proceso no solo garantiza la calidad y consistencia de los datos, sino que también facilita su integración en plataformas analíticas avanzadas. Por ejemplo, ETL permite preparar los datos para ser utilizados

en herramientas como Power BI y Tableau, proporcionando una base sólida para el análisis y la visualización estratégica (Srivastava et al., 2022).

Por otro lado, el OLAP (Procesamiento Analítico en Línea) se posiciona como una técnica clave para realizar análisis multidimensionales, lo que permite a las organizaciones explorar diferentes perspectivas de sus datos. Estas capacidades son particularmente útiles para identificar patrones, tendencias y anomalías en áreas como ventas, logística y finanzas, optimizando así la toma de decisiones informadas. Según Srivastava et al. (2022), el OLAP es una herramienta indispensable para las empresas que buscan aprovechar al máximo sus datos históricos y actuales.

Además, la construcción de dashboards e informes automáticos se ha convertido en una práctica estándar dentro del BI. Estos paneles, diseñados con herramientas como Tableau o Power BI, proporcionan una representación visual clara y concisa de los indicadores clave de rendimiento (KPI). Al ofrecer una vista panorámica de métricas críticas en tiempo real, los dashboards permiten a los equipos de trabajo monitorear objetivos, detectar desviaciones y reaccionar con rapidez ante los cambios del entorno. Como subraya Srivastava et al. (2022), esta capacidad de convertir datos crudos en información visualmente atractiva y accionable es fundamental para mantener la competitividad en mercados dinámicos.

En conjunto, estas técnicas no solo permiten transformar datos dispersos en información estratégica, sino que también habilitan a las organizaciones para adaptarse con agilidad a los desafíos y oportunidades emergentes del mercado, consolidando su ventaja competitiva en la era digital (Srivastava et al., 2022).

Por último, los medios tecnológicos que habilitan estas soluciones abarcan una amplia gama de herramientas y plataformas que garantizan una integración fluida y eficiente de los

sistemas empresariales. Uno de los elementos más destacados son las APIs REST, que actúan como puentes esenciales para conectar de manera dinámica y segura diferentes sistemas y aplicaciones, integrando plataformas de Business Intelligence (BI) con soluciones especializadas como Machine Learning (ML) y sistemas ERP (Stalin et al., 2024).

En los entornos industriales, los sensores IoT desempeñan un papel crítico al proporcionar datos en tiempo real que alimentan dashboards interactivos y tableros de control, posibilitando un monitoreo constante y detallado de indicadores clave de rendimiento (KPI). Estos sensores son utilizados, por ejemplo, para rastrear parámetros esenciales como la temperatura, la presión o las vibraciones en maquinaria industrial, lo que resulta fundamental para diagnosticar problemas y anticiparse a posibles fallas (Stalin et al., 2024).

Asimismo, la integración con sistemas ERP y CRM ha demostrado ser una estrategia clave para garantizar una visión consolidada del negocio. Esta conexión permite un flujo de información mucho más ágil entre departamentos, abarcando áreas tradicionalmente aisladas, como logística, ventas, recursos humanos y operaciones. De esta forma, las empresas pueden unificar datos y optimizar la toma de decisiones estratégicas en tiempo real, maximizando resultados y minimizando riesgos (Stalin et al., 2024).

En conjunto, estas tecnologías no solo potencian la capacidad analítica de las organizaciones, sino que también fomentan una adaptabilidad y resiliencia frente a los desafíos del mercado moderno. Como ha sido destacado por Stalin et al. (2024), el uso combinado de sensores IoT, APIs REST y sistemas integrados como ERP y CRM ayuda a construir una infraestructura sólida que soporta la innovación continua y la eficiencia operativa.

En síntesis, la literatura revisada no solo demuestra la amplia adopción de la Inteligencia de Negocios (BI) en sectores diversos, sino que también resalta la importancia de un ecosistema

técnico sólido y multifacético. Este ecosistema se compone de herramientas visuales avanzadas, como Power BI y Tableau, que permiten a las organizaciones transformar datos complejos en representaciones gráficas fáciles de interpretar. Además, las plataformas en la nube, tales como Google Cloud AI y Azure ML Studio, ofrecen entornos escalables y colaborativos que potencian la capacidad analítica de las empresas.

Otro elemento clave es la integración mediante APIs REST, que garantiza una conexión fluida entre sistemas dispares, desde plataformas de BI hasta soluciones especializadas como Machine Learning (ML) y sistemas de planificación de recursos empresariales (ERP). Estas tecnologías permiten agilizar los flujos de trabajo y fomentar una toma de decisiones fundamentada en tiempo real, maximizando la eficiencia operativa.

Por último, el uso de medios tecnológicos como arquitecturas híbridas y GPUs para el procesamiento intensivo de datos subraya la evolución hacia infraestructuras más robustas y adaptables. Esta combinación de herramientas y tecnologías no solo optimiza los procesos de análisis de datos, sino que también habilita a las organizaciones para construir estructuras resilientes, anticiparse a los desafíos y aprovechar las oportunidades emergentes en un mercado en constante cambio.

Las herramientas más citadas en la literatura especializada incluyen Power BI, Tableau, QlikView y SAP BusinessObjects, todas destacadas por su capacidad para proporcionar visualización interactiva de datos, facilitar la integración con diversas fuentes de información y ofrecer un enfoque de autoservicio analítico. Según Selvarajan (2024), estas herramientas no solo permiten a los usuarios explorar grandes volúmenes de datos de manera intuitiva, sino que también fomentan la colaboración entre equipos mediante opciones de personalización y generación de informes automatizados. Por su parte, Necochea-Chamorro & Larrea-Goycochea

(2023) resaltan cómo estas plataformas son esenciales para el monitoreo continuo de métricas clave de rendimiento (KPIs), ayudando a las organizaciones a identificar tendencias, prevenir riesgos y tomar decisiones estratégicas en tiempo real.

Entre las técnicas más utilizadas en este contexto se encuentran los procesos ETL (Extract, Transform, Load), que permiten preparar y consolidar datos de múltiples sistemas para su posterior análisis; la creación de dashboards interactivos, que ofrecen una vista integral y actualizada de las operaciones; y las capacidades de OLAP (Procesamiento Analítico en Línea), especialmente valoradas por su habilidad para realizar análisis multidimensionales. Estas prácticas son fundamentales para garantizar que las empresas puedan traducir datos complejos en insights accionables. (Selvarajan, 2024; Necochea-Chamorro & Larrea-Goycochea, 2023).

Además, estas herramientas y técnicas se apoyan en tecnologías de última generación como las APIs REST, que facilitan la integración de plataformas empresariales; los sistemas ERP, que consolidan procesos internos clave; el almacenamiento en la nube, que asegura escalabilidad y acceso remoto; y las arquitecturas híbridas, que ofrecen flexibilidad y rendimiento óptimos. En conjunto, este ecosistema tecnológico permite a las organizaciones desplegar estrategias analíticas más robustas y adaptadas a las exigencias dinámicas del mercado actual, tal como lo subrayan los estudios de Selvarajan (2024) y Necochea-Chamorro & Larrea-Goycochea (2023).

### **Machine Learning (ML)**

Entre las herramientas más destacadas para desarrollar aplicaciones de Machine Learning se encuentran librerías especializadas como Scikit-learn, XGBoost, Keras y TensorFlow, que son particularmente efectivas en entornos basados en Python. De acuerdo con García Meza & Lázaro Barrera (2025), estas herramientas ofrecen una flexibilidad notable para abordar aplicaciones

complejas como el modelado de clientes según niveles de riesgo. En estos casos, algoritmos avanzados como Random Forest y Logistic Regression han demostrado su capacidad para identificar patrones de comportamiento con una alta precisión, facilitando análisis más profundos y decisiones mejor fundamentadas.

En aplicaciones industriales, como lo expone A. Sharma et al. (2021), el uso de algoritmos avanzados como Support Vector Machines (SVM) y Convolutional Neural Networks (CNN) ha transformado significativamente el diagnóstico de fallas en maquinaria y el mantenimiento predictivo. Estos algoritmos destacan por su capacidad para procesar señales temporales complejas y datos sensoriales multidimensionales, tales como patrones de vibración, fluctuaciones de temperatura y variaciones en la corriente eléctrica. La implementación de estas tecnologías permite no solo predecir fallos antes de que ocurran, minimizando tiempos de inactividad y costos asociados, sino también optimizar procesos de producción al identificar oportunidades para ajustes y mejoras continuas en el rendimiento del equipo.

Por otro lado, en los sectores financiero y de retail, K-Means emerge como una herramienta esencial para la segmentación de clientes y el análisis de comportamiento, según los casos documentados por Rachman et al. (2021). Este algoritmo no supervisado resulta particularmente útil debido a su capacidad para agrupar grandes volúmenes de datos en perfiles significativos. Por ejemplo, en el contexto del retail, puede identificar patrones de compra recurrentes, preferencias de productos y niveles de lealtad del cliente. Mientras tanto, en el ámbito financiero, K-Means facilita la evaluación del riesgo crediticio al clasificar a los usuarios según su historial de pagos, ingresos y otras variables clave. Esto no solo permite a las organizaciones desarrollar campañas de marketing personalizadas y estrategias de cobranza más

efectivas, sino que también contribuye a una mejor gestión de riesgos y toma de decisiones fundamentadas.

En términos de plataformas, los estudios revisados destacan el uso de entornos como Jupyter Notebooks, Google Colab y Amazon SageMaker, que no solo facilitan la experimentación y el entrenamiento de modelos, sino también su despliegue en sistemas productivos con escalabilidad y eficiencia. Estas herramientas son especialmente valoradas por proporcionar funcionalidades avanzadas que permiten integrar procesos de Machine Learning en flujos empresariales. Por ejemplo, Chen et al. (2022) señalan cómo plataformas en la nube como Azure ML y Google Cloud AI ofrecen entornos colaborativos, seguros y de alto rendimiento. Dichas plataformas no solo optimizan la gestión de grandes volúmenes de datos, sino que posibilitan la integración de modelos con otras capas de análisis y visualización, fomentando una toma de decisiones más fundamentada y adaptativa. Además, estas soluciones permiten abordar proyectos complejos en equipos interdisciplinarios, maximizando su impacto en áreas como la inteligencia empresarial y la optimización operativa.

La literatura especializada destaca un equilibrio en el uso de técnicas de análisis de datos mediante algoritmos supervisados y no supervisados, cada uno diseñado para abordar diferentes necesidades y contextos. Entre los algoritmos supervisados más utilizados se encuentran la regresión logística, los árboles de decisión, Random Forest y las máquinas de soporte vectorial (SVM), debido a su capacidad para identificar patrones y realizar predicciones con alta precisión. Por otro lado, los algoritmos no supervisados como K-Means y el análisis de componentes principales (PCA) son esenciales para la clasificación y reducción de dimensiones en conjuntos de datos complejos, posibilitando la interpretación de clusters y relaciones subyacentes.

Además, en años recientes, el aprendizaje por refuerzo ha comenzado a ganar relevancia por su enfoque iterativo, que permite a los modelos mejorar sus decisiones a partir de recompensas acumulativas. Yin & Fernandez (2020) subrayan su impacto en el mantenimiento adaptativo, donde el sistema aprende a optimizar estrategias de intervención en maquinaria, y en la logística inteligente, que se beneficia de la capacidad del aprendizaje por refuerzo para ajustarse dinámicamente a las demandas cambiantes del entorno operativo. Estos avances no solo demuestran la versatilidad de las técnicas analíticas modernas, sino que también abren nuevas posibilidades para su integración en sistemas empresariales avanzados.

Finalmente, los medios tecnológicos que sustentan el funcionamiento de estos modelos se basan en infraestructuras avanzadas que integran el uso de GPU (procesadores gráficos) para acelerar el entrenamiento y la ejecución de algoritmos complejos, especialmente en tareas que involucran grandes volúmenes de datos o redes neuronales profundas. Además, el aprovechamiento de entornos contenedorizados, como Docker, ha permitido estandarizar el despliegue de modelos y su integración en diversos entornos de producción, facilitando la escalabilidad y la replicación en múltiples sistemas. La integración con APIs RESTful también se destaca como un elemento clave, ya que proporciona una interfaz eficiente para consumir modelos desde sistemas productivos en tiempo real, eliminando barreras técnicas entre los procesos analíticos y las aplicaciones empresariales. Chen et al. (2022) documentan un ejemplo práctico donde un modelo de Machine Learning desplegado como microservicio es integrado en plataformas de telecomunicaciones, logrando mejoras significativas en los tiempos de respuesta y adaptabilidad ante cambios dinámicos en el entorno operativo.

En términos generales, la literatura revisada refleja que el Machine Learning ha trascendido su rol inicial como herramienta analítica para convertirse en un pilar estratégico en la

toma de decisiones empresariales. Su capacidad para anticipar eventos futuros, como fallos en maquinaria o fluctuaciones de demanda, le otorga un papel indispensable en la planificación y optimización de procesos. Igualmente, su uso en la segmentación de clientes y personalización de servicios ha demostrado ser altamente efectivo para mejorar la experiencia del usuario y fomentar la lealtad en mercados competitivos. Chen et al. (2022) destacan que, al desplegar modelos predictivos en flujos de decisión automática, las organizaciones no solo mejoran su capacidad de respuesta, sino que también refuerzan su resiliencia al adaptarse rápidamente a escenarios cambiantes, consolidándose como entidades más dinámicas, basadas en evidencia y orientadas al futuro.

Las plataformas más utilizadas en el desarrollo y despliegue de aplicaciones de Machine Learning incluyen Google Cloud AI, AWS SageMaker, Azure ML Studio y Jupyter Notebooks. Cada una de estas plataformas ofrece características esenciales para la experimentación, entrenamiento y despliegue de modelos en entornos empresariales, aportando herramientas que permiten integrar procesos analíticos en flujos de trabajo productivos. Por ejemplo, García Meza & Lázaro Barrera (2025) destacan que estas plataformas permiten a los equipos interdisciplinarios maximizar el impacto de sus proyectos mediante entornos colaborativos y funcionalidades que favorecen la escalabilidad y la gestión eficiente de recursos computacionales.

En términos de técnicas analíticas, las más citadas en la literatura incluyen algoritmos supervisados como la regresión logística, los árboles de decisión, Random Forest y XGBoost, así como modelos más complejos basados en redes neuronales. Paralelamente, los algoritmos no supervisados como el clustering mediante K-Means y el análisis de componentes principales (PCA) son fundamentales para la clasificación y reducción dimensional en conjuntos de datos

extensos. García Meza & Lázaro Barrera (2025) subrayan la capacidad de estas técnicas para abordar problemas empresariales que requieren alta precisión en la identificación de patrones y segmentación de clientes.

Además, el aprendizaje por refuerzo emerge como un enfoque innovador que ha ganado relevancia en años recientes. Este método iterativo permite a los sistemas mejorar sus decisiones mediante recompensas acumulativas, adaptándose dinámicamente a los cambios del entorno operativo. Según García Meza & Lázaro Barrera (2025), esta técnica ha demostrado ser efectiva en aplicaciones como el mantenimiento adaptativo de maquinaria, donde los modelos optimizan estrategias de intervención, y en la logística inteligente, que se beneficia de su capacidad para ajustar operaciones de manera proactiva.

Finalmente, estas herramientas y técnicas operan sobre arquitecturas tecnológicas avanzadas que incluyen el uso de GPUs para acelerar el procesamiento de grandes volúmenes de datos y la ejecución de algoritmos complejos. Además, García Meza & Lázaro Barrera (2025) resaltan el papel de las APIs REST en la integración de modelos predictivos en sistemas productivos en tiempo real, así como el uso de entornos contenedorizados como Docker, que facilitan la estandarización y escalabilidad en distintos contextos empresariales, consolidando el Machine Learning como un pilar clave en la toma de decisiones estratégicas.

## **Big Data**

Las herramientas tecnológicas asociadas a Big Data han sido objeto de un amplio análisis en la literatura especializada. Entre las más recurrentes destacan Apache Hadoop y su ecosistema, que incluye componentes como HDFS y MapReduce, los cuales son fundamentales para el almacenamiento y procesamiento distribuido de datos. A estas se suma Apache Spark, una plataforma que optimiza el procesamiento en memoria y permite realizar análisis rápidos sobre

conjuntos masivos de datos. En este contexto, Rosati et al. (2023) documentan un caso práctico en el que la implementación de estas tecnologías se combina con sensores industriales para capturar y procesar datos en tiempo real. Este enfoque permitió anticipar fallos en centros de mecanizado con una precisión milimétrica, ilustrando cómo la integración de herramientas avanzadas impulsa la eficacia operativa y fortalece la capacidad predictiva de los sistemas industriales.

Además, herramientas como Hive y Kafka destacan por sus aplicaciones especializadas en el ecosistema de Big Data. Hive, por ejemplo, actúa como un motor de consultas SQL diseñado específicamente para manejar y analizar datos masivos almacenados en sistemas distribuidos, proporcionando a las organizaciones una manera eficiente de extraer conocimiento útil de grandes volúmenes de información. Por otro lado, Kafka se posiciona como un sistema robusto de mensajería distribuida que facilita el análisis en tiempo real de flujos de datos. Su implementación es clave para gestionar eventos de alta frecuencia y garantizar la consistencia en el procesamiento de datos en múltiples sistemas simultáneamente.

Chen et al. (2022) documentan un caso específico en el sector de las telecomunicaciones donde la integración de estas herramientas permitió el análisis simultáneo de miles de eventos por segundo, mejorando significativamente la capacidad de monitorear el comportamiento de usuarios, prever necesidades futuras y realizar mantenimiento predictivo en redes complejas. Este ejemplo resalta cómo dichas tecnologías pueden no solo optimizar procesos internos, sino también ofrecer ventajas competitivas en mercados dinámicos y altamente tecnificados.

El uso de plataformas tecnológicas en Big Data resulta esencial para aprovechar al máximo su capacidad de gestión y análisis de datos masivos. Entre las principales plataformas destacan Google BigQuery, Azure Data Lake y Amazon S3 combinada con EMR, las cuales

ofrecen no solo almacenamiento escalable, sino también capacidades avanzadas de procesamiento. Yin & Fernandez (2020) destacan que estas plataformas permiten unificar datos provenientes de diversas fuentes, como bases de datos relacionales, registros de actividad (logs), sensores industriales y sistemas ERP, en lo que se conoce como "data lakes". Estos repositorios centralizados no solo facilitan la organización de grandes volúmenes de información, sino que también habilitan análisis sofisticados, integrando modelos de Machine Learning e inteligencia empresarial para obtener perspectivas profundas y accionables.

Desde el punto de vista técnico, las técnicas más utilizadas en el análisis de datos masivos incluyen el procesamiento por lotes (batch processing), que permite realizar análisis históricos sobre grandes volúmenes de datos acumulados y es ideal para contextos donde la inmediatez no es un requisito esencial. Este enfoque facilita la generación de reportes detallados y el desarrollo de modelos predictivos más robustos, además de ser ampliamente aplicado en sectores como manufactura y finanzas, donde los patrones históricos resultan cruciales (Rosati et al., 2023).

Por otro lado, el streaming analytics se posiciona como una herramienta clave para el procesamiento de eventos en tiempo real. Este método es especialmente útil en sectores como las telecomunicaciones y el retail, donde la velocidad de respuesta ante comportamientos dinámicos de los usuarios puede determinar el éxito operativo. Por ejemplo, Rosati et al. (2023) destacan cómo su implementación en sistemas industriales permite tomar decisiones inmediatas basadas en datos generados por sensores, optimizando procesos y reduciendo tiempos de inactividad.

Además, la combinación de arquitecturas Lambda y Kappa ha emergido como una solución híbrida altamente efectiva para entornos que requieren tanto análisis históricos como procesamiento en tiempo real. La arquitectura Lambda integra datos históricos y en tiempo real en un único sistema, mientras que Kappa simplifica el diseño al enfocarse exclusivamente en

eventos recientes. Estas arquitecturas ofrecen mayor flexibilidad y capacidad de adaptación en ecosistemas empresariales altamente dinámicos, tal como señalan Rosati et al. (2023) y Amalina et al. (2020), quienes subrayan su capacidad para reducir la complejidad operativa y mejorar la eficiencia del análisis en diversos sectores.

Nobanee (2020) destaca un enfoque técnico clave en el ámbito financiero: la minería de datos aplicada a grandes volúmenes de información contable y económica. Este método combina algoritmos estadísticos avanzados con estructuras distribuidas para procesar datos de manera eficiente, permitiendo no solo identificar anomalías contables, sino también evaluar riesgos financieros con precisión y construir modelos de predicción económica altamente sofisticados. La integración de estas técnicas en sistemas empresariales modernos ha demostrado ser fundamental para optimizar la toma de decisiones estratégicas en sectores donde la estabilidad y la previsión son esenciales.

El aprovechamiento de medios tecnológicos en Big Data incluye el uso de sistemas distribuidos y bases de datos NoSQL como MongoDB y Cassandra, que permiten gestionar grandes volúmenes de datos de manera eficiente. Además, la integración con tecnologías de Internet de las Cosas (IoT) ha demostrado ser fundamental para la captación de datos provenientes de dispositivos inteligentes en tiempo real. Rosati et al. (2023) destacan un caso práctico en el que sensores CNC y sistemas de medición de coordenadas generaban registros automáticamente en brokers MQTT. Estos datos eran posteriormente almacenados en nubes como Azure Blob Storage, facilitando la organización y análisis de información industrial en gran escala.

En conjunto, estas referencias posicionan a Big Data como una tecnología indispensable para capturar y comprender la complejidad del entorno empresarial actual, donde las decisiones

estratégicas se basan en el análisis profundo de datos. Según Rosati et al. (2023), la integración de herramientas avanzadas como sensores industriales y sistemas de almacenamiento en la nube no solo mejora la eficiencia operativa, sino que también permite anticipar fallos y optimizar procesos en tiempo real, lo que ilustra el impacto transformador de su implementación en entornos industriales.

Lejos de ser solo infraestructura tecnológica, Big Data se convierte en una ventaja competitiva cuando se articula con herramientas analíticas, plataformas de automatización y sistemas de visualización avanzada. Chen et al. (2022) destacan su relevancia en el sector de las telecomunicaciones, donde las tecnologías como Kafka y Hive facilitan el análisis simultáneo de miles de eventos por segundo, mejorando significativamente el monitoreo del comportamiento de usuarios y permitiendo un mantenimiento predictivo en redes complejas.

En el ecosistema de Big Data predominan tecnologías como Hadoop y Spark, que son fundamentales para el procesamiento distribuido y el análisis rápido de datos masivos. Asimismo, herramientas como Hive y Kafka sobresalen por sus aplicaciones especializadas: Hive actúa como un motor de consulta eficaz para el análisis de datos distribuidos, mientras que Kafka garantiza la consistencia en el procesamiento de eventos de alta frecuencia. Estas soluciones, según Yin & Fernandez (2020), se integran eficientemente en plataformas como Google BigQuery, Azure y AWS, que no solo proporcionan almacenamiento escalable, sino también capacidades avanzadas para unificar datos provenientes de múltiples fuentes y habilitar modelos de Machine Learning.

Por último, el uso de técnicas como el procesamiento por lotes y el streaming analytics permite a las organizaciones realizar análisis históricos detallados y tomar decisiones inmediatas basadas en dinámicas en tiempo real. La combinación de arquitecturas Lambda y Kappa,

mencionada por Rosati et al. (2023) y Amalina et al. (2020), ofrece soluciones híbridas que equilibran análisis en tiempo real y acumulado, lo que resulta especialmente útil en sectores dinámicos como manufactura y retail. Estas tecnologías no solo mejoran la eficiencia del análisis, sino también reducen la complejidad operativa, posicionando a Big Data como un elemento esencial para la innovación continua y la competencia en mercados altamente tecnificados.

### **Desarrollo de un Análisis Comparativo para Identificar Herramientas Tecnológicas por Sector Empresarial**

A partir del análisis temático de los 50 artículos, se elaboró un cuadro comparativo enfocado en los sectores empresariales predominantes: manufactura, salud, retail, finanzas y telecomunicaciones. Este cuadro asoció cada sector con tecnologías, herramientas y modelos analíticos específicos, lo que permitió identificar patrones clave en la adopción y el impacto de estas soluciones.

**Tabla 5**

*Tecnologías, Herramientas y Modelos por Sector*

Sector	BI	ML	Big DATA
Manufactura	Power BI, Tableau	Random Forest, SVM	Hadoop, Spark
Salud	Power BI, Qlik	Redes neuronales, SVM	Hive, MongoDB
Retail	Tableau, SAP BO	K-Means, XGBoost	Hadoop, Kafka
Finanzas	Qlik, SAP BO	Logistic Regression, RF	Cassandra, Spark
Telecomunicaciones	QlikView, IBM Cognos	Gradient Boosting, SVM	Hive, Kafka

La Tabla 5 muestra como en el sector manufacturero, las herramientas de visualización como Power BI han demostrado ser fundamentales para monitorear indicadores clave de desempeño (KPIs) en tiempo real. Esto ha contribuido a mejorar tanto el control de producción

como la eficiencia energética, tal como lo señala A. Sharma et al. (2021). Asimismo, los algoritmos avanzados como Support Vector Machines (SVM) y Random Forest se utilizan ampliamente para el mantenimiento predictivo, gracias a su robustez y su capacidad para procesar datos sensoriales provenientes de maquinaria industrial. Además, el uso de tecnologías Big Data como Apache Spark ha permitido flujos de análisis en tiempo real, lo cual es particularmente útil para gestionar datos de sensores industriales, como lo documenta Rosati et al. (2023).

En el ámbito de la salud, Yin & Fernandez (2020) destacan cómo herramientas como Power BI y Qlik han transformado la gestión hospitalaria y el monitoreo de indicadores clínicos, mejorando significativamente la calidad del servicio. En cuanto a los algoritmos de aprendizaje automático, las redes neuronales y los modelos SVM son esenciales para el análisis de imágenes médicas y la predicción de diagnósticos complejos. Por otro lado, bases de datos como MongoDB, junto con soluciones como Hive, han permitido la integración y el manejo eficiente de datos clínicos tanto estructurados como no estructurados, facilitando su uso tanto en investigaciones como en aplicaciones diagnósticas.

En el sector retail, Alqhatani et al. (2022) proponen un modelo híbrido que combina inteligencia de negocios (BI) mediante herramientas como Tableau y SAP BO con técnicas de aprendizaje automático. Este enfoque incluye el uso de algoritmos como XGBoost para predecir comportamientos de compra y K-Means para segmentar clientes de manera mucho más precisa. Además, el uso de flujos de datos en tiempo real gestionados por Apache Kafka ha permitido supervisar eficientemente ventas, promociones y programas de fidelización, optimizando la experiencia del cliente y las estrategias comerciales.

En el sector financiero, Richards et al. (2019) resaltan el papel estratégico de herramientas de BI como Qlik y SAP BO en la consolidación de información contable y financiera. Estos sistemas no solo estructuran los datos, sino que también permiten una visualización clara para la toma de decisiones. Modelos predictivos como la regresión logística y Random Forest son esenciales en tareas como el scoring crediticio y el análisis de riesgos, como lo señalan García Meza & Lázaro Barrera (2025). Además, la implementación de soluciones Big Data, como Spark y Cassandra, ha facilitado la gestión de grandes volúmenes de datos transaccionales, lo que permite procesarlos con rapidez y aplicarlos en la detección de fraudes y el cumplimiento regulatorio.

En telecomunicaciones, Srivastava et al. (2022) identifican herramientas como QlikView e IBM Cognos como elementos claves para la gestión de paneles de control que supervisan usuarios, tráfico de red y facturación. En cuanto a modelos de aprendizaje automático, algoritmos como Gradient Boosting y SVM han mostrado un desempeño sobresaliente en la predicción de deserción de clientes. Finalmente, tecnologías como Hive y Kafka ofrecen una integración ágil y escalable de sistemas de mensajería en tiempo real con análisis históricos, lo que resulta fundamental para manejar millones de eventos diarios de manera eficiente y estratégica.

Este análisis comparativo no solo detalla la relación entre sectores y tecnologías, sino que también refuerza la importancia de adaptar estas soluciones a las necesidades específicas de cada industria, optimizando procesos y generando ventajas competitivas sostenibles.

### **Validación de Hallazgos Basados en Casos Documentados**

Tras la clasificación detallada de herramientas, técnicas y plataformas, y el análisis comparativo por sector anteriormente expuesto, se procedió a validar estos hallazgos mediante

casos documentados cuidadosamente seleccionados dentro de la revisión sistemática. Este enfoque permitió no solo contrastar la evidencia teórica con aplicaciones prácticas en diversos contextos organizacionales, sino también profundizar en cómo estas tecnologías han impactado de manera específica en los procesos y resultados de diferentes industrias. La validación no solo refuerza la solidez de los hallazgos, sino que también arroja luz sobre aspectos clave que no siempre son evidentes en los análisis iniciales, dotando de mayor relevancia al plan de trabajo planteado.

Uno de los desafíos más frecuentes identificado en esta fase de validación es la carencia de infraestructura tecnológica adecuada y escalable. Este problema afecta especialmente a las organizaciones que aún dependen de arquitecturas tecnológicas tradicionales, las cuales no son capaces de soportar de manera eficiente soluciones avanzadas como Big Data o modelos de aprendizaje automático (ML) implementados a gran escala. Amalina et al. (2020) destacan que este déficit tecnológico es particularmente crítico en empresas medianas, las cuales suelen enfrentar restricciones presupuestales y carecen de acceso a servicios en la nube suficientemente robustos para satisfacer las demandas de procesamiento y almacenamiento modernos. Este tipo de limitaciones no solo ralentiza la adopción de estas herramientas, sino que también perpetúa la brecha tecnológica entre las grandes corporaciones y las pymes, afectando la competitividad del sector.

Uno de los principales desafíos es la resistencia cultural al cambio dentro de las organizaciones. Bordeleau et al. (2020) explican que, en las pequeñas y medianas empresas (pymes), la introducción de soluciones como Business Intelligence (BI) y Machine Learning (ML) suele enfrentarse a barreras culturales significativas. Esto se debe, en gran parte, a la falta de alineación entre las estrategias organizacionales y la analítica de datos, así como a la

percepción errónea de que estas tecnologías son innecesariamente costosas y requieren procesos complejos de implementación. Superar esta resistencia demanda no solo un enfoque técnico, sino también un esfuerzo en la formación y sensibilización de los equipos para que comprendan el potencial transformador de estas herramientas, estableciendo una cultura de datos sólida que conecte la visión estratégica con la tecnología.

Además, la escasez de talento especializado con perfiles híbridos se presenta como un obstáculo crítico para muchas empresas. Silva et al. (2021) destacan la importancia de contar con personas que no solo posean conocimientos técnicos en ciencia de datos e inteligencia de negocios, sino que también tengan un entendimiento profundo del sector en el que operan. Sin embargo, la falta de estos perfiles dentro de las organizaciones genera una dependencia excesiva de consultores externos y recursos ocasionales, lo que limita la capacidad de las empresas para desarrollar internamente su madurez analítica. Para abordar este problema, es clave invertir en programas de formación y desarrollo profesional, así como fomentar alianzas con instituciones académicas que puedan proveer talento capacitado para enfrentar los retos emergentes en el campo del análisis de datos.

Por último, la integración de datos heterogéneos representa otro desafío fundamental para las organizaciones que buscan aprovechar tecnologías avanzadas. Rosati et al. (2023) señalan que gran parte de los datos utilizados en soluciones de IoT, plataformas ERP y sistemas heredados suelen ser inconsistentes y carecen de estándares comunes, lo que dificulta su procesamiento para modelos predictivos y herramientas de visualización estratégica. Este problema requiere esfuerzos sustanciales en términos de calidad, limpieza y gobernanza de datos. La implementación de políticas claras sobre la gestión de datos y la adopción de tecnologías que faciliten la interoperabilidad entre sistemas puede ser esencial para superar estas barreras. Solo

con una infraestructura de datos limpia y bien estructurada es posible garantizar resultados analíticos precisos que informen decisiones estratégicas y generen valor para la organización.

A pesar de estos obstáculos, los casos documentados también resaltan las numerosas ventajas obtenidas por las organizaciones que logran implementar con éxito estas tecnologías. En primer lugar, la automatización de procesos, tanto operativos como analíticos, ha demostrado ser un cambio transformador en términos de eficiencia y costos. Por ejemplo, Stalin et al. (2024) reportan un caso en el sector manufacturero donde la integración de inteligencia de negocios (BI) y aprendizaje automático (ML) permitió reducir el ciclo de reporte operativo de días a minutos, lo que no solo optimizó los flujos de trabajo, sino también mejoró la capacidad de respuesta ante situaciones críticas. Este nivel de automatización no solo libera recursos humanos para tareas más estratégicas, sino que también refuerza la estabilidad operativa al minimizar errores manuales.

Otra ventaja clave es la toma de decisiones basada en datos, que ha evolucionado hacia un enfoque más ágil y estratégico. Srivastava et al. (2022) señalan que las organizaciones con tableros de BI bien diseñados logran identificar desviaciones operativas casi de inmediato, lo que les permite ajustar sus estrategias con evidencia tangible en lugar de depender únicamente de la intuición. Este enfoque ha sido particularmente útil en sectores altamente volátiles, donde los cambios rápidos en el mercado y las demandas de los consumidores exigen respuestas adaptativas y fundamentadas en datos confiables. Además, la capacidad de visualizar datos en tiempo real mejora significativamente la colaboración entre los equipos, facilitando decisiones más alineadas con los objetivos organizacionales.

Desde el punto de vista comercial, la personalización en los servicios y productos ha surgido como una ventaja competitiva crucial. García Meza & Lázaro Barrera (2025) destacan

cómo el uso de modelos predictivos en el sector financiero no solo permitió anticipar comportamientos de cartera y riesgos crediticios, sino también ajustar proactivamente las políticas de cobranza, logrando mejoras sustanciales en los índices de recuperación de crédito. Este ejemplo subraya cómo la analítica avanzada puede transformar áreas críticas de negocio, proporcionando soluciones más precisas y eficaces. Además, Araque González & Giampietro Torres (2023) describen cómo las herramientas de BI han sido fundamentales para llevar la experiencia del cliente a nuevos niveles mediante la segmentación detallada y el análisis de patrones de consumo. Esto permite a las empresas diseñar estrategias más personalizadas y relevantes, aumentando la fidelidad del cliente y, en última instancia, impulsando el crecimiento de ingresos sostenibles.

Estos casos no solo validan los hallazgos previos, sino que refuerzan una idea esencial del plan operativo: la integración efectiva de BI, ML y Big Data no es simplemente una cuestión tecnológica, sino también un desafío organizacional y estratégico. Las empresas que logran superar barreras como la infraestructura inadecuada, la resistencia cultural al cambio y la escasez de talento especializado acceden a una ventaja competitiva sostenible. Esta ventaja radica en la capacidad de tomar decisiones más inteligentes, desarrollar procesos más eficientes y establecer relaciones más significativas y duraderas con sus clientes. En este sentido, la inversión en tecnología y en cultura organizacional orientada hacia los datos se convierte en una estrategia imprescindible para garantizar resultados positivos en un entorno empresarial cada vez más competitivo.

Finalmente, se evidencia que las herramientas más críticas para la toma de decisiones estratégicas en el contexto de la Industria 4.0 son aquellas asociadas con Business Intelligence, destacando especialmente plataformas como Power BI, Tableau, QlikView y SAP

BusinessObjects, por su capacidad para transformar grandes volúmenes de datos en información visual accionable.

Asimismo, tecnologías de Machine Learning como XGBoost, Random Forest, y algoritmos de clustering como K-Means están experimentando un significativo crecimiento debido a su eficacia en predicción y segmentación de clientes. En cuanto a Big Data, Apache Spark, Kafka y Hadoop mantienen un crecimiento sostenido gracias a su capacidad para gestionar análisis en tiempo real y procesamiento distribuido.

No obstante, se identifican brechas importantes relacionadas con la integración de datos heterogéneos, resistencia cultural al cambio dentro de las organizaciones y una escasez crítica de talento especializado con perfil híbrido, lo cual limita significativamente el aprovechamiento integral de estas tecnologías emergentes en el ámbito empresarial y la toma de decisiones.

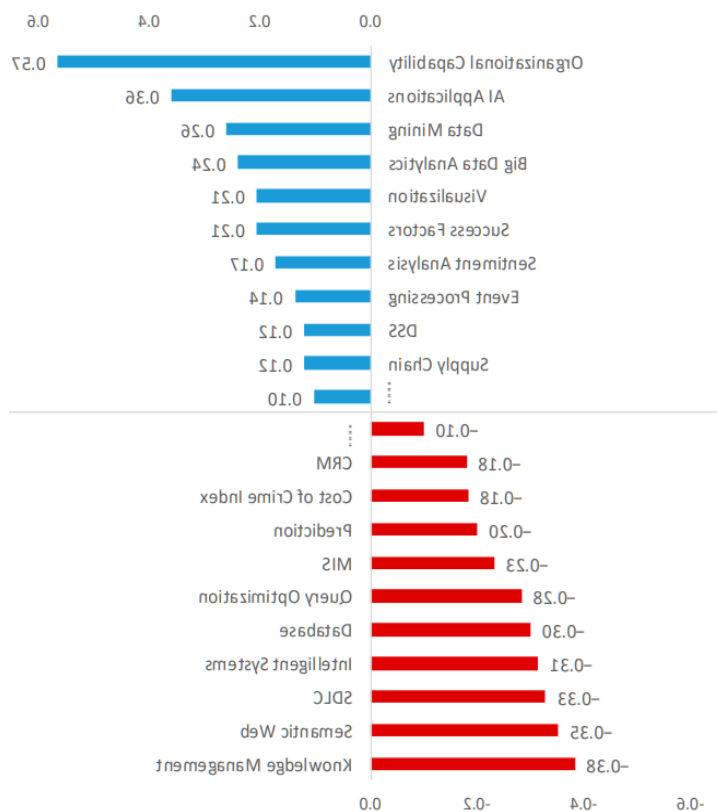
## **Retos y Beneficios en la Integración Estratégica**

En este capítulo se presentan los resultados del análisis de los artículos seleccionados sobre los retos y beneficios que implica la integración de Business Intelligence, Machine Learning y Big Data en la gestión estratégica de la Industria 4.0. Para ello, se eligieron las investigaciones más relevantes, identificando en cada una los aspectos mencionados. Finalmente, se llevó a cabo un análisis comparativo de la muestra seleccionada.

El artículo “Business Intelligence Strategies, Best Practices, and Latest Trends: Analysis of Scientometric Data from 2003 to 2023 Using Machine Learning” destaca cómo la integración de Business Intelligence con tecnologías como Big Data y Machine Learning ha impulsado una transformación profunda en las organizaciones.

De acuerdo con Gurcan et al. (2023), una de las principales fortalezas radica en la capacidad de transformar grandes volúmenes de datos en información relevante, convirtiéndose así en una fuente clave para la toma de decisiones, tanto a nivel operativo como estratégico. Esta habilidad permite a las organizaciones responder con mayor rapidez y precisión ante los cambios del entorno. A continuación, se presentan los principales retos y beneficios identificados:

Figura 5

*Tendencias Temáticas*

*Nota.* Tomado de Business Intelligence Strategies, Best Practices, and Latest Trends: Analysis of Scientometric Data from 2003 to 2023 Using Machine Learning Gurcan et al. (2023).

Tal como se observa en la figura 5, los beneficios más relevantes señalados por Gurcan et al. incluyen: en primer lugar, la “Organizational Capability” (+0.57), que ha mostrado el mayor crecimiento. Esto refleja la creciente importancia de alinear las capacidades técnicas con las competencias organizacionales para lograr una adopción efectiva de BI. Este avance abarca tanto el desarrollo de habilidades de liderazgo como la consolidación de una cultura orientada a los datos y la implementación de estructuras ágiles.

En segundo lugar, destacan las “AI Applications” (+0.36), que representan la evolución del BI tradicional hacia sistemas inteligentes de apoyo a la toma de decisiones. El crecimiento de este tema evidencia que las organizaciones ya no se conforman con informes históricos, sino que buscan automatizar decisiones predictivas (Gurcan et al., 2023).

Por último, sobresalen áreas como “Data Mining”, “Big Data Analytics” y “Visualization” (con incrementos entre +0.21 y +0.26), tecnologías esenciales para la exploración profunda de grandes volúmenes de datos. Su consolidación está directamente relacionada con la necesidad de obtener insights relevantes en tiempo real (Gurcan et al., 2023).

Estos desarrollos muestran que el BI contemporáneo ha dejado de ser solo una herramienta de monitoreo para convertirse en un motor estratégico de transformación digital, innovación y ventaja competitiva (Gurcan et al., 2023).

Entre los principales desafíos identificados por el autor para lograr una integración exitosa y significativa de estas tecnologías en las organizaciones, la figura 3 ilustra una tendencia a la baja en diversas áreas:

Gestión del conocimiento (Knowledge Management, -0.38): Aunque sigue siendo relevante, la gestión tradicional del conocimiento ha perdido protagonismo frente al auge de sistemas automatizados basados en aprendizaje automático e inteligencia artificial. Esto pone de manifiesto la necesidad de replantear las estrategias organizacionales para aprovechar el conocimiento en escenarios dominados por grandes volúmenes de datos (Gurcan et al., 2023).

Semantic Web (-0.35) y SDLC (-0.33): La caída de estos temas evidencia una transición desde estructuras rígidas y tradicionales hacia contextos más ágiles y adaptables, enfocados en servicios. Para las organizaciones, esto implica el reto técnico de modernizar la infraestructura de BI y convertirla en entornos aptos para la analítica avanzada (Gurcan et al., 2023).

Intelligent Systems (-0.31) y Database (-0.30): El descenso en su relevancia indica que disponer de sistemas inteligentes o grandes bases de datos ya no es suficiente; el verdadero desafío radica en generar valor de negocio mediante la analítica prescriptiva y la toma autónoma de decisiones (Gurcan et al., 2023).

Query Optimization y MIS (entre -0.23 y -0.28): Estas áreas clásicas han sido desplazadas por plataformas que reducen la complejidad técnica, lo que revela una carencia en la formación de talento: muchas organizaciones siguen ancladas en prácticas tradicionales que ya no responden a las demandas actuales (Gurcan et al., 2023).

CRM y Prediction (de -0.10 a -0.20): El descenso de estos conceptos sugiere un cambio de enfoque: el objetivo ya no es solo predecir variables específicas (como ventas), sino anticipar comportamientos dinámicos dentro de sistemas complejos (Gurcan et al., 2023).

En conjunto, la información reflejada en la figura no solo muestra qué temas ganan o pierden relevancia en el ámbito de Business Intelligence, sino que también señala los verdaderos retos actuales. Ya no basta con contar con tecnología avanzada o acumular datos; el principal desafío consiste en desarrollar capacidades organizacionales para aprovechar estratégicamente esa información.

Dentro de este marco de referencia, aunque no se detallan casos puntuales, el análisis permite vislumbrar cómo el Business Intelligence, potenciado por Machine Learning y Big Data, ya está impactando de manera significativa en sectores estratégicos. El crecimiento de ciertos temas en la literatura refleja la aplicación real de estas tecnologías en distintos ámbitos.

Por ejemplo, en el sector salud, la presencia destacada de Health Information Systems (HIS) demuestra cómo la inteligencia de negocios optimiza la toma de decisiones clínicas, facilita una mejor gestión de los recursos hospitalarios y anticipa riesgos sanitarios. En un

contexto delicado como este, la capacidad de interpretar datos con agilidad se convierte en una ventaja competitiva, e incluso puede marcar la diferencia entre una atención eficiente y una respuesta tardía.

En el ámbito educativo, las investigaciones están enfocándose cada vez más en el impacto del BI en el aprendizaje personalizado, la evaluación del desempeño y la mejora continua de los programas académicos. El crecimiento del tema Higher Education en las publicaciones evidencia que las instituciones universitarias toman decisiones pedagógicas basadas en datos y diseñan estrategias sustentadas en la evidencia, más allá de la intuición.

En el sector industrial, conceptos como Industry 4.0 y Smart Grid ilustran una historia diferente, pero igual de relevante. Aquí, el BI actúa como el cerebro que analiza miles de datos para optimizar procesos, reducir desperdicios, predecir fallas técnicas o gestionar de manera eficiente el consumo energético. No basta con contar con maquinaria inteligente; se trata de dotar de inteligencia a toda la operación.

Cada uno de estos sectores representa un capítulo particular en la transformación de la gestión estratégica. El BI ha dejado de ser simplemente una herramienta administrativa para convertirse en una palanca de cambio que se adapta a las necesidades específicas de cada industria. Lo que antes era solo un generador de reportes, hoy es una brújula capaz de guiar decisiones complejas en tiempo real.

En síntesis, tras los temas en ascenso que señalan Gurcan et al. (2023), se encuentran aplicaciones reales, decisiones humanas y transformaciones culturales. Aunque no se mencionen casos individuales, estos hallazgos ofrecen una visión clara sobre cómo el BI está impulsando la transformación de sectores enteros desde su núcleo.

El artículo “Effective Demand Forecasting Model Using Business Intelligence Empowered With Machine Learning” presenta un modelo de pronóstico de demanda que integra Business Intelligence (BI) con técnicas avanzadas de Machine Learning, utilizando en particular el algoritmo DeepAR de Amazon SageMaker. Esta sinergia no solo incrementa la precisión en las previsiones, sino que revoluciona la manera en que las organizaciones planifican y toman decisiones tanto operativas como estratégicas (Khan et al., 2020). A continuación, se detallan los principales retos y beneficios identificados:

Uno de los aportes más notables del modelo propuesto por Khan es su alta precisión predictiva: en pruebas reales, el sistema alcanzó un 92.38% de exactitud, mejorando significativamente los resultados obtenidos con el proceso manual anterior. Este avance permitió optimizar tanto la gestión de compras como la administración de inventarios, reduciendo pérdidas por sobreproducción y asegurando una respuesta eficaz a la demanda del mercado.

El modelo también brindó la posibilidad de generar pronósticos personalizados por tienda y por semana, permitiendo una planificación detallada y estratégica. Importante destacar que, lejos de desplazar el criterio humano, el sistema incorporó mecanismos para revisión, ajustes manuales y flujos de aprobación, fusionando así la potencia de la analítica con la experiencia del negocio.

La centralización de la información y los procesos fue otro beneficio clave. Gracias a su arquitectura, el sistema integró datos provenientes de ventas, inventarios, calendarios y campañas de marketing en una única plataforma web interactiva, accesible para todos los niveles de la organización.

Además, la implementación del modelo fomentó una cultura organizacional orientada a la toma de decisiones basada en datos. Las proyecciones dejaron de ser simples predicciones para

convertirse en herramientas activas que moldean escenarios futuros. Esto se tradujo en una mayor agilidad, visibilidad y capacidad de adaptación frente a entornos cambiantes.

Sin embargo, la transición no estuvo exenta de desafíos. Uno de los principales fue la dependencia de datos históricos robustos: para generar pronósticos confiables, el modelo requería información previa suficiente. En el caso de nuevas tiendas o registros limitados, se implementaron reglas heurísticas complementarias, aunque esto reducía la eficiencia del algoritmo.

También fue necesario abordar la integración de datos provenientes de fuentes muy diversas —como ventas, inventarios, calendarios fiscales y periodos promocionales—, lo que implicó desarrollar procesos exhaustivos de limpieza y normalización antes de alimentar el motor de Machine Learning.

La gestión del cambio organizacional representó otro reto importante. El antiguo sistema, basado en Excel, ofrecía escasa visibilidad y trazabilidad. Su reemplazo requirió redefinir procesos, establecer jerarquías para la aprobación y capacitar al personal en el uso de nuevas herramientas más técnicas y centralizadas.

Por último, la complejidad técnica asociada a la configuración del sistema —como el ajuste de hiperparámetros, el uso de AWS SageMaker y la implementación de modelos RNN para series temporales— demandó la participación de equipos altamente especializados, lo cual constituye un reto adicional para empresas que carecen de talento analítico propio.


A pesar de que el artículo no cita casos individuales específicos, describe de forma detallada la aplicación del modelo en contextos organizacionales y geográficos diversos. Utilizando datos reales y simulados, el análisis muestra cómo el sistema puede adaptarse eficazmente según las necesidades de cada entorno.

En el sector retail, por ejemplo, las tiendas se agruparon por regiones (norte, sur, este y oeste), utilizando datos históricos desde 2015 para proyectar las ventas semanales del año 2020, logrando captar los picos estacionales como tendencias realistas semana a semana.

Para aquellas tiendas de reciente apertura, especialmente en la región este, se optó por una estrategia híbrida que combinó reglas empresariales con predicciones automatizadas, compensando así la escasez de datos anteriores y manteniendo el funcionamiento preciso del sistema (Khan et al., 2020).

### Figura 6

*Predicción de Khan (2020) en una Empresa Retail*



*Nota.* Tomado de Effective Demand Forecasting Model Using Business Intelligence Empowered With Machine Learning Khan et al. (2020)

A nivel organizacional, la Figura 6 ilustra la integración de datos históricos y proyecciones para toda la empresa durante el año 2020; en ella, el eje x representa las semanas y el eje y muestra las ventas o inventarios en dólares. Esta perspectiva global posibilitó la toma de decisiones estratégicas más informadas, como la planificación de compras, la optimización de inventarios y la preparación de campañas comerciales.

En síntesis, la implementación del modelo no solo permitió automatizar el pronóstico de la demanda, sino que impulsó a la empresa a replantear su dinámica operativa: se transitó de una gestión reactiva a una proactiva, de métodos manuales a sistemas inteligentes, y de una fragmentación de datos a una estrategia conectada e integral (Khan et al., 2020).

El artículo “Business Intelligence using Machine Learning and Data Mining techniques- An analysis” nos sumerge en uno de los grandes retos de la era digital: convertir el desorden de datos dispersos en diversas plataformas en información relevante para la toma de decisiones estratégicas. Los autores parten de una observación clara y contundente: el volumen de datos está creciendo a tal velocidad que las metodologías tradicionales de análisis han dejado de ser suficientes para mantener el ritmo. (R. Sharma & Srinath, 2018)

El análisis presentado en el estudio resalta que, cuando se implementa de manera adecuada, la minería de datos apoyada en machine learning permite descubrir patrones antes invisibles entre miles de registros, y a partir de ellos construir una auténtica inteligencia de negocios. Uno de los elementos clave es el uso de métodos para la detección de anomalías, conocidos como outliers, los cuales dejan de ser vistos simplemente como ruido para convertirse en señales valiosas que pueden anticipar riesgos o revelar oportunidades inéditas.

El documento propone una taxonomía de metodologías para identificar outliers, abarcando enfoques estadísticos, de distancia, densidad, redes neuronales y aprendizaje no supervisado. Estas estrategias contribuyen a depurar y estructurar los datos, haciéndolos útiles para análisis estratégicos más profundos.

Asimismo, los autores subrayan la importancia de técnicas de minería de datos no estructurados, como el análisis de redes sociales o registros de eventos, que representan una fuente significativa de conocimiento organizacional si se interpretan correctamente. En este

sentido, no basta con poseer grandes volúmenes de información: es esencial contar con herramientas que permitan extraer valor en entornos diversos y dinámicos.

El enfoque Organizational Data Mining (ODM) expuesto en el artículo abre la puerta a la automatización del conocimiento dentro de las organizaciones, posibilitando la toma de decisiones basadas en comportamientos internos, registros históricos, transacciones e incluso interacciones en línea.

No obstante, alcanzar este nivel de integración no está exento de desafíos. Sharma y Srinath advierten sobre varios retos estructurales que deben afrontarse para lograr una integración exitosa de BI y machine learning en la gestión estratégica.

Uno de los mayores obstáculos es la complejidad de los datos. A medida que los conjuntos de datos se vuelven más dimensionales y dispersos —como sucede en redes sociales o registros temporales— identificar patrones confiables resulta cada vez más complicado. En estos escenarios, muchas técnicas convencionales pierden eficacia o se tornan costosas en términos computacionales.

Otra dificultad importante es la carencia de estructuras formales para datos no estructurados. La mayoría de las soluciones actuales están diseñadas para datos ordenados en tablas, pero en la práctica, las organizaciones se enfrentan a comentarios de clientes, correos electrónicos, archivos PDF, registros web y otros tipos de información que no se ajustan fácilmente a ese formato.

A esto se suma la complejidad en la visualización: aunque se logren identificar patrones útiles, presentarlos de forma comprensible para la toma de decisiones es un reto tanto técnico como de diseño.

Finalmente, los autores destacan la baja transferibilidad de los modelos entre dominios. Es decir, un modelo efectivo en la detección de fraudes con tarjetas de crédito puede no ser útil para analizar redes logísticas o predecir enfermedades, lo que limita la aplicabilidad transversal del BI estratégico.

El análisis temático de los hallazgos permite identificar con claridad los sectores donde el uso de BI y ML tiene un impacto tangible. Por ejemplo, en ciberseguridad, los modelos de detección de anomalías ayudan a identificar actividades maliciosas o intentos de intrusión en redes, convirtiendo al BI en una herramienta fundamental para la defensa digital organizacional.

En el ámbito de la salud, las técnicas de detección de outliers se emplean en el diagnóstico de enfermedades (como el cáncer pulmonar) y para evaluar la eficacia de vacunas en distintas poblaciones. Detectar patrones inusuales en datos médicos agiliza la respuesta clínica y mejora la asignación de recursos.

Sectores como la meteorología y las finanzas se benefician de la identificación de patrones cíclicos —por ejemplo, en precios de acciones, tráfico vial o flujos energéticos— lo que permite anticipar comportamientos estacionales y adaptar estrategias de manera proactiva.

En telecomunicaciones, los sistemas de BI permiten detectar sobrecargas, fallos o ataques en tiempo real, optimizando la gestión de infraestructuras críticas.

Por último, en banca y seguros, el machine learning funciona como un radar que detecta patrones atípicos y previene fraudes, evitando así pérdidas considerables.

En suma, en todos estos casos, los datos por sí solos no son suficientes: se requiere inteligencia tecnológica y organizacional para interpretarlos y convertirlos en acciones concretas. El trabajo de Sharma & Srinath nos recuerda que el verdadero potencial de la analítica radica no

solo en los algoritmos, sino en su aplicación para construir estrategias empresariales más inteligentes, anticipativas y humanas.

El artículo titulado “Machine Learning in Business Intelligence 4.0: Cost Control in a Destination Hotel” expone cómo un hotel ubicado en la costa sureste de España enfrentó el reto diario del control de costos mediante un enfoque innovador. En vez de apearse a los métodos financieros tradicionales, el equipo apostó por utilizar el consumo real de productos como indicador principal de eficiencia. Durante tres años, un equipo multidisciplinario conformado por científicos de datos y especialistas del área implementó un sistema basado en algoritmos de clustering jerárquico, cuyo propósito era agrupar productos similares según sus patrones de consumo y costo. Este sistema permitió detectar qué productos podían ser sustituidos por otros equivalentes y más económicos, sin comprometer la calidad del servicio ofrecido. La meta era clara: optimizar la gestión de recursos a través de la tecnología, demostrando que la verdadera innovación reside en la aplicación inteligente de los datos. (Sánchez-Torres et al., 2022)

Uno de los principales logros fue el desarrollo del concepto de “producto genérico”, que agrupaba artículos similares—como diferentes tipos de pan, jugos o embutidos—bajo un mismo código. Esto facilitó la normalización y comparación de datos a lo largo del tiempo de manera eficiente.

El uso de algoritmos permitió también identificar productos susceptibles de ser reemplazados, tomando en cuenta variables como el costo, el volumen de consumo y el comportamiento estacional. De este modo, se optimizó la rotación de inventario y se evitaron compras innecesarias, lo que resultó en una reducción de desperdicios y ahorros concretos para el hotel.

El sistema incorporó, además, variables relacionadas con el perfil del cliente y la producción financiera, lo que hizo posible personalizar la gestión según el tipo de huésped (por ejemplo, considerando el número de comidas incluidas o el nivel de ocupación). Esta capa adicional enriqueció los modelos analíticos y facilitó decisiones más estratégicas y adaptadas al contexto.

En el ámbito tecnológico, el estudio evidenció que la combinación de técnicas de Machine Learning no supervisado con paneles expertos (Business Analysis with Expert Assessment – BAEA) genera una sinergia poderosa: la tecnología potencia, pero no sustituye, la intuición y experiencia del negocio.

Sin embargo, alcanzar estos resultados implicó superar varios desafíos. El primero fue la dispersión de los datos en “islas tecnológicas”: cada sistema del hotel (inventario, compras, punto de venta, finanzas) almacenaba información de forma aislada y muchas veces inaccesible. Fue necesario modificar infraestructuras, crear conectores y validar la calidad de los datos antes de construir el data warehouse.

El modelado también presentó retos: el algoritmo HAC debió ajustarse para contemplar diferentes hipótesis por consumo o costo, así como calibrar variables, pesos y distancias de corte para obtener resultados coherentes. Frecuentemente, los datos resultaban inconsistentes, con ruido o valores atípicos que complicaban el análisis.

Otro desafío fue de carácter cultural y operativo: se requirió la colaboración activa de especialistas en alimentos y bebidas, compras e informática, quienes validaron la viabilidad de las recomendaciones generadas por el algoritmo. Sin este aporte humano, las sugerencias técnicas carecerían de impacto real.

Finalmente, la integración de perfiles de cliente exigió especial atención a la privacidad y cumplimiento del RGPD europeo, garantizando que el análisis de comportamiento respetara la confidencialidad de los datos personales.

Los hallazgos de este caso aplicado ofrecen una visión directa sobre el impacto en el sector hotelero, particularmente en el área de alimentos y bebidas. A lo largo del estudio, se implementó un sistema de inteligencia de negocios que no solo facilitó el control de costos, sino que también permitió:

- Detectar productos sustitutos equivalentes sin afectar la calidad del servicio; por ejemplo, identificar productos como magdalenas, muffins, panes y jugos que podían ser reemplazados por alternativas más económicas, pero de características similares.
- Mejorar la gestión del consumo de acuerdo con el perfil del cliente, incorporando variables como ocupación, tipo de paquete adquirido (con o sin pensión completa) y volumen de consumo al modelo para generar decisiones más inteligentes y personalizadas.
- Anticipar decisiones de compra basadas en agrupamientos de comportamiento, facilitando negociaciones con proveedores, mejor control de existencias y reducción de mermas en cocina.

Este caso demuestra que la aplicación de BI 4.0 no está reservada solo para grandes corporaciones o sectores tecnológicos. Sectores tradicionales como el turismo también pueden beneficiarse significativamente: cambiar un producto por otro puede significar miles de euros en ahorro anual. (Sánchez-Torres et al., 2022)

El artículo “35yearsofresearchonbusiness intelligence process: a synthesis of afragmentedliterature” de Talaoui & Kohtamäki ofrece una perspectiva estratégica, más allá del enfoque meramente técnico. En vez de centrarse en modelos o algoritmos concretos, los autores

se plantean una cuestión fundamental para las organizaciones actuales: ¿de qué manera la inteligencia artificial puede transformar un modelo de negocio? Para abordar esta interrogante, presentan una revisión sistemática de 103 investigaciones que exploran la relación entre la IA y tres pilares esenciales de la gestión empresarial: la estrategia, la innovación y el aprendizaje organizacional. (Talaoui & Kohtamäki, 2020)

Uno de los aportes más destacados que señalan los autores es cómo la IA transforma la creación, entrega y captura de valor en las organizaciones. No se limita a optimizar procesos; realmente redefine el propósito y la manera en que opera el modelo de negocio.

Desde la perspectiva estratégica, la IA brinda herramientas para prever escenarios con mayor precisión, fortaleciendo así la toma de decisiones en entornos cambiantes. En cuanto a la innovación, facilita el desarrollo de productos y servicios novedosos al descubrir patrones y necesidades emergentes a partir del análisis de grandes volúmenes de datos. A nivel organizacional, fomenta una cultura de aprendizaje continuo, donde la información se convierte en el motor para desarrollar nuevas capacidades.

Asimismo, los autores resaltan el potencial de la IA para personalizar experiencias a gran escala, lo que resulta fundamental en empresas orientadas al cliente. Esta personalización no solo impulsa la fidelización, sino que también revela oportunidades de negocio que antes pasaban desapercibidas.

En esencia, la IA no es solo un apoyo tecnológico para los procesos existentes, sino un factor que impulsa la reinención de los pilares fundamentales del negocio, dando lugar a lo que los autores llaman “modelos de negocio impulsados por IA”.

No obstante, la adopción de IA enfrenta importantes barreras. Según Talaoui & Kohtamäki, una de las principales dificultades es la carencia de capacidades organizacionales

para incorporar, adaptar y escalar la inteligencia artificial dentro del modelo de negocio. No basta con disponer de la tecnología: es indispensable crear condiciones culturales y estructurales para que su impacto sea real.

Otra dificultad clave es la tensión entre la automatización y el control humano. Varios estudios revisados indican que delegar decisiones estratégicas a sistemas de IA puede generar resistencia en los equipos directivos, especialmente cuando no comprenden la lógica o el funcionamiento de los modelos predictivos.

Además, los autores advierten sobre el riesgo de que las iniciativas de IA se desarrollen de forma aislada en distintos departamentos, como marketing u operaciones, sin una visión global. Esto limita la posibilidad de una transformación integral del negocio.

Por último, subrayan la importancia de abordar los retos éticos asociados a la IA: desde la transparencia en el uso de datos y la explicabilidad de los algoritmos, hasta el impacto en el empleo y la redefinición de los roles laborales. Abordar estos aspectos es fundamental para una integración responsable y sostenible.

Aunque el artículo no se centra en un caso concreto, sí ofrece una clasificación temática de aplicaciones de IA en varios sectores, lo que permite identificar patrones y trasladar aprendizajes.

En salud, la IA destaca por su uso en el análisis predictivo para diagnósticos y tratamientos personalizados, mejorando la precisión y la rapidez de las decisiones clínicas.

En manufactura y logística, ayuda a optimizar las cadenas de suministro, anticipar mantenimientos y ajustar las líneas de producción en tiempo real, integrando la tecnología directamente en el núcleo operativo.

En retail y servicios financieros, las aplicaciones se orientan a la hiperpersonalización, la detección de fraudes y la gestión de riesgos, impactando tanto en la propuesta de valor como en la rentabilidad.

A nivel organizativo, se observa una tendencia a automatizar funciones de soporte (como recursos humanos y atención al cliente), permitiendo enfocarse en tareas de mayor valor y redefiniendo las competencias clave en los equipos.

En conclusión, la revisión de Talaoui & Kohtamäki (2020) no solo organiza el panorama actual de la IA en los negocios, sino que proporciona un marco profundo para comprender que integrar inteligencia artificial es ante todo una decisión estratégica, más allá de lo meramente tecnológico. El reto fundamental no es implementar una herramienta, sino repensar todo el modelo de negocio a la luz de lo que la IA hace posible y exige.

El artículo “Business intelligence using machine learning algorithms” analiza el caso de una compañía farmacéutica que aspira a ir más allá de la simple venta de productos: su objetivo es comprender a profundidad a su clientela, anticipar sus necesidades y fundamentar sus decisiones estratégicas en datos sólidos. Para alcanzar esta meta, Hamzehi y Hosseini desarrollan un modelo de Business Intelligence (BI) potenciado por algoritmos de Machine Learning, enfocado en la segmentación de clientes y el análisis detallado de sus patrones de compra. (Hamzehi & Hosseini, 2022)

Uno de los aportes clave del artículo radica en la integración de los modelos RFM, LRFM y NLRFM, que permiten segmentar a las y los clientes no solo en función de su valor económico, sino también de su fidelidad y la diversidad de productos adquiridos. Esta segmentación avanzada facilita identificar a las y los clientes más valiosos (“platino”) y diseñar estrategias personalizadas para cada segmento.

El sistema desarrollado incorpora tres algoritmos de agrupamiento (K-means, DBSCAN y Optics) para analizar los patrones de consumo, siendo K-means el que alcanzó la mayor precisión (índice de pureza = 0.96). Gracias a este análisis, la empresa identificó agrupaciones naturales de comportamiento y pudo asignar políticas comerciales diferenciadas según cada grupo.

Asimismo, la aplicación de reglas de asociación (Apriori) permitió descubrir frecuencias altas de productos adquiridos en conjunto, revelando oportunidades para promociones cruzadas, optimización de la disposición en almacenes y estrategias de fidelización más efectivas.

Se destaca también la implementación de una plataforma de BI visual e intuitiva basada en Power BI, que favoreció la adopción de la herramienta en todos los niveles organizativos.

Entre los desafíos encontrados, el principal fue consolidar un repositorio de datos (data warehouse) que integrara fuentes diversas: ventas, devoluciones, logística y comportamiento en puntos de venta. La falta de integración previa generaba inconsistencias y dificultaba el seguimiento de la información.

Además, fue necesario realizar un preprocesamiento exhaustivo para transformar datos nominales en variables numéricas normalizadas, lo que exigió metodologías específicas y personal capacitado en análisis estadístico y programación.

Otro reto relevante fue el ajuste de los parámetros en los algoritmos de clustering, en particular para DBSCAN y Optics, donde factores como la densidad y el radio de vecindad podían alterar notablemente los resultados. Este proceso requirió múltiples iteraciones y validación con personas expertas del negocio para interpretar adecuadamente los grupos generados.

Un desafío adicional consistió en traducir los hallazgos técnicos en decisiones prácticas: convertir métricas y patrones en estrategias concretas para la segmentación, promociones y mejoras en la cadena de valor.

Mediante la segmentación con RFM y sus variantes (LRFM y NLRFM), se definieron acciones adaptadas a distintos perfiles de clientela: desde campañas de recuperación hasta iniciativas de fidelización y recompra.

El análisis del carrito de compras con Apriori permitió identificar combinaciones de productos con potencial para ofertas cruzadas, descuentos estratégicos y mejoras en la organización de inventarios tanto físicos como digitales.

La herramienta también facilitó detectar por qué ciertos productos no se vendían juntos, lo que llevó a optimizar la planificación comercial y la gestión de inventarios.

En síntesis, el estudio no solo expone un modelo técnico eficaz, sino que demuestra cómo el Business Intelligence apoyado en Machine Learning puede transformar datos dispersos en conocimiento accionable y convertir una operación tradicional en una organización guiada por inteligencia. (Hamzehi & Hosseini, 2022)

El artículo “A Review on Business Analytics: Definitions, Techniques, Applications and Challenges”, elaborado por Liu et al. (2023), ofrece una visión integral del ámbito del Business Analytics (BA), explorando su evolución conceptual, las principales áreas de aplicación y los retos que persisten en su puesta en práctica. Aunque el análisis no se limita a un sector concreto, su enfoque transversal permite identificar tendencias que repercuten en la integración del BA, el Big Data y el Machine Learning dentro de las estrategias empresariales actuales. (Liu et al., 2023)

Uno de los aportes más relevantes de esta revisión es la articulación de técnicas analíticas a lo largo de las tres etapas del análisis de datos: descriptiva, predictiva y prescriptiva. Estas fases se complementan para transformar información bruta en decisiones estratégicas sólidas.

Entre los principales beneficios, destaca la capacidad del Business Analytics para crear valor organizacional mediante:

- Visualización y comprensión de patrones complejos: Herramientas como Power BI y Tableau, junto con técnicas como clustering y minería de asociaciones, permiten identificar tendencias históricas y segmentar audiencias con mayor precisión.
- Predicción con algoritmos avanzados: Desde modelos ARIMA hasta redes neuronales profundas como LSTM y DeepAR, las empresas pueden adelantarse a los cambios del mercado y preparar respuestas estratégicas.
- Recomendaciones accionables mediante analítica prescriptiva: A través de algoritmos heurísticos y modelos de optimización, el BA sugiere decisiones óptimas en áreas como logística, precios y marketing.

El estudio resalta cómo estas técnicas se aplican con éxito en sectores como la salud, el comercio minorista, las finanzas e incluso en deportes profesionales, consolidando al Business Analytics como una pieza clave para el crecimiento y la innovación empresarial.

En cuanto a los desafíos, Liu et al. (2023) identifican dos grandes grupos:

- Calidad de los datos: En el entorno del Big Data, la cantidad de información no es suficiente; la clave está en su integridad, precisión y coherencia. Datos incompletos o erróneos pueden distorsionar los modelos analíticos y conducir a decisiones equivocadas.
- Privacidad y seguridad de la información: En un contexto global con regulaciones estrictas, la protección de los datos es indispensable. El artículo subraya que la ausencia de

infraestructuras de seguridad robustas puede impedir la implementación exitosa de BA, especialmente con información sensible.

También se mencionan barreras técnicas, como la necesidad de hardware especializado, la dificultad para interpretar los algoritmos de deep learning por su carácter de “caja negra”, y la dependencia de personal calificado capaz de implementar soluciones éticas y comprensibles.

Asimismo, aunque no se expone un caso de estudio concreto, la revisión sistemática permite observar cómo organizaciones de distintas industrias aplican Business Analytics (BA) y Machine Learning (ML) en diversas áreas funcionales. Esta visión ofrece un panorama amplio de prácticas reales y aplicaciones exitosas.

En el sector salud, el BA se utiliza para la detección temprana de enfermedades, análisis de historiales médicos y optimización de recursos hospitalarios. Los modelos predictivos apoyan la anticipación de brotes, minimizan errores diagnósticos y adaptan tratamientos en tiempo real, demostrando cómo los datos bien interpretados pueden salvar vidas.

En el comercio minorista, las técnicas analíticas posibilitan la hipersegmentación de clientes, precios dinámicos y experiencias personalizadas de compra. Gracias a métodos como K-means, ARIMA o redes neuronales, los comercios pueden generar ofertas a la medida y prever tendencias de consumo con antelación.

En el ámbito financiero, los modelos analíticos facilitan la detección de fraudes, evaluación de riesgos crediticios y recomendaciones de inversión automatizadas. Además, las entidades aprovechan la visualización avanzada para monitorear indicadores en tiempo real y reaccionar con agilidad ante el mercado.

En manufactura y cadena de suministro, sobresalen los algoritmos prescriptivos que optimizan rutas logísticas, programan mantenimientos predictivos y ajustan la producción a demanda proyectada, marcando la diferencia entre eficiencia e improvisación.

Incluso en el deporte profesional, el BA se emplea para evaluar el rendimiento de jugadores, prevenir lesiones y diseñar estrategias basadas en datos históricos y en tiempo real.

En suma, Liu et al. (2023) evidencian que el Business Analytics ha dejado de ser una herramienta de nicho para convertirse en una infraestructura transversal que impregna sectores tan diversos como la salud y el entretenimiento. Su impacto ya no depende únicamente de la tecnología disponible, sino de la disposición de las organizaciones para integrar los datos en el centro de su estrategia.

El artículo “Business Intelligence (BI) in Firm Performance: Role of Big Data Analytics and Blockchain Technology” expone cómo la integración de Business Intelligence con Big Data Analytics y Blockchain puede convertirse en el motor clave del desempeño organizacional, como lo demuestra el análisis realizado en 12 empresas tecnológicas de Croacia. (Pancić et al., 2023)

Uno de los hallazgos centrales del estudio es que la integración de BI, Big Data Analytics y Blockchain genera un impacto positivo y significativo en el desempeño organizacional. Se destacan varios beneficios, entre ellos:

- Mejoras notables en la toma de decisiones estratégicas, gracias al acceso inmediato a datos y herramientas analíticas que permiten anticipar tanto riesgos como oportunidades.
- Incremento de la eficiencia operativa, particularmente en procesos logísticos y de cadena de suministro, donde blockchain aporta trazabilidad y transparencia.
- Mayor capacidad de innovación, al identificar patrones de comportamiento y consumo que facilitan el desarrollo de productos personalizados.

- El papel mediador de la tecnología: el BI potencia su impacto al integrarse estratégicamente con Big Data y Blockchain, creando un ecosistema donde la información se transforma en ventaja competitiva.

El estudio también subraya que estos beneficios se ven potenciados cuando la tecnología se acompaña de una gestión adecuada del talento humano. No basta con adquirir herramientas avanzadas; es fundamental incorporarlas de forma inteligente en el modelo de negocio para maximizar su valor.

No obstante, obtener estos resultados no es automático. El análisis revela una serie de desafíos estructurales que limitan el impacto del BI:

- Desalineación entre capacidades tecnológicas y objetivos estratégicos, donde muchas empresas implementan BI o blockchain sin una visión clara de cómo contribuirán a sus metas comerciales.

- Déficit de capacidades organizativas para adoptar y escalar estas tecnologías, especialmente en empresas medianas que cuentan con recursos y conocimientos técnicos limitados.

- Resistencia al cambio, lo que resulta en un uso poco óptimo de las plataformas de BI; incluso con la herramienta disponible, las decisiones suelen seguir basándose en métodos tradicionales.

- Dificultades en la adopción de blockchain, como la falta de interoperabilidad entre sistemas y la necesidad de construir una base sólida de confianza técnica, aún pendiente en muchas organizaciones.

Por tanto, el verdadero reto reside tanto en la transformación de procesos como en el fortalecimiento del capital humano, para que el uso de datos se convierta en un recurso estratégico y transversal.

Aunque el artículo no se enfoca en un caso empresarial único, presenta un estudio empírico que involucra a 12 empresas tecnológicas en Croacia, permitiendo identificar patrones claros de implementación. Mediante encuestas a 387 empleados y el uso de un modelo de ecuaciones estructurales (PLS-SEM), se observó que las organizaciones que integran BI, Big Data y Blockchain alcanzan un mayor desempeño organizacional, reflejado en mayores niveles de innovación y eficiencia.

Un aspecto clave destacado es la experiencia y competencia del personal en el uso de BI: aquellas empresas cuyos equipos dominan estas herramientas obtienen una ventaja significativa en la interpretación de datos y en la toma ágil de decisiones. Además, el uso de blockchain para asegurar la integridad de los datos en procesos logísticos ha incrementado la confianza en las decisiones comerciales.

El estudio demuestra que los beneficios sustanciales no provienen únicamente de instalar herramientas de BI, sino de alinearlas con una cultura de decisiones basada en la evidencia y una visión estratégica clara del uso de los datos.

En suma, Pancić et al. (2023) muestran que el auténtico valor de BI no reside en la herramienta en sí, sino en la manera en que se implementa, se conecta con otras tecnologías y se integra en la lógica organizacional. Esta lección resulta crucial para aquellas empresas que desean pasar de la simple recolección de datos a la transformación profunda de su negocio.

El análisis realizado por Popović y su equipo parte de una cuestión fundamental para las pequeñas y medianas empresas: ¿la implementación de sistemas de Business Intelligence (BI)

realmente impulsa el desempeño empresarial? Para encontrar respuestas, el estudio profundiza en el día a día de 181 PYMEs europeas, indagando no solo en el grado de adopción de BI, sino también en la manera en que estas organizaciones aprovechan sus capacidades y el impacto concreto que ello genera en su rendimiento organizacional. (Popovič et al., 2019)

La investigación diferencia claramente entre dos enfoques en el uso de Business Intelligence: uno rutinario, donde la herramienta se utiliza de manera repetitiva y limitada, y otro innovador, que implica explotar nuevas funcionalidades y aplicar el sistema de forma creativa para abordar desafíos específicos. Esta distinción resulta fundamental, ya que el alcance y la profundidad con que se emplea el BI repercuten directamente en los beneficios que las organizaciones obtienen de la tecnología. (Popovič et al., 2019)

Ambos enfoques de utilización se traducen en avances notables dentro de áreas clave de la empresa. Por ejemplo, en los departamentos de marketing y ventas, la aplicación de BI brinda a las PYMEs la capacidad de detectar tendencias emergentes, anticipar las demandas del mercado y personalizar productos o servicios para satisfacer mejor las necesidades de la clientela, lo que fortalece su posicionamiento competitivo. (Popovič et al., 2019)

En el ámbito de las operaciones internas, la implementación de BI impulsa una toma de decisiones más informada, optimiza la productividad del equipo y agiliza tanto los procesos administrativos como logísticos. (Popovič et al., 2019)

También, aunque en menor medida, se observaron mejoras en la gestión de compras: las empresas lograron optimizar los costos de inventario, fortalecer la coordinación con proveedores y agilizar los procesos de adquisición, evidenciando así que los beneficios del BI pueden extenderse a distintas áreas funcionales cuando se implementa estratégicamente. (Popovič et al., 2019)

Esta perspectiva va más allá de evaluar únicamente los resultados finales, ya que facilita el análisis de los efectos intermedios del BI: permite identificar de qué manera cada área funcional se ve impactada por el sistema y cómo estas transformaciones contribuyen —o no— a generar mejoras globales en el desempeño organizacional. (Popovič et al., 2019)

No obstante, los beneficios del BI no siempre son automáticos ni están exentos de retos. El estudio evidencia que, en muchas PYMEs, persiste una barrera cultural y organizacional que limita el aprovechamiento pleno de estas tecnologías. Con frecuencia, el personal se restringe a un uso básico y repetitivo del sistema, sin explorar a fondo sus capacidades. Esta falta de exploración e innovación reduce considerablemente el impacto positivo que el BI podría generar en la empresa. (Popovič et al., 2019)

Un desafío adicional es la limitada adopción del BI en áreas como compras y aprovisionamiento. Si bien se reconoce el valor potencial de estas herramientas, la persistencia de prácticas tradicionales y la escasa digitalización en dichos departamentos dificultan que el impacto del BI sea tan significativo como en ventas o en la gestión interna. (Popovič et al., 2019)

Un desafío frecuentemente desapercibido, pero determinante, es la infrautilización del sistema BI. Es común que las empresas inviertan en estas plataformas, pero no desarrollen plenamente las competencias necesarias para aprovecharlas al máximo. Sin procesos consistentes de capacitación, acompañamiento y una verdadera cultura de exploración, el BI termina siendo una herramienta sofisticada que no logra integrarse de manera significativa en la estrategia y la toma de decisiones organizacionales. (Popovič et al., 2019)

Si bien no se presenta un caso individual específico, la investigación en sí funciona como un compendio colectivo de 181 PYMEs. Entre los hallazgos más relevantes destaca que el uso innovador del BI genera un impacto mucho mayor en el desempeño empresarial que el uso

meramente rutinario. Así, las organizaciones que experimentaron con funciones avanzadas del sistema—como la combinación de métricas, el análisis cruzado de datos o la creación de visualizaciones dinámicas—fueron capaces de identificar oportunidades de mercado con mayor agilidad que aquellas que se limitaron a elaborar reportes estándar. (Popovič et al., 2019)

Un caso destacado es el de una empresa mediana del sector servicios, mencionada de forma anónima en el estudio, que experimentó avances notables en sus indicadores de productividad tras integrar el BI con su sistema de gestión interna. Esta integración le permitió acortar los tiempos de respuesta, anticipar posibles cuellos de botella en sus operaciones y fundamentar sus decisiones en datos actualizados en tiempo real. (Popovič et al., 2019)

El estudio enfatiza que el verdadero valor del Business Intelligence no reside solo en la tecnología, sino en la forma en que las organizaciones la aprovechan. Contar con una plataforma avanzada no garantiza resultados sobresalientes si no se impulsa una actitud estratégica e innovadora en su uso. Por el contrario, incluso una PYME con recursos limitados puede alcanzar ventajas competitivas notables cuando adopta una cultura orientada a los datos y explora de manera creativa las capacidades del BI. Así, la clave está en la mentalidad y el enfoque, más que en las herramientas mismas. (Popovič et al., 2019)

En la visión planteada por Lepenioti y su equipo, el Business Analytics (BA) trasciende su papel tradicional como herramienta de soporte y se posiciona como un pilar fundamental para alcanzar ventajas competitivas sostenibles. El análisis parte de una interrogante central: ¿de qué manera las capacidades analíticas se integran efectivamente en la toma de decisiones estratégicas de las organizaciones contemporáneas?

Con el fin de abordar esta cuestión, las y los autores no solo desarrollan un marco teórico sólido, sino que también lo complementan con una exhaustiva revisión de literatura y casos de

aplicación. Así, demuestran cómo el análisis de datos tiene el potencial de transformar profundamente la manera en que las empresas conciben y estructuran su estrategia organizacional. (Lepeniotti et al., 2020)

Lepeniotti y su equipo subrayan que la integración del Business Analytics en la estrategia organizacional ofrece un valor clave: la capacidad de transformar datos en conocimiento práctico, facilitando que las empresas conviertan información en decisiones y estas, a su vez, en ventajas competitivas sostenibles. (Lepeniotti et al., 2020)

- Un beneficio clave es la mejora sustancial en la calidad de las decisiones empresariales. Al incorporar modelos analíticos descriptivos, predictivos y prescriptivos, las organizaciones pueden fundamentar sus acciones en datos concretos en lugar de depender únicamente de la intuición, lo que permite tomar decisiones estratégicas con mayor impacto y certeza. (Lepeniotti et al., 2020)

- La capacidad de reducir la incertidumbre en entornos dinámicos se vuelve un activo esencial, especialmente en sectores como el retail, la banca o la logística. En estos contextos, donde los cambios del mercado y del entorno pueden impactar rápidamente la rentabilidad, contar con herramientas analíticas sólidas permite anticipar escenarios y responder de manera ágil y precisa, minimizando riesgos y mejorando la toma de decisiones estratégicas. (Lepeniotti et al., 2020)

- La integración de dashboards y visualizaciones en tiempo real favorece que todas las áreas de la organización trabajen sobre datos consistentes y actualizados, lo que fortalece la colaboración interdepartamental y asegura que las estrategias se alineen en torno a objetivos comunes. (Lepeniotti et al., 2020)

- Integración con aprendizaje organizacional: el BA no solo ofrece respuestas inmediatas, sino que alimenta procesos de aprendizaje continuo dentro de la empresa, fortaleciendo sus capacidades dinámicas. (Lepenioti et al., 2020)

En definitiva, el estudio evidencia que cuando el BA se articula con claridad a los niveles táctico y estratégico, se convierte en un factor que impulsa el rendimiento y la resiliencia empresarial a largo plazo.

Pero este camino no está exento de barreras. El estudio identifica varios retos estructurales que dificultan la integración real del BA con la toma de decisiones estratégicas.

- Falta de cultura organizacional orientada a datos: muchas empresas todavía no confían en los análisis, o dependen demasiado de la experiencia subjetiva de sus líderes. Esto limita la adopción efectiva de insights analíticos en la planificación estratégica. (Lepenioti et al., 2020)

- Fragmentación de los sistemas de información: cuando las bases de datos están dispersas o los sistemas no están integrados, se pierde trazabilidad, consistencia y velocidad en la generación de informes útiles. (Lepenioti et al., 2020)

- Desconexión entre técnicos y estrategias: uno de los puntos críticos es que los científicos de datos y los tomadores de decisiones no siempre hablan el mismo idioma. Esta brecha puede convertir al BA en un recurso infrautilizado, o incluso malinterpretado. (Lepenioti et al., 2020)

- Falta de modelos de evaluación de impacto estratégico: aunque muchas empresas ya utilizan BA, pocas cuentan con mecanismos sistemáticos para evaluar si sus decisiones realmente están generando valor a nivel estratégico. (Lepenioti et al., 2020)

Estos retos no son técnicos solamente: son culturales, estructurales y humanos. Requieren rediseñar procesos, fomentar nuevas habilidades y establecer puentes entre la analítica y la visión del negocio.

Aunque el artículo es principalmente teórico y estructural, ofrece ejemplos concretos de cómo se ha aplicado el BA en la práctica a través de estudios de caso secundarios, extraídos de literatura reciente.

Por ejemplo, en el sector de la aviación comercial, el estudio recoge cómo compañías líderes han utilizado modelos de predicción de demanda para ajustar precios de boletos en tiempo real, optimizar asignación de flota y anticiparse a patrones de cancelación. Este tipo de decisiones, apoyadas en BA, resultaron en mejoras directas en la ocupación de vuelos y en la rentabilidad operativa. (Lepenioti et al., 2020)

En el sector bancario, se destacan prácticas como la detección temprana de clientes propensos a la fuga, el análisis del riesgo crediticio en base a fuentes no estructuradas, y la personalización de ofertas. Todo ello permite al banco no solo mitigar riesgos, sino fortalecer relaciones comerciales y aumentar el valor del cliente a largo plazo. (Lepenioti et al., 2020)

Finalmente, el marco propuesto en el artículo se convierte en sí mismo en un modelo replicable para cualquier organización que quiera integrar la analítica como músculo estratégico. El modelo parte de tres pilares: capacidades analíticas, procesos de decisión, y alineación organizacional, y sirve como hoja de ruta para evaluar el nivel de madurez analítica de una empresa y su capacidad de convertir datos en acción efectiva. (Lepenioti et al., 2020)

Punia y sus colegas son un ejemplo ejemplar de cómo la analítica predictiva puede evolucionar hacia una analítica prescriptiva dentro de la industria minorista. En lugar de quedarse en la estimación de la demanda, dan un paso más: proponen un modelo totalmente data-driven para la optimización de inventarios en un entorno con múltiples productos y restricciones de capacidad, enfrentando los dilemas clásicos del modelo “newsvendor”. Pero no lo hacen

desde la teoría aislada; lo construyen desde la práctica, con datos reales, algoritmos actuales y desafíos muy concretos.

Uno de los beneficios más destacados del enfoque propuesto por los autores es su carácter libre de distribución: en lugar de asumir que la demanda sigue una distribución normal (como hacen los modelos clásicos), este modelo utiliza métodos de machine y deep learning para estimar directamente la demanda futura, basándose en datos históricos de ventas y variables contextuales como promociones, clima y calendario. (Punia et al., 2020)

El resultado de esto es doble. Por un lado, se logra una precisión significativamente mayor en las predicciones (con errores menores usando Random Forest y Deep Neural Networks, ver Tabla 3, p. 7). Por otro, se integra de forma natural con la optimización de inventarios, evitando los errores derivados de suposiciones erróneas sobre la demanda. (Punia et al., 2020)

Además, el modelo permite integrar múltiples productos bajo restricciones reales, como la capacidad de exhibición en tienda, utilizando heurísticas jerárquicas que asignan de forma eficiente el espacio o presupuesto entre los productos disponibles. Esta flexibilidad lo hace especialmente útil para industrias con productos perecederos o de alta rotación. (Punia et al., 2020)

Sin embargo, el camino hacia esta solución no está exento de retos. El primero y más evidente es técnico: construir modelos predictivos robustos que integren múltiples variables externas requiere grandes volúmenes de datos, capacidades de cómputo significativas y conocimiento especializado en aprendizaje automático. (Punia et al., 2020)

El segundo reto es metodológico. Integrar la estimación de demanda y la optimización de inventarios en un solo paso, utilizando regresión cuantil y principios de minimización de riesgo

empírico (ERM), implica un rediseño del enfoque tradicional a la gestión de inventarios. Esta transición exige que las organizaciones adopten un pensamiento más algorítmico y menos basado en reglas predefinidas. (Punia et al., 2020)

El tercer desafío es organizacional: aunque el modelo tiene un excelente desempeño, su adopción en el mundo real requiere cambios en los procesos de toma de decisiones, en la infraestructura de TI y en la cultura organizacional, que debe pasar de “intuir” la demanda a “confiar” en los datos.

A diferencia de otros estudios que se enfocan en el nivel conceptual o sectorial, el trabajo de Punia et al. (2020) aterriza sus propuestas en un caso empírico concreto: una cadena minorista que vende alimentos perecederos. La base de datos utilizada incluye 156 semanas de ventas de 16 productos, con variables relacionadas con clima, promociones, visitas a tienda, precios, y hasta indicadores económicos regionales como el índice de actividad económica (Econ\_Index).

A partir de este escenario, los autores comparan diferentes métodos de predicción, incluyendo modelos clásicos como ARIMA y métodos de vanguardia como Random Forest y Deep Neural Networks. El resultado es contundente: RF y DNN superan en precisión y menor error a todos los demás modelos. Por ejemplo, el modelo de Random Forest logró un error absoluto medio (MAE) de apenas 1.47, frente a 7.42 del modelo estacional naïve **【Tabla 3】** . (Punia et al., 2020)

Pero lo más relevante es lo que sucede cuando estas predicciones se usan para tomar decisiones reales: la optimización de inventarios basada en el modelo QR-ML (regresión cuantil con machine learning) redujo los costos totales de inventario en todos los grupos de productos, llegando a ser 100% más eficiente que métodos como el de máxima aproximación o el empírico con distribución normal. (Punia et al., 2020)

En otras palabras, no solo se predice mejor. Se gestiona mejor. Se ahorra. Se decide con más confianza. Y se convierte la ciencia de datos en una ventaja tangible para la operación del negocio.

Rai y sus colegas reúnen a una comunidad internacional de expertos para ofrecer una visión condensada pero reveladora sobre cómo el Machine Learning (ML) está transformando la industria manufacturera dentro del paradigma de la Industria 4.0. En lugar de analizar un solo caso o técnica, esta obra articula una visión holística de cómo la analítica, la inteligencia artificial y el aprendizaje automático están rediseñando el presente y futuro de las operaciones industriales inteligentes. (Rai et al., 2021)

El artículo destaca una serie de beneficios estratégicos del uso de ML en manufactura, agrupados en tres grandes fases del ciclo de producción:

1. Operaciones y Producción: Desde la predicción de mantenimiento hasta la inspección automatizada de calidad, el ML permite reducir errores, minimizar paradas inesperadas y mejorar la eficiencia en línea. (Rai et al., 2021)

2. Post-producción: Tecnologías como el IoT y la analítica prescriptiva permiten rastrear y optimizar la distribución de productos, así como mejorar la experiencia del cliente mediante personalización y trazabilidad. (Rai et al., 2021)

3. Sostenibilidad y competitividad: La integración de ML con otras tecnologías (cloud computing, digital twins, realidad aumentada) permite a las empresas lograr una producción más ágil, sostenible y basada en decisiones inteligentes, incluso en entornos volátiles. (Rai et al., 2021)

Entre los ejemplos concretos se encuentra el uso de visión por computadora con sensores económicos y redes neuronales para la inspección continua, la mejora de líneas de ensamblaje, la

reducción de mermas en la cadena de suministro, y la predicción del estado de componentes clave en maquinaria crítica. (Rai et al., 2021)

Pero el avance no es automático. Rai et al. señalan varios desafíos significativos para la plena adopción del ML en entornos manufactureros:

- Curación, almacenamiento y razonamiento de Big Data: Aunque los sensores industriales generan grandes volúmenes de datos, muchas empresas no cuentan con procesos sólidos para estructurarlos, limpiarlos o interpretarlos correctamente. (Rai et al., 2021)

- Edge computing y ciberseguridad: A medida que los dispositivos de producción se conectan a la nube, los retos de latencia, protección de datos y escalabilidad se vuelven centrales para la viabilidad del ecosistema ciberfísico. (Rai et al., 2021)

- Escasez de datos etiquetados y generalización limitada: Muchas técnicas de ML requieren conjuntos de datos robustos y bien anotados, lo cual es escaso o costoso de obtener en entornos industriales reales. (Rai et al., 2021)

- Falta de integración entre modelos físicos y ML: En industrias donde los errores pueden ser costosos o peligrosos, se requiere combinar el conocimiento físico del proceso con modelos algorítmicos (enfoques híbridos), una tarea aún en desarrollo. (Rai et al., 2021)

Si bien Rai et al. (2021) no relatan un caso específico de empresa, el artículo funciona como una síntesis aplicada de múltiples desarrollos experimentales, cada uno de ellos ilustrando un aspecto clave del avance de ML en manufactura.

- En inspección automatizada, se destaca el caso de Chen et al. (2020), donde se emplean CNNs y SVM para detectar defectos en chips mediante imágenes de rayos X, logrando resultados de alta precisión a bajo costo. (Rai et al., 2021)

- En diagnóstico de fallas, se menciona el enfoque de Wang et al. (2020) que combina aprendizaje profundo (DLSTM) con redes convolucionales deformables para detectar fallas en rodamientos bajo condiciones variables, usando *transfer learning* para generalizar a nuevos contextos con pocos datos. (Rai et al., 2021)

- En optimización de procesos, Lorenz et al. (2021) aplican minería de procesos a líneas de producción complejas, demostrando mejoras tangibles en productividad en una planta de productos sanitarios. (Rai et al., 2021)

- Finalmente, Jian et al. (2020) proponen un sistema de programación híbrida en nube para coordinar tareas en ambientes distribuidos, utilizando algoritmos de optimización bioinspirados y redes LSTM. (Rai et al., 2021)

Estos hallazgos, dispersos en distintas áreas de aplicación, comparten un hilo común: el ML no solo predice, sino que transforma, permite decidir y optimizar, incluso bajo incertidumbre. A través de estos ejemplos, se demuestra que la manufactura inteligente no es una promesa, sino una realidad en evolución acelerada.

El artículo de Adenekan (2025) se erige como una hoja de ruta para entender el presente y futuro de la inteligencia de negocios moderna. A diferencia de enfoques centrados en una tecnología específica, este estudio apuesta por una visión convergente: integrar Big Data, Inteligencia Artificial, Aprendizaje Automático, Internet de las Cosas y Blockchain para rediseñar la manera en que las organizaciones toman decisiones. No se trata de una mejora incremental; se trata de revolucionar la arquitectura misma del Business Intelligence (BI).

Desde las primeras secciones, el autor destaca cómo esta integración tecnológica potencia las capacidades del BI en tres niveles clave: análisis predictivo, toma de decisiones en tiempo real y fortalecimiento de la seguridad de los datos. (Adenekan, 2025)

- La Inteligencia Artificial (IA) y el Machine Learning (ML) automatizan la extracción de patrones, mejoran la precisión de los modelos predictivos y permiten ajustar decisiones en función de datos históricos y en tiempo real. (Adenekan, 2025)

- El Internet de las Cosas (IoT) aporta un flujo constante de datos desde sensores, máquinas y dispositivos conectados, lo que permite una visibilidad operativa sin precedentes, especialmente útil en logística, ciudades inteligentes y salud pública(Adenekan, 2025).

- Blockchain, por su parte, garantiza la integridad y transparencia de los datos. Al utilizar libros contables inmutables y contratos inteligentes, las decisiones basadas en datos se blindan ante manipulaciones o fraudes. (Adenekan, 2025)

- Finalmente, el Big Data Analytics actúa como columna vertebral, organizando y haciendo operables volúmenes masivos de información de múltiples fuentes (estructuradas y no estructuradas). (Adenekan, 2025)

Adenekan sintetiza esta sinergia como la base de una nueva era del BI: descentralizada, automatizada y más resiliente frente al cambio.

A pesar del panorama prometedor, el autor no omite las barreras que impiden una adopción fluida:

- 1.Escalabilidad técnica: tecnologías como blockchain y el ML requieren recursos computacionales significativos. La infraestructura de muchas empresas aún no está preparada para operar a escala con este tipo de arquitecturas. (Adenekan, 2025)

- 2.Interoperabilidad y compatibilidad entre sistemas: combinar herramientas heredadas con nuevas plataformas genera fricciones técnicas y problemas de gobernanza de datos. (Adenekan, 2025)

3.Privacidad y cumplimiento normativo: el uso de datos en tiempo real (especialmente provenientes del IoT) pone en juego la protección de la privacidad del usuario y la adherencia a normativas como GDPR y CCPA. (Adenekan, 2025)

4.Costo y complejidad de implementación: pequeñas y medianas empresas enfrentan obstáculos financieros y de talento humano para desplegar estas soluciones. Los expertos entrevistados por Adenekan revelan que muchas organizaciones carecen de personal capacitado para explotar el potencial de estas tecnologías. (Adenekan, 2025)

Estos retos no invalidan la transformación digital, pero sí exigen una planificación estratégica integral, que contemple tanto la parte tecnológica como la organizacional y cultural.

Uno de los aportes más valiosos de este artículo es que no se limita a presentar una visión conceptual. Adenekan construye un caso transversal a partir del análisis de entrevistas y estudios sectoriales, generando evidencia empírica sobre cómo estas tecnologías están siendo integradas en sectores como salud, finanzas y manufactura. (Adenekan, 2025)

- En finanzas, el uso de IA combinada con blockchain ha permitido detectar fraudes en tiempo real y automatizar procesos de verificación de identidad, reduciendo en 75% los incidentes de seguridad en algunas instituciones bancarias. (Adenekan, 2025)

- En el sector salud, se identificaron hospitales que aplican IA para diagnosticar enfermedades crónicas a partir de imágenes y registros médicos, mientras que el IoT monitorea signos vitales y Blockchain asegura la trazabilidad de los historiales clínicos. (Adenekan, 2025)

- En supply chain y ciudades inteligentes, el modelo híbrido entre edge computing y analítica en la nube permite tomar decisiones locales en milisegundos (como activar semáforos inteligentes o reconfigurar rutas de entrega) con base en datos del entorno. (Adenekan, 2025)

Estos ejemplos no son meros escenarios hipotéticos. Adenekan los respalda con métricas como la mejora del 140% en la velocidad de procesamiento, un aumento del 26% en la precisión de modelos predictivos, y una reducción del 75% en brechas de seguridad comparado con BI tradicional. (Adenekan, 2025)

Más que un caso, es una síntesis representativa del tipo de impacto que puede tener un BI realmente inteligente y conectado.

### **Análisis Comparativo**

En primer término, Gurcan et al. (2023) destacan que la integración de Business Intelligence, Machine Learning y Big Data permite transformar grandes volúmenes de datos en conocimientos útiles que impulsan la toma de decisiones ágiles y precisas. Este autor subraya un notable incremento en la capacidad organizacional (+0.57) para alinear competencias técnicas con objetivos estratégicos. El análisis expone cómo las aplicaciones de inteligencia artificial han evolucionado, pasando de simples reportes históricos a sofisticados sistemas de apoyo predictivo para la gestión empresarial. Además, hace hincapié en la consolidación de tecnologías como Data Mining, Big Data Analytics y Visualization (+0.21 a +0.26), claves para ofrecer información estratégica en tiempo real y potenciar la innovación y la ventaja competitiva.

Por su parte, Khan et al. (2020) presentan el caso de éxito de un modelo predictivo en el sector retail, basado en el algoritmo DeepAR de Amazon SageMaker, que logró una precisión del 92.38 % en la previsión de demanda. Gracias a este modelo, fue posible reducir considerablemente las pérdidas por sobreproducción, optimizar los inventarios y planificar semanalmente por tienda. No obstante, estos autores advierten sobre la necesidad de contar con datos históricos sólidos y sobre la complejidad técnica inherente a la integración y normalización de fuentes diversas, como datos fiscales y promociones.

Desde una visión crítica, Sharma & Srinath (2018) evidencian el valor de la minería de datos soportada en ML, que convierte conjuntos de datos dispersos en conocimiento estratégico, especialmente mediante la detección avanzada de anomalías. Este enfoque resulta esencial en sectores sensibles como ciberseguridad, salud, meteorología y finanzas. Sin embargo, también señalan que el análisis de datos altamente complejos y no estructurados exige técnicas avanzadas y, en consecuencia, elevados recursos computacionales.

El estudio de Sánchez-Torres et al. (2022) aporta una perspectiva innovadora en el ámbito hotelero, donde el uso de algoritmos de clustering jerárquico facilitó el control de costos al identificar productos sustitutos más económicos, reduciendo mermas y desperdicios. A pesar de estos avances, los autores encuentran dificultades operativas relacionadas con la integración de sistemas dispersos y la inconsistencia en la calidad de los datos.

En lo referente a la resistencia cultural, Bordeleau et al. (2020) y Popovič et al. (2019) subrayan que la adopción efectiva de BI y ML requiere mucho más que tecnología: implica una transformación profunda en la mentalidad y cultura organizacional. Particularmente en pymes, la arraigada tradición operativa y la baja digitalización constituyen barreras relevantes que dificultan el aprovechamiento pleno de estas herramientas.

Talaoui & Kohtamäki (2020) refuerzan esta idea, al señalar que la inteligencia artificial tiene el potencial de redefinir modelos de negocio y aportar valor, pero enfrenta importantes retos organizativos, entre ellos la resistencia de los equipos directivos a automatizar decisiones estratégicas y los desafíos éticos relacionados con la transparencia y explicabilidad de los modelos.

Por otro lado, Liu et al. (2023) y Rosati et al. (2023) destacan los retos técnicos derivados de la calidad y heterogeneidad de los datos, enfatizando la necesidad de procesos rigurosos de

limpieza, normalización y gobierno para garantizar análisis fiables. Asimismo, reconocen la importancia de plataformas robustas como Apache Spark y Hadoop para procesar de manera eficiente grandes volúmenes de información en entornos como telecomunicaciones y manufactura.

Con respecto al talento, Rosati et al. (2023) documentan cómo la escasez de perfiles híbridos limita la capacidad de las empresas para gestionar e interpretar análisis complejos, obligándolas a depender en exceso de consultorías externas.

Pese a estos desafíos, los beneficios son contundentes, como se puede ver en la tabla 6: la automatización de procesos operativos y analíticos, la optimización proactiva del inventario, la eficiencia operativa y la personalización de servicios y productos se presentan como resultados tangibles.

**Tabla 6**

*Beneficios de la Integración*

Beneficios identificados	Impacto Estratégico	Referencia	Sector Afectado
Capacidad organizacional aumentada	Alineación técnica-estratégica	Gurcan et al. (2023)	General
Automatización predictiva con IA	Decisiones predictivas automatizadas	Gurcan et al. (2023)	General
Alta precisión predictiva (92.38%)	Optimización de compras e inventarios	Khan et al. (2020)	Retail
Pronósticos personalizados	Planificación detallada estratégica	Khan et al. (2020)	Retail
Centralización de información y procesos	Mejor visibilidad y adaptación ágil	Khan et al. (2020)	Retail

Beneficios identificados	Impacto Estratégico	Referencia	Sector Afectado
Identificación avanzada de patrones (outliers)	Anticipación de riesgos y oportunidades	Sharma & Srinath (2018)	General (Ciberseguridad, Salud)
Control de costos y sustitución de productos	Reducción de desperdicios y costos	Sánchez-Torres et al. (2022)	Hotelero (Alimentos y Bebidas)
Segmentación avanzada de clientes	Estrategias personalizadas efectivas	Hamzehi & Hosseini (2022)	Farmacéutico
Reglas de asociación (Apriori)	Optimización inventarios y promociones	Hamzehi & Hosseini (2022)	Farmacéutico
Mejora en toma de decisiones estratégicas	Anticipación proactiva a riesgos/oportunidades	Pancić et al. (2023)	Tecnológico
Incremento eficiencia operativa con blockchain	Transparencia y trazabilidad	Pancić et al. (2023)	Tecnológico

En síntesis, la integración estratégica de BI, ML y Big Data en la Industria 4.0 supone superar importantes retos técnicos, organizativos y culturales, como se puede observar en la tabla 7. Sin embargo, las organizaciones que logran esta convergencia no solo optimizan sus operaciones, sino que alcanzan ventajas competitivas sostenibles gracias a una toma de decisiones más inteligente, precisa y ágil en un escenario cada vez más dinámico y tecnológico.

**Tabla 7***Retos de la Integración*

Retos identificados	Implicación	Referencia	Sector Afectado
Gestión tradicional del conocimiento	Replantear estrategias organizacionales	Gurcan et al. (2023)	General
Transición de estructuras rígidas (Semantic Web y SDLC)	Modernizar infraestructura BI	Gurcan et al. (2023)	General
Generar valor mediante analítica prescriptiva	Necesidad de toma autónoma de decisiones	Gurcan et al. (2023)	General
Dependencia de datos históricos robustos	Implementación heurística complementaria	Khan et al. (2020)	Retail
Integración y normalización de fuentes diversas	Desarrollar procesos de limpieza robustos	Khan et al. (2020)	Retail
Complejidad técnica en configuraciones de ML	Necesidad de talento especializado	Khan et al. (2020)	Retail
Complejidad dimensional de datos	Necesidad de técnicas avanzadas	Sharma & Srinath (2018)	General

Retos identificados	Implicación	Referencia	Sector Afectado
Carencia de estructuras para datos no estructurados	Limitación en análisis efectivo	Sharma & Srinath (2018)	General
Dispersión de datos en 'islas tecnológicas'	Dificultad en integración efectiva	Sánchez-Torres et al. (2022)	Hotelero (Alimentos y Bebidas)
Ajuste en algoritmos clustering	Requerimiento de calibración continua	Sánchez-Torres et al. (2022)	Hotelero (Alimentos y Bebidas)
Resistencia cultural al cambio	Barreras en adopción efectiva de BI y ML	Bordeleau et al. (2020), Popovič et al. (2019)	PyMES
Falta de talento híbrido especializado	Dependencia de consultores externos	Silva et al. (2021)	General
Desalineación tecnológica-estratégica	Implementaciones poco óptimas	Pancić et al. (2023)	Tecnológico
Dificultades técnicas en blockchain	Interoperabilidad y confianza limitada	Pancić et al. (2023)	Tecnológico

## Conclusiones

La implementación de tecnologías emergentes como Business Intelligence, Machine Learning y Big Data no solo proporciona soluciones efectivas para la gestión de información, sino que actúa como un diferenciador clave entre organizaciones capaces de adaptarse rápidamente a entornos cambiantes y aquellas que permanecen rezagadas en términos tecnológicos. Las empresas que logran integrar estas herramientas estratégicamente experimentan un impulso significativo en su capacidad para personalizar la experiencia del cliente, anticipar riesgos financieros, y optimizar la eficiencia operativa, posicionándose así con una ventaja competitiva sólida en sus sectores.

La investigación revela que el éxito de las iniciativas tecnológicas en Business Intelligence, Machine Learning y Big Data depende considerablemente de una integración fluida no solo entre herramientas tecnológicas, sino también entre equipos humanos multidisciplinarios. Las organizaciones que fomentan la colaboración interdepartamental, apoyada en herramientas intuitivas de visualización y plataformas analíticas avanzadas, consiguen decisiones estratégicas más fundamentadas y adaptativas. Este enfoque subraya la necesidad de no solo enfocarse en la adquisición de tecnologías punteras, sino también en el desarrollo de una cultura organizacional abierta a la colaboración y al aprendizaje continuo para aprovechar plenamente el potencial de estas soluciones digitales.

En la transición hacia la Industria 4.0, la verdadera ventaja competitiva no radica únicamente en implementar tecnologías avanzadas de manera aislada, sino en la capacidad de integrarlas sinérgicamente en plataformas unificadas. La interoperabilidad entre herramientas analíticas avanzadas como Power BI, plataformas de Machine Learning (Azure ML, AWS SageMaker) y sistemas robustos de gestión de Big Data (Spark, Hadoop), permite a las

organizaciones tomar decisiones ágiles y precisas al aprovechar al máximo la interacción entre datos históricos y análisis predictivos en tiempo real.

Un hallazgo clave derivado del análisis es que las empresas exitosas en la adopción de la Industria 4.0 se destacan por adoptar infraestructuras híbridas que combinan almacenamiento en la nube con tecnologías en las instalaciones (on-premises). Esta estrategia permite una flexibilidad operativa significativa, facilitando tanto la escalabilidad ante la creciente demanda de procesamiento de grandes volúmenes de datos como la adaptación rápida a requerimientos específicos de privacidad y seguridad. De esta manera, las organizaciones logran equilibrar eficiencia, seguridad y rendimiento, estableciendo bases sólidas para el crecimiento sostenible en entornos altamente digitalizados.

La integración estratégica de Business Intelligence, Machine Learning y Big Data en la Industria 4.0 implica superar retos tanto tecnológicos como culturales, especialmente en pequeñas y medianas empresas donde la resistencia al cambio y la falta de talento híbrido limitan el avance. El desafío no es solo adoptar herramientas avanzadas, sino fomentar una cultura organizacional adaptable e innovadora. Las organizaciones que apuestan por la capacitación interna, alianzas estratégicas y la inversión constante en infraestructura tecnológica, logran transformar la información en decisiones ágiles y efectivas, posicionándose como líderes en sectores competitivos gracias a su capacidad para convertir datos complejos en ventajas operativas y estratégicas.

La automatización avanzada impulsada por tecnologías como el Machine Learning y algoritmos predictivos, ha evolucionado más allá de simples mejoras operativas y reducción de costos, convirtiéndose en una pieza fundamental para la toma de decisiones estratégicas en las organizaciones actuales. Estas tecnologías brindan capacidades excepcionales para personalizar

decisiones sobre productos y servicios, anticipar proactivamente riesgos financieros y responder de manera ágil a las cambiantes condiciones del mercado. El verdadero impacto de estas herramientas radica en cómo potencian decisiones informadas y precisas, enriqueciendo la experiencia del cliente y fortaleciendo la resiliencia competitiva de las organizaciones. Los casos analizados reflejan que la ventaja estratégica en la Industria 4.0 no solo se obtiene mediante la innovación tecnológica, sino fundamentalmente a través de una integración inteligente y estratégica de estas soluciones dentro de los procesos decisorios organizacionales, impulsando modelos de negocio dinámicos, adaptativos y profundamente orientados al análisis avanzado de datos.

## Recomendaciones

Las recomendaciones para futuras investigaciones en analítica avanzada y transformación digital enfatizan la importancia de enfoques integrales que combinen metodologías cualitativas y cuantitativas. Es fundamental comprender en profundidad las percepciones y resistencias culturales de las personas colaboradoras, así como desarrollar modelos híbridos que permitan predecir y contextualizar resultados, mejorando la toma de decisiones estratégicas. En este sentido, se sugiere focalizar esfuerzos en el estudio de PyMEs, buscando soluciones escalables, accesibles y con costos asequibles, especialmente aquellas que aprovechen tecnologías en la nube para cerrar la brecha tecnológica.

Además, se destaca la necesidad de abordar aspectos éticos y de gobernanza mediante el desarrollo de marcos que gestionen riesgos de privacidad, sesgos algorítmicos y transparencia en procesos automatizados. La formación de talento híbrido, capaz de combinar habilidades técnicas con visión estratégica de negocio, resulta clave, por lo que se recomienda investigar modelos educativos innovadores y colaboraciones universidad-empresa. Paralelamente, la integración y estandarización de datos provenientes de fuentes diversas —como IoT, ERP y CRM— es vista como un reto técnico prioritario para facilitar la adopción efectiva de plataformas analíticas.

Finalmente, se propone documentar casos de éxito detallados que sirvan como modelos replicables y explorar cómo la analítica avanzada puede contribuir a la sostenibilidad y minimizar el impacto ambiental en sectores industriales clave. El desarrollo de plataformas integradas que combinen Business Intelligence, Machine Learning, Big Data y tecnologías emergentes como Blockchain e Inteligencia Artificial, permitirá consolidar una ventaja

competitiva sostenible y fortalecer la toma de decisiones basada en datos en el marco de la Industria 4.0.

### Referencias Bibliográficas

- Adenekan, T. K. (2025). *Revolutionizing Business Intelligence: Integrating Big Data, AI, Machine Learning, IoT, and Blockchain for Smarter Decision-Making*.  
<https://www.researchgate.net/publication/389340232>
- Ain, N. U., Vaia, G., DeLone, W. H., & Waheed, M. (2019). Two decades of research on business intelligence system adoption, utilization and success – A systematic literature review. *Decision Support Systems*, 125. <https://doi.org/10.1016/j.dss.2019.113113>
- Alasa, D. K. (2021). Enhanced business intelligence through the convergence of big data analytics, AI, Machine Learning, IoT and Blockchain. *Open Access Research Journal of Science and Technology*, 2(2), 023–030. <https://doi.org/10.53022/oarjst.2021.2.2.0042>
- Alqhatani, A., Ashraf, M. S., Ferzund, J., Shaf, A., Abosaq, H. A., Rahman, S., Irfan, M., & Alqhtani, S. M. (2022). 360° Retail Business Analytics by Adopting Hybrid Machine Learning and a Business Intelligence Approach. *Sustainability*, 14(19), 11942. <https://doi.org/10.3390/su141911942>
- Alshahrani, S. T. (2023). Industry 4.0 in “Major Emerging Markets”: A Systematic Literature Review of Benefits, Use, Challenges, and Mitigation Strategies in Supply Chain Management. *Sustainability*, 15(20), 14811. <https://doi.org/10.3390/su152014811>
- Al-Zoubi, L., Al-Khazaleh, S., & Badwan, N. (2023). Financial Risk Management in the Supply Chain Using Business Intelligence and Big Data. *The International Journal of Business and Management Research*, 7(1), 1–27. <https://www.researchgate.net/publication/371986804>
- Amalina, F., Targio Hashem, I. A., Azizul, Z. H., Fong, A. T., Firdaus, A., Imran, M., & Anuar, N. B. (2020). Blending Big Data Analytics: Review on Challenges and a Recent Study. *IEEE Access*, 8, 3629–3645. <https://doi.org/10.1109/ACCESS.2019.2923270>

- Araque González, G. A., & Giampietro Torres, V. J. (2023). El Big Data aplicado en la industria 4.0 : un caso en el sector textil colombiano con un enfoque en la inteligencia de negocios. *Cuaderno Activa*, 14(1). <https://doi.org/10.53995/20278101.1176>
- Bordeleau, F. E., Mosconi, E., & de Santa-Eulalia, L. A. (2020). Business intelligence and analytics value creation in Industry 4.0: a multiple case study in manufacturing medium enterprises. *Production Planning and Control*, 31(2–3), 173–185. <https://doi.org/10.1080/09537287.2019.1631458>
- Boulahia, C., Behja, H., Chbihi Louhdi, M. R., & Boulahia, Z. (2024). The multi-criteria evaluation of research efforts based on ETL software: from business intelligence approach to big data and semantic approaches. *Evolutionary Intelligence*, 17(4), 2099–2124. <https://doi.org/10.1007/s12065-023-00899-z>
- Chen, Y., Li, C., & Wang, H. (2022). Big Data and Predictive Analytics for Business Intelligence: A Bibliographic Study (2000–2021). *Forecasting*, 4(4), 767–786. <https://doi.org/10.3390/forecast4040042>
- Dueñas-Ramírez, L. M., Villegas-López, G. A., Castiblanco-Tique, S., & Castaño-Restrepo, C. A. (2020). Casos de éxito en la implementación del mantenimiento predictivo mediante el uso de tecnologías de la industria 4.0 en empresas colombianas. *Actas Del III Congreso Internacional de Ingeniería de Sistemas*, 109–121.
- Figueroa-Donayre, E. M., Guillén-Guevara, M. L., Humpiri-Flores, R., Cabel-Moscoso, D. J., Sullon-Macalupu, A. A., & Humpiri-Flores, M. E. (2023). Machine Learning en la Industria 4.0: Análisis de su relevancia y aplicaciones. *Ñawparisun - Revista de Investigación Científica*, 4(3), 93–98. <https://doi.org/10.47190/nric.v4i3.272>

- Garate, G. (2022, March). *¿Qué entendemos por algoritmo?* . <https://ude.edu.uy/que-son-algoritmos/>
- García Meza, V. A., & Lázaro Barrera, S. H. (2025). *Revisión teórica de modelos de Machine Learning para la predicción del comportamiento de pago en clientes gestionados desde contact-center, sector cobranzas* [Especialización]. Universidad Nacional Abierta y a Distancia.
- García-Jiménez, A. de-J., Aguilar-Morales, N., Hernández-Triano, L., & Lancaster-Díaz, E. (2021). LA INTELIGENCIA DE NEGOCIOS: HERRAMIENTA CLAVE PARA EL USO DE LA INFORMACIÓN Y LA TOMA DE DECISIONES EMPRESARIALES. *Revista de Investigaciones Universidad Del Quindío*, 33(1), 132–139.  
<https://doi.org/10.33975/riuq.vol33n1.514>
- Granados, R. (2016). *Modelos de Regresión Lineal Múltiple*.
- Gurcan, F., Ayaz, A., Menekse Dalveren, G. G., & Derawi, M. (2023). Business Intelligence Strategies, Best Practices, and Latest Trends: Analysis of Scientometric Data from 2003 to 2023 Using Machine Learning. *Sustainability (Switzerland)*, 15(13).  
<https://doi.org/10.3390/su15139854>
- Hamzehi, M., & Hosseini, S. (2022). Business intelligence using machine learning algorithms. *Multimedia Tools and Applications*, 81(23), 33233–33251. <https://doi.org/10.1007/s11042-022-13132-3>
- Iberdorla. (2022). *“Machine Learning”: definición, tipos y aplicaciones prácticas*. Iberdrola.  
<https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatico>
- Khan, M. A., Saqib, S., Alyas, T., Ur Rehman, A., Saeed, Y., Zeb, A., Zareei, M., & Mohamed, E. M. (2020). Effective Demand Forecasting Model Using Business Intelligence

Empowered with Machine Learning. *IEEE Access*, 8, 116013–116023.

<https://doi.org/10.1109/ACCESS.2020.3003790>

Lanza Cruz, I. L. (2016). *Definición y análisis de indicadores estratégicos para redes sociales. Un caso de estudio en el sector automovilístico* [Maestría]. Escuela Superior de Tecnología y Ciencias Experimentales.

Lepenioti, K., Bousdekis, A., Apostolou, D., & Mentzas, G. (2020). Prescriptive analytics: Literature review and research challenges. *International Journal of Information Management*, 50, 57–70. <https://doi.org/10.1016/j.ijinfomgt.2019.04.003>

Liu, S., Liu, O., & Chen, J. (2023). A Review on Business Analytics: Definitions, Techniques, Applications and Challenges. *Mathematics*, 11(4), 899. <https://doi.org/10.3390/math11040899>

McKinney, W. (2022). *Python for Data Analysis Data Wrangling with pandas, NumPy & Jupyter* (J. Haberman, A. Rufino, C. Faucher, & S. Saruba, Eds.; Third). O'Reilly Media Inc.

Moher, D., Liberati, A., Tetzlaff, J., & Altman, D. (2009). Moher D, Liberati A, Tetzlaff J, Altman DG, Group P Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *PLoS Med* 6: e1000097. *Open Medicine : A Peer-Reviewed, Independent, Open-Access Journal*, 3, e123-30. <https://doi.org/10.1016/j.jclinepi.2009.06.005>

Necochea-Chamorro, J. I., & Larrea-Goycochea, L. (2023). Business Intelligence Applied in the Corporate Sector: A Systematic Review. *TEM Journal*, 12(4), 2225–2234. <https://doi.org/10.18421/TEM124-33>

- Niu, Y., Ying, L., Yang, J., Bao, M., & Sivaparthipan, C. B. (2021). Organizational business intelligence and decision making using big data analytics. *Information Processing & Management*, 58(6), 102725. <https://doi.org/10.1016/j.ipm.2021.102725>
- Nobanee, H. (2020). Big Data in Business: A Bibliometric Analysis of Relevant Literature. *Big Data*, 8(6), 459–463. <https://doi.org/10.1089/big.2020.29042.edi>
- Oracle. (2013). *What Are RESTful Web Services? - The Java EE 6 Tutorial*. Oracle. <https://docs.oracle.com/javaee/6/tutorial/doc/gijqy.html>
- Pancić, M., Čučić, D., & Serdarušić, H. (2023). Business Intelligence (BI) in Firm Performance: Role of Big Data Analytics and Blockchain Technology. *Economies*, 11(3). <https://doi.org/10.3390/economies11030099>
- Paradza, D., & Daramola, O. (2021). Business intelligence and business value in organisations: A systematic literature review. *Sustainability (Switzerland)*, 13(11382). <https://doi.org/10.3390/su132011382>
- Popovič, A., Puklavec, B., & Oliveira, T. (2019). Justifying business intelligence systems adoption in SMEs: Impact of systems use on firm performance. *Industrial Management and Data Systems*, 119(1), 210–228. <https://doi.org/10.1108/IMDS-02-2018-0085>
- Punia, S., Singh, S. P., & Madaan, J. K. (2020). From predictive to prescriptive analytics: A data-driven multi-item newsvendor model. *Decision Support Systems*, 136, 113340. <https://doi.org/10.1016/j.dss.2020.113340>
- Rachman, F. P., Santoso, H., & Djajadi, A. (2021). Machine Learning Mini Batch K-means and Business Intelligence Utilization for Credit Card Customer Segmentation. *IJACSA International Journal of Advanced Computer Science and Applications*, 12(10), 218–227. [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org)

- Raghupathi, W., & Raghupathi, V. (2021). Contemporary business analytics: An overview. *Data*, 6(86). <https://doi.org/10.3390/data6080086>
- Rai, R., Tiwari, M. K., Ivanov, D., & Dolgui, A. (2021). Machine learning in manufacturing and industry 4.0 applications. *International Journal of Production Research*, 59(16), 4773–4778. <https://doi.org/10.1080/00207543.2021.1956675>
- Rane, N. L., Paramesha, M., Choudhary, S. P., & Rane, J. (2024). *Business intelligence through artificial intelligence: a review*. <https://ssrn.com/abstract=4831916>
- Raschka, S., & Mirjalili, V. (2017). *Python Machine Learning* (2nd ed., Vol. 2). Packt Publishing.
- Richards, G., Yeoh, W., Chong, A. Y. L., & Popovič, A. (2019). Business Intelligence Effectiveness and Corporate Performance Management: An Empirical Analysis. *Journal of Computer Information Systems*, 59(2), 188–196. <https://doi.org/10.1080/08874417.2017.1334244>
- Rosati, R., Romeo, L., Cecchini, G., Tonetto, F., Viti, P., Mancini, A., & Frontoni, E. (2023). From knowledge-based to big data analytic model: a novel IoT and machine learning based decision support system for predictive maintenance in Industry 4.0. *Journal of Intelligent Manufacturing*, 34(1), 107–121. <https://doi.org/10.1007/s10845-022-01960-x>
- Sánchez-Torres, F., González, I., & Dobrescu, C. C. (2022). Machine Learning in Business Intelligence 4.0: Cost Control in a Destination Hotel. *International Journal of Interactive Multimedia and Artificial Intelligence*, 7(3), 86–95. <https://doi.org/10.9781/ijimai.2022.02.008>
- Sandner, P., Gross, J., & Richter, R. (2020). Convergence of Blockchain, IoT, and AI. *Frontiers in Blockchain*, 3. <https://doi.org/10.3389/fbloc.2020.522600>

- Selvarajan, G. P. (2024). The Role of Machine Learning Algorithms in Business Intelligence: Transforming Data into Strategic Insights. *International Journal of Advanced Research and Interdisciplinary Scientific Endeavours*, 1(7), 2024. <https://doi.org/10.61359/11.2206-2440>
- Sharma, A., Podoplelova, E., Shapovalov, G., Tselykh, A., & Tselykh, A. (2021). Sustainable Smart Cities: Convergence of Artificial Intelligence and Blockchain. *Sustainability*, 13(23), 13076. <https://doi.org/10.3390/su132313076>
- Sharma, R., & Srinath, P. (2018). Business Intelligence using Machine Learning and Data Mining techniques-An analysis. *IEEE Xplore*, 42487, 1473–1478.
- Silva, A. J., Cortez, P., Pereira, C., & Pilastrri, A. (2021). Business analytics in Industry 4.0: A systematic review. *Expert Systems*, 38(7). <https://doi.org/10.1111/exsy.12741>
- Srivastava, G., S, M., Venkataraman, R., V, K., & N, P. (2022). A review of the state of the art in business intelligence software. *Enterprise Information Systems*, 16(1), 1–28. <https://doi.org/10.1080/17517575.2021.1872107>
- Stalin, L., Telenchana, L., Alexandra, X., López, Q., Marcelo, D., Haro, R., Ángel, L., & Sánchez, C. (2024). La Utilización de la Big Data y Business Intelligence en la formulación de decisiones estratégicas para empresas del sector industrial. *Revista Social Fronteriza*, 4(2). [https://doi.org/10.59814/resofro.2024.4\(2\)e196](https://doi.org/10.59814/resofro.2024.4(2)e196)
- Talaoui, Y., & Kohtamäki, M. (2020). 35 years of research on business intelligence process: a synthesis of a fragmented literature. *Management Research Review*, 44(5), 677–717. <https://doi.org/10.1108/MRR-07-2020-0386>
- Tavera Romero, C. A., Ortiz, J. H., Khalaf, O. I., & Ríos Prado, A. (2021). Business Intelligence: Business Evolution after Industry 4.0. *Sustainability*, 13(18), 10026. <https://doi.org/10.3390/su131810026>

- VanderPlas, J. (2023). *Python Data Science Handbook Essential Tools for Working with Data* (A. Black, J. Leonard, K. Tozer, & R. Head, Eds.; Second). O'Reilly Media Inc.
- Yin, J., & Fernandez, V. (2020). A systematic review on business analytics. *Journal of Industrial Engineering and Management*, 13(2), 283–295.  
<https://doi.org/10.3926/jiem.3030>

## Apéndices

### Apéndice A

*Puntuación de Referencias por Tipología*

[https://unadvirtualedu-my.sharepoint.com/personal/dyacevedod\\_unadvirtual\\_edu\\_co/Documents/Proyecto%20de%20Grado/Proyecto/Ap%C3%A9ndice.xlsx](https://unadvirtualedu-my.sharepoint.com/personal/dyacevedod_unadvirtual_edu_co/Documents/Proyecto%20de%20Grado/Proyecto/Ap%C3%A9ndice.xlsx)

### Apéndice B

*Matriz Revisión Sistemática de Estudios*

[https://unadvirtualedu-my.sharepoint.com/personal/dyacevedod\\_unadvirtual\\_edu\\_co/Documents/Proyecto%20de%20Grado/Proyecto/Ap%C3%A9ndice.xlsx](https://unadvirtualedu-my.sharepoint.com/personal/dyacevedod_unadvirtual_edu_co/Documents/Proyecto%20de%20Grado/Proyecto/Ap%C3%A9ndice.xlsx)