INTELIGENCIA ARTIFICIAL Y ANALÍTICA PREDICTIVA PARA LA COMPETITIVIDAD EMPRESARIAL

Modelos de segmentación automatizada, predicción y recomendación estratégica



Gissela Alexandra Arcos Naranjo

Primera edición · 2026

ISBN: 978-9907-0-2126-4 DOI 10.64584/iaap3256



INTELIGENCIA ARTIFICIAL Y ANALÍTICA PREDICTIVA PARA LA COMPETITIVIDAD EMPRESARIAL

Modelos de segmentación automatizada, predicción y recomendación estratégica

AUTORES

Gissela Alexandra Arcos Naranjo
Instituto Superior Tecnológico España.
gissela.arcos@iste.edu.ec
Unidad de Ciencia y Tecnología
https://orcid.org/0000-0003-1028-1224



INTELIGENCIA ARTIFICIAL Y ANALÍTICA PREDICTIVA PARA LA COMPETITIVIDAD EMPRESARIAL
Modelos de segmentación automatizada, predicción y recomendación estratégica.

ARTIFICIAL INTELLIGENCE AND PREDICTIVE ANALYTICS FOR BUSINESS COMPETITIVENESS
Automated Segmentation, Forecasting, and Strategic Recommendation Models

Primera edición, octubre 23 del 2026

ISBN: 978-9907-0-2126-4 (e-book)

DOI: 10.64584/iaap3256

Editado por:
Ing. Marco Salazar C.
Telf. 0960677758
Ambato-Ecuador

Esta obra está bajo una licencia Creative Commons Atribución-NoComercial-SinDerivadas 4.0 Internacional

Este libro ha sido sometido a un proceso de evaluación por pares externos con base a la normativa editorial. También dispone de revisión antiplagio. **Ver anexos**
Prohibida su reproducción total o parcial..

Diseño y diagramación.
Diseño, montaje y producción editorial. **MS Editorial**

ISBN: 978-9907-0-2126-4

Hecho en Ambato, Ecuador
Made in Ambato, Ecuador.

PRÓLOGO

La transformación digital de las organizaciones constituye uno de los procesos de mayor trascendencia en la evolución contemporánea de la gestión empresarial. En un entorno caracterizado por la aceleración tecnológica, la creciente disponibilidad de información y la complejidad de los mercados, las empresas enfrentan el desafío de desarrollar capacidades que les permitan interpretar su realidad, anticipar escenarios y adoptar decisiones estratégicas sustentadas en evidencia. En este contexto, la inteligencia artificial y la analítica predictiva emergen como instrumentos de especial relevancia para comprender los factores que condicionan la competitividad, fortalecer los procesos organizacionales y generar nuevas oportunidades de innovación y creación de valor.

La incorporación de tecnologías inteligentes en el ámbito empresarial representa una transformación que trasciende la automatización de actividades operativas. Su verdadero alcance se manifiesta en la posibilidad de convertir datos heterogéneos en conocimiento estratégico, identificar patrones que difícilmente podrían reconocerse mediante procedimientos convencionales y desarrollar modelos analíticos orientados a reducir la incertidumbre en los procesos de decisión. Sin embargo, el aprovechamiento de estas capacidades requiere una articulación rigurosa entre fundamentos científicos, infraestructura tecnológica, calidad de la información, competencias organizacionales y conocimiento especializado del contexto empresarial.

Desde esta perspectiva, la obra Inteligencia artificial y analítica predictiva para la competitividad empresarial: modelos de segmentación automatizada, predicción y recomendación estratégica aborda una problemática de significativa pertinencia académica y aplicada: la necesidad de integrar las capacidades de la inteligencia artificial con los procesos de planificación,



análisis y decisión empresarial, mediante una estructura metodológica que permita avanzar desde la identificación de patrones hasta la formulación de recomendaciones estratégicas contextualizadas.

El planteamiento central del libro reconoce que la competitividad empresarial no depende exclusivamente de la disponibilidad de recursos tecnológicos, sino de la capacidad organizacional para utilizarlos de manera coherente con sus objetivos, características y condiciones de operación. Bajo este enfoque, la inteligencia artificial adquiere valor estratégico cuando sus resultados se incorporan a procesos de interpretación, aprendizaje y actuación, conservando la participación del criterio humano como componente indispensable de la gestión responsable.

Uno de los aspectos conceptuales relevantes de la obra es la articulación de tres capacidades analíticas complementarias: segmentación automatizada, predicción y recomendación estratégica. La primera permite identificar agrupaciones y comportamientos diferenciados a partir de la información disponible; la segunda facilita la estimación de escenarios y tendencias mediante modelos sustentados en datos; y la tercera orienta la interpretación de los resultados hacia alternativas de actuación que pueden ser consideradas por los responsables de la gestión empresarial. Esta integración proporciona una perspectiva sistémica del aprovechamiento de la inteligencia artificial, en la que los procedimientos algorítmicos no constituyen fines independientes, sino componentes interrelacionados de una arquitectura de apoyo a la decisión.

La relevancia de este enfoque adquiere particular significado en el contexto de las micro, pequeñas y medianas empresas, cuyo desempeño se encuentra condicionado por restricciones financieras, tecnológicas y organizacionales que pueden dificultar la incorporación de herramientas analíticas avanzadas. En los

entornos productivos latinoamericanos, caracterizados por una marcada heterogeneidad empresarial, resulta fundamental promover alternativas metodológicas que reconozcan las diferencias en los niveles de madurez digital, disponibilidad de información y capacidad de inversión. En consecuencia, la obra contribuye a examinar las posibilidades de una adopción gradual y contextualizada de la inteligencia artificial, evitando concepciones exclusivamente tecnológicas que desconozcan las condiciones reales del tejido productivo.

Desde el punto de vista científico, el contenido establece una relación entre la gestión empresarial, la inteligencia de negocios, la ciencia de datos y los métodos de aprendizaje automático. Esta convergencia disciplinaria permite comprender la competitividad como un fenómeno multidimensional, en el que interactúan variables comerciales, financieras, operativas, tecnológicas y organizacionales. Asimismo, sitúa la gestión de la información como una condición fundamental para el desarrollo de sistemas inteligentes, destacando la importancia de la integración de fuentes, la calidad de los datos, la construcción de variables pertinentes y la interpretación de los resultados analíticos.

La estructura de la obra responde a una secuencia de desarrollo conceptual y metodológico que parte de los fundamentos de la competitividad empresarial en la era de la inteligencia artificial y avanza hacia el tratamiento de los datos como recursos estratégicos. A partir de esta base, se profundiza en los componentes analíticos que sustentan los procesos de segmentación, predicción y recomendación, así como en las consideraciones necesarias para articularlos dentro de soluciones orientadas al fortalecimiento de la capacidad decisional de las organizaciones.



Esta aproximación permite reconocer que la utilidad de un modelo inteligente no debe evaluarse únicamente por su complejidad computacional o por sus indicadores de desempeño técnico. Su pertinencia también depende de la calidad de la información utilizada, la consistencia de sus supuestos, la posibilidad de interpretar sus resultados y la correspondencia entre las recomendaciones generadas y las necesidades concretas de la organización. En este sentido, la obra promueve una comprensión integral de la inteligencia artificial, vinculando el rigor metodológico con la aplicabilidad empresarial.

Otro elemento fundamental es la consideración de los desafíos asociados con la implementación responsable de sistemas inteligentes. La protección de los datos, la transparencia de los procedimientos, la identificación de posibles sesgos, la gobernanza tecnológica y la supervisión humana constituyen dimensiones que deben incorporarse al análisis de las soluciones basadas en inteligencia artificial. La capacidad predictiva de un algoritmo, por sí sola, no garantiza decisiones apropiadas; sus resultados requieren evaluación crítica, contextualización y mecanismos de seguimiento que permitan determinar su contribución efectiva a los objetivos empresariales.

En el ámbito de la investigación aplicada, esta publicación ofrece una base conceptual y metodológica para orientar el diseño y estudio de herramientas de analítica empresarial. Su contenido permite establecer relaciones entre problemas organizacionales y alternativas tecnológicas, favoreciendo la formulación de propuestas que integren conocimientos administrativos y computacionales. De esta manera, el libro se proyecta como un recurso académico para investigadores, docentes, estudiantes de educación superior, profesionales de la administración y responsables de organizaciones interesados en comprender las posibilidades y limitaciones de la inteligencia artificial aplicada a la gestión estratégica.



La vinculación entre conocimiento científico y necesidades empresariales constituye, además, una dimensión relevante de la obra. En escenarios donde las instituciones de educación superior están llamadas a fortalecer su contribución al desarrollo productivo, la investigación aplicada puede favorecer la construcción de metodologías y soluciones tecnológicas contextualizadas. La generación de conocimiento adquiere así una dimensión práctica cuando permite comprender problemas específicos, orientar procesos de innovación y establecer fundamentos para futuras iniciativas de transferencia tecnológica.

En términos epistemológicos, el libro invita a reconsiderar la relación entre información, conocimiento y decisión. La disponibilidad de grandes volúmenes de datos no implica necesariamente una mayor capacidad estratégica, del mismo modo que la utilización de algoritmos sofisticados no asegura ventajas competitivas sostenibles. La generación de valor exige procesos de interpretación que permitan transformar resultados analíticos en conocimiento organizacional y, posteriormente, en acciones susceptibles de evaluación y mejora continua. Esta perspectiva sitúa el aprendizaje empresarial como un proceso dinámico, sustentado en la interacción entre capacidades humanas y tecnológicas.

En definitiva, la presente obra plantea una aproximación a la competitividad empresarial aumentada por inteligencia artificial, entendida como la capacidad de integrar información, modelos analíticos, conocimiento organizacional y criterio gerencial para fortalecer la comprensión del entorno y apoyar decisiones estratégicas. Su principal contribución conceptual radica en examinar la inteligencia artificial no como un sustituto de la dirección empresarial, sino como un conjunto de capacidades que pueden ampliar las posibilidades de análisis, anticipación y respuesta de las organizaciones.



La lectura de este libro representa una oportunidad para reflexionar sobre los fundamentos que deben orientar la transformación digital de las empresas y sobre las condiciones necesarias para convertir la innovación tecnológica en capacidades organizacionales. Su enfoque integrador invita a superar la adopción instrumental de herramientas inteligentes y avanzar hacia modelos de gestión donde los datos, la analítica y el conocimiento humano participen de manera articulada en la construcción de decisiones responsables, pertinentes y orientadas a resultados.

En un escenario empresarial marcado por la incertidumbre y la transformación permanente, el desafío no consiste únicamente en disponer de tecnologías capaces de procesar información, sino en desarrollar organizaciones preparadas para comprenderla, interpretarla y utilizarla estratégicamente. Bajo esta premisa, la obra aporta fundamentos para continuar investigando y desarrollando soluciones de inteligencia artificial que respondan a necesidades empresariales concretas y contribuyan al fortalecimiento de la competitividad, la innovación y el desarrollo productivo.

La autora



CAPÍTULO 1

COMPETITIVIDAD EMPRESARIAL EN LA ERA DE LA INTELIGENCIA ARTIFICIAL

1.1. Introducción

La competitividad empresarial atraviesa una etapa de transformación caracterizada por la convergencia entre digitalización, disponibilidad masiva de datos, automatización e inteligencia artificial (IA). Las organizaciones operan actualmente en mercados donde la velocidad de los cambios tecnológicos, las nuevas formas de interacción con los consumidores y la aparición constante de modelos de negocio digitales obligan a revisar las fuentes tradicionales de ventaja competitiva. En este escenario, la capacidad para recopilar información, interpretarla y convertirla oportunamente en decisiones adquiere una importancia comparable a la disponibilidad de recursos financieros, físicos y humanos. La transformación digital debe entenderse, por tanto, como un proceso que modifica progresivamente las capacidades de las empresas y no únicamente como la incorporación aislada de tecnologías (Dini et al., 2021).

En el ámbito latinoamericano, esta transformación presenta características particulares. El tejido productivo está conformado por organizaciones con importantes diferencias en tamaño, recursos, infraestructura, conocimientos tecnológicos y posibilidades de inversión. Esta heterogeneidad provoca que las tecnologías digitales se incorporen de manera desigual y que las empresas más pequeñas enfrenten mayores dificultades para avanzar desde usos tecnológicos básicos hacia aplicaciones analíticas avanzadas. La transformación digital de las MiPymes requiere, por ello, una visión sistémica que considere simultáneamente infraestructura, competencias, servicios tecnológicos,

financiamiento, articulación institucional y capacidades internas de las organizaciones (Dini et al., 2021).

Figura 1. Inteligencia artificial y competitividad



Nota: Fuente: Elaboración propia con IA.

La inteligencia artificial profundiza este proceso al incorporar capacidades para analizar información, reconocer regularidades, automatizar determinadas actividades y apoyar la generación de predicciones. Su importancia empresarial no reside exclusivamente en ejecutar tareas con mayor velocidad, sino en ampliar las posibilidades de utilizar los datos para comprender fenómenos que afectan a la organización. De esta forma, la IA puede contribuir al análisis de clientes, comportamiento comercial, productividad, demanda, riesgos y oportunidades, siempre que sus resultados se integren adecuadamente con los procesos empresariales y el conocimiento de quienes toman decisiones (Jung & Katz, 2026). Esta perspectiva permite diferenciar entre la adopción instrumental y la adopción estratégica de la IA. La primera ocurre cuando una empresa utiliza herramientas inteligentes para resolver tareas puntuales; la segunda exige integrar datos, tecnología, personas y procesos con objetivos empresariales claramente definidos. En consecuencia, disponer de una aplicación de IA no implica necesariamente haber desarrollado una capacidad

estratégica. La generación de valor depende de que la organización pueda transformar las capacidades tecnológicas en aprendizaje, innovación y mejores decisiones (Soto et al., 2026).

La relevancia de esta discusión aumenta cuando se consideran las micro, pequeñas y medianas empresas. La IA puede disminuir determinadas barreras de acceso a capacidades analíticas y de automatización, pero al mismo tiempo introduce nuevas exigencias relacionadas con calidad de los datos, talento humano, inversión, seguridad, gobernanza y adaptación organizacional. En América Latina persisten brechas estructurales que condicionan el aprovechamiento productivo de estas tecnologías, por lo que su adopción debe analizarse considerando las particularidades económicas y empresariales de la región (Jung & Katz, 2026).

Desde esta perspectiva, el presente capítulo analiza la transformación de la competitividad empresarial en la era de la inteligencia artificial mediante siete ejes interrelacionados: transformación de la competitividad en entornos digitales, empresa basada en datos, capacidades dinámicas y ventaja competitiva, madurez analítica, ecosistemas empresariales inteligentes, IA como capacidad estratégica y oportunidades y desafíos para las MiPymes. Estos fundamentos permitirán comprender posteriormente cómo la segmentación automatizada, la analítica predictiva y los sistemas de recomendación pueden articularse dentro de un modelo orientado al fortalecimiento de la competitividad.

1.2. Transformación de la competitividad en entornos digitales

La competitividad empresarial ha dejado de depender exclusivamente de variables tradicionales como costos, productividad, calidad, localización o disponibilidad de recursos. Aunque estos elementos continúan siendo

relevantes, los entornos digitales incorporan nuevas capacidades relacionadas con conectividad, conocimiento, innovación, velocidad de respuesta y utilización estratégica de la información. Una organización puede disponer de recursos semejantes a los de sus competidores y, sin embargo, alcanzar resultados diferentes debido a su capacidad para interpretar el mercado y reaccionar oportunamente frente a sus transformaciones (Dini et al., 2021).

La digitalización modifica, además, la forma en que las empresas interactúan con sus mercados. Los consumidores pueden comparar alternativas, comunicar experiencias, interactuar con marcas y modificar rápidamente sus preferencias. Paralelamente, las empresas generan información a través de transacciones, redes sociales, plataformas comerciales, sistemas administrativos y otros puntos de contacto. Esta dinámica convierte la información digital en un recurso que puede contribuir a comprender con mayor profundidad los comportamientos del mercado y sustentar decisiones empresariales (Dini et al., 2021).

No obstante, digitalizar una actividad no equivale necesariamente a transformar una organización. Una empresa puede utilizar redes sociales, aplicaciones de mensajería, facturación electrónica o comercio electrónico y continuar desarrollando sus decisiones estratégicas de manera predominantemente intuitiva. La transformación adquiere mayor profundidad cuando la tecnología se integra con los procesos, genera información relevante, modifica las prácticas organizacionales y contribuye a desarrollar nuevas capacidades para competir (Dini et al., 2021).

Esta distinción resulta fundamental para las MiPymes. Debido a restricciones financieras y de talento, resulta poco realista asumir que todas las organizaciones pueden incorporar simultáneamente tecnologías de alta complejidad. Un proceso gradual permite priorizar aquellas herramientas capaces de resolver problemas concretos y avanzar posteriormente hacia

soluciones de mayor sofisticación. Por tanto, el nivel de digitalización debe relacionarse con la madurez organizacional y con la capacidad efectiva para transformar tecnología en valor empresarial (Dini et al., 2021).

La IA introduce un nuevo nivel dentro de este proceso porque permite pasar de la digitalización de información a su utilización inteligente. Mientras que una plataforma tradicional puede registrar ventas, un sistema analítico puede utilizar esos registros para reconocer patrones; posteriormente, un modelo predictivo puede estimar posibles comportamientos futuros. El cambio fundamental radica en avanzar desde la acumulación de información hacia su utilización como insumo para anticipar y orientar decisiones (Jung & Katz, 2026).

En consecuencia, la competitividad digital puede entenderse como una capacidad organizacional para integrar recursos tecnológicos, información y conocimiento con la finalidad de responder al mercado, innovar y generar valor. Esta perspectiva evita asumir que las organizaciones más tecnificadas son automáticamente las más competitivas. Lo determinante es la capacidad de transformar la tecnología disponible en mejores procesos, conocimiento empresarial y decisiones estratégicas.

1.3. La empresa basada en datos

La expansión de las tecnologías digitales ha incrementado de manera sustancial la cantidad y diversidad de información disponible para las organizaciones. Las ventas, transacciones, inventarios, interacciones digitales, campañas publicitarias y relaciones con los clientes generan datos capaces de aportar conocimiento sobre el funcionamiento interno de la empresa y las condiciones de su entorno competitivo. Sin embargo, la disponibilidad de información no produce valor automáticamente; es necesario desarrollar capacidades para organizarla, analizarla e interpretarla de acuerdo con necesidades empresariales



concretas. En las MiPymes, este proceso se encuentra condicionado por diferencias en recursos, infraestructura y niveles de madurez tecnológica, por lo que la transformación digital debe adaptarse a las características particulares de cada organización (Dini et al., 2021).

Una empresa basada en datos puede comprenderse como una organización que incorpora de manera sistemática información cuantitativa y cualitativa en sus procesos de análisis y toma de decisiones. Esta orientación no supone sustituir la experiencia, el conocimiento acumulado ni el criterio de los responsables empresariales. Por el contrario, busca complementar esas capacidades con evidencia obtenida mediante el procesamiento de información, de modo que las percepciones gerenciales puedan contrastarse con comportamientos observables, tendencias y resultados derivados del análisis. De esta manera, los datos se convierten progresivamente en un recurso para reducir determinados niveles de incertidumbre y fortalecer la capacidad de respuesta de la organización (Dini et al., 2021).

Figura 2. Inteligencia artificial y conpetitividad



Nota. Fuente: Autora con IA

Poseer información tampoco equivale a disponer de inteligencia empresarial. Una organización puede acumular numerosos registros y, aun así, obtener un aprovechamiento limitado si estos permanecen fragmentados, desactualizados o desvinculados de las decisiones que necesita adoptar. La generación de conocimiento exige identificar qué información resulta pertinente, establecer procedimientos para su captura e integración, asegurar condiciones adecuadas para su utilización y construir indicadores que permitan interpretar los fenómenos empresariales. En consecuencia, el valor estratégico de los datos depende menos de su volumen aislado que de la capacidad organizacional para convertirlos en información susceptible de apoyar decisiones (Dini et al., 2021; Latorre et al., 2024).

En el ámbito del marketing digital, esta transformación adquiere particular relevancia debido a la diversidad de señales generadas durante la relación entre consumidores y organizaciones. Las visitas a plataformas digitales, las compras, las respuestas a campañas y las interacciones en diferentes canales proporcionan información que puede contribuir a comprender las características y comportamientos de los clientes. Cuando estos datos se integran y analizan mediante técnicas de inteligencia artificial, analítica de datos y aprendizaje automático, es posible identificar patrones y construir segmentaciones basadas en información comportamental, fortaleciendo el conocimiento del mercado y el diseño de estrategias diferenciadas (Berrío-Meneses et al., 2025).

La calidad de la información constituye, además, una condición relevante para el desarrollo de soluciones empresariales basadas en inteligencia artificial. Los sistemas de aprendizaje automático procesan datos para identificar relaciones y producir resultados, por lo que la preparación de la información forma parte del propio proceso de construcción de estas soluciones. La existencia de registros incompletos, inconsistentes o insuficientemente representativos puede afectar



la utilidad de los análisis y exige incorporar procedimientos de revisión, preparación y gestión de datos antes de utilizar modelos de mayor complejidad. El desarrollo responsable de IA requiere, por ello, integrar consideraciones técnicas, de seguridad, privacidad y gestión durante su implementación (Latorre et al., 2024).

Esta necesidad representa un desafío particular para las micro, pequeñas y medianas empresas. En América Latina, la incorporación de tecnologías digitales presenta una marcada heterogeneidad asociada, entre otros factores, con el tamaño de las organizaciones y con el grado de madurez de las tecnologías consideradas. En consecuencia, avanzar hacia organizaciones orientadas por datos requiere estrategias graduales y compatibles con las capacidades reales de cada empresa, evitando trasladar de manera automática modelos tecnológicos concebidos para organizaciones con mayores recursos, infraestructura y especialización (Dini et al., 2021).

Desde el enfoque desarrollado en esta obra, los datos constituyen el punto de partida de un proceso progresivo de generación de inteligencia competitiva. Una base informacional suficientemente organizada permite avanzar hacia procesos de segmentación automatizada, construcción de modelos predictivos y generación de recomendaciones estratégicas. En consecuencia, se propone considerar la gestión del dato como un componente transversal de la estrategia competitiva y no únicamente como una función tecnológica. Bajo esta perspectiva, el valor no se encuentra en acumular información, sino en desarrollar la capacidad organizacional para transformarla progresivamente en conocimiento que apoye la decisión empresarial.

1.4. Capacidades dinámicas y ventaja competitiva

Los mercados contemporáneos se desenvuelven en condiciones de cambio continuo asociadas con la evolución tecnológica, las preferencias de los consumidores, los canales de comercialización y las nuevas formas de competencia. En este escenario, la permanencia empresarial no depende exclusivamente de los recursos disponibles en un momento determinado, sino también de la capacidad de la organización para adaptarlos, combinarlos y reconfigurarlos frente a las transformaciones de su entorno. Desde esta perspectiva, las capacidades dinámicas adquieren relevancia como un mecanismo organizacional relacionado con la adaptación y el fortalecimiento de la competitividad (González-Samaniego & Valenzo-Jiménez, 2020).

El enfoque de capacidades dinámicas permite comprender cómo las organizaciones desarrollan mecanismos para identificar cambios y oportunidades del entorno, movilizar recursos para aprovecharlos y reconfigurar sus estructuras y procesos cuando las circunstancias lo requieren. Estas capacidades resultan especialmente relevantes en escenarios caracterizados por incertidumbre y transformación tecnológica, debido a que permiten vincular el aprendizaje organizacional con la adaptación estratégica y la innovación. En las pymes, la evidencia muestra que el fortalecimiento de capacidades dinámicas puede contribuir a responder con mayor flexibilidad a los cambios del mercado y favorecer su competitividad (González-Samaniego & Valenzo-Jiménez, 2020; González-Arellano & Acosta-Gonzaga, 2021)

.

La incorporación de inteligencia artificial puede ampliar algunas de estas capacidades al facilitar el procesamiento de información y la identificación de patrones, tendencias y relaciones relevantes para la organización. Sin embargo, la adopción de IA no debe interpretarse como un resultado estratégico en sí mismo. Evidencia reciente obtenida en pymes ecuatorianas muestra que los

beneficios de la adopción de inteligencia artificial para la innovación y la competitividad se encuentran relacionados con el desarrollo de capacidades organizacionales para identificar oportunidades, aprovecharlas mediante acciones de innovación y reconfigurar recursos frente a condiciones cambiantes (Sánchez-Rodríguez et al., 2025).

Esta relación permite diferenciar, para efectos del enfoque desarrollado en esta obra, entre **capacidad tecnológica** y **capacidad estratégica**. La primera se relaciona con la disponibilidad, adopción y utilización de determinadas tecnologías; la segunda corresponde a la capacidad de integrarlas deliberadamente con los recursos, conocimientos, procesos y objetivos de la organización. En consecuencia, empresas que disponen de herramientas tecnológicas semejantes pueden obtener resultados diferentes debido a variaciones en sus capacidades internas, infraestructura de datos, competencias del talento humano, cultura organizacional y mecanismos de toma de decisiones. La evidencia reciente sobre adopción de IA en pymes respalda precisamente la importancia de estas condiciones organizacionales para convertir la tecnología en resultados estratégicos (Sánchez et al., 2025).

La generación de ventaja competitiva mediante inteligencia artificial, por tanto, no depende exclusivamente del algoritmo utilizado. A medida que determinadas soluciones tecnológicas se vuelven accesibles para diferentes organizaciones, su sola adquisición pierde capacidad de diferenciación. El potencial estratégico se fortalece cuando la tecnología se combina con recursos difíciles de reproducir de manera idéntica, como los datos propios de la organización, el conocimiento acumulado, las competencias del talento humano, la experiencia empresarial y la comprensión específica de los clientes y del mercado. La literatura reciente señala que la relación entre capacidades dinámicas, innovación y



competitividad depende precisamente de la manera en que las organizaciones articulan y reconfiguran estos recursos (Horta Lázaro et al., 2025).

Para las MiPymes, esta perspectiva resulta especialmente relevante porque sus restricciones de recursos pueden limitar la adopción de infraestructuras tecnológicas complejas. En lugar de concebir la competitividad digital como una carrera determinada únicamente por el volumen de inversión, estas organizaciones pueden orientar la utilización de inteligencia artificial hacia problemas empresariales concretos, fortalecer progresivamente sus capacidades de datos y aprovechar el conocimiento especializado que poseen sobre sus clientes y mercados. Estudios realizados en pymes ecuatorianas muestran que el aprovechamiento estratégico de la IA requiere fortalecer capacidades organizacionales y de datos, particularmente en contextos donde existen restricciones tecnológicas, financieras y de talento especializado (Sánchez et al., 2025).

Desde la perspectiva propuesta en este libro, la inteligencia artificial puede actuar como un catalizador de capacidades dinámicas cuando contribuye a detectar señales del entorno, analizar información, explorar alternativas y apoyar determinados procesos decisionales. No obstante, la transformación de esos resultados en acciones continúa dependiendo de las capacidades humanas y organizacionales para interpretar la información y ejecutar decisiones. En consecuencia, se plantea que la competitividad empresarial basada en IA surge de la interacción entre datos, capacidad tecnológica, conocimiento organizacional y capacidad estratégica, y no de la sustitución automática del criterio humano por sistemas algorítmicos.



1.5. Madurez Analítica Empresarial

La madurez analítica empresarial puede comprenderse como el desarrollo progresivo de las capacidades que permiten a una organización transformar datos en información útil e incorporarla de manera sistemática en sus procesos de decisión. Este desarrollo no ocurre de forma homogénea. Mientras algunas empresas concentran la gestión de información en registros operativos y hojas de cálculo, otras han incorporado indicadores, sistemas de visualización y herramientas capaces de analizar escenarios futuros. Por ello, la madurez analítica debe entenderse como una combinación de tecnología, disponibilidad y calidad de datos, competencias humanas y capacidad organizacional para utilizar los resultados del análisis en la gestión empresarial.

En una etapa inicial, la **analítica descriptiva** se concentra en representar situaciones que ya han ocurrido. Los registros históricos pueden organizarse mediante indicadores relacionados con ventas, clientes, costos, inventarios, campañas o desempeño comercial. Su contribución consiste en ofrecer una representación estructurada de la situación empresarial y establecer una base de conocimiento sobre el comportamiento pasado. Aunque este nivel no está diseñado principalmente para anticipar acontecimientos, constituye un soporte para análisis de mayor profundidad (Suárez Alemán, 2024).

La **analítica diagnóstica** amplía el análisis al examinar las posibles razones asociadas con los resultados observados. En lugar de limitarse a identificar cambios en los indicadores, busca explorar relaciones entre variables y reconocer factores que contribuyan a explicar determinados comportamientos. De esta manera, la organización avanza desde la descripción de los acontecimientos hacia la comprensión de las posibles causas y relaciones presentes en la información disponible (Suárez Alemán, 2024).

La **analítica predictiva** utiliza información histórica, relaciones entre variables y técnicas analíticas para generar estimaciones acerca de comportamientos futuros. En el ámbito empresarial puede aplicarse, entre otros propósitos, a la estimación de ventas y demanda, al análisis del comportamiento de los clientes o a la anticipación de determinados riesgos. Estas predicciones no representan certezas acerca del futuro, sino estimaciones que pueden aportar evidencia adicional para la planificación y la preparación frente a distintos escenarios (Suárez Alemán, 2024).

La **analítica prescriptiva** incorpora un nivel orientado hacia la acción al utilizar los resultados del análisis para evaluar alternativas y apoyar la selección de posibles respuestas. En esta etapa, la pregunta ya no se concentra exclusivamente en conocer qué ocurrió, explicar sus causas o estimar qué podría suceder, sino en determinar qué alternativas pueden considerarse frente al escenario analizado. En consecuencia, este tipo de analítica conecta el conocimiento obtenido de los datos con procesos de optimización y apoyo a la decisión (Suárez Alemán, 2024).

A partir de estos fundamentos, en esta obra se propone una adaptación orientada específicamente al desarrollo de la herramienta inteligente para fortalecer la competitividad empresarial:
Descripción → Diagnóstico → Predicción → Recomendación → Decisión estratégica.
La secuencia propuesta no pretende sustituir la clasificación tradicional de la analítica, sino adaptarla al propósito tecnológico y estratégico desarrollado en este libro. Mientras la literatura diferencia las funciones descriptiva, diagnóstica, predictiva y prescriptiva, en esta propuesta se incorpora explícitamente la recomendación como vínculo entre los resultados generados por los modelos y la decisión empresarial. De esta manera, la arquitectura



conceptual se articula con los tres componentes centrales de la herramienta desarrollada: segmentación automatizada, predicción y recomendación estratégica.

La madurez analítica tampoco debe equipararse exclusivamente con la sofisticación del software disponible. El aprovechamiento de la analítica requiere la articulación de datos, capacidades humanas y tecnología, debido a que la disponibilidad de herramientas no garantiza por sí misma su incorporación efectiva en los procesos de decisión. El avance organizacional ocurre cuando la información y los resultados analíticos se integran de manera habitual en las actividades de planificación, seguimiento y evaluación (Departamento Administrativo de la Función Pública [DAFP], 2022).

Esta visión resulta especialmente pertinente en América Latina y el Caribe, donde los ecosistemas de inteligencia artificial presentan diferentes niveles de desarrollo. El Índice Latinoamericano de Inteligencia Artificial 2025 analiza el estado de la IA regional considerando tres dimensiones principales: factores habilitantes; investigación, desarrollo y adopción; y gobernanza. Esta estructura evidencia que el desarrollo de capacidades relacionadas con inteligencia artificial depende de múltiples condiciones complementarias y no únicamente de la disponibilidad de herramientas tecnológicas (Soto et al., 2025).

Desde el enfoque desarrollado en este libro, avanzar en madurez analítica significa evolucionar desde el registro y comprensión de acontecimientos hacia la utilización estratégica de los datos. En este proceso, la inteligencia artificial amplía las posibilidades de segmentar, predecir y generar recomendaciones, mientras que la decisión estratégica continúa vinculada con el conocimiento empresarial y el criterio humano. Por esta razón, la madurez analítica constituye

una capacidad organizacional relevante para transformar los resultados de los modelos de IA en acciones orientadas al fortalecimiento de la competitividad.

1.6. Ecosistemas empresariales inteligentes

La competitividad contemporánea se desarrolla dentro de redes de interacción. Las empresas se relacionan con clientes, proveedores, universidades, instituciones financieras, gobiernos, plataformas tecnológicas y otras organizaciones. Estos actores intercambian información y recursos, por lo que la capacidad competitiva de una empresa también puede verse influida por la calidad del ecosistema en el que participa.

La transformación digital refuerza estas interdependencias. Una mipyme puede utilizar infraestructura en la nube de un proveedor, vender mediante una plataforma externa, recibir pagos por medios digitales y desarrollar campañas mediante servicios tecnológicos especializados. De esta manera, capacidades que anteriormente debían construirse internamente pueden obtenerse mediante diferentes participantes del ecosistema.

Los ecosistemas inteligentes incorporan además la posibilidad de compartir y combinar información procedente de distintas fuentes. Datos empresariales pueden complementarse con información sectorial, comercial, económica o territorial. La integración de fuentes puede mejorar la comprensión del entorno y permitir desarrollar modelos más sensibles a las condiciones en las que opera cada organización.

Sin embargo, la interconexión también genera nuevas responsabilidades. La circulación de datos exige mecanismos relacionados con seguridad, privacidad, interoperabilidad y gobernanza. Cuanto mayor sea la dependencia de

plataformas y servicios externos, mayor será la necesidad de establecer criterios para gestionar la información y evaluar los riesgos asociados.

En América Latina, el fortalecimiento de los ecosistemas de IA requiere desarrollar simultáneamente factores habilitantes, capacidades de investigación, adopción tecnológica, talento y mecanismos de gobernanza. La competitividad basada en inteligencia artificial no depende únicamente de decisiones individuales de las empresas, sino también de condiciones institucionales y tecnológicas que faciliten su desarrollo (Soto et al., 2025).

La colaboración entre academia y empresa posee especial importancia dentro de esta lógica. Los proyectos de investigación aplicada pueden transformar problemas empresariales en preguntas investigables y posteriormente convertir resultados científicos en herramientas, metodologías o prototipos. Esta interacción favorece la transferencia de conocimiento y permite contextualizar las tecnologías a necesidades empresariales específicas.

1.7. Inteligencia artificial como capacidad estratégica

Considerar la IA como capacidad estratégica implica superar una interpretación exclusivamente tecnológica. Su valor no está determinado por la novedad del algoritmo, sino por su contribución a los objetivos de la organización. Una implementación estratégica comienza identificando un problema empresarial y posteriormente analiza si la IA puede aportar una solución pertinente.

Esta lógica puede representarse mediante una secuencia diferente a la adopción tecnológica convencional:

Problema empresarial → Datos → Modelo analítico → Resultado → Interpretación → Decisión → Acción → Evaluación.



El proceso no debería comenzar preguntando qué herramienta de IA adquirir, sino qué problema empresarial necesita resolverse. Esta inversión de la lógica permite reducir el riesgo de incorporar tecnologías sin una finalidad definida y favorece la construcción de proyectos orientados a resultados.

La IA puede fortalecer la capacidad estratégica mediante diversas funciones. Los algoritmos pueden clasificar información, identificar segmentos, estimar resultados o generar recomendaciones. Cada función responde a una necesidad distinta, por lo que su selección debe guardar correspondencia con las preguntas que la organización pretende resolver.

La IA tampoco elimina el papel del directivo. Los resultados de un modelo se generan a partir de determinados datos, variables y supuestos. La decisión empresarial incorpora elementos que pueden no encontrarse completamente representados en ellos, como experiencia, restricciones internas, reputación, relaciones comerciales o condiciones imprevistas. Por ello, la función más razonable de la IA consiste en aumentar la capacidad analítica de las personas.
Los estudios recientes sobre América Latina muestran que la IA posee potencial para contribuir a la productividad, pero que su aprovechamiento está condicionado por inversión y capacidades laborales. La CEPAL advierte que la región mantiene limitaciones para capturar plenamente los beneficios económicos asociados con esta transformación tecnológica (Jung & Katz, 2026).

El desarrollo regional de la IA también depende de talento humano. La evolución del ILIA ha otorgado creciente importancia a la adopción y al capital humano como indicadores del progreso relativo de las economías latinoamericanas. Esto confirma que las capacidades humanas continúan siendo



esenciales incluso en escenarios caracterizados por una mayor automatización (Soto et al., 2026).

Por consiguiente, puede definirse la **capacidad estratégica de IA** como la habilidad organizacional para combinar datos, modelos inteligentes, conocimiento humano y procesos decisionales con la finalidad de generar acciones que contribuyan al cumplimiento de objetivos empresariales.

1.8. IA y marketing empresarial inteligente

El marketing representa un ámbito especialmente favorable para la utilización estratégica de IA debido al volumen y diversidad de datos generados por los consumidores. Las interacciones digitales proporcionan información sobre comportamientos, preferencias, respuestas a campañas y patrones de compra que pueden analizarse para mejorar la comprensión del mercado.

La primera contribución relevante se encuentra en la **segmentación automatizada**. Las empresas tradicionalmente han agrupado consumidores mediante criterios demográficos, geográficos o conductuales previamente definidos. Los modelos analíticos permiten complementar este enfoque identificando estructuras presentes en los datos y descubriendo grupos que pueden no resultar evidentes mediante análisis convencionales

.

La segmentación automatizada no significa delegar completamente la estrategia de mercado al algoritmo. Los grupos identificados deben ser interpretados desde una perspectiva empresarial. Un segmento matemáticamente consistente puede carecer de utilidad comercial si no presenta características diferenciables o si la organización no posee recursos para atenderlo.

La segunda capacidad corresponde a la **predicción**. Una vez identificados determinados perfiles, los modelos pueden utilizar información histórica para estimar posibles comportamientos futuros. Las empresas pueden analizar probabilidades relacionadas con compra, demanda, respuesta comercial o diferentes indicadores estratégicos.

La tercera capacidad corresponde a la **recomendación estratégica**. La predicción responde esencialmente qué podría ocurrir, mientras que la recomendación intenta aportar información sobre posibles cursos de acción. La combinación de ambas permite avanzar hacia sistemas que no solamente describan mercados, sino que proporcionen soporte analítico para diseñar estrategias.

Por ello, el enfoque desarrollado en este libro propone integrar tres capacidades: **SEGMENTAR → PREDECIR → RECOMENDAR.**

La innovación no radica únicamente en ejecutar individualmente estas funciones. Su potencial se encuentra en integrarlas dentro de un proceso continuo donde los resultados de la segmentación alimentan los modelos predictivos y ambos componentes contribuyen posteriormente a generar recomendaciones contextualizadas.

1.9. Oportunidades para las micro, pequeñas y medianas empresas

Las MiPymes pueden beneficiarse especialmente de la reducción de las barreras de acceso a tecnologías digitales. Herramientas disponibles mediante servicios en la nube permiten utilizar capacidades de procesamiento, automatización y análisis sin construir necesariamente grandes infraestructuras internas. Esta evolución abre oportunidades para organizaciones que históricamente han tenido menor capacidad de inversión tecnológica.



Figura 3. Inteligencia artificial y competitividad



Nota. Fuente: Autora con ayuda de la IA

Una primera oportunidad corresponde a la eficiencia. La automatización de determinadas tareas puede disminuir tiempos y permitir que el personal se concentre en actividades donde el juicio humano aporta mayor valor. Sin embargo, automatizar no debería constituir un objetivo aislado; debe existir una relación entre la actividad automatizada y los resultados que la empresa busca mejorar.

Una segunda oportunidad es el conocimiento del cliente. Las MiPymes suelen poseer relaciones cercanas con sus mercados, pero una parte importante de ese conocimiento puede permanecer en la experiencia individual de propietarios o vendedores. La analítica permite sistematizar parte de esa información y convertirla en conocimiento organizacional reutilizable.

La tercera oportunidad se relaciona con la anticipación. Los modelos predictivos pueden proporcionar información sobre posibles escenarios y facilitar la planificación. Para organizaciones con recursos limitados, reducir determinadas incertidumbres puede ser particularmente valioso porque los

errores de inventario, inversión o asignación comercial pueden tener impactos proporcionalmente mayores.

La cuarta oportunidad es la personalización. La identificación de segmentos permite diferenciar acciones según características y necesidades, evitando aplicar una misma estrategia a todos los clientes. Esta capacidad puede contribuir a una utilización más eficiente de recursos comerciales.

La IA también puede favorecer procesos de innovación. Investigaciones recientes realizadas en pymes latinoamericanas y mexicanas muestran un interés creciente por vincular transformación digital, inteligencia artificial y competitividad empresarial, aunque su aprovechamiento depende de condiciones organizacionales y tecnológicas específicas (Porras Sandoval et al., 2025).

1.10. Desafíos de las MiPymes frente a la inteligencia artificial

El primer desafío corresponde a los **datos**. Muchas MiPymes poseen información, pero no necesariamente se encuentra organizada para fines analíticos. Bases fragmentadas, registros manuales e inconsistencias pueden impedir la construcción de modelos confiables. La preparación de datos debe considerarse una inversión estratégica y no una actividad secundaria.

El segundo desafío es el **talento humano**. Utilizar estratégicamente IA requiere personas capaces de comprender tanto el problema empresarial como las posibilidades y limitaciones de la tecnología. La CEPAL identifica precisamente la disponibilidad de talento y capacidades laborales como uno de los factores que condicionan el aprovechamiento económico de la IA en América Latina (Jung & Katz, 2026).



El tercer desafío es la **inversión**. Aunque las herramientas se han vuelto más accesibles, una implementación empresarial puede involucrar integración, capacitación, almacenamiento, seguridad y mantenimiento. América Latina mantiene brechas importantes de inversión en capacidades vinculadas con IA, lo que limita el ritmo con el que sus beneficios pueden extenderse en el tejido productivo (Jung & Katz, 2026).

Un cuarto desafío corresponde a la cultura organizacional. La incorporación de herramientas analíticas puede modificar la forma en que se toman decisiones. Las empresas necesitan desarrollar una cultura en la que la evidencia sea utilizada para complementar la experiencia y donde los resultados de los modelos puedan ser cuestionados, interpretados y evaluados.

También existen desafíos de gobernanza y confianza. El desarrollo de los ecosistemas de IA requiere considerar no solamente infraestructura y adopción, sino mecanismos de gobernanza capaces de orientar su utilización. La evaluación regional de la CEPAL incorpora precisamente la gobernanza como una de las dimensiones fundamentales para analizar la madurez de los ecosistemas de IA (Soto et al., 2025).

Finalmente, existe un desafío estratégico: evitar adoptar IA únicamente porque constituye una tendencia. La implementación debería comenzar por necesidades claramente identificadas y disponer de indicadores que permitan evaluar si la solución genera valor. Una herramienta inteligente que no modifica positivamente una decisión, proceso o resultado empresarial difícilmente puede considerarse una innovación estratégica.



1.11. Propuesta conceptual: competitividad empresarial aumentada por IA

A partir del análisis precedente, en esta obra se propone el concepto de **competitividad empresarial aumentada por inteligencia artificial** para representar la capacidad organizacional de combinar información, modelos analíticos, conocimiento humano y tecnología con el propósito de mejorar la comprensión del mercado, anticipar escenarios y apoyar decisiones estratégicas. La utilización del término *aumentada* responde a una consideración fundamental: la IA no sustituye la totalidad de la capacidad gerencial, sino que puede ampliar las posibilidades de análisis. La experiencia humana proporciona contexto, interpretación y juicio; los modelos aportan capacidad de procesamiento y detección de patrones. Su interacción puede generar decisiones más informadas que las obtenidas mediante cualquiera de los componentes de manera aislada.

A partir de esta concepción, se propone como aporte integrador del libro la siguiente cadena de generación de valor:

DATOS EMPRESARIALES
↓
INTEGRACIÓN Y CALIDAD DE DATOS
↓
ANALÍTICA EMPRESARIAL
↓
SEGMENTACIÓN AUTOMATIZADA
↓
PREDICCIÓN
↓
RECOMENDACIÓN ESTRATÉGICA



↓

DECISIÓN GERENCIAL

↓

ACCIÓN EMPRESARIAL

↓

EVALUACIÓN Y APRENDIZAJE

↓

FORTALECIMIENTO DE LA COMPETITIVIDAD

La propuesta introduce además un mecanismo de retroalimentación. Los resultados de las decisiones generan nuevos datos, estos datos permiten actualizar el conocimiento disponible y el aprendizaje obtenido puede emplearse para ajustar posteriormente los modelos. La inteligencia empresarial se configura, así como un ciclo y no como una intervención tecnológica aislada. Dentro de este modelo, la segmentación responde quiénes o qué grupos presentan características comunes; la predicción estima qué podría ocurrir; y la recomendación estratégica analiza qué alternativas pueden considerarse. La decisión final corresponde a la organización, manteniendo la supervisión humana sobre el proceso.

Esta arquitectura conceptual constituye el vínculo directo entre el presente capítulo y el proyecto Herramienta de Analítica Predictiva, Segmentación Automatizada y Recomendación Estratégica basada en Inteligencia Artificial para Fortalecer la Competitividad Empresarial. El libro desarrolla los fundamentos conceptuales y metodológicos, mientras que la herramienta puede constituir la materialización tecnológica de dichos componentes.

La competitividad empresarial en la era de la inteligencia artificial no puede explicarse únicamente mediante la incorporación de tecnología. El verdadero



cambio se encuentra en la capacidad para convertir datos en conocimiento y utilizar ese conocimiento para mejorar decisiones, innovar y responder oportunamente a las transformaciones del entorno.

La empresa basada en datos representa un primer nivel de esta evolución. Sin información organizada y confiable resulta difícil desarrollar capacidades analíticas avanzadas. Sobre esta base pueden incorporarse progresivamente herramientas descriptivas, diagnósticas, predictivas y prescriptivas que amplíen las posibilidades de análisis empresarial.

Las capacidades dinámicas explican por qué dos organizaciones con acceso a tecnologías semejantes pueden alcanzar resultados diferentes. La IA genera posibilidades, pero la organización necesita identificar oportunidades, interpretar resultados, reorganizar recursos y transformar conocimiento en acciones. La ventaja competitiva se encuentra, por consiguiente, en la interacción entre recursos tecnológicos y capacidades organizacionales.

Los ecosistemas empresariales inteligentes amplían esta perspectiva al demostrar que la transformación no ocurre de manera aislada. Empresas, universidades, proveedores tecnológicos, instituciones y gobiernos forman parte de redes que pueden facilitar o limitar la innovación. El estado de los ecosistemas latinoamericanos de IA presenta avances, pero también brechas de adopción, talento y gobernanza que deben considerarse al diseñar soluciones empresariales (Soto et al, 2025; Soto et al, 2026).

Para las MiPymes, la inteligencia artificial representa simultáneamente una oportunidad y un desafío. Puede democratizar determinadas capacidades analíticas y favorecer procesos de automatización, segmentación y predicción; sin embargo, exige mejorar datos, competencias, inversión y gobernanza. La



adopción gradual y vinculada con problemas empresariales concretos constituye una vía coherente para reducir estos obstáculos.

Figura 4. La inteligencia artificial y la competitividad



Nota. Fuente: Autora con ayuda de la IA

El planteamiento central de este capítulo sostiene que la IA alcanza mayor relevancia competitiva cuando deja de utilizarse como herramienta aislada y se integra dentro de una arquitectura de decisión. Por ello, la secuencia datos → segmentación automatizada → predicción → recomendación estratégica → decisión → aprendizaje constituye el eje conceptual que orientará los capítulos siguientes.

En definitiva, el futuro de la competitividad no debe plantearse como una oposición entre inteligencia humana e inteligencia artificial. Una perspectiva empresarial más consistente consiste en construir organizaciones donde ambas capacidades se complementen: la tecnología amplía la posibilidad de procesar información y reconocer patrones, mientras que las personas aportan contexto, creatividad, responsabilidad y criterio estratégico. Esta complementariedad constituye la base de lo que en esta obra se denomina competitividad empresarial aumentada por inteligencia artificial.

CAPÍTULO 2

DE LOS DATOS EMPRESARIALES A LA INTELIGENCIA ESTRATÉGICA

2.1. Introducción

La inteligencia artificial aplicada a la gestión empresarial no comienza con la selección de un algoritmo. Antes de entrenar un modelo predictivo, ejecutar un procedimiento de segmentación o generar una recomendación estratégica, es necesario construir una infraestructura informacional capaz de representar adecuadamente el fenómeno empresarial que se desea analizar. Esta premisa convierte la gestión de datos en uno de los fundamentos metodológicos de cualquier sistema inteligente orientado a la competitividad.

La transformación digital contemporánea ha incrementado de manera sustancial la cantidad y diversidad de información generada por las organizaciones. Sistemas de facturación, plataformas de comercio electrónico, herramientas CRM, sistemas contables, campañas digitales, aplicaciones empresariales y canales de atención producen registros que pueden utilizarse para comprender clientes, operaciones y mercados. No obstante, el volumen de información no constituye por sí mismo inteligencia estratégica. Para alcanzar ese nivel es necesario integrar, depurar, contextualizar y transformar los registros en estructuras adecuadas para el análisis (Dini et al., 2021).

La transformación digital productiva adquiere relevancia precisamente porque permite relacionar tecnología con productividad, reducción de



costos, diversificación de mercados y nuevos modelos de negocio. En América Latina, sin embargo, el avance continúa siendo heterogéneo y presenta desafíos vinculados con capacidades digitales, gobernanza, articulación institucional y adopción de tecnologías emergentes como inteligencia artificial y macrodatos (Patiño et al., 2025).

Desde una perspectiva metodológica, el dato puede considerarse la materia prima del sistema inteligente, pero su utilidad depende de una cadena de procesamiento. La información necesita pasar por etapas de adquisición, validación, integración, transformación, ingeniería de características y estructuración antes de convertirse en un conjunto de datos adecuado para aprendizaje automático. Cada etapa introduce decisiones metodológicas que pueden afectar posteriormente la calidad de las predicciones y recomendaciones.

La relevancia de esta preparación aumenta cuando se pretende construir soluciones destinadas a MiPymes. Las empresas de menor tamaño pueden disponer de información valiosa y, simultáneamente, presentar bajos niveles de estructuración. La evidencia latinoamericana señala que la adopción empresarial de IA se encuentra asociada con factores como tamaño, capital humano, digitalización previa y utilización de tecnologías complementarias, entre ellas servicios en la nube y sistemas para gestionar relaciones con clientes (Jung & Katz, 2025).

El propósito de este capítulo consiste, por tanto, en construir la base metodológica de datos sobre la cual se sustentará posteriormente la **Herramienta de Analítica Predictiva, Segmentación Automatizada y**



Recomendación Estratégica basada en Inteligencia Artificial para Fortalecer la Competitividad Empresarial. Se desarrollan las arquitecturas modernas de datos, fuentes internas y externas, integración, calidad, ingeniería de características, construcción de variables empresariales, indicadores de competitividad, gobernanza, interoperabilidad y preparación de *datasets* para inteligencia artificial.

Figura 5. De los datos empresarial a la inteligencia del negocio



Nota: Fuente: Autora con ayuda de IA

2.2. De los datos a la inteligencia estratégica empresarial

La existencia de datos no implica automáticamente la existencia de conocimiento. Una transacción registrada en un sistema representa un hecho empresarial; cuando ese registro se relaciona con otras transacciones puede producir información; cuando la información es interpretada dentro de un contexto adquiere significado; y cuando dicho conocimiento se utiliza para seleccionar una alternativa de actuación puede convertirse en inteligencia estratégica.

En este libro se propone comprender esta evolución mediante la siguiente cadena:

Dato → Información → Conocimiento → Inteligencia → Decisión → Acción → Resultado → Aprendizaje.

Esta cadena representa un ciclo y no un proceso lineal cerrado. Las decisiones generan acciones; las acciones producen resultados; y los resultados generan nuevos datos que pueden utilizarse para evaluar decisiones anteriores y mejorar modelos posteriores.

Desde una perspectiva empresarial, esta retroalimentación constituye una característica fundamental de las organizaciones orientadas por datos. El aprendizaje no ocurre únicamente en las personas; también puede institucionalizarse mediante indicadores, repositorios, modelos y sistemas capaces de conservar y procesar información histórica.

El desarrollo reciente de herramientas analíticas demuestra la relevancia de integrar múltiples dimensiones dentro de los procesos decisionales. La CEPAL ha desarrollado incluso herramientas de simulación computacional capaces de combinar dimensiones productivas y digitales, anticipar escenarios y evaluar alternativas, ilustrando la evolución desde la descripción de información hacia mecanismos analíticos destinados a apoyar decisiones basadas en evidencia (Kejsefman et al., 2026).

Desde esta perspectiva, la inteligencia estratégica empresarial puede definirse en esta obra como la capacidad sistemática de transformar datos internos y externos en conocimiento analítico útil para anticipar escenarios, identificar patrones y apoyar decisiones orientadas al fortalecimiento de la competitividad.



2.3. Arquitectura moderna de datos para inteligencia empresarial

Una arquitectura de datos establece los componentes, relaciones y reglas mediante los cuales la información circula desde los sistemas donde se origina hasta los mecanismos donde es utilizada. Su función no consiste únicamente en almacenar registros, sino en asegurar que los datos adecuados puedan encontrarse disponibles en el momento y formato requeridos para el análisis.

Para una solución de inteligencia artificial empresarial pueden distinguirse conceptualmente seis capas:

Capa 1. Fuentes de datos

↓

Capa 2. Ingesta e integración

↓

Capa 3. Almacenamiento

↓

Capa 4. Procesamiento y calidad

↓

Capa 5. Analítica e inteligencia artificial

↓

Capa 6. Consumo, visualización y recomendación.

La primera capa contiene los sistemas de origen. Estos pueden incluir ERP, CRM, sistemas contables, hojas de cálculo, plataformas de comercio electrónico, información de marketing, datos territoriales y fuentes externas.



La segunda capa corresponde a la ingesta. Su función consiste en trasladar información desde los sistemas de origen hacia la infraestructura analítica. Dependiendo de las características del proyecto, la transferencia puede realizarse por lotes, mediante archivos, consultas programadas o interfaces de programación de aplicaciones. La tercera capa corresponde al almacenamiento. Su diseño depende de la naturaleza y volumen de la información. Las organizaciones pueden utilizar bases relacionales, almacenes analíticos, repositorios de objetos o arquitecturas híbridas.

La cuarta capa constituye uno de los elementos críticos del sistema porque comprende limpieza, validación, transformación, normalización y generación de variables. Una arquitectura puede almacenar grandes cantidades de información y, sin embargo, producir resultados deficientes cuando esta etapa no se desarrolla adecuadamente. La quinta capa incorpora herramientas de inteligencia empresarial, estadística y aprendizaje automático. En ella se implementan procedimientos de segmentación, modelos predictivos y mecanismos de recomendación.

Finalmente, la sexta capa convierte los resultados técnicos en información utilizable. Un modelo empresarial no termina cuando genera una probabilidad; necesita presentar el resultado mediante indicadores, alertas, perfiles, explicaciones o recomendaciones comprensibles para quienes toman decisiones.

Esta arquitectura permite establecer un principio metodológico fundamental: los modelos de IA constituyen solamente una capa dentro de un sistema de inteligencia empresarial más amplio.



2.4. Data warehouse, data lake y arquitecturas híbridas

El *data warehouse* constituye una arquitectura orientada principalmente al análisis de información estructurada. Su utilidad reside en consolidar datos procedentes de distintas fuentes dentro de estructuras diseñadas para consultas, indicadores e inteligencia empresarial.

En estos entornos pueden utilizarse modelos dimensionales organizados alrededor de hechos y dimensiones. Una tabla de hechos puede registrar ventas, mientras dimensiones relacionadas pueden describir cliente, producto, tiempo, canal o territorio. Esta organización facilita análisis multidimensionales.

Un modelo conceptual simplificado podría representarse así:

HECHO_VENTAS

- Identificador de empresa
- Identificador de cliente
- Identificador de producto
- Fecha
- Cantidad
- Precio
- Descuento
- Importe

Relacionado con:

DIM_EMPRESA

DIM_CLIENTE

DIM_PRODUCTO



DIM_TIEMPO
DIM_CANAL
DIM_TERRITORIO

Esta estructura facilita responder preguntas empresariales como qué segmentos compran determinados productos, qué zonas presentan mayor crecimiento o qué canales generan mayor facturación.

El *data lake*, en cambio, permite conservar información con menor transformación inicial y puede incorporar datos estructurados, semiestructurados y no estructurados. Su flexibilidad resulta útil cuando existen múltiples fuentes o cuando todavía no se conoce completamente qué análisis se realizarán.

Entre ambos enfoques han surgido arquitecturas híbridas orientadas a combinar flexibilidad de almacenamiento con mecanismos de control y rendimiento analítico. Sin embargo, la selección tecnológica debe guardar proporcionalidad con las necesidades del proyecto.
Para una mipyme, una arquitectura excesivamente compleja puede aumentar costos sin producir beneficios equivalentes. El diseño debe privilegiar escalabilidad y modularidad, permitiendo comenzar con una infraestructura manejable y evolucionar conforme aumenten el volumen de información y las necesidades analíticas.

2.5. Fuentes internas de información



Las fuentes internas representan información producida directamente por las operaciones empresariales. Su principal fortaleza es que describen comportamientos reales ocurridos dentro de la organización.

Datos comerciales

Comprenden ventas, pedidos, devoluciones, descuentos, canales, productos y comportamiento histórico. Constituyen una fuente central para modelos destinados a predecir ventas o identificar perfiles comerciales.

Datos de clientes

Los sistemas CRM pueden aportar información sobre frecuencia de contacto, antecedentes de compra, interacciones, solicitudes y oportunidades. Cuando se integran adecuadamente permiten construir una visión longitudinal del cliente.

Datos financieros

Ingresos, egresos, costos, márgenes, liquidez, endeudamiento y comportamiento de pago permiten incorporar la dimensión económica dentro de los modelos de competitividad.

Datos operativos

Inventarios, tiempos de entrega, rotación, capacidad utilizada y productividad proporcionan información sobre la eficiencia interna.

Datos de marketing



Las campañas generan métricas relacionadas con impresiones, alcance, clics, conversiones, costo de adquisición y respuesta del mercado.

Datos digitales

Los sitios web, aplicaciones y plataformas de comercio electrónico producen registros de navegación e interacción que pueden aportar información sobre comportamientos previos a la compra.

La integración de estas fuentes permite construir una visión empresarial más completa. El desafío metodológico consiste en establecer identificadores que permitan relacionarlas sin perder consistencia.

2.6. Fuentes externas y contextualización estratégica

Los modelos construidos exclusivamente con información interna pueden representar adecuadamente el comportamiento histórico de la empresa y, al mismo tiempo, ignorar transformaciones relevantes del entorno. La incorporación de datos externos permite contextualizar los patrones observados.

Las fuentes externas pueden incluir estadísticas oficiales, información económica, características territoriales, indicadores sectoriales, datos demográficos y registros empresariales legalmente disponibles.

En proyectos vinculados con competitividad empresarial, la dimensión territorial puede ser especialmente importante. Empresas con características internas semejantes pueden encontrarse expuestas a condiciones diferentes según ubicación, densidad comercial, accesibilidad o concentración de actividades económicas.



La integración de variables externas debe realizarse mediante criterios metodológicos claros. La información necesita poseer compatibilidad temporal y geográfica con las observaciones empresariales. Una variable provincial, por ejemplo, no debe interpretarse automáticamente como una característica específica de cada empresa.

Figura 5. De los datos empresarial a la inteligencia del negocio



Nota: Fuente: Autora con ayuda de IA

También debe analizarse la periodicidad. Relacionar información empresarial mensual con un indicador externo actualizado cada varios años puede generar una apariencia de precisión superior a la que realmente posee el dato. Por esta razón, cada fuente externa debería acompañarse de una ficha que documente:

institución productora → variable → unidad → cobertura → periodicidad → fecha de actualización → nivel territorial → procedimiento de integración.

Esta trazabilidad permite determinar posteriormente qué información intervino en cada modelo

2.7. Procesos ETL y ELT

La integración de datos puede implementarse mediante procesos ETL: *Extract, Transform, Load*. La primera etapa obtiene información desde las fuentes; la segunda aplica transformaciones y controles; y la tercera carga los datos procesados dentro del repositorio analítico.
Conceptualmente:

FUENTES → EXTRACCIÓN → TRANSFORMACIÓN → VALIDACIÓN → CARGA → REPOSITORIO ANALÍTICO.

Entre las transformaciones pueden incluirse normalización de nombres, conversión de fechas, homologación de unidades, eliminación de duplicados y creación de identificadores.
En arquitecturas modernas también puede utilizarse ELT: *Extract, Load, Transform*. En este caso, los datos son cargados antes de realizar gran parte de las transformaciones, aprovechando posteriormente la capacidad computacional del repositorio.

La elección entre ETL y ELT depende de factores como infraestructura, volumen, sensibilidad y necesidad de conservar datos originales. Ninguno debe considerarse universalmente superior.



Para la herramienta planteada en este libro, el proceso puede concebirse en dos niveles: una **zona de datos originales**, donde se conserva una copia controlada de la información recibida, y una **zona analítica**, donde se almacenan datos depurados y transformados.

Mantener esta separación mejora la trazabilidad porque permite reconstruir cómo una observación original terminó convertida en una variable utilizada por un modelo.

2.8. Calidad del dato y perfilado estadístico

Antes de entrenar modelos debe desarrollarse un proceso sistemático de perfilado de datos. Su finalidad es conocer la estructura real del conjunto disponible y detectar problemas antes de que sean incorporados al aprendizaje automático.

El perfilado puede analizar, entre otros elementos:

número de observaciones;
tipo de cada variable;
porcentaje de valores ausentes;
cantidad de valores únicos;
distribuciones;
rangos;
duplicados;
inconsistencias;
valores extremos.

La **completitud** analiza la proporción de información disponible. Una variable con 70 % de datos ausentes puede poseer utilidad limitada, aunque la decisión final depende de la importancia conceptual y del patrón de ausencia.

La **unicidad** resulta particularmente importante para identificadores. Si una clave diseñada para representar empresas aparece duplicada inesperadamente, puede existir un problema de integración.
La **consistencia** evalúa si las reglas se cumplen en distintas fuentes. Una misma categoría escrita de varias maneras puede fragmentar artificialmente los datos.

La **validez** determina si los valores respetan dominios previamente definidos. Por ejemplo, un porcentaje fuera de un intervalo razonable debe investigarse antes de utilizarse.

La **oportunidad** o actualidad evalúa si la información se encuentra suficientemente actualizada para el propósito analítico.
Una propuesta propia para el proyecto consiste en construir un Índice de Calidad del Dato Empresarial (ICDE) antes de permitir que un conjunto ingrese al pipeline de aprendizaje automático.

Puede conceptualizarse como:
ICDE = f (completitud, exactitud, consistencia, unicidad, validez, actualidad).

La ponderación no debería fijarse arbitrariamente. Debería establecerse según el contexto, documentarse y validarse metodológicamente antes de emplear el índice en una investigación.

2.9. Tratamiento técnico de valores ausentes

Los valores faltantes constituyen un problema frecuente y no deben resolverse mediante eliminación automática. Antes de seleccionar un procedimiento es necesario comprender por qué falta la información.

La ausencia puede producirse porque la variable no fue registrada, porque no era aplicable o porque determinadas empresas decidieron no proporcionarla. Cada situación posee implicaciones diferentes.

Entre las estrategias posibles se encuentran eliminación de observaciones, imputación mediante medidas estadísticas, imputación basada en grupos o utilización de procedimientos algorítmicos.

La elección depende del porcentaje de ausencia, tipo de variable, tamaño de la muestra y mecanismo que produjo el dato faltante.

Una práctica metodológicamente adecuada consiste en comparar las distribuciones antes y después de la imputación. Esto permite evaluar si el procedimiento ha modificado artificialmente la estructura del conjunto.

También puede crearse una variable indicadora de ausencia cuando el hecho de no poseer determinado dato tenga significado empresarial.

2.10. Valores atípicos y comportamiento empresarial excepcional



Un valor extremo no debe interpretarse automáticamente como error. Puede representar una empresa con comportamiento excepcional y, precisamente por ello, contener información relevante.

La detección puede realizarse mediante criterios estadísticos como rango intercuartílico, puntuaciones estandarizadas o métodos multivariantes. Sin embargo, la decisión sobre conservar o excluir una observación debe incorporar conocimiento del contexto.
Por ejemplo, un incremento extraordinario de ventas puede corresponder a un error de digitación, pero también a una campaña exitosa o un contrato excepcional.

Eliminar indiscriminadamente estos registros puede reducir la capacidad del modelo para aprender comportamientos empresariales legítimos.
La regla metodológica propuesta consiste en **detectar → investigar → documentar → decidir**, evitando la secuencia automática **detectar → eliminar**.

2.11. Ingeniería de características

La ingeniería de características constituye una de las etapas de mayor importancia en el desarrollo de modelos empresariales. Su objetivo consiste en transformar datos originales en representaciones que permitan capturar mejor los patrones asociados con el problema.
Supóngase que existen las variables:

fecha de primera compra;
fecha de última compra;
número de compras;



monto total comprado.

A partir de ellas pueden generarse:

Antigüedad del cliente

= fecha actual − fecha de primera compra.

Recencia

= fecha actual − fecha de última compra.

Frecuencia

= número de compras durante un período.

Valor promedio

= monto total / número de compras.

Estas características poseen mayor significado empresarial que los registros originales considerados de forma aislada.

En un modelo de competitividad pueden construirse variables derivadas como crecimiento de ventas, intensidad digital, concentración de clientes, diversificación comercial o variabilidad de ingresos.

La ingeniería de características representa el punto donde conocimiento empresarial y conocimiento técnico deben interactuar. Generar matemáticamente cientos de variables no garantiza que estas posean significado.

Por ello, cada característica debería acompañarse de:

nombre → definición conceptual → fórmula → fuente → unidad → temporalidad → justificación empresarial.

2.12. Transformaciones matemáticas y escalamiento

Los algoritmos presentan diferentes sensibilidades a las escalas de las variables. Una característica medida en millones puede dominar

numéricamente sobre otra expresada entre cero y uno aunque ambas posean relevancia conceptual semejante.

La estandarización transforma las variables considerando su media y desviación estándar, mientras la normalización puede reescalarlas dentro de intervalos determinados.

Estas transformaciones resultan especialmente relevantes para algoritmos basados en distancias. En segmentación mediante *k-means*, por ejemplo, la escala puede modificar sustancialmente la formación de grupos.

Las distribuciones muy asimétricas pueden requerir transformaciones adicionales. Variables empresariales como ventas o número de clientes suelen presentar concentraciones importantes y algunos valores elevados.

Toda transformación debe registrarse dentro del pipeline para garantizar que los nuevos datos reciban exactamente el mismo procesamiento utilizado durante el entrenamiento.

2.13. Codificación de variables categóricas

Muchas variables empresariales no son numéricas: sector, provincia, canal, forma jurídica o categoría comercial. Los algoritmos requieren procedimientos específicos para representar estas características.

Una técnica habitual es la codificación binaria de categorías mediante variables indicadoras. Sin embargo, cuando una característica posee numerosas categorías puede generar matrices de alta dimensionalidad.



Las categorías ordinales requieren especial cuidado porque existe un orden conceptual. Asignar valores numéricos puede ser razonable cuando la distancia entre categorías se interpreta correctamente.

La codificación debe evitar introducir relaciones inexistentes. Asignar arbitrariamente 1 a comercio, 2 a servicios y 3 a manufactura podría hacer que determinados algoritmos interpreten un orden matemático que no existe.

2.14. Selección de características y reducción de dimensionalidad

Incorporar todas las variables disponibles no necesariamente mejora un modelo. Características redundantes, irrelevantes o altamente correlacionadas pueden incrementar complejidad y dificultar interpretación.

La selección de características puede combinar criterios teóricos, análisis estadístico y procedimientos algorítmicos.

El conocimiento experto permite eliminar variables sin relación conceptual con el problema. Posteriormente pueden analizarse correlaciones, redundancias y capacidad explicativa.

En contextos empresariales, la interpretabilidad constituye un criterio importante. Un modelo ligeramente menos preciso pero sustentado en variables comprensibles puede poseer mayor utilidad para la toma de decisiones que otro cuya lógica resulte difícil de explicar.



Las técnicas de reducción de dimensionalidad pueden resultar útiles cuando existen numerosas características correlacionadas, aunque su utilización debe considerar el equilibrio entre eficiencia matemática e interpretabilidad empresarial.

2.15. Construcción metodológica de variables de competitividad

La competitividad es un constructo multidimensional y no debería reducirse automáticamente a una única variable financiera. Su operacionalización necesita responder al marco conceptual definido en la investigación.

Para la herramienta planteada pueden considerarse inicialmente dimensiones como:

Desempeño comercial

crecimiento de ventas;

frecuencia de transacciones;

estabilidad comercial.

Mercado y clientes

retención;

adquisición;

concentración de clientes;

diversificación.

Capacidad digital

utilización de canales digitales;

presencia tecnológica;

automatización.

Eficiencia empresarial



productividad;

utilización de recursos;

rotación.

Innovación y adaptación

incorporación de productos;

utilización de nuevas tecnologías;

capacidad de respuesta.

Estas dimensiones constituyen una propuesta metodológica inicial y deben ser sometidas a validación antes de convertirse en un índice definitivo.

Una opción consiste en construir un Índice Multidimensional de Competitividad Empresarial (IMCE):

$$\mathbf{IMCE = w_1D_1 + w_2D_2 + w_3D_3 + \ldots + w_nD_n}$$

donde **D** representa las dimensiones y **w** sus ponderaciones.

Las ponderaciones pueden determinarse mediante técnicas estadísticas, juicio experto o métodos multicriterio. El procedimiento seleccionado debe justificarse para evitar asignaciones arbitrarias.

2.16. Diseño de indicadores KPI para inteligencia estratégica

Un KPI no es simplemente una métrica disponible. Debe representar un aspecto crítico del desempeño y guardar relación con un objetivo estratégico.

La arquitectura de indicadores puede organizarse en tres niveles:



KPI descriptivos: muestran lo ocurrido.

KPI predictivos: anticipan resultados.

KPI prescriptivos: se vinculan con posibles acciones.

Por ejemplo:

Descriptivo: ventas del último trimestre.

Predictivo: ventas estimadas para el siguiente trimestre.

Prescriptivo: estrategia sugerida ante la trayectoria prevista.

Esta evolución transforma el dashboard tradicional en un sistema de inteligencia estratégica.

En el modelo propuesto, los indicadores no deben aparecer como elementos independientes. Cada KPI puede vincularse con segmento, predicción y recomendación.

Así, una empresa podría visualizar:

Segmento: crecimiento digital emergente.

Predicción: probabilidad elevada de incremento comercial

Indicador crítico: baja retención.

Recomendación: fortalecer fidelización y automatización CRM.

Este tipo de integración representa uno de los elementos diferenciadores que puede incorporarse posteriormente a la herramienta.

2.17. Gobernanza y linaje de datos

La gobernanza establece responsabilidades sobre los activos de información. Su objetivo es garantizar que los datos posean responsables, definiciones, estándares de calidad y reglas de utilización.

Puede establecerse conceptualmente una estructura compuesta por:

Data Owner: responsable empresarial del dato.



Data Steward: responsable de calidad y definición.
Data Custodian: responsable técnico de almacenamiento y protección.
Estas funciones pueden concentrarse en pocas personas dentro de una mipyme, pero las responsabilidades deberían permanecer claramente definidas.

El **linaje de datos** permite conocer el recorrido de una variable desde su fuente original hasta el resultado final.
Ejemplo:
Sistema de ventas → tabla transacciones → depuración → agregación mensual → crecimiento de ventas → modelo predictivo → dashboard.

Este registro es especialmente importante para IA porque permite explicar de dónde procede la información que sustenta una predicción.
La gobernanza ha adquirido una importancia creciente en los marcos regionales de IA. El ILIA 2025 analiza los ecosistemas latinoamericanos a partir de factores habilitantes, investigación, desarrollo y adopción, y gobernanza, mostrando que la madurez de IA no puede comprenderse únicamente mediante disponibilidad tecnológica (Soto et al., 2025).

2.18. Interoperabilidad técnica, semántica y organizacional

La interoperabilidad técnica permite que dos sistemas intercambien datos.

La interoperabilidad semántica garantiza que ambos comprendan el mismo significado.



La interoperabilidad organizacional establece procesos y responsabilidades compatibles.

Esta diferenciación es fundamental. Dos sistemas pueden intercambiar perfectamente un campo denominado “ventas” y utilizar definiciones distintas: uno puede registrar facturación emitida y otros ingresos efectivamente cobrados.

Por ello, una arquitectura de IA empresarial debería incorporar un **diccionario de datos** donde se documenten nombres, definiciones, tipos, unidades y reglas.

El diccionario evita que las mismas variables adquieran significados diferentes durante las etapas del proyecto.

Las API pueden facilitar la interoperabilidad técnica al permitir comunicación automatizada entre aplicaciones. Sin embargo, la conectividad tecnológica no resuelve por sí sola los problemas semánticos.

2.19. Construcción del dataset maestro empresarial

Una vez integradas y depuradas las fuentes puede construirse el Dataset Maestro Empresarial (DME), concepto que se propone en esta obra para identificar la estructura analítica central utilizada por los modelos.

Cada fila puede representar una empresa en determinado momento temporal:



ID empresa	Periodo	Sector	Ventas	Crecimiento	Clientes	Retención	Intensidad digital	Antigüedad	Segmento

El dataset debe incluir únicamente variables justificadas y técnicamente procesadas.

Una decisión especialmente importante es la unidad de análisis. Si se pretende predecir competitividad empresarial, la observación podría representar empresa-período. Si se pretende predecir comportamiento de clientes, la unidad sería cliente-período.

Modificar la unidad de análisis cambia completamente la interpretación de los modelos.

Figura 7. De los datos a la inteligencia del negocio



Nota: Fuente: Autora con ayuda de IA

También debe establecerse una fecha de corte. Las características utilizadas para predecir un resultado deben estar disponibles antes del acontecimiento que se intenta anticipar.

2.20. Prevención de fuga de información

La fuga de información o *data leakage* constituye uno de los errores metodológicos más graves en analítica predictiva. Se produce cuando el modelo recibe durante su entrenamiento información que en una situación real no estaría disponible al momento de generar la predicción. Supóngase que se desea predecir si las ventas aumentarán el siguiente trimestre. Incorporar como característica una variable calculada utilizando información de ese trimestre futuro produciría un modelo artificialmente preciso.

La fuga también puede ocurrir cuando se realizan transformaciones sobre todo el conjunto antes de dividirlo entre entrenamiento y prueba.

Por ejemplo, calcular parámetros de normalización utilizando conjuntamente datos de entrenamiento y evaluación permite que información del conjunto de prueba influya indirectamente en el entrenamiento.

La regla metodológica debe ser:

División de datos → ajuste de transformaciones con entrenamiento → aplicación a validación/prueba.

Esta práctica debe aplicarse a imputación, normalización, selección de características y otras transformaciones aprendidas a partir de los datos.

2.21. División entre entrenamiento, validación y prueba



Para evaluar adecuadamente un modelo, los datos necesitan dividirse en subconjuntos con funciones diferentes.

El conjunto de entrenamiento permite ajustar los parámetros del modelo.

El conjunto de validación ayuda a seleccionar configuraciones y comparar alternativas.

El conjunto de prueba proporciona una evaluación final sobre observaciones no utilizadas durante el desarrollo.

En proyectos empresariales con dimensión temporal, la separación cronológica suele ser especialmente relevante.

Una posible estructura sería:

Entrenamiento: períodos iniciales

Validación: períodos intermedios

Prueba: períodos recientes.

De esta forma, el modelo se evalúa bajo una condición semejante a su utilización real: aprender del pasado para intentar anticipar el futuro.

2.22. Desbalance de clases

En determinados problemas empresariales, el acontecimiento que interesa predecir puede ser poco frecuente. Por ejemplo, abandono de clientes, incumplimiento o crecimiento extraordinario.

Un conjunto con 95 % de casos negativos y 5 % positivos puede producir un modelo aparentemente preciso simplemente prediciendo siempre la clase mayoritaria.

Por esta razón, la exactitud global no debería ser la única métrica.



Deben considerarse métricas como precisión, sensibilidad, especificidad, F1 y áreas bajo curvas de desempeño según la naturaleza del problema.

También pueden emplearse técnicas de ponderación o remuestreo, siempre evitando aplicarlas antes de la separación entre entrenamiento y prueba para impedir contaminación.

2.23. Dataset para segmentación automatizada

El dataset destinado a segmentación posee requisitos diferentes al utilizado en predicción.

En aprendizaje no supervisado no existe necesariamente una variable objetivo. El propósito consiste en encontrar estructuras presentes en las características seleccionadas.

Las variables deben elegirse según su capacidad para diferenciar perfiles empresariales.

Por ejemplo:

- tamaño;
- crecimiento;
- frecuencia comercial;
- digitalización;
- retención;
- diversificación;
- productividad.

La estandarización adquiere especial importancia en algoritmos basados en distancia.

Posteriormente, la calidad de los segmentos puede evaluarse mediante indicadores matemáticos y criterios empresariales.



Un clúster no debe considerarse útil únicamente porque un indicador estadístico sea favorable. Debe poseer coherencia y permitir diseñar estrategias diferenciadas.

2.24. Dataset para analítica predictiva

El dataset predictivo necesita definir claramente una variable objetivo.

Si se pretende estimar ventas:

y = ventas futuras.

Si se pretende estimar crecimiento:

y = tasa futura de crecimiento.

Si se pretende clasificar competitividad:

y = categoría competitiva.

Las características **X** deben corresponder exclusivamente a información disponible antes del horizonte de predicción.

Formalmente:

$$\hat{y} = f(X)$$

donde **X** representa características empresariales y $\hat{y}$ la estimación producida por el modelo.

La selección del algoritmo debe realizarse posteriormente a la definición del problema, y no al contrario.

2.25. Dataset para recomendación estratégica

El sistema de recomendación representa un nivel adicional porque necesita relacionar perfiles, predicciones y alternativas de acción.

Conceptualmente puede plantearse:

$$R = g(S, P, K, C)$$

donde:

R = recomendación,

S = segmento empresarial,



P = predicción,

K = indicadores de desempeño,

C = contexto empresarial.

Por ejemplo, dos empresas pueden presentar una misma predicción negativa, pero requerir recomendaciones diferentes debido a sus segmentos y capacidades.

Una empresa con baja digitalización podría recibir recomendaciones relacionadas con infraestructura y canales; otra con elevada digitalización, pero baja retención podría requerir estrategias de fidelización.

Este enfoque permite pasar de una recomendación genérica hacia una recomendación contextualizada.

2.26. Feature Store empresarial

Cuando una herramienta evoluciona hacia operación continua puede resultar conveniente establecer un repositorio controlado de características o *feature store*.

Su función consiste en mantener definiciones consistentes de variables utilizadas por distintos modelos.

Por ejemplo, si "crecimiento trimestral" es utilizado simultáneamente por segmentación y predicción, ambos módulos deberían utilizar la misma definición.

El repositorio puede registrar:

nombre;

definición;



fórmula;

fuente;

frecuencia;

responsable;

versión.

Esta práctica evita duplicaciones y discrepancias entre modelos.

Para una herramienta destinada inicialmente a MiPymes, no es indispensable implementar una plataforma compleja. El concepto puede materializarse mediante un catálogo estructurado de características.

2.27. Versionamiento y reproducibilidad

Los datasets cambian con el tiempo. También cambian reglas de limpieza, variables y modelos.

Por ello, cada ejecución debería registrar al menos:

versión de datos + versión de transformación + versión del modelo + fecha.

Esto permite reconstruir posteriormente qué combinación produjo determinado resultado. La reproducibilidad posee valor científico y empresarial. Desde la investigación permite verificar resultados; desde la gestión facilita auditoría y corrección de errores. Una herramienta vinculada con un proyecto académico debe prestar especial atención a este componente porque fortalece la trazabilidad metodológica entre investigación, modelo y producto tecnológico.



2.28. Seguridad y privacidad desde el diseño

La arquitectura de datos debe incorporar seguridad desde sus primeras etapas. Entre los principios aplicables se encuentran minimización, control de acceso, separación de funciones, cifrado cuando corresponda, respaldo y registro de actividades.

No todos los usuarios necesitan acceder a toda la información. Un dashboard gerencial puede utilizar resultados agregados sin mostrar datos personales individuales.

Cuando sea posible, los identificadores directos pueden sustituirse por códigos internos para reducir exposición.

La privacidad tampoco debe considerarse únicamente como una obligación jurídica. La confianza constituye un activo empresarial y una gestión inadecuada de información puede afectar reputación y relaciones comerciales.

Los marcos recientes de IA para América Latina destacan precisamente la articulación entre infraestructura, datos, talento y gobernanza como pilares necesarios para avanzar desde estrategias generales hacia implementaciones confiables y operativas (Martorell & Porrúa, 2026).

2.29. Arquitectura metodológica propuesta para la herramienta

A partir de los componentes desarrollados se propone la siguiente arquitectura metodológica para la herramienta de este proyecto:



NIVEL 1. ADQUISICIÓN

Fuentes internas + fuentes externas

↓

NIVEL 2. INTEGRACIÓN

ETL/ELT + interoperabilidad + homologación

↓

NIVEL 3. CALIDAD

Perfilado + validación + tratamiento de ausentes + análisis de atípicos

↓

NIVEL 4. GOBERNANZA

Diccionario + linaje + permisos + versionamiento

↓

NIVEL 5. INGENIERÍA ANALÍTICA

Construcción de variables + transformación + selección de características

↓

NIVEL 6. DATASET MAESTRO

Dataset empresarial versionado

↓

NIVEL 7. INTELIGENCIA ARTIFICIAL

Segmentación + Predicción + Recomendación

↓

NIVEL 8. INTELIGENCIA ESTRATÉGICA

KPI + Dashboard + Alertas + Explicaciones

↓

NIVEL 9. DECISIÓN



Interpretación gerencial + selección de estrategias

↓

NIVEL 10. APRENDIZAJE

Resultados → nuevos datos → actualización del sistema.

Esta arquitectura constituye un aporte metodológico integrador de la obra. No se propone como sustitución de marcos tecnológicos existentes, sino como una estructura conceptual específicamente orientada a vincular datos empresariales con los tres componentes centrales del proyecto: segmentación automatizada, predicción y recomendación estratégica.

2.30. Modelo DATO–IA–ESTRATEGIA

Como síntesis del capítulo, se propone denominar **Modelo DATO–IA–ESTRATEGIA** al flujo conceptual mediante el cual la información empresarial evoluciona hasta convertirse en soporte para decisiones competitivas.

El modelo puede expresarse en tres macrofases:

FASE I. DATO

Capturar → Integrar → Depurar → Gobernar → Transformar.

FASE II. INTELIGENCIA ARTIFICIAL

Segmentar → Predecir → Explicar → Recomendar.

FASE III. ESTRATEGIA

Interpretar → Decidir → Ejecutar → Medir → Aprender.

La primera fase garantiza que la materia prima posea suficiente calidad. La segunda transforma los datos mediante técnicas analíticas. La tercera



devuelve los resultados al dominio empresarial y evita que el sistema se convierta únicamente en un ejercicio algorítmico.

La incorporación explícita de la etapa explicar resulta especialmente importante. Una predicción puede poseer buen desempeño estadístico y, sin embargo, presentar poca utilidad gerencial si el usuario desconoce qué variables influyeron en ella. Esta cuestión será profundizada posteriormente mediante inteligencia artificial explicable.

El modelo establece además una relación circular:

DATO → IA → ESTRATEGIA → RESULTADO → NUEVO DATO.

Este ciclo representa el principio de aprendizaje continuo que puede orientar la evolución tecnológica de la herramienta.

2.31. Consideraciones específicas para las MiPymes

La aplicación del modelo en MiPymes debe realizarse mediante un enfoque proporcional. No resulta necesario que una pequeña empresa disponga desde el inicio de un *data lake*, infraestructura distribuida o equipos especializados.

Una primera versión puede funcionar mediante bases estructuradas, procesos automatizados de importación y un catálogo controlado de variables.

Conforme aumenten volumen, variedad y frecuencia de los datos, la arquitectura puede evolucionar.

La escalabilidad debe incorporarse al diseño desde el comienzo, aunque no todos los componentes se implementen inmediatamente.



Esta estrategia es consistente con la evidencia regional. La transformación digital productiva latinoamericana continúa presentando diferencias entre países, sectores y empresas, mientras que la digitalización previa constituye un factor relevante para la adopción posterior de tecnologías como IA (Katz, 2024; Jung & Katz, 2025).

Para una mipyme, el objetivo no debe ser reproducir la infraestructura de una gran corporación. El propósito consiste en construir la mínima arquitectura de datos capaz de producir inteligencia empresarial confiable y escalable.

2.32. Validación de la arquitectura de datos

Antes de utilizar la arquitectura para entrenar modelos se propone desarrollar una validación en cuatro niveles.

Validación técnica

Comprueba integridad, formatos, duplicados y funcionamiento de los procesos.

Validación estadística

Examina distribuciones, valores ausentes, extremos y relaciones entre variables.

Validación empresarial

Expertos evalúan si variables e indicadores representan adecuadamente la realidad del negocio.

Validación analítica

Se determina si la información posee suficiente capacidad para sustentar los modelos previstos.

Esta estructura evita asumir que un dataset técnicamente limpio es automáticamente útil.

La validación empresarial adquiere especial importancia porque determinados errores no pueden detectarse exclusivamente mediante código. Un valor puede ser matemáticamente válido y empresarialmente imposible.

2.33. De la arquitectura de datos a la ventaja competitiva

La arquitectura desarrollada en este capítulo no debe interpretarse como infraestructura tecnológica aislada. Su propósito final consiste en reducir la distancia entre información y decisión.

Una organización con datos fragmentados puede tardar días en consolidar un informe. Una arquitectura integrada puede automatizar parte de ese proceso.

Una empresa que únicamente observa indicadores históricos reacciona después de que ocurren los acontecimientos. Incorporar analítica predictiva permite anticipar determinados escenarios.

Cuando los resultados predictivos se combinan con segmentación y recomendación, la organización puede avanzar hacia decisiones diferenciadas según sus características.

La CEPAL señala que capturar el valor productivo de la IA requiere combinar infraestructura digital, datos y talento especializado con políticas y capacidades productivas. Esta relación confirma que los datos constituyen un componente fundamental, aunque su valor depende de las



capacidades complementarias que permiten convertirlos en productividad e innovación (Soto et al., 2026).

Por ello, la arquitectura de datos constituye una **capacidad estratégica habilitadora**. No genera competitividad de manera aislada, pero crea las condiciones para que la analítica y la IA puedan contribuir a ella.

El desarrollo de inteligencia artificial empresarial comienza antes del algoritmo. La arquitectura de datos, integración, calidad y construcción de variables determinan la base informacional sobre la que posteriormente se ejecutarán los modelos.

Los datos empresariales se originan en múltiples fuentes y formatos. Convertirlos en un activo estratégico requiere superar la fragmentación y construir mecanismos que garanticen coherencia, trazabilidad y significado.

Las arquitecturas modernas proporcionan diferentes alternativas para almacenar e integrar información, pero su selección debe responder a las necesidades reales de la organización. En MiPymes, la modularidad y escalabilidad resultan más relevantes que la complejidad tecnológica.

Los procesos ETL y ELT permiten construir pipelines reproducibles. Su principal valor metodológico consiste en evitar transformaciones manuales difíciles de auditar y garantizar que las reglas puedan aplicarse consistentemente a nuevos datos.

La calidad debe evaluarse antes de utilizar información en modelos. Completitud, consistencia, unicidad, validez y actualidad constituyen



dimensiones fundamentales, pero también debe analizarse si los datos representan adecuadamente el fenómeno empresarial.

La ingeniería de características constituye el puente entre datos y aprendizaje automático. Su desarrollo exige combinar conocimiento empresarial, estadística y ciencia de datos para transformar registros operativos en variables con significado analítico.

La construcción de indicadores permite operacionalizar dimensiones de competitividad y posteriormente utilizarlas en segmentación, predicción y recomendación.

La gobernanza, el linaje y el versionamiento garantizan trazabilidad. Estos componentes adquieren especial relevancia en una herramienta derivada de investigación, donde los resultados necesitan poder relacionarse con datos, procedimientos y modelos específicos.

La prevención de fuga de información, la separación adecuada entre entrenamiento y evaluación y el tratamiento del desbalance constituyen requisitos metodológicos indispensables para evitar resultados artificialmente favorables.

Los datasets para segmentación, predicción y recomendación poseen objetivos diferentes y, por tanto, no deberían construirse mecánicamente como una única matriz sin distinguir sus funciones analíticas.



El Dataset Maestro Empresarial, el Índice de Calidad del Dato Empresarial, el Índice Multidimensional de Competitividad Empresarial y el Modelo DATO–IA–ESTRATEGIA se plantean en esta obra como propuestas conceptuales que deberán operacionalizarse y validarse empíricamente antes de presentarse como instrumentos comprobados.

La arquitectura metodológica propuesta permite establecer una cadena completa:
Fuentes → Integración → Calidad → Gobernanza → Ingeniería de características → Dataset Maestro → Segmentación → Predicción → Explicabilidad → Recomendación → Dashboard → Decisión → Aprendizaje.

Esta cadena constituye la base metodológica sobre la cual puede construirse la herramienta tecnológica vinculada al proyecto. De esta manera, el capítulo no se limita a describir técnicas de gestión de información, sino que establece la conexión entre datos empresariales, inteligencia artificial y competitividad.

La transformación fundamental ocurre cuando una empresa deja de preguntarse únicamente qué datos posee y comienza a preguntarse qué conocimiento puede construir con ellos, qué puede anticipar y qué decisiones puede mejorar. En ese punto, los datos dejan de ser un residuo de las operaciones y comienzan a convertirse en infraestructura estratégica para la inteligencia empresarial..



CAPÍTULO 3.

INTELIGENCIA ARTIFICIAL Y APRENDIZAJE AUTOMÁTICO APLICADOS A LA GESTIÓN EMPRESARIAL.

3.1. Inteligencia artificial en la gestión empresarial

La inteligencia artificial (IA) representa uno de los principales componentes de la transformación tecnológica contemporánea, debido a su capacidad para procesar grandes volúmenes de información, reconocer patrones, automatizar procedimientos y generar resultados que apoyan la toma de decisiones. En el ámbito empresarial, su utilización permite superar una visión exclusivamente descriptiva de los datos y avanzar hacia modelos capaces de identificar comportamientos, anticipar acontecimientos y proporcionar información que contribuya a formular estrategias organizacionales. Por esta razón, la IA se relaciona progresivamente con la innovación, la eficiencia y la generación de ventajas competitivas en entornos empresariales caracterizados por elevados niveles de incertidumbre (Ramírez Lemus et al., 2026).

La incorporación de inteligencia artificial en las organizaciones no debe entenderse únicamente como la adopción de nuevas herramientas informáticas. Su verdadero valor se encuentra en la capacidad de integrar datos, modelos analíticos y conocimiento empresarial para mejorar procesos de planificación y decisión. Las organizaciones pueden emplear estas tecnologías para analizar ventas, estudiar el comportamiento de los clientes, reconocer tendencias del mercado, automatizar determinadas

operaciones y construir escenarios que faciliten una respuesta anticipada ante los cambios del entorno (Micó, 2023).

La capacidad de procesar información adquiere especial relevancia en empresas que disponen de registros históricos que tradicionalmente han sido utilizados únicamente con propósitos administrativos. Facturas, ventas, características de clientes, productos, precios, frecuencia de compra, canales comerciales y otros registros pueden convertirse en fuentes de conocimiento cuando son procesados mediante técnicas analíticas adecuadas. De este modo, la IA posibilita transformar información dispersa en patrones útiles para comprender el comportamiento empresarial y sustentar decisiones con mayor evidencia (Chambi Condori, 2023).

Esta perspectiva constituye el fundamento tecnológico del proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, debido a que la propuesta busca integrar diferentes niveles de procesamiento de datos empresariales. La finalidad consiste en identificar segmentos, generar predicciones y convertir los resultados obtenidos en recomendaciones que proporcionen información útil para fortalecer los procesos de decisión y la competitividad empresarial.

3.2. Aprendizaje automático y analítica empresarial

El aprendizaje automático, denominado también *machine learning*, constituye una rama de la inteligencia artificial orientada al desarrollo de



algoritmos capaces de reconocer patrones a partir de los datos. A diferencia de los sistemas convencionales, en los cuales todas las instrucciones deben establecerse previamente mediante reglas explícitas, los modelos de aprendizaje automático utilizan información histórica para ajustar sus parámetros y posteriormente generar clasificaciones, estimaciones o agrupaciones sobre nuevas observaciones (Bender et al., 2020).

Figura 8. IA y Machine learning



Nota. Fuente: La autora con ayuda de la IA

En el contexto empresarial, esta capacidad permite utilizar información acumulada por las organizaciones para descubrir relaciones que pueden resultar difíciles de identificar mediante análisis convencionales. El aprendizaje automático puede aplicarse, entre otros escenarios, a la estimación de ventas, segmentación de clientes, detección de comportamientos atípicos, análisis de riesgo, recomendación de

productos y reconocimiento de patrones de consumo. Su utilidad aumenta conforme la empresa dispone de información histórica estructurada y establece mecanismos adecuados para asegurar su calidad (Chapa Zumba, 2023).

La aplicación del aprendizaje automático requiere reconocer que no existe un único algoritmo apropiado para todos los problemas empresariales. El procedimiento debe comenzar con la comprensión de la necesidad organizacional, continuar con la preparación de los datos y posteriormente establecer el tipo de aprendizaje y los algoritmos susceptibles de resolver el problema. Esta secuencia evita que la implementación tecnológica se convierta en un proceso aislado de los objetivos empresariales (Bender et al., 2020).

Dentro del proyecto propuesto, el aprendizaje automático constituye el componente analítico encargado de transformar los registros empresariales en resultados cuantificables. Los modelos podrán utilizarse para identificar agrupaciones de clientes o empresas, estimar comportamientos futuros y proporcionar información que posteriormente alimente el componente de recomendación estratégica.

3.3. Aprendizaje automático supervisado

El aprendizaje supervisado se caracteriza por trabajar con datos en los cuales se conoce previamente el resultado que se desea predecir. Durante el entrenamiento, el algoritmo analiza las relaciones existentes entre diferentes variables de entrada y una variable objetivo. A partir de estas relaciones construye un modelo matemático que posteriormente puede

utilizarse para generar estimaciones sobre observaciones que no participaron directamente en el proceso de aprendizaje.

Los problemas supervisados pueden clasificarse principalmente en **clasificación** y **regresión**. La clasificación busca asignar una observación a una categoría determinada, mientras que la regresión procura estimar un valor cuantitativo. En la gestión empresarial, ambos procedimientos poseen aplicaciones importantes, debido a que numerosas decisiones pueden representarse mediante categorías o valores numéricos obtenidos a partir de datos históricos.

Los algoritmos de clasificación pueden emplearse, por ejemplo, para establecer si un cliente presenta una probabilidad elevada o reducida de abandonar la organización, identificar niveles de riesgo, clasificar prospectos comerciales o reconocer perfiles con determinada posibilidad de responder positivamente a una campaña. Estas aplicaciones permiten transformar variables históricas en categorías útiles para orientar decisiones comerciales y administrativas.

La regresión, por otra parte, puede utilizarse para estimar valores continuos como ventas futuras, ingresos, demanda, volumen de operaciones o valor esperado de un cliente. En Ecuador se han desarrollado propuestas orientadas específicamente a la implementación de software de predicción de ventas para PYMES mediante técnicas de aprendizaje automático, evidenciando la aplicabilidad de estos procedimientos en organizaciones de menor tamaño (Bajaña Rosado & Romero Riera, 2023).



Para el proyecto planteado, el aprendizaje supervisado constituye principalmente la base del módulo de **predicción**. Los datos históricos recopilados de las empresas podrán emplearse para entrenar modelos capaces de estimar indicadores futuros. Estas predicciones deberán posteriormente representarse mediante indicadores comprensibles que permitan a los responsables empresariales utilizarlas como elementos complementarios dentro de sus procesos de planificación.

3.4. Aprendizaje automático no supervisado

El aprendizaje no supervisado se utiliza cuando los datos disponibles no contienen una variable objetivo previamente definida. En este caso, el algoritmo busca descubrir estructuras internas, similitudes, agrupaciones o comportamientos presentes dentro del conjunto de información. Su importancia empresarial radica en que permite analizar bases de datos sin necesidad de conocer previamente las categorías existentes.

Entre las principales técnicas de aprendizaje no supervisado se encuentra el análisis de conglomerados o *clustering*. Su propósito consiste en organizar las observaciones en grupos cuyos integrantes presenten características semejantes entre sí y diferencias respecto de los integrantes de otros grupos. Esta propiedad ha convertido al *clustering* en una herramienta particularmente útil para la segmentación automatizada de mercados y clientes (Chambi Condori, 2023).

Uno de los algoritmos frecuentemente utilizados para esta finalidad es **K-means**, mediante el cual las observaciones se distribuyen alrededor de centroides representativos de cada agrupación. Su aplicación en



contextos comerciales permite identificar conjuntos de consumidores o clientes a partir de variables relacionadas con comportamiento, características transaccionales o preferencias. Estudios realizados en el ámbito latinoamericano evidencian la utilidad del aprendizaje automático para apoyar procesos de segmentación de mercado y gestión de marketing (Chambi Condori, 2023).

En Ecuador también se han desarrollado aplicaciones de segmentación de clientes mediante técnicas de aprendizaje automático. Chapa Zumba (2023), por ejemplo, aplicó el algoritmo K-means para segmentar clientes de una institución financiera ecuatoriana y relacionar los grupos identificados con la recomendación de productos financieros. Los resultados mostraron la posibilidad de obtener grupos diferenciados a partir de los datos disponibles y utilizar posteriormente esta información con fines comerciales.

Por tanto, dentro del presente proyecto, el aprendizaje no supervisado constituye la base del componente de **segmentación automatizada**. A partir de variables empresariales previamente seleccionadas, será posible identificar perfiles diferenciados y posteriormente analizar las características particulares de cada agrupación. Esta información puede servir como insumo para diseñar estrategias específicas y alimentar los módulos de predicción y recomendación.

3.5. Selección de algoritmos de aprendizaje automático

La selección del algoritmo representa una etapa determinante en el desarrollo de soluciones basadas en aprendizaje automático. No resulta



metodológicamente adecuado seleccionar un modelo exclusivamente porque sea tecnológicamente novedoso; su elección debe responder a la naturaleza del problema, estructura de los datos, cantidad de observaciones disponibles, características de las variables y finalidad empresarial de los resultados.

En problemas supervisados pueden evaluarse algoritmos como regresión logística, árboles de decisión, bosques aleatorios (*Random Forest*), máquinas de vectores de soporte y diferentes métodos de potenciación o *boosting*. Cuando la variable objetivo es cuantitativa, pueden compararse modelos de regresión y otros algoritmos predictivos. La comparación permite determinar cuál alternativa ofrece resultados más consistentes para las características específicas del conjunto de datos utilizado.

Para problemas de segmentación pueden emplearse algoritmos como K-means, métodos jerárquicos y técnicas basadas en densidad. La elección depende de la distribución de las observaciones y del propósito del análisis. La experiencia desarrollada en estudios ecuatorianos muestra que tanto K-means como los métodos de agrupamiento jerárquico pueden utilizarse para identificar segmentos, aunque los resultados requieren ser evaluados mediante métricas que permitan comprobar la cohesión y separación de los grupos obtenidos (Chapa Zumba, 2023; Hidalgo Bailón & Cedeño-Valarezo, 2025).

En consecuencia, el presente proyecto plantea la comparación de algoritmos como una estrategia metodológica antes de establecer los modelos definitivos. La decisión no dependerá exclusivamente del valor

obtenido en una métrica determinada, sino también de aspectos como estabilidad, facilidad de interpretación, capacidad de generalización y utilidad de los resultados para la gestión empresarial.

3.6. Preparación de datos para el aprendizaje automático

La calidad de un modelo de aprendizaje automático se encuentra estrechamente relacionada con la calidad de la información utilizada para su construcción. Antes del entrenamiento es necesario ejecutar procesos de revisión, depuración y transformación de los datos, debido a que registros incompletos, inconsistentes o duplicados pueden alterar los patrones aprendidos por los algoritmos.

La preparación puede comprender actividades como identificación de valores faltantes, análisis de registros duplicados, detección de valores atípicos, codificación de variables categóricas, normalización o estandarización de variables y selección de atributos relevantes. La finalidad consiste en construir un conjunto de información suficientemente consistente para representar el fenómeno empresarial que se pretende analizar.

La preparación de los datos debe estar acompañada de una adecuada comprensión del contexto. Una variable estadísticamente disponible no necesariamente posee utilidad empresarial, mientras que determinados atributos pueden adquirir importancia únicamente cuando se analizan conjuntamente. Por ello, el conocimiento de los procesos organizacionales debe complementar las decisiones técnicas adoptadas durante el procesamiento de información.



Para la herramienta inteligente propuesta, esta etapa permitirá estructurar las bases empresariales antes de aplicar los algoritmos de segmentación y predicción. La documentación de las transformaciones realizadas será necesaria para garantizar trazabilidad y permitir la reproducción posterior de los resultados.

Figura 8. Preparacion de datos



Nota: Fuente. Autora con ayuda de la IA

3.7. Entrenamiento y validación de modelos

El entrenamiento corresponde al proceso mediante el cual un algoritmo aprende las relaciones presentes en los datos. Sin embargo, el propósito de un modelo predictivo no consiste simplemente en reproducir correctamente la información con la cual fue construido, sino en proporcionar resultados razonables ante nuevas observaciones. Esta propiedad se conoce como capacidad de generalización.

Para evaluar dicha capacidad, los datos deben separarse metodológicamente. Una parte se utiliza para entrenar el modelo y otra se reserva para comprobar su desempeño. Dependiendo del volumen de información disponible, pueden establecerse conjuntos de entrenamiento, validación y prueba. De esta manera, la evaluación se realiza con observaciones que no fueron utilizadas directamente para ajustar los parámetros del algoritmo.

La validación cruzada constituye otra estrategia para evaluar modelos. Su funcionamiento consiste en dividir el conjunto de información en diferentes subconjuntos y repetir sucesivamente los procesos de entrenamiento y validación. Esta práctica proporciona una evaluación más robusta porque disminuye la dependencia de una única división de la base de datos.

Dentro del proyecto, el entrenamiento y validación deberán documentarse para cada modelo desarrollado. Esto permitirá registrar el conjunto de variables empleado, algoritmo, hiperparámetros, tamaño de las particiones, métricas obtenidas y criterios utilizados para seleccionar la configuración definitiva.

3.8. Métricas de desempeño

Las métricas permiten cuantificar el funcionamiento de los modelos y facilitan la comparación entre diferentes alternativas. Su selección debe corresponder con la naturaleza del problema analizado, debido a que las medidas empleadas para clasificación son diferentes de aquellas utilizadas para regresión o agrupamiento.



En los problemas de clasificación pueden emplearse exactitud (*accuracy*), precisión, sensibilidad o *recall*, especificidad y puntuación F1. Estas medidas proporcionan perspectivas diferentes del comportamiento del algoritmo. La exactitud, por ejemplo, permite establecer la proporción total de predicciones correctas, mientras que precisión y sensibilidad permiten analizar con mayor detalle el comportamiento respecto de determinadas categorías.

En los modelos de regresión pueden utilizarse el error absoluto medio (MAE), el error cuadrático medio (MSE), la raíz del error cuadrático medio (RMSE) y el coeficiente de determinación (R^2). Las métricas de error permiten establecer la distancia existente entre los valores observados y los valores estimados por el modelo, mientras que el coeficiente de determinación proporciona información complementaria sobre la capacidad explicativa de las variables utilizadas.

En los modelos de agrupamiento pueden emplearse indicadores como el coeficiente de silueta, que permite evaluar simultáneamente la cohesión interna y la separación entre grupos. Investigaciones ecuatorianas recientes sobre segmentación mediante análisis de clúster han utilizado precisamente este tipo de indicadores para comprobar si las agrupaciones obtenidas poseen una estructura adecuada (Hidalgo Bailón & Cedeño-Valarezo, 2025).

Para el proyecto propuesto, la selección del algoritmo definitivo deberá sustentarse en las métricas obtenidas durante la validación. Sin embargo,



la evaluación técnica deberá complementarse con un análisis empresarial para determinar si los resultados generados poseen utilidad práctica.

3.9. Prevención del sobreajuste

El sobreajuste u *overfitting* ocurre cuando un modelo aprende excesivamente las particularidades de los datos utilizados durante el entrenamiento y pierde capacidad para responder correctamente frente a información nueva. Un modelo sobreajustado puede presentar excelentes resultados durante el desarrollo y, al mismo tiempo, producir predicciones deficientes cuando se incorpora a un entorno empresarial real.

La prevención del sobreajuste puede realizarse mediante diferentes estrategias, entre ellas la validación cruzada, regularización, selección adecuada de variables, reducción de la complejidad del modelo y ajuste de hiperparámetros. En determinados algoritmos también pueden establecerse límites de profundidad, procedimientos de poda o mecanismos de detención temprana.

El control del sobreajuste adquiere particular importancia en aplicaciones empresariales debido a que las condiciones comerciales evolucionan permanentemente. Los patrones identificados en un determinado período pueden modificarse como consecuencia de cambios en clientes, precios, productos, competidores o condiciones económicas. Por esta razón, los modelos deben evaluarse periódicamente utilizando información reciente.



En el sistema propuesto, la capacidad de generalización tendrá mayor importancia que la obtención de resultados excepcionalmente altos sobre los datos de entrenamiento. El propósito consiste en desarrollar modelos suficientemente robustos para procesar nuevos registros empresariales y mantener niveles adecuados de desempeño.

3.10. Interpretabilidad e inteligencia artificial explicable

La creciente complejidad de los algoritmos ha generado la necesidad de desarrollar mecanismos que permitan comprender cómo se producen las predicciones. La inteligencia artificial explicable (XAI) busca precisamente proporcionar herramientas para interpretar las decisiones realizadas por modelos de aprendizaje automático y reducir el denominado problema de la "caja negra" (Pezzini, 2024).

La explicabilidad resulta especialmente relevante cuando las salidas de un algoritmo intervienen en decisiones empresariales. Un gerente no necesita únicamente conocer que las ventas podrían disminuir o que determinado cliente presenta un comportamiento particular; también requiere identificar qué variables contribuyeron al resultado. De esta manera, la predicción puede analizarse conjuntamente con el conocimiento y experiencia del responsable de la organización (Pezzini, 2024).

Entre las técnicas utilizadas para mejorar la explicabilidad se encuentran la importancia de variables, extracción de reglas y métodos como LIME y SHAP. Estos procedimientos permiten aproximarse al comportamiento interno de modelos complejos y establecer la contribución de



determinadas características a una predicción. Las investigaciones contemporáneas sobre XAI destacan precisamente la necesidad de mejorar la transparencia y confianza en los sistemas inteligentes (Pezzini, 2024).

En Ecuador también se han estudiado aplicaciones de inteligencia artificial explicable vinculadas con sistemas de recomendación. Molina Villacís et al. (2024) analizaron técnicas interpretativas dentro de un sistema de recomendación basado en IA, evidenciando la importancia de incorporar explicaciones cuando los algoritmos generan resultados destinados a apoyar procesos de decisión.

En el presente proyecto, la interpretabilidad permitirá complementar las predicciones y recomendaciones. El sistema deberá procurar que el usuario comprenda cuáles variables poseen mayor influencia sobre los resultados, evitando presentar exclusivamente valores numéricos carentes de contexto empresarial.

3.11. AutoML: automatización del aprendizaje automático

El aprendizaje automático automatizado o AutoML comprende procedimientos destinados a automatizar diferentes etapas del desarrollo de modelos, entre ellas la selección de variables, elección de algoritmos, configuración de hiperparámetros y comparación de resultados. Su finalidad consiste en disminuir la cantidad de actividades repetitivas que tradicionalmente requieren intervención manual durante el desarrollo de soluciones analíticas (Bender et al., 2020).



AutoML adquiere relevancia porque la construcción convencional de modelos requiere conocimiento técnico especializado y numerosas iteraciones. La automatización permite experimentar con diferentes configuraciones y seleccionar alternativas prometedoras en períodos más reducidos. Sin embargo, este procedimiento no elimina la necesidad de supervisión humana, especialmente durante la definición del problema, preparación de datos e interpretación de resultados (Bender et al., 2020). La evolución reciente de AutoML ha ampliado la automatización hacia prácticamente todas las fases del ciclo de aprendizaje automático. Las herramientas actuales pueden intervenir en la ingeniería y selección de características, identificación de algoritmos, optimización de hiperparámetros, evaluación y comparación de modelos. Esta evolución facilita el acceso a capacidades analíticas avanzadas, aunque mantiene desafíos relacionados con interpretabilidad, calidad de datos y control de los modelos (Tomak, 2026).

Dentro del proyecto, AutoML puede utilizarse como un componente complementario para acelerar la comparación entre diferentes modelos predictivos. No obstante, la decisión final deberá considerar simultáneamente el desempeño estadístico, interpretabilidad y pertinencia empresarial.

3.12. Inteligencia artificial aplicada a las ventas

La predicción de ventas constituye una aplicación directa de la analítica predictiva empresarial. La disponibilidad de registros históricos permite identificar tendencias, variaciones y patrones que posteriormente pueden utilizarse para construir estimaciones sobre períodos futuros. Esta



información puede contribuir a mejorar la planificación comercial, financiera y operativa de la organización.

La aplicación de aprendizaje automático a las ventas permite incorporar múltiples variables dentro de un mismo proceso analítico. En lugar de observar únicamente el comportamiento histórico de un indicador, los modelos pueden analizar relaciones entre diferentes características y determinar cuáles poseen mayor capacidad para explicar o anticipar sus variaciones.

En el contexto ecuatoriano, Bajaña Rosado y Romero Riera (2023) desarrollaron una propuesta de software de predicción de ventas para una PYME basada en técnicas de aprendizaje automático. El estudio evidencia que estas herramientas pueden utilizarse para automatizar estimaciones comerciales y apoyar el manejo de la información dentro de organizaciones empresariales.

En el proyecto propuesto, este componente permitirá generar estimaciones relacionadas con el comportamiento futuro de indicadores comerciales. La finalidad será que las predicciones puedan visualizarse dentro de la plataforma mediante indicadores y gráficos comprensibles que faciliten la planificación empresarial.

3.13. Inteligencia artificial aplicada a clientes y segmentación

La gestión de clientes constituye uno de los campos empresariales con mayores posibilidades de aplicación del aprendizaje automático. Las transacciones comerciales generan información relacionada con



frecuencia, monto, productos adquiridos y comportamiento temporal. Cuando estos registros se procesan mediante técnicas de agrupamiento, es posible reconocer perfiles que anteriormente podían permanecer ocultos dentro de la base de datos.

Figura 10. Machine learning en la gestion empresarial



Nota. Fuente. Autora con ayuda de la IA

La segmentación automatizada supera parcialmente las limitaciones de clasificaciones realizadas exclusivamente mediante criterios generales, debido a que utiliza patrones identificados directamente en los datos. Chambi Condori (2023) demuestra que los modelos de *clustering* pueden emplearse como herramientas de segmentación de consumidores y contribuir a la gestión del marketing empresarial.

La experiencia ecuatoriana también proporciona evidencia sobre estas aplicaciones. Chapa Zumba (2023) utilizó K-means para segmentar clientes de una institución financiera ecuatoriana, obteniendo grupos diferenciados que posteriormente fueron utilizados para identificar

clientes potenciales para distintos productos. Este tipo de aproximación evidencia la relación existente entre segmentación automatizada y recomendación comercial.

Para el proyecto desarrollado, los segmentos podrán construirse considerando variables relacionadas con las características y comportamiento de las unidades analizadas. Posteriormente, cada agrupación podrá ser caracterizada mediante indicadores que permitan identificar fortalezas, necesidades o comportamientos particulares.

3.14. Inteligencia artificial aplicada al análisis de mercado

El análisis de mercado mediante inteligencia artificial permite procesar información procedente de diferentes fuentes y reconocer patrones relacionados con consumidores, demanda, comportamiento comercial y cambios en el entorno. La capacidad de procesar grandes cantidades de información facilita una transición desde análisis retrospectivos hacia aproximaciones predictivas que permitan anticipar determinados escenarios.

Los cambios en el comportamiento de los consumidores muestran la necesidad de utilizar herramientas capaces de identificar nuevas configuraciones del mercado. Chambi Condori (2023) señala que los recursos de aprendizaje automático aplicados a la segmentación permiten reconocer movimientos en los segmentos de consumidores y proporcionan información útil para la gestión del marketing.



La incorporación de estas herramientas no significa que los algoritmos sustituyan el conocimiento del mercado. Los modelos procesan información disponible y generan patrones matemáticos; sin embargo, corresponde a los responsables empresariales interpretar esos resultados considerando factores económicos, sociales, competitivos y organizacionales.

En consecuencia, la plataforma propuesta buscará combinar resultados analíticos con información comprensible para el usuario. Las tendencias identificadas deberán representarse mediante indicadores que faciliten el análisis y permitan contextualizar los resultados dentro de las condiciones particulares de cada organización.

3.15. Inteligencia artificial y competitividad empresarial

La competitividad empresarial depende de múltiples capacidades organizacionales, entre ellas la posibilidad de obtener información, interpretarla oportunamente y convertirla en decisiones. Dentro de este escenario, la inteligencia artificial puede fortalecer la capacidad analítica de las organizaciones al proporcionar herramientas para identificar patrones, anticipar comportamientos y automatizar determinadas actividades de procesamiento.

Ramírez Lemus et al. (2026) destacan que la implementación de inteligencia artificial mantiene una relación relevante con los procesos de innovación y competitividad empresarial. Las organizaciones buscan utilizar estas tecnologías para responder con mayor rapidez a las



transformaciones del mercado y fortalecer su posicionamiento en entornos caracterizados por cambios tecnológicos continuos.

Sin embargo, la tecnología no genera competitividad de manera automática. Su contribución depende de la existencia de datos adecuados, infraestructura, conocimientos, capacidades organizacionales y mecanismos para convertir los resultados analíticos en decisiones. Una empresa puede disponer de un algoritmo técnicamente avanzado y obtener escasos beneficios si sus resultados no son comprendidos o utilizados dentro de la gestión.

Por ello, el presente proyecto concibe la inteligencia artificial como una herramienta de apoyo a la gestión empresarial. El propósito no consiste simplemente en automatizar procedimientos, sino en desarrollar capacidades que permitan convertir información empresarial en conocimiento susceptible de ser utilizado para mejorar decisiones y fortalecer la competitividad.

3.16. Integración de segmentación, predicción y recomendación estratégica

La arquitectura conceptual del proyecto integra tres capacidades analíticas: **segmentación automatizada, predicción y recomendación estratégica**. Estos componentes representan diferentes niveles de transformación de los datos y permiten avanzar desde el reconocimiento de patrones hacia la generación de información orientada a la toma de decisiones.



La segmentación automatizada constituye el primer nivel. Mediante técnicas de aprendizaje no supervisado se identifican agrupaciones con características semejantes. La utilidad de esta etapa consiste en reconocer perfiles diferenciados que puedan ser descritos mediante indicadores y utilizados posteriormente para diseñar estrategias específicas (Chambi Condori, 2023; Chapa Zumba, 2023).

El segundo nivel corresponde a la predicción. A partir de información histórica y modelos supervisados, la plataforma podrá estimar determinados comportamientos futuros. En este nivel, las métricas de desempeño y los procedimientos de validación permitirán determinar si las estimaciones presentan suficiente estabilidad para ser incorporadas al sistema.

El tercer nivel corresponde a la recomendación estratégica. Las salidas de segmentación y predicción podrán transformarse en insumos para formular alternativas de actuación. Por ejemplo, la identificación de un determinado segmento junto con una predicción de reducción de ventas podría activar recomendaciones asociadas con estrategias comerciales, fidelización, promoción u optimización de recursos.

Este proceso no pretende automatizar completamente las decisiones empresariales. La recomendación generada debe considerarse como información de apoyo que el responsable de la organización evalúa conjuntamente con su experiencia y conocimiento del contexto. La incorporación de mecanismos de explicabilidad permitirá, además,

conocer qué variables contribuyeron a las predicciones y recomendaciones obtenidas (Pezzini, 2024; Molina Villacís et al., 2024).

Figura 11. La gestión empresarial y el machine learning



Nota. Fuente. Autora con ayuda de la IA

3.17. Modelo conceptual de inteligencia artificial propuesto

A partir de los fundamentos analizados, el modelo conceptual del proyecto puede estructurarse mediante una secuencia integrada:

Datos empresariales → Preprocesamiento → Segmentación automatizada → Modelos predictivos → Evaluación e interpretabilidad → Recomendación estratégica → Dashboard de indicadores → Toma de decisiones → Competitividad empresarial.

Los datos empresariales constituyen el insumo inicial. Después de los procedimientos de depuración y transformación, la información puede ser procesada mediante algoritmos no supervisados para identificar segmentos y mediante algoritmos supervisados para construir

predicciones. Los resultados deberán ser evaluados mediante métricas y complementados con técnicas de interpretabilidad.

Posteriormente, la información obtenida alimentará el componente de recomendación estratégica. Este módulo relacionará los patrones identificados con posibles acciones empresariales y presentará los resultados mediante un tablero de control o *dashboard*. La visualización permitirá transformar los resultados técnicos de los algoritmos en información comprensible para los responsables empresariales.

De esta manera, la propuesta integra la dimensión tecnológica con la dimensión gerencial. Los algoritmos proporcionan capacidad de procesamiento y reconocimiento de patrones, mientras que la interpretación humana permite contextualizar los resultados y adoptar las decisiones que correspondan a las condiciones particulares de cada organización.

3.18. Síntesis del capítulo

La inteligencia artificial y el aprendizaje automático constituyen herramientas con un importante potencial para transformar los datos empresariales en información útil para la gestión. El aprendizaje supervisado facilita la construcción de modelos predictivos; el aprendizaje no supervisado permite identificar estructuras y segmentos; las métricas proporcionan mecanismos objetivos de evaluación; y las técnicas de explicabilidad contribuyen a comprender los resultados producidos por modelos complejos.

La selección de algoritmo*/////s, entrenamiento, validación y prevención del sobreajuste constituyen etapas esenciales para garantizar que los resultados obtenidos posean suficiente consistencia. De manera complementaria, AutoML ofrece mecanismos para automatizar actividades repetitivas y acelerar la comparación entre modelos, aunque su utilización no sustituye la intervención de especialistas ni el conocimiento del contexto empresarial (Bender et al., 2020; Tomak, 2026).

En relación con el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, estos fundamentos permiten establecer una arquitectura en la cual los datos empresariales son transformados progresivamente en segmentos, predicciones, explicaciones y recomendaciones. La finalidad consiste en proporcionar una herramienta que apoye la toma de decisiones basada en evidencia y contribuya al fortalecimiento de las capacidades analíticas de las empresas.

Por tanto, el valor estratégico de la propuesta no reside exclusivamente en utilizar inteligencia artificial, sino en integrar sus diferentes componentes dentro de un proceso orientado a las necesidades empresariales. La articulación entre datos, aprendizaje automático, analítica predictiva, explicabilidad y recomendación estratégica permitirá construir una herramienta capaz de generar información pertinente para apoyar decisiones relacionadas con ventas, clientes, mercado y competitividad.



CAPÍTULO 4.

ANALÍTICA PREDICTIVA PARA ANTICIPAR EL COMPORTAMIENTO EMPRESARIAL.

4.1. Analítica predictiva en el contexto empresarial

La transformación digital ha incrementado significativamente la capacidad de las organizaciones para generar y almacenar información relacionada con ventas, clientes, productos, operaciones, inventarios y comportamiento del mercado. Sin embargo, la acumulación de datos no representa por sí misma una ventaja competitiva. El verdadero valor se produce cuando estos registros son procesados y convertidos en conocimiento que facilite la comprensión de los acontecimientos pasados y contribuya a anticipar posibles comportamientos futuros. En este contexto, la analítica predictiva constituye una herramienta estratégica para fortalecer los procesos de planificación y toma de decisiones empresariales (Casanova-Villalba et al., 2023).

La analítica predictiva integra procedimientos estadísticos, minería de datos, aprendizaje automático y análisis de series temporales para identificar relaciones y patrones existentes en los datos históricos. A partir de estos patrones es posible construir modelos que estimen el comportamiento probable de variables relevantes para la empresa. Por tanto, su finalidad no consiste en determinar con certeza lo que sucederá, sino en proporcionar estimaciones cuantitativas que permitan reducir parcialmente la incertidumbre asociada con las decisiones empresariales (Calle García et al., 2024).

La incorporación de este enfoque modifica la forma en que las organizaciones utilizan su información. Los datos dejan de ser exclusivamente registros de acontecimientos pasados y se convierten en insumos para identificar tendencias, estimar escenarios y detectar tempranamente modificaciones en el comportamiento empresarial. Esta capacidad resulta especialmente importante en entornos caracterizados por cambios en la demanda, preferencias de los consumidores, competencia y condiciones económicas (Casanova-Villalba et al., 2023). En relación con el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, la analítica predictiva constituye uno de sus componentes centrales. Los modelos permitirán procesar información histórica de las empresas para generar estimaciones relacionadas con ventas, demanda y comportamiento comercial, cuyos resultados posteriormente podrán alimentar los mecanismos de recomendación estratégica.

4.2. Del análisis descriptivo a la analítica predictiva

El análisis descriptivo representa el primer nivel del aprovechamiento de los datos empresariales. Su función consiste en organizar y resumir información histórica para responder fundamentalmente a la pregunta **¿qué ocurrió?** Indicadores de ventas, crecimiento, número de clientes, ingresos, productos comercializados y variaciones periódicas permiten obtener una representación estructurada del desempeño pasado de la organización (Casanova-Villalba et al., 2023).

Este nivel analítico resulta fundamental porque permite reconocer características básicas de los datos antes de desarrollar modelos de mayor complejidad. La representación mediante tablas, estadísticas e indicadores facilita identificar tendencias, valores atípicos, períodos de crecimiento o disminución y posibles relaciones entre variables. En consecuencia, la analítica descriptiva constituye el fundamento sobre el cual pueden desarrollarse posteriormente procedimientos predictivos.

Figura 12. Analìtica prdictiva



Nota. Fuente: Autora con ayuda de la IA

La analítica predictiva amplía esta perspectiva al intentar responder a la pregunta **¿qué podría ocurrir?** Para ello utiliza patrones históricos y relaciones entre variables con el propósito de estimar comportamientos futuros. El tránsito desde una visión descriptiva hacia una predictiva permite que las empresas no solamente conozcan sus resultados anteriores, sino que dispongan de información anticipada para apoyar sus procesos de planificación (Calle García et al., 2024).

Esta transición implica un cambio relevante en la gestión de la información. Mientras un tablero descriptivo puede indicar que las ventas disminuyeron durante los últimos meses, un modelo predictivo intenta determinar cuál podría ser su comportamiento en períodos posteriores. Esta capacidad permite avanzar desde una gestión predominantemente reactiva hacia otra con mayores posibilidades de anticipación.

En el sistema propuesto, ambos enfoques deberán coexistir. Los *dashboards* proporcionarán información descriptiva sobre el desempeño empresarial, mientras que los modelos predictivos utilizarán estos datos históricos para estimar comportamientos futuros. La integración permitirá que los usuarios comparen simultáneamente lo ocurrido, la situación actual y las tendencias esperadas.

4.3. Fundamentos de la predicción empresarial

La predicción empresarial parte del análisis de información histórica para identificar estructuras susceptibles de aportar conocimiento sobre acontecimientos posteriores. Sin embargo, esta premisa debe manejarse con cautela, debido a que el comportamiento futuro no constituye una reproducción exacta del pasado. Los mercados experimentan transformaciones y pueden aparecer acontecimientos que alteren las relaciones previamente observadas.

Los métodos de pronóstico pueden clasificarse en enfoques cualitativos y cuantitativos. Los primeros se fundamentan principalmente en conocimiento experto, juicio y valoración de escenarios; los segundos utilizan información histórica y procedimientos matemáticos para



estimar el comportamiento futuro. En ambientes empresariales con disponibilidad de registros estructurados, los modelos cuantitativos adquieren particular importancia debido a su capacidad para procesar sistemáticamente grandes cantidades de información (Viteri et al., 2022).

La literatura científica sobre predicción de demanda reconoce diferentes familias metodológicas, entre ellas promedios móviles, suavización exponencial, modelos de regresión y análisis de series temporales. La elección depende del horizonte de predicción, estructura de los datos, presencia de tendencias, estacionalidad y finalidad de las estimaciones. No existe, por tanto, un procedimiento universalmente superior para todos los problemas de pronóstico (Viteri et al., 2022).

La predicción empresarial debe concebirse como un proceso sistemático que comprende definición del problema, recopilación y preparación de información, selección de variables, construcción del modelo, entrenamiento, validación, evaluación y monitoreo. Esta secuencia permite reducir el riesgo de obtener modelos estadísticamente satisfactorios, pero empresarialmente poco relevantes.

4.4. Construcción de modelos de pronóstico

La construcción de un modelo de pronóstico comienza con la definición precisa de la variable que se desea anticipar. Esta etapa requiere establecer el indicador objetivo, horizonte temporal y frecuencia de predicción. Una empresa puede necesitar estimaciones de ventas semanales, mensuales o trimestrales, y cada uno de estos escenarios puede requerir diferentes niveles de información y metodologías.

Posteriormente debe desarrollarse un análisis exploratorio de los datos. Esta etapa permite identificar distribución de variables, tendencias, valores extremos, información faltante, estacionalidad y posibles relaciones entre características. Una comprensión adecuada del comportamiento histórico evita seleccionar modelos sin considerar la naturaleza real de los datos.

La construcción también requiere determinar qué variables poseen capacidad explicativa. En una predicción de ventas pueden considerarse registros históricos, productos, precios, promociones, temporadas y otras características disponibles. La incorporación de variables adicionales debe responder a criterios analíticos y empresariales, evitando aumentar innecesariamente la complejidad del modelo.

Una práctica metodológicamente recomendable consiste en comparar varios modelos bajo condiciones de evaluación semejantes. Los resultados obtenidos mediante diferentes técnicas permiten seleccionar la alternativa que presenta mayor estabilidad y menor error. La literatura sobre pronóstico señala precisamente la importancia de evaluar diferentes métodos en función de la estructura particular de los datos y del horizonte temporal requerido (Viteri et al., 2022; Rahmer et al., 2022).

4.5. Regresión como herramienta predictiva

La regresión constituye uno de los métodos fundamentales de la analítica predictiva cuando la variable que se pretende estimar posee naturaleza cuantitativa. Su objetivo consiste en determinar la relación existente entre



una variable dependiente y una o varias variables explicativas, permitiendo posteriormente utilizar dicha relación para generar estimaciones.

La regresión lineal representa una aproximación ampliamente utilizada debido a su relativa simplicidad e interpretabilidad. Los coeficientes estimados permiten conocer la dirección y magnitud de las relaciones existentes entre las variables. Esta característica resulta especialmente valiosa en aplicaciones empresariales porque facilita comprender los factores asociados con las predicciones.

La utilización de regresión también puede extenderse hacia información estructurada temporalmente. Alonso-Rodríguez (2021) demuestra que los modelos de regresión pueden utilizarse para realizar predicciones de series temporales mediante la identificación de tendencias y relaciones presentes en observaciones registradas secuencialmente.

Sin embargo, las relaciones empresariales no siempre son lineales. El comportamiento de ventas y demanda puede depender de interacciones complejas entre diferentes factores. Por esta razón, la regresión tradicional puede complementarse con algoritmos de aprendizaje automático capaces de representar relaciones no lineales cuando la naturaleza de los datos así lo requiera.

En el proyecto propuesto, la regresión podrá utilizarse para generar estimaciones cuantitativas de indicadores empresariales. Su aplicación deberá acompañarse de procedimientos de validación y métricas de error



que permitan establecer si las estimaciones poseen suficiente estabilidad para ser incorporadas al módulo predictivo.

4.6. Clasificación predictiva

La clasificación constituye otra de las principales técnicas de aprendizaje supervisado. A diferencia de la regresión, cuyo resultado corresponde generalmente a un valor numérico continuo, la clasificación busca asignar las observaciones a determinadas categorías previamente establecidas.

En un contexto empresarial, estos modelos pueden utilizarse para clasificar clientes según su probabilidad de abandono, establecer niveles de riesgo, identificar comportamientos comerciales o categorizar empresas de acuerdo con determinadas condiciones predictivas. Esta información permite convertir conjuntos complejos de variables en categorías que facilitan la interpretación gerencial.

Los modelos de clasificación pueden generar probabilidades asociadas con cada resultado. Esta característica resulta especialmente importante porque permite superar una interpretación exclusivamente binaria. En lugar de señalar simplemente que una situación ocurrirá o no ocurrirá, el modelo puede indicar la probabilidad estimada correspondiente.

La selección de un modelo de clasificación debe considerar tanto el desempeño estadístico como las consecuencias empresariales derivadas de los errores. Un falso positivo y un falso negativo pueden producir impactos diferentes dependiendo del problema analizado. Por esta razón,



métricas como precisión, sensibilidad, especificidad y F1 proporcionan información complementaria para evaluar el comportamiento de los modelos.

Para el proyecto, la clasificación puede complementar los modelos de predicción cuantitativa. Los resultados podrán convertirse en niveles o categorías que faciliten la interpretación de los usuarios y permitan asociar posteriormente determinadas condiciones con recomendaciones estratégicas.

4.7. Series temporales aplicadas al comportamiento empresarial

Las series temporales están constituidas por observaciones registradas sucesivamente durante períodos determinados. En el contexto empresarial, variables como ventas, demanda, ingresos, número de clientes, inventarios y precios pueden estructurarse cronológicamente para estudiar su comportamiento.

Una serie temporal puede presentar diferentes componentes, entre ellos tendencia, estacionalidad, ciclos y variaciones aleatorias. La tendencia refleja movimientos sostenidos de crecimiento o disminución; la estacionalidad corresponde a comportamientos que se repiten periódicamente; mientras que las fluctuaciones irregulares representan variaciones que no siguen necesariamente una estructura sistemática (Fernández López et al., 2020).

El reconocimiento de estos componentes resulta indispensable para interpretar correctamente la evolución de una variable. Un incremento de



ventas durante determinados meses no necesariamente representa crecimiento permanente si dicho comportamiento se repite anualmente como consecuencia de un fenómeno estacional.

Los modelos temporales permiten separar o representar estos componentes y proyectarlos hacia períodos posteriores. Entre las técnicas utilizadas se encuentran suavización exponencial, Holt-Winters, modelos autorregresivos y diferentes extensiones de ARIMA. La literatura científica muestra que las series temporales constituyen uno de los enfoques fundamentales para realizar predicciones de corto plazo (Viteri et al., 2022).

Fernández López et al. (2020) aplicaron técnicas de series temporales para construir un modelo de predicción de demanda en una cadena hotelera, evidenciando la utilidad de los registros históricos para anticipar comportamientos y proporcionar información orientada a la planificación.

4.8. Predicción de ventas

La predicción de ventas constituye una aplicación estratégica de la analítica predictiva debido a su relación directa con la planificación empresarial. Conocer anticipadamente el comportamiento probable de las ventas permite mejorar decisiones relacionadas con compras, inventarios, recursos humanos, presupuesto y estrategias comerciales.

Los registros históricos representan la principal fuente de información para desarrollar estos modelos. La identificación de tendencias y estacionalidades permite comprender cómo ha evolucionado el



comportamiento comercial y establecer patrones susceptibles de ser utilizados para estimar períodos posteriores.

No obstante, el comportamiento de las ventas puede depender de múltiples factores. Variables relacionadas con precio, promociones, temporada, características del producto y condiciones del mercado pueden modificar las tendencias históricas. Por esta razón, los modelos predictivos deben incorporar aquellas variables que posean relevancia comprobable y disponibilidad suficiente.

La inteligencia artificial amplía las posibilidades de estos modelos debido a su capacidad para reconocer relaciones complejas dentro de grandes volúmenes de información. Mendoza Arce et al. (2024) señalan que la incorporación de IA en los negocios está modificando áreas como marketing y ventas mediante el análisis de datos, automatización y generación de información orientada a decisiones.

Dentro del presente proyecto, la predicción de ventas constituirá uno de los indicadores principales del módulo de analítica predictiva. El sistema deberá presentar valores históricos y pronosticados, permitiendo observar tendencias y desviaciones que posteriormente puedan relacionarse con recomendaciones estratégicas.

4.9. Predicción de la demanda

La predicción de demanda busca estimar la cantidad futura de productos o servicios que podría requerir un mercado durante un período

determinado. Esta información resulta relevante para coordinar inventarios, compras, producción, logística y recursos financieros.

Viteri et al. (2022), mediante una revisión de la literatura científica, identifican diferentes métodos utilizados para predecir demanda y señalan la relevancia del análisis de series temporales, medias y técnicas de suavización exponencial, especialmente para horizontes de corto plazo. Los autores también destacan la necesidad de monitorear los modelos y realizar ajustes cuando aparecen desviaciones entre valores reales y pronosticados.

Los modelos de pronóstico de demanda pueden presentar distintos niveles de complejidad. Rahmer et al. (2022) evaluaron modelos cuantitativos para el pronóstico de demanda agregada, incluyendo procesos estocásticos, modelos ARFIMA y modelos de espacio de estados mediante filtro de Kalman. La diversidad metodológica demuestra que la selección debe responder a la estructura particular del problema.

La importancia empresarial del pronóstico radica en el costo de los errores. Una subestimación de demanda puede ocasionar pérdida de ventas o desabastecimiento, mientras que una sobreestimación puede incrementar inventarios y costos. Por ello, el modelo debe evaluarse considerando no solamente la precisión matemática, sino también las consecuencias económicas de sus desviaciones.

En el proyecto desarrollado, la predicción de demanda permitirá complementar el análisis de ventas y proporcionar información

anticipada sobre posibles variaciones. Esta capacidad puede relacionarse posteriormente con recomendaciones sobre planificación comercial, inventarios y asignación de recursos.

4.10. Métodos de suavización para el pronóstico

La suavización exponencial constituye una familia de métodos ampliamente utilizada para pronosticar variables temporales. Su funcionamiento asigna pesos diferentes a las observaciones históricas, otorgando generalmente mayor relevancia a los registros recientes.

Estos métodos resultan especialmente útiles cuando las organizaciones necesitan desarrollar pronósticos de corto plazo utilizando información histórica. Dependiendo de la estructura de la serie pueden incorporarse componentes de nivel, tendencia y estacionalidad.

Figura 12. Predicción de demanda



Nota. Fuente: Autora con ayuda de la IA

Moraes et al. (2023) aplicaron suavización exponencial a la predicción de demanda empresarial y destacan su utilidad para apoyar decisiones relacionadas con planificación. La utilización de series históricas permite

estructurar un proceso cuantitativo que complementa las estimaciones intuitivas realizadas por los responsables empresariales.

La incorporación de estos métodos dentro de una plataforma inteligente resulta pertinente porque proporciona modelos de referencia relativamente interpretables. Sus resultados pueden compararse con algoritmos más complejos para determinar si el incremento de complejidad produce mejoras suficientemente importantes en el desempeño predictivo.

4.11. Detección temprana de cambios

Una de las ventajas de la analítica predictiva consiste en que puede utilizarse no solamente para generar pronósticos, sino también para detectar modificaciones respecto del comportamiento esperado. Esta capacidad permite identificar señales antes de que sus efectos se encuentren completamente reflejados en los indicadores empresariales.

Los cambios pueden manifestarse mediante reducciones sostenidas de ventas, modificaciones en patrones de demanda, pérdida de clientes, incrementos inesperados o desviaciones respecto de tendencias históricas. Cuando estas variaciones son identificadas tempranamente, la empresa dispone de mayor tiempo para analizar sus causas y considerar posibles respuestas.

Calle García et al. (2024) destacan precisamente el papel de la analítica predictiva en la anticipación de cambios dentro del entorno empresarial.



Su utilización permite identificar tendencias y proporcionar información que puede contribuir a mejorar la capacidad de respuesta organizacional. Un procedimiento posible consiste en comparar los valores observados con los valores esperados por el modelo. Cuando las diferencias superan determinados límites, el sistema puede generar una alerta. No obstante, la señal debe interpretarse considerando el contexto, debido a que una anomalía estadística no representa necesariamente una situación negativa.

En el proyecto propuesto, la detección temprana permitirá convertir la plataforma en un instrumento proactivo. El sistema podrá identificar desviaciones y proporcionar información complementaria que facilite evaluar si existe una situación que requiere atención gerencial.

4.12. Evaluación de escenarios

Las organizaciones operan bajo condiciones de incertidumbre y no siempre resulta adecuado basar una decisión en una única predicción. La evaluación de escenarios permite analizar diferentes configuraciones posibles y observar cómo podrían modificarse los resultados empresariales ante cambios en determinadas variables.

Un escenario representa una combinación coherente de supuestos. En términos empresariales pueden construirse escenarios relacionados con crecimiento de ventas, reducción de demanda, modificaciones de precios, variaciones en número de clientes o cambios en costos.

Una estructura habitual puede diferenciar un escenario base, uno favorable y otro adverso. El escenario base representa la evolución



esperada según los patrones identificados; los escenarios alternativos modifican determinadas condiciones para evaluar el posible comportamiento de los resultados.

El propósito de esta metodología no consiste en seleccionar cuál escenario ocurrirá, sino en ampliar la capacidad de planificación. La empresa puede analizar anticipadamente diferentes condiciones y considerar las acciones que podrían resultar pertinentes en cada una de ellas.

Dentro de la plataforma propuesta, la evaluación de escenarios complementará los resultados predictivos. De esta manera, el usuario no observará únicamente un valor pronosticado, sino diferentes trayectorias posibles que faciliten la evaluación estratégica.

4.13. Incertidumbre de las predicciones

Toda predicción contiene un determinado nivel de incertidumbre. Los modelos se construyen a partir de información histórica y, por tanto, no pueden incorporar perfectamente todos los acontecimientos que podrían modificar el comportamiento futuro.

La incertidumbre puede proceder de diferentes fuentes, entre ellas errores de medición, información incompleta, variabilidad natural de los datos, cambios estructurales del mercado y limitaciones propias del modelo. Reconocer estas condiciones constituye una práctica fundamental para evitar que los resultados sean interpretados como certezas.



Los modelos de series temporales proporcionan estimaciones puntuales que pueden complementarse con intervalos de predicción. Estos intervalos representan un rango dentro del cual se espera que se encuentre el valor futuro bajo determinados supuestos. Su amplitud proporciona información adicional sobre el grado de incertidumbre asociado con la estimación.

La incertidumbre generalmente aumenta conforme se amplía el horizonte de pronóstico. Las estimaciones realizadas para períodos cercanos disponen de mayor información reciente, mientras que las predicciones de largo plazo se encuentran expuestas a un mayor número de acontecimientos no observados.

Por esta razón, la plataforma deberá comunicar claramente la incertidumbre. Los resultados pueden representarse mediante intervalos, bandas alrededor de las predicciones o indicadores de confiabilidad, evitando presentar cifras con una apariencia de exactitud superior a la que realmente proporciona el modelo.

4.14. Confiabilidad de los modelos predictivos

La confiabilidad de un modelo no debe establecerse exclusivamente mediante su capacidad para ajustarse a los datos históricos. Un modelo predictivo debe demostrar que puede mantener un desempeño adecuado frente a información que no participó directamente en su construcción.

Para problemas cuantitativos pueden utilizarse métricas como el error absoluto medio (MAE), error cuadrático medio (MSE), raíz del error cuadrático medio (RMSE) y error porcentual absoluto medio (MAPE).



Estas métricas permiten cuantificar la diferencia entre valores observados y predichos.

El MAE expresa el promedio de los errores absolutos y proporciona una medida relativamente intuitiva. El RMSE penaliza con mayor intensidad las desviaciones elevadas, mientras que MAPE expresa el error de forma porcentual cuando los valores analizados permiten su aplicación.
La evaluación debe considerar varias métricas debido a que cada una representa diferentes características del error. Seleccionar un modelo exclusivamente por un indicador puede conducir a interpretaciones incompletas.

En la predicción de demanda también resulta necesario realizar un monitoreo permanente. Viteri et al. (2022) destacan la importancia de comparar los valores reales y pronosticados y corregir los modelos cuando aparecen desviaciones relevantes. Este principio será fundamental dentro del sistema propuesto.

4.15. Monitoreo y actualización de las predicciones

Los modelos predictivos deben considerarse sistemas dinámicos debido a que el comportamiento empresarial cambia con el tiempo. Las relaciones aprendidas a partir de información histórica pueden perder capacidad explicativa cuando aparecen nuevas condiciones de mercado.
El monitoreo consiste en comparar periódicamente las predicciones con los resultados reales. Cuando los errores comienzan a incrementarse sistemáticamente, puede existir evidencia de que el modelo requiere actualización.



La incorporación de nuevos datos permite realizar procesos de reentrenamiento. De esta manera, los modelos pueden incorporar información más reciente y adaptarse progresivamente a cambios en el comportamiento de las variables empresariales.

El proceso debe mantener trazabilidad sobre las diferentes versiones de los modelos. Registrar fechas de entrenamiento, variables, parámetros y métricas facilita comparar su evolución y seleccionar aquellas configuraciones que mantengan mayor estabilidad.

Para el proyecto, esta capacidad permitirá que la plataforma no permanezca limitada al comportamiento existente durante su desarrollo inicial. La actualización periódica contribuirá a mantener la pertinencia de las predicciones conforme se incorporen nuevos registros.

4.16. Analítica predictiva y toma de decisiones gerenciales

El propósito final de la analítica predictiva consiste en proporcionar información que pueda ser incorporada a las decisiones. La calidad técnica de un modelo posee valor limitado si los resultados no pueden interpretarse o no se encuentran relacionados con problemas concretos de la organización.

Casanova-Villalba et al. (2023) identifican la analítica predictiva como una herramienta estratégica para la toma de decisiones gerenciales y destacan su capacidad para anticipar tendencias, mejorar procesos de planificación y promover una gestión fundamentada en datos. Sin



embargo, también señalan la importancia de aspectos como calidad de la información, competencias analíticas y cultura organizacional.

Por ello, las predicciones deben presentarse de manera comprensible. Los usuarios empresariales requieren visualizar tendencias, cambios, niveles de error y factores relevantes sin necesidad de interpretar directamente la complejidad matemática de los algoritmos.

La utilización de *dashboards* facilita esta comunicación porque permite integrar información histórica, indicadores actuales y resultados predictivos. De esta forma, la plataforma puede funcionar como un punto de encuentro entre los modelos analíticos y las decisiones gerenciales.

4.17. Analítica predictiva y competitividad empresarial

La competitividad empresarial se relaciona con la capacidad de una organización para adaptarse, innovar y responder oportunamente a las condiciones de su entorno. En este contexto, la inteligencia artificial y la analítica predictiva pueden contribuir a fortalecer la capacidad de procesamiento de información y anticipación.

Ramírez Lemus et al. (2026) analizan la relación entre inteligencia artificial y competitividad empresarial, señalando la importancia que adquieren estas tecnologías para responder a los cambios del mercado e impulsar procesos de innovación. Su incorporación modifica la forma en que las empresas analizan información y desarrollan estrategias.



La analítica predictiva puede contribuir a esta capacidad mediante la anticipación de ventas, demanda y modificaciones de comportamiento. Sin embargo, disponer de una predicción no genera automáticamente una ventaja competitiva; es necesario que la organización convierta la información en decisiones y acciones.

En consecuencia, la ventaja potencial no procede exclusivamente de la tecnología, sino de la integración entre datos, modelos analíticos, conocimiento gerencial y capacidad de respuesta. Este enfoque resulta particularmente relevante para el proyecto, debido a que la herramienta propuesta busca conectar resultados analíticos con recomendaciones estratégicas.

4.18. Integración de la analítica predictiva en el modelo propuesto

A partir de los fundamentos desarrollados, el componente predictivo del proyecto puede estructurarse mediante la siguiente secuencia:

Datos empresariales → análisis descriptivo → preparación de información → selección de variables → construcción de modelos → entrenamiento y validación → predicción → cuantificación de incertidumbre → detección de cambios → escenarios → recomendación estratégica → dashboard → toma de decisiones.

En la primera etapa, los datos empresariales serán organizados y analizados descriptivamente. Este procedimiento permitirá identificar tendencias, características y posibles problemas de calidad antes de desarrollar los modelos.

La segunda etapa estará constituida por la construcción y comparación de modelos. Dependiendo de la naturaleza de la variable, podrán utilizarse regresión, clasificación y métodos de series temporales. Cada alternativa deberá evaluarse mediante métricas apropiadas antes de incorporarse al sistema.

La tercera etapa comprenderá la interpretación de los resultados. Las predicciones deberán complementarse con indicadores de error, niveles de incertidumbre y mecanismos de detección de cambios. Esto permitirá evitar una interpretación determinista de los valores obtenidos.

Finalmente, los resultados serán incorporados al módulo de recomendación estratégica y representados mediante el *dashboard*. Esta integración permitirá que los usuarios dispongan de información histórica, actual y prospectiva dentro de una misma herramienta.

4.19. Integración de segmentación, predicción y recomendación estratégica

La analítica predictiva adquiere mayor utilidad cuando se integra con la segmentación automatizada desarrollada mediante técnicas de aprendizaje no supervisado. Los segmentos identificados pueden utilizarse posteriormente como unidades diferenciadas para realizar predicciones.

Esta combinación permite pasar de una estimación general hacia pronósticos específicos. Por ejemplo, en lugar de proyectar únicamente las ventas totales, el sistema podría analizar el comportamiento esperado



de diferentes segmentos y reconocer cuáles presentan perspectivas de crecimiento o disminución.

La segmentación responde a la pregunta **¿qué grupos existen?**; la predicción permite analizar **¿cómo podrían comportarse posteriormente?**; mientras que la recomendación estratégica busca proporcionar información sobre **¿qué acciones podrían considerarse ante esos resultados?**

Figura 13. Analítica predictiva



Nota: Fuente: autora con ayuda de la IA

La integración de estos tres niveles representa uno de los principales fundamentos del proyecto. Los algoritmos no se utilizan como componentes aislados, sino como partes de una arquitectura analítica orientada progresivamente hacia la generación de conocimiento empresarial.

4.20. Analítica predictiva aplicada a microempresas

La utilización de inteligencia artificial en microempresas presenta oportunidades importantes, aunque también requiere considerar limitaciones relacionadas con disponibilidad y calidad de información, infraestructura tecnológica y competencias digitales.

Murillo Valverde et al. (2024), al estudiar la utilización de inteligencia artificial en microempresas de Guayaquil, evidencian la creciente importancia de estas tecnologías en organizaciones de menor tamaño y su relación con los procesos de competitividad empresarial.

La implementación de modelos predictivos en este tipo de organizaciones debe priorizar soluciones proporcionales a la cantidad y calidad de los datos disponibles. Un algoritmo complejo no necesariamente representa la mejor alternativa cuando existe un histórico reducido o variables poco estructuradas.

Por ello, la herramienta propuesta deberá considerar diferentes niveles de madurez de los datos empresariales. En determinadas organizaciones podrán aplicarse modelos temporales relativamente sencillos, mientras que aquellas que dispongan de información más extensa podrán beneficiarse de algoritmos de aprendizaje automático de mayor complejidad.

Esta flexibilidad permitirá que el sistema se adapte a la realidad empresarial y evite establecer requisitos tecnológicos que puedan dificultar su utilización por parte de micro y pequeñas empresas.



4.21. Síntesis del capítulo

La analítica predictiva permite avanzar desde una comprensión retrospectiva del comportamiento empresarial hacia una perspectiva orientada a anticipar posibles acontecimientos. Su funcionamiento integra datos históricos, procedimientos estadísticos, series temporales y algoritmos de aprendizaje automático con el propósito de generar estimaciones que apoyen la planificación.

La regresión proporciona mecanismos para estimar variables cuantitativas, mientras que la clasificación permite anticipar categorías y probabilidades. Las series temporales resultan particularmente importantes para analizar ventas y demanda cuando los datos se encuentran organizados cronológicamente (Alonso-Rodríguez, 2021; Fernández López et al., 2020).

La predicción de demanda constituye una aplicación estratégica porque permite anticipar requerimientos y mejorar la planificación de recursos. La literatura científica demuestra la existencia de diferentes métodos y destaca la necesidad de seleccionar, evaluar y monitorear permanentemente los modelos utilizados (Viteri et al., 2022; Rahmer et al., 2022).

La detección temprana de cambios y el análisis de escenarios amplían la utilidad de los modelos al proporcionar señales y alternativas para enfrentar diferentes condiciones empresariales. Al mismo tiempo, la comunicación de la incertidumbre permite evitar que los pronósticos sean interpretados como resultados absolutamente ciertos.



En el marco del proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, la analítica predictiva constituye el componente encargado de transformar patrones históricos en conocimiento prospectivo. Los resultados generados podrán integrarse con la segmentación automatizada y alimentar posteriormente el módulo de recomendación estratégica.

En consecuencia, el valor de la propuesta reside en integrar **analítica descriptiva, segmentación, predicción, detección temprana, escenarios, interpretación y recomendación estratégica** dentro de una misma arquitectura tecnológica. Esta integración permitirá que la información empresarial evolucione desde el registro de acontecimientos hacia un recurso para anticipar comportamientos y fortalecer la toma de decisiones orientada a la competitividad.



CAPÍTULO 5.

SEGMENTACIÓN EMPRESARIAL AUTOMATIZADA MEDIANTE INTELIGENCIA ARTIFICIAL

5.1. Segmentación empresarial en entornos basados en datos

La segmentación constituye un proceso mediante el cual un conjunto heterogéneo de individuos, clientes, empresas u observaciones es dividido en grupos que presentan determinadas características comunes. En el contexto empresarial, esta práctica permite reconocer diferencias relevantes entre unidades de análisis y facilita la formulación de estrategias diferenciadas. Tradicionalmente, las organizaciones han utilizado variables demográficas, geográficas, económicas o comerciales para establecer categorías; sin embargo, el crecimiento de las bases de datos empresariales ha incrementado la necesidad de utilizar procedimientos capaces de reconocer estructuras más complejas (Chambi Condori, 2023).

La disponibilidad de información procedente de ventas, clientes, transacciones, comportamiento de compra, canales comerciales y otros procesos empresariales proporciona nuevas posibilidades para desarrollar segmentaciones basadas en evidencia. En lugar de establecer únicamente categorías predeterminadas, los algoritmos pueden analizar simultáneamente múltiples variables e identificar similitudes que no resultan evidentes mediante una observación convencional de los datos. Esta capacidad convierte a la inteligencia artificial y al aprendizaje automático en herramientas relevantes para mejorar el conocimiento de

la estructura interna de los mercados y las organizaciones (Chambi Condori, 2023).

Desde esta perspectiva, la segmentación automatizada no debe entenderse únicamente como una clasificación tecnológica de registros. Su propósito empresarial consiste en transformar grandes cantidades de información en grupos interpretables que permitan comprender comportamientos diferenciados y apoyar decisiones relacionadas con marketing, ventas, clientes, productos y competitividad. El valor del procedimiento depende, por tanto, tanto de la calidad matemática de los agrupamientos como de su capacidad para proporcionar conocimiento susceptible de ser utilizado estratégicamente (Cueva Estrada et al., 2023).

Dentro del proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, este componente constituye la primera capa de inteligencia analítica. La identificación automática de perfiles permitirá reconocer estructuras presentes en los datos y generar segmentos que posteriormente podrán vincularse con modelos predictivos y mecanismos de recomendación estratégica.

5.2. Limitaciones de la segmentación tradicional

Los procedimientos tradicionales de segmentación suelen comenzar con criterios establecidos previamente por el investigador o responsable empresarial. Variables como edad, ubicación, tamaño empresarial, nivel de ingresos, sector económico o frecuencia de compra permiten construir



categorías comprensibles y relativamente fáciles de implementar. No obstante, estos procedimientos pueden resultar insuficientes cuando existen múltiples características que interactúan simultáneamente (Chambi Condori, 2023).

Una de sus principales limitaciones radica en que los grupos suelen definirse antes de examinar exhaustivamente la estructura interna de los datos. Esto puede conducir a clasificaciones que reflejen criterios conceptuales válidos, pero que no necesariamente representen los patrones existentes dentro de la información disponible. Dos clientes pertenecientes al mismo grupo demográfico, por ejemplo, pueden presentar comportamientos de compra considerablemente diferentes.

Otra limitación corresponde a la dificultad para procesar grandes cantidades de variables. A medida que aumenta el volumen y diversidad de información empresarial, resulta más complejo establecer manualmente reglas capaces de representar todas las combinaciones posibles. Los algoritmos de aprendizaje automático permiten analizar simultáneamente múltiples dimensiones y reconocer estructuras que pueden permanecer ocultas en procedimientos convencionales (Chambi Condori, 2023).

La segmentación tradicional tampoco se adapta automáticamente a los cambios observados en los datos. Cuando los clientes modifican sus comportamientos o aparecen nuevas condiciones comerciales, las categorías establecidas previamente pueden perder representatividad. Los sistemas automatizados ofrecen la posibilidad de recalcular



periódicamente los segmentos e identificar modificaciones en su composición.

Esto no significa que la segmentación tradicional carezca de utilidad. Variables convencionales continúan proporcionando información importante para interpretar los resultados. La diferencia consiste en que la inteligencia artificial permite complementar estos criterios mediante patrones derivados directamente de los datos.

5.3. Aprendizaje no supervisado para la segmentación

El aprendizaje no supervisado constituye una rama del aprendizaje automático orientada al análisis de datos que no disponen de una variable objetivo previamente etiquetada. A diferencia del aprendizaje supervisado, el algoritmo no intenta aprender una respuesta conocida, sino identificar estructuras, relaciones o agrupaciones presentes en la información.

Esta característica resulta particularmente apropiada para los problemas de segmentación. Cuando una empresa dispone de una base de clientes o registros empresariales, puede desconocer inicialmente cuántos perfiles existen o cuáles son sus características. Los algoritmos no supervisados permiten explorar la estructura de estos datos sin establecer previamente todas las categorías posibles.

El *clustering* o análisis de conglomerados constituye una de las técnicas más utilizadas dentro de este enfoque. Su objetivo consiste en formar grupos en los cuales las observaciones pertenecientes a un mismo clúster



presenten mayor semejanza entre sí que respecto de aquellas ubicadas en otros grupos. Esta lógica permite descubrir perfiles a partir de las características reales de los datos (Chambi Condori, 2023).

En aplicaciones empresariales, las variables utilizadas para formar clústeres pueden incluir frecuencia de compra, valor monetario, número de transacciones, productos adquiridos, características comerciales, indicadores financieros o diferentes atributos organizacionales. La selección dependerá de la unidad de análisis y de la finalidad estratégica de la segmentación.

Para el presente proyecto, el aprendizaje no supervisado permitirá desarrollar una segmentación basada en las características observadas en las empresas o clientes analizados. Los segmentos no serán únicamente categorías impuestas previamente, sino agrupaciones obtenidas mediante similitudes cuantificables presentes en los datos.

5.4. Clustering como mecanismo de descubrimiento de estructuras

El análisis de clúster constituye una herramienta exploratoria que permite descubrir estructuras dentro de conjuntos de datos multidimensionales. El procedimiento busca maximizar la similitud entre observaciones pertenecientes al mismo grupo y, simultáneamente, incrementar las diferencias respecto de otros grupos.

Esta propiedad convierte al *clustering* en una herramienta relevante para la analítica empresarial. Una base de datos aparentemente homogénea puede contener diferentes perfiles de clientes, empresas o



comportamientos comerciales. Los algoritmos permiten identificar estas configuraciones y convertirlas en agrupaciones susceptibles de análisis.
El resultado del agrupamiento depende considerablemente de las variables seleccionadas y de la forma en que estas son representadas. Variables medidas en escalas muy diferentes pueden influir desproporcionadamente en los cálculos de distancia. Por ello, procedimientos como normalización y estandarización adquieren especial importancia antes de ejecutar determinados algoritmos.

Además, la presencia de valores extremos puede modificar la estructura de los grupos. El análisis exploratorio previo debe identificar estas observaciones y determinar si corresponden a errores, situaciones excepcionales o comportamientos empresariales legítimos que deben conservarse.

En consecuencia, el *clustering* no constituye simplemente la ejecución automática de un algoritmo. Requiere un proceso que integre selección de variables, preparación de datos, comparación de alternativas, evaluación de los grupos e interpretación empresarial.

5.5. Algoritmo K-means

K-means constituye uno de los algoritmos de agrupamiento más utilizados debido a su relativa simplicidad, eficiencia computacional y facilidad de implementación. Su propósito consiste en dividir un conjunto de observaciones en un número previamente establecido de grupos representados mediante centroides.

El procedimiento comienza generalmente con la selección de *K* centroides. Cada observación se asigna al centro más cercano de acuerdo con una medida de distancia y posteriormente los centroides son recalculados utilizando las observaciones asignadas. Este procedimiento se repite iterativamente hasta alcanzar una condición de convergencia.
Una de las principales ventajas de K-means es su capacidad para procesar grandes conjuntos de información con costos computacionales relativamente reducidos. Esta característica favorece su utilización en segmentación de clientes y mercados, especialmente cuando se trabaja con variables cuantitativas correctamente preparadas (Chambi Condori, 2023).

No obstante, K-means presenta limitaciones. El número de clústeres debe establecerse previamente, los resultados pueden depender de la inicialización de los centroides y el algoritmo presenta mayor dificultad cuando los grupos poseen formas irregulares, densidades diferentes o cantidades significativas de valores atípicos.

Por esta razón, la aplicación de K-means requiere complementar el algoritmo con procedimientos para determinar un número adecuado de segmentos. Entre las herramientas utilizadas se encuentran el método del codo y el coeficiente de silueta, los cuales proporcionan información cuantitativa para comparar diferentes valores de *K*.

En el proyecto propuesto, K-means constituye una alternativa importante para desarrollar la segmentación automatizada debido a su capacidad para generar agrupaciones relativamente fáciles de caracterizar. Sin



embargo, su selección definitiva deberá depender de la comparación con otros algoritmos y de la calidad de los segmentos obtenidos.

5.6. Determinación del número adecuado de clústeres

Uno de los principales desafíos de K-means consiste en determinar cuántos segmentos deben generarse. Establecer arbitrariamente el número de grupos puede producir una representación poco adecuada de la estructura existente en los datos.

El método del codo constituye una estrategia utilizada para orientar esta decisión. Su funcionamiento consiste en ejecutar el algoritmo con diferentes valores de *K* y observar cómo disminuye la variabilidad interna de los grupos. El punto a partir del cual agregar nuevos clústeres produce mejoras relativamente pequeñas puede considerarse como una alternativa razonable.

Otra herramienta es el coeficiente de silueta, que combina información sobre cohesión y separación. Valores superiores indican generalmente que las observaciones se encuentran adecuadamente asociadas con su propio grupo y suficientemente separadas de otros conglomerados.
Sin embargo, el número matemáticamente adecuado de segmentos no siempre coincide con el número más útil para la organización. Una solución con numerosos grupos puede presentar un buen resultado estadístico y ser difícil de convertir en estrategias diferenciadas.

Por ello, dentro del proyecto se propone combinar **criterios estadísticos y criterios empresariales**. El número definitivo de segmentos deberá



proporcionar una estructura consistente desde el punto de vista analítico y, simultáneamente, perfiles suficientemente claros para facilitar su interpretación estratégica.

5.7. Clustering jerárquico

El agrupamiento jerárquico constituye una alternativa a los algoritmos particionales como K-means. Su característica principal consiste en construir una estructura progresiva de agrupaciones que puede representarse mediante un dendrograma.

Los procedimientos jerárquicos pueden ser aglomerativos o divisivos. En el enfoque aglomerativo, cada observación comienza como un grupo independiente y posteriormente los grupos más similares se combinan sucesivamente. En el enfoque divisivo se parte de un único conjunto y se realizan separaciones progresivas.

El dendrograma constituye una herramienta visual particularmente importante porque permite observar las relaciones existentes entre los grupos y analizar diferentes niveles de segmentación. Dependiendo del punto en el cual se realice el corte del árbol, pueden obtenerse distintas cantidades de conglomerados.

Esta característica puede resultar útil en análisis empresariales porque permite observar tanto perfiles generales como subdivisiones más específicas. Una organización podría identificar inicialmente tres grandes segmentos y posteriormente analizar subgrupos existentes dentro de cada uno.



Sin embargo, los algoritmos jerárquicos pueden presentar mayores costos computacionales cuando se trabaja con bases de datos extensas. Además, los resultados dependen de la medida de distancia y del criterio de enlace utilizado para determinar la proximidad entre grupos.

Dentro del proyecto, el clustering jerárquico puede utilizarse como mecanismo comparativo y exploratorio. Su representación mediante dendrogramas permitirá comprender la estructura de similitud existente entre las unidades analizadas antes de seleccionar la segmentación definitiva.

5.8. DBSCAN y segmentación basada en densidad

DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) representa un enfoque diferente a K-means y al clustering jerárquico. En lugar de formar grupos principalmente alrededor de centroides, identifica regiones del espacio de datos que presentan elevada concentración de observaciones y las separa de regiones menos densas.

Una característica importante de DBSCAN consiste en que no requiere establecer previamente el número exacto de clústeres. El algoritmo utiliza parámetros relacionados con la distancia máxima entre observaciones próximas y el número mínimo de puntos necesario para considerar una región como suficientemente densa.

Esta metodología permite reconocer grupos con formas irregulares y detectar observaciones que no pertenecen claramente a ningún

conglomerado. Dichas observaciones pueden ser identificadas como ruido o valores atípicos.

Desde la perspectiva empresarial, esta capacidad puede resultar útil para identificar comportamientos poco frecuentes. Una observación considerada ruido desde el punto de vista matemático podría representar un cliente excepcional, una empresa con comportamiento atípico o una situación comercial que requiera análisis específico.

DBSCAN también presenta limitaciones. La selección de sus parámetros puede resultar compleja y su funcionamiento puede deteriorarse cuando existen grupos con densidades considerablemente diferentes o cuando los datos poseen una elevada cantidad de dimensiones.

Por esta razón, su utilización dentro del proyecto deberá evaluarse comparativamente. DBSCAN puede proporcionar información complementaria especialmente cuando la estructura de los datos no responde adecuadamente a agrupaciones aproximadamente esféricas.

5.9. Comparación entre K-means, clustering jerárquico y DBSCAN

Los tres algoritmos analizados responden a lógicas diferentes y, por tanto, no existe una alternativa universalmente superior. K-means resulta eficiente cuando los grupos presentan estructuras relativamente compactas y existe la posibilidad de establecer un número razonable de segmentos. El clustering jerárquico facilita comprender relaciones progresivas entre observaciones, mientras que DBSCAN posee ventajas cuando existen formas irregulares y valores atípicos.



La elección debe realizarse a partir de las características de la información disponible. Factores como número de observaciones, dimensionalidad, presencia de ruido, densidad de los grupos y finalidad empresarial influyen sobre la conveniencia de cada algoritmo.

Desde una perspectiva metodológica, resulta conveniente aplicar diferentes alternativas sobre el mismo conjunto de datos y comparar sus resultados mediante métricas internas. Esta práctica permite evitar que la selección dependa exclusivamente de preferencias técnicas.

Sin embargo, la evaluación no puede limitarse a indicadores matemáticos. Un clúster debe poder describirse mediante características relevantes y permitir establecer diferencias comprensibles respecto de otros grupos. De lo contrario, su utilidad estratégica será limitada.
Para el proyecto, se plantea por tanto una estrategia de **comparación algorítmica**, en la cual K-means, clustering jerárquico y DBSCAN puedan ser evaluados antes de seleccionar el modelo de segmentación que presente mejor equilibrio entre consistencia estadística e interpretación empresarial.

5.10. Selección automatizada de segmentos

La automatización de la segmentación no significa únicamente ejecutar un algoritmo sin intervención humana. Una arquitectura verdaderamente automatizada debe incorporar mecanismos para evaluar diferentes configuraciones y seleccionar aquellas que produzcan agrupaciones de mayor calidad.

El sistema puede ejecutar distintos valores de *K*, comparar coeficientes de silueta, analizar cohesión y separación y almacenar las configuraciones con mejores resultados. En algoritmos basados en densidad también pueden evaluarse diferentes combinaciones de parámetros.

Esta lógica permite reducir decisiones arbitrarias durante la construcción de los segmentos. En lugar de establecer manualmente una cantidad fija de grupos para todas las bases empresariales, el sistema puede explorar diferentes configuraciones y proporcionar una alternativa basada en criterios cuantitativos.

No obstante, la automatización no debe eliminar la interpretación humana. Una solución matemáticamente óptima puede producir segmentos difíciles de diferenciar desde la perspectiva empresarial. El resultado automatizado debe considerarse una propuesta analítica que posteriormente requiere validación.

Dentro del proyecto, la selección automatizada constituirá una función relevante de la herramienta inteligente. El sistema podrá comparar diferentes configuraciones y recomendar una estructura de segmentación, mostrando simultáneamente las métricas que sustentan dicha selección.

5.11. Construcción de perfiles empresariales inteligentes

La generación de clústeres representa solamente la primera parte de la segmentación. Después de identificar los grupos resulta necesario



determinar qué características distinguen a cada uno. Este proceso puede denominarse **perfilamiento inteligente**.

La construcción de perfiles implica calcular estadísticas descriptivas e indicadores para las variables que conforman cada segmento. Promedios, medianas, frecuencias, proporciones y distribuciones permiten reconocer qué características predominan dentro de cada agrupación.

Posteriormente, estas características pueden convertirse en descripciones comprensibles. En lugar de mostrar únicamente "Clúster 1", la plataforma podría caracterizarlo mediante sus atributos predominantes. Esto facilita que el usuario empresarial comprenda las diferencias entre los segmentos.

La denominación de los perfiles debe realizarse después de analizar los resultados y no antes de ejecutar el algoritmo. Establecer previamente etiquetas como "alto potencial" o "bajo rendimiento" podría introducir interpretaciones que los datos no necesariamente respaldan.
Por esta razón, el proyecto deberá mantener inicialmente identificadores neutrales y posteriormente construir descripciones fundamentadas en las variables observadas. Esta metodología contribuirá a reducir interpretaciones subjetivas y fortalecer la trazabilidad del análisis.

5.12. Segmentación dinámica

Los segmentos empresariales no deben considerarse estructuras permanentes. Los clientes modifican sus hábitos, las empresas

evolucionan, aparecen nuevos productos y las condiciones económicas pueden alterar las relaciones existentes entre variables.

La segmentación dinámica busca responder a esta característica mediante actualizaciones periódicas de los modelos. A medida que se incorporan nuevos datos, los algoritmos pueden volver a calcular las agrupaciones y determinar si la estructura original continúa representando adecuadamente la realidad.

Esta capacidad permite analizar migraciones entre segmentos. Un cliente puede pasar de un perfil de baja frecuencia a otro de mayor actividad, mientras que una empresa puede modificar su posición relativa respecto de indicadores de ventas, productividad o competitividad.

El análisis de estas transiciones proporciona información adicional. No solamente permite conocer a qué segmento pertenece actualmente una observación, sino también identificar cómo ha evolucionado su comportamiento.

Para el proyecto, la segmentación dinámica permitirá que la herramienta evolucione juntamente con los datos empresariales. Los segmentos podrán actualizarse en períodos previamente establecidos o cuando el sistema detecte cambios significativos en la estructura de la información.

5.13. Identificación de patrones ocultos

Una de las principales ventajas del aprendizaje no supervisado consiste en su capacidad para descubrir estructuras que no fueron definidas previamente. Estas relaciones pueden considerarse patrones ocultos



debido a que no resultan evidentes mediante una observación directa de la base de datos.

Los patrones pueden corresponder a combinaciones particulares de variables. Dos empresas con niveles de ventas similares pueden pertenecer a segmentos diferentes si presentan comportamientos distintos en crecimiento, clientes, productos u otros indicadores.

La identificación de estas configuraciones permite superar análisis basados en una sola variable. La inteligencia artificial puede considerar simultáneamente múltiples dimensiones y determinar similitudes a partir de la interacción entre ellas.

No obstante, el descubrimiento algorítmico debe complementarse con interpretación. Una relación estadística no representa automáticamente una explicación causal. Los patrones identificados indican asociaciones o similitudes que posteriormente deben ser analizadas dentro del contexto empresarial.

En el proyecto propuesto, esta capacidad permitirá descubrir perfiles que podrían permanecer invisibles mediante procedimientos convencionales. Los resultados podrán posteriormente relacionarse con modelos predictivos para analizar si diferentes segmentos presentan comportamientos futuros distintos.



5.14. Interpretación estratégica de los clústeres

La interpretación estratégica representa la etapa que transforma los resultados matemáticos del clustering en conocimiento empresarial. Un conjunto de centroides o distancias posee escasa utilidad para un gerente si no puede relacionarse con características concretas de la organización. El primer paso consiste en identificar las variables que diferencian a cada grupo. Estas características permiten construir una descripción objetiva del segmento y compararlo con los demás.

Posteriormente pueden analizarse las implicaciones empresariales. Si un segmento presenta determinadas características comerciales, la organización puede estudiar qué estrategias resultan pertinentes para dicho perfil. Sin embargo, las acciones no deben derivarse automáticamente de una etiqueta, sino del análisis conjunto de los indicadores.

Chambi Condori (2023) señala que la aplicación de *machine learning* en segmentación permite identificar grupos de consumidores y proporciona información susceptible de utilizarse en estrategias de marketing. La utilidad final depende de convertir los resultados técnicos en conocimiento interpretable para la organización.

La interpretación estratégica también permite determinar si una segmentación técnicamente correcta posee verdadera utilidad. Dos grupos estadísticamente diferentes pueden requerir exactamente la misma estrategia empresarial, en cuyo caso mantenerlos separados podría aportar poco valor práctico.



En consecuencia, dentro del proyecto se propone evaluar los clústeres mediante una doble perspectiva: **validez analítica y relevancia estratégica**.

5.15. Segmentación y comportamiento del consumidor

El comportamiento del consumidor constituye una de las áreas en las cuales la segmentación automatizada presenta mayores posibilidades. Las interacciones comerciales generan registros relacionados con frecuencia de compra, valor monetario, productos, canales y períodos de actividad.

Estos atributos pueden utilizarse para construir representaciones multidimensionales de los clientes. Los algoritmos identifican similitudes entre dichas representaciones y forman grupos basados en comportamiento observable.

Chambi Condori (2023) analiza precisamente la aplicación de aprendizaje automático a la segmentación de mercados y muestra cómo estas herramientas permiten estudiar cambios en el comportamiento de consumidores y proporcionar información para la gestión de marketing.
La utilización de variables comportamentales puede complementar los criterios sociodemográficos tradicionales. Dos personas con características demográficas semejantes pueden mantener patrones comerciales diferentes; por tanto, combinar ambas dimensiones puede proporcionar una representación más completa.
En la plataforma propuesta, este enfoque podrá utilizarse cuando las empresas dispongan de información transaccional de sus clientes. Los

segmentos resultantes podrán posteriormente relacionarse con predicciones y recomendaciones diferenciadas.

5.16. Segmentación empresarial y competitividad

La segmentación automatizada también puede utilizarse para analizar empresas y no exclusivamente clientes. Variables relacionadas con ventas, crecimiento, recursos, digitalización, características comerciales y desempeño pueden permitir identificar diferentes perfiles empresariales.

Esta perspectiva resulta particularmente relevante para proyectos orientados a micro y pequeñas empresas, debido a que no todas presentan las mismas capacidades, necesidades ni condiciones competitivas. Aplicar una estrategia homogénea a organizaciones heterogéneas puede reducir la efectividad de las intervenciones.

Los algoritmos de agrupamiento permiten reconocer estructuras internas dentro de poblaciones empresariales. Posteriormente, los perfiles obtenidos pueden utilizarse para identificar características predominantes y diseñar recomendaciones diferenciadas.

La inteligencia artificial adquiere valor en este escenario porque permite procesar simultáneamente múltiples indicadores y detectar configuraciones que pueden resultar difíciles de establecer mediante clasificaciones manuales. Su aplicación puede contribuir a desarrollar sistemas de apoyo a decisiones basados en evidencia (Casanova-Villalba et al., 2023).



Para el proyecto, esta posibilidad resulta especialmente relevante debido a que permitirá generar perfiles empresariales que posteriormente puedan vincularse con diferentes estrategias orientadas al fortalecimiento de la competitividad.

5.17. Integración entre segmentación y analítica predictiva

La segmentación automatizada y la analítica predictiva constituyen componentes complementarios. La primera permite identificar estructuras existentes dentro de los datos, mientras que la segunda utiliza información histórica para anticipar comportamientos posteriores.

La integración puede realizarse utilizando los segmentos como una variable adicional dentro de los modelos predictivos o desarrollando modelos independientes para determinados grupos. Esta estrategia permite analizar si los diferentes perfiles presentan comportamientos futuros diferenciados.

Por ejemplo, después de identificar tres segmentos empresariales, la plataforma podría estimar la evolución esperada de las ventas dentro de cada uno. Los resultados permitirían conocer no solamente el comportamiento agregado, sino las diferencias existentes entre perfiles.

Esta integración incrementa la granularidad de la información disponible. Una predicción general puede ocultar tendencias opuestas entre segmentos, mientras que un análisis diferenciado permite reconocer qué grupos presentan determinados comportamientos.



En consecuencia, dentro del proyecto la segmentación no constituirá un resultado aislado. Los perfiles generados alimentarán posteriormente los componentes de predicción y recomendación estratégica.

5.18. De los clústeres a la recomendación estratégica

La recomendación estratégica representa una etapa posterior a la segmentación y predicción. Una vez identificados los perfiles y analizado su posible comportamiento, el sistema puede proporcionar información asociada con alternativas de actuación.

Este procedimiento debe mantener una separación clara entre resultado analítico y decisión empresarial. El algoritmo puede indicar que determinado segmento presenta ciertas características o tendencias, pero corresponde al responsable empresarial evaluar las acciones considerando información adicional del entorno.

Las recomendaciones pueden construirse mediante reglas previamente validadas, sistemas de conocimiento o mecanismos de recomendación. La selección de estrategias debe mantener trazabilidad para que el usuario pueda comprender qué información originó la sugerencia.

Por ejemplo, el sistema podría identificar un segmento caracterizado por reducción de frecuencia de compra y, posteriormente, relacionarlo con determinadas acciones de fidelización. Sin embargo, la plataforma debería mostrar los indicadores que sustentan la recomendación para facilitar su evaluación.



De esta manera, la inteligencia artificial no sustituye la decisión gerencial, sino que organiza información compleja y proporciona alternativas fundamentadas en patrones identificados mediante los datos.

5.19. Arquitectura de segmentación automatizada propuesta

A partir de los fundamentos analizados, el módulo de segmentación del proyecto puede estructurarse mediante la siguiente secuencia:

Datos empresariales → selección de variables → limpieza → tratamiento de valores atípicos → normalización/estandarización → ejecución de algoritmos → evaluación de clústeres → selección automatizada → construcción de perfiles → interpretación empresarial → segmentación dinámica → integración predictiva → recomendación estratégica.

La primera fase comprende la preparación de información. La calidad de los datos y la selección de variables condicionarán directamente la estructura de los segmentos obtenidos.

En la segunda fase se ejecutarán diferentes algoritmos. K-means permitirá evaluar soluciones basadas en centroides; el clustering jerárquico facilitará examinar relaciones progresivas mediante dendrogramas; y DBSCAN permitirá explorar agrupaciones basadas en densidad y detectar posibles observaciones atípicas.

La tercera fase corresponde a la evaluación. Las soluciones obtenidas serán comparadas mediante métricas como coeficiente de silueta y otros



indicadores de cohesión y separación. Los resultados matemáticos serán complementados mediante criterios de interpretación empresarial.

La cuarta fase estará orientada al perfilamiento. Cada clúster será descrito mediante las variables que lo caracterizan y se establecerán diferencias respecto de los demás grupos.

Finalmente, los segmentos serán incorporados a los componentes de predicción y recomendación estratégica. De esta manera, la segmentación constituirá una pieza integrada dentro de la arquitectura general de inteligencia artificial propuesta.

5.20. Propuesta conceptual del módulo inteligente de segmentación

La estructura conceptual del módulo puede expresarse mediante cinco capas:

Capa 1. Datos: información empresarial y comercial.

Capa 2. Procesamiento: limpieza, transformación, normalización y selección de características.

Capa 3. Inteligencia: aplicación y comparación de K-means, clustering jerárquico y DBSCAN.

Capa 4. Conocimiento: identificación de segmentos, caracterización de perfiles, patrones ocultos y cambios temporales.

Capa 5. Decisión: integración de los perfiles con predicciones, recomendaciones y visualización mediante dashboard.

Esta estructura permite diferenciar claramente el procesamiento técnico de la información y su posterior utilización estratégica. Los algoritmos operan sobre los datos, pero su resultado debe convertirse en

conocimiento interpretable antes de incorporarse a una decisión empresarial.

La arquitectura también facilita la trazabilidad. El usuario podrá conocer qué variables fueron utilizadas, qué algoritmo produjo la segmentación, cuáles fueron sus métricas y qué características permitieron describir cada grupo.

Esta transparencia resulta relevante para evitar que los segmentos sean percibidos como categorías arbitrarias generadas por un sistema de inteligencia artificial. La plataforma debe proporcionar evidencia suficiente para comprender por qué determinadas observaciones presentan similitudes y cómo fueron construidos los perfiles.

5.21. Síntesis del capítulo

La segmentación empresarial automatizada mediante inteligencia artificial permite evolucionar desde categorías establecidas exclusivamente mediante criterios previos hacia agrupaciones derivadas de los patrones presentes en los datos. Este enfoque resulta particularmente útil cuando las organizaciones disponen de información multidimensional y necesitan reconocer estructuras que no son fácilmente identificables mediante procedimientos tradicionales (Chambi Condori, 2023).

El aprendizaje no supervisado proporciona el fundamento metodológico de esta capacidad. Dentro de este enfoque, K-means, clustering jerárquico y DBSCAN representan alternativas con características diferentes. K-means destaca por su eficiencia y facilidad de



interpretación; el agrupamiento jerárquico proporciona una representación progresiva de las relaciones; y DBSCAN facilita identificar estructuras basadas en densidad y observaciones atípicas.

La selección del algoritmo debe sustentarse en las características de los datos y no exclusivamente en la popularidad de una determinada técnica. Las métricas de cohesión y separación permiten evaluar cuantitativamente los resultados, pero deben complementarse con criterios empresariales que determinen si los segmentos obtenidos poseen significado práctico.

La construcción de perfiles constituye una fase indispensable después del agrupamiento. Los clústeres deben ser caracterizados mediante variables e indicadores que permitan comprender sus diferencias y posteriormente asociarlos con acciones o análisis específicos.

La segmentación dinámica amplía esta capacidad al reconocer que los perfiles pueden modificarse con el tiempo. La actualización periódica de los modelos permitirá identificar migraciones entre grupos y modificaciones en la estructura de los datos.

En el marco del proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, este componente representa una etapa fundamental de la arquitectura analítica. La secuencia **segmentación → perfilamiento → predicción**



→ **recomendación** permitirá transformar información empresarial en conocimiento progresivamente orientado hacia la toma de decisiones.

De esta manera, la segmentación automatizada no constituye únicamente una técnica estadística, sino un mecanismo para descubrir heterogeneidad empresarial, identificar patrones ocultos y generar perfiles que permitan desarrollar análisis y estrategias diferenciadas. Su integración con analítica predictiva y recomendación estratégica contribuirá a construir una herramienta inteligente orientada al fortalecimiento de la capacidad analítica y competitiva empresarial.



CAPÍTULO 6.

INTELIGENCIA ARTIFICIAL EXPLICABLE PARA DECISIONES EMPRESARIALES

6.1. Inteligencia artificial explicable en la gestión empresarial

La inteligencia artificial ha ampliado las posibilidades de análisis de las organizaciones al permitir procesar grandes volúmenes de información, identificar regularidades, realizar predicciones y apoyar la generación de recomendaciones. Sin embargo, el incremento de la capacidad predictiva también ha introducido un desafío relevante: algunos modelos poseen estructuras suficientemente complejas como para dificultar que sus usuarios comprendan las razones asociadas con los resultados obtenidos. En este contexto se desarrolla la Inteligencia Artificial Explicable, conocida como *Explainable Artificial Intelligence* (XAI), como un campo orientado a mejorar la comprensión e interpretación de los sistemas inteligentes y de sus resultados (Ortega Ovalle, 2026; Robles-Zambrano et al., 2026).

La necesidad de explicabilidad adquiere particular importancia cuando los resultados de un algoritmo participan en decisiones empresariales. Una estimación de ventas, la clasificación de un cliente, la identificación de un segmento o una recomendación estratégica puede influir sobre la asignación de recursos y las acciones de una organización. En estas circunstancias, disponer únicamente del resultado numérico puede resultar insuficiente; el responsable empresarial también necesita elementos que le permitan valorar qué información intervino en la

estimación y cuáles fueron los factores con mayor influencia (Lalama Freire, 2025).

Desde esta perspectiva, XAI no debe concebirse exclusivamente como un conjunto de herramientas técnicas destinadas a visualizar el funcionamiento de algoritmos. Su importancia también reside en facilitar la comunicación entre los sistemas computacionales y las personas responsables de interpretar sus resultados. Esto permite transformar salidas matemáticas complejas en información con mayor significado para los procesos de gestión y decisión (Robles-Zambrano et al., 2026).

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, la explicabilidad se incorpora como una capacidad transversal. La plataforma no deberá limitarse a señalar qué segmento ha sido identificado, qué comportamiento se estima o qué alternativa estratégica se propone; también deberá proporcionar información que permita comprender los principales factores relacionados con dichos resultados.

6.2. El problema de la opacidad algorítmica

Los algoritmos de aprendizaje automático presentan diferentes niveles de complejidad. Algunos modelos poseen estructuras relativamente sencillas que facilitan examinar la relación existente entre variables de entrada y resultados. Otros incorporan numerosos parámetros, interacciones y transformaciones internas que dificultan reconstruir intuitivamente el procedimiento seguido para generar una determinada predicción (Ortega Ovalle, 2026).

Esta dificultad suele asociarse con el concepto de opacidad algorítmica. El problema no consiste necesariamente en que el algoritmo funcione



incorrectamente, sino en que el usuario puede tener dificultades para comprender la lógica que relaciona la información suministrada con el resultado producido. Esta situación puede limitar la capacidad para evaluar predicciones, detectar comportamientos inesperados o justificar la utilización de una determinada recomendación (Robles-Zambrano et al., 2026).

En el ámbito empresarial, la opacidad puede convertirse en una barrera para la utilización efectiva de los modelos. Si un sistema anticipa una disminución de ventas, pero no proporciona información sobre los factores relacionados con la estimación, el gerente dispone de una señal predictiva pero de pocos elementos para analizarla estratégicamente. La explicabilidad busca reducir esta brecha entre capacidad computacional y comprensión humana (Lalama Freire, 2025).

Por esta razón, la arquitectura propuesta en esta investigación considera que la precisión predictiva y la capacidad explicativa son dimensiones complementarias. Un modelo útil para apoyar decisiones empresariales debe evaluarse no solamente por su desempeño estadístico, sino también por la posibilidad de comunicar de manera razonable cómo determinadas variables contribuyen a sus resultados (Ortega Ovalle, 2026).

6.3. De la predicción a la explicación

La analítica predictiva intenta estimar comportamientos futuros utilizando patrones identificados en información histórica. La explicabilidad introduce una dimensión adicional al buscar información sobre los factores que intervienen en las predicciones. Por ello, predicción y explicación responden a preguntas diferentes, aunque relacionadas (Lalama Freire, 2025).

Una predicción puede responder, por ejemplo, a la pregunta: **¿cuál es el comportamiento estimado de las ventas durante el siguiente período?** Una explicación busca complementar ese resultado mediante otra interrogante: **¿qué características del modelo contribuyeron con mayor intensidad a producir esa estimación?** La segunda respuesta permite contextualizar la primera y proporciona elementos adicionales para su valoración.

Esta distinción resulta especialmente importante porque una explicación del comportamiento de un modelo no equivale necesariamente a demostrar causalidad en el fenómeno empresarial. Si una variable presenta elevada contribución en una predicción, significa que el algoritmo la utilizó de manera relevante para producir ese resultado bajo la estructura aprendida; ello no demuestra, por sí solo, que modificar dicha variable vaya a causar automáticamente un determinado efecto en la realidad empresarial.

Por consiguiente, las explicaciones generadas mediante XAI deben interpretarse como evidencia acerca del funcionamiento predictivo del modelo y no como demostraciones automáticas de relaciones causales. Esta precaución evita convertir asociaciones algorítmicas en conclusiones empresariales que excedan la evidencia disponible.

6.4. Interpretabilidad y explicabilidad

Interpretabilidad y explicabilidad son conceptos estrechamente relacionados, aunque no completamente equivalentes. La interpretabilidad puede entenderse como el grado en que una persona consigue comprender las relaciones utilizadas por un modelo, mientras que la explicabilidad incorpora mecanismos destinados a comunicar de



manera comprensible las razones asociadas con determinados resultados algorítmicos (Ortega Ovalle, 2026).

Algunos algoritmos presentan mayor interpretabilidad intrínseca. Determinadas regresiones o árboles de decisión, por ejemplo, permiten examinar de forma relativamente directa las relaciones utilizadas para generar resultados. En cambio, otros modelos pueden alcanzar estructuras considerablemente más complejas y requerir herramientas adicionales de explicación.

Los métodos aplicados después de entrenar un modelo suelen denominarse explicaciones *post hoc*. Estas técnicas permiten estudiar el comportamiento de algoritmos complejos sin necesidad de reemplazarlos por modelos completamente transparentes. SHAP y LIME se encuentran entre los métodos frecuentemente utilizados dentro de esta perspectiva (Lalama Freire, 2025; Riccio Anastacio et al., 2025).

La selección entre un modelo intrínsecamente interpretable y uno más complejo debe considerar la finalidad empresarial. Una mejora limitada en precisión no necesariamente justifica sacrificar considerablemente la comprensión del resultado, especialmente cuando la decisión requiere una justificación clara ante los responsables de la organización.

6.5. Explicaciones globales y explicaciones locales

La explicabilidad puede analizarse desde una perspectiva global o local. Las explicaciones globales intentan proporcionar una visión general del comportamiento del modelo, identificando variables o patrones que influyen de manera recurrente sobre el conjunto de predicciones (Ortega Ovalle, 2026).

En una aplicación empresarial, este nivel podría utilizarse para determinar qué características poseen mayor relevancia general en la



predicción de ventas, demanda o comportamiento comercial. La información global permite comprender cómo funciona el modelo en términos generales, aunque no necesariamente explica con suficiente precisión cada observación particular.

Las explicaciones locales se concentran en un resultado individual. En lugar de analizar el comportamiento promedio del algoritmo, examinan qué variables contribuyeron a una predicción específica. Esto permite responder por qué el sistema asignó determinada estimación a una empresa, cliente o período concreto.

Ambos niveles resultan complementarios. Una plataforma orientada a decisiones empresariales debería permitir observar el comportamiento general del modelo y, cuando el usuario lo requiera, profundizar en la explicación de casos específicos.

6.6. Importancia de las variables

La importancia de variables constituye uno de los mecanismos más accesibles para aproximarse a la interpretación de modelos de aprendizaje automático. Su propósito consiste en establecer cuáles características de entrada poseen mayor peso o contribución dentro del comportamiento predictivo del algoritmo (Lalama Freire, 2025).

En el contexto empresarial, estas variables pueden estar relacionadas con ventas históricas, número de clientes, frecuencia de compra, comportamiento de la demanda, precios, temporalidad, productos, indicadores financieros o características derivadas de los segmentos identificados.

La utilidad de esta información reside en que permite concentrar la atención en aquellos atributos que el modelo considera más relevantes. Sin embargo, su interpretación debe realizarse con cautela, debido a que



diferentes métodos de importancia pueden medir conceptos distintos y producir resultados diferentes.

Además, una variable predictivamente importante no debe interpretarse automáticamente como una causa del fenómeno. La plataforma deberá comunicar esta diferencia para evitar que una asociación identificada por el algoritmo se transforme incorrectamente en una afirmación causal.

6.7. SHAP como técnica de explicación

SHAP, acrónimo de *SHapley Additive exPlanations*, es una metodología de atribución de características utilizada para analizar la contribución de las variables a las predicciones de modelos de aprendizaje automático. La técnica se fundamenta conceptualmente en los valores de Shapley procedentes de la teoría de juegos y distribuye la diferencia entre una predicción y un valor de referencia entre las características consideradas por el modelo (Riccio Anastacio et al., 2025).

El resultado permite analizar cómo cada característica contribuye al valor predicho. Una variable puede desplazar la estimación hacia valores superiores o inferiores respecto de una referencia, proporcionando información sobre la dirección y magnitud de su contribución.

Una de las principales ventajas de SHAP es la posibilidad de combinar explicaciones individuales con análisis agregados. Los valores correspondientes a múltiples observaciones pueden utilizarse para estudiar patrones generales, mientras que el análisis de una observación específica permite examinar las variables asociadas con una predicción particular (Lalama Freire, 2025).

Esta característica resulta especialmente apropiada para la plataforma propuesta. El gerente podría visualizar qué variables son generalmente relevantes para el modelo y posteriormente seleccionar una predicción

específica para conocer qué factores tuvieron mayor participación en ese resultado.

6.8. SHAP aplicado a predicciones empresariales

Supóngase que el modelo predictivo de la plataforma estima una disminución de ventas para el período siguiente. Mostrar exclusivamente el porcentaje esperado proporcionaría información prospectiva, pero no permitiría comprender suficientemente el comportamiento del algoritmo. Mediante SHAP, el sistema podría identificar que determinadas características contribuyeron a desplazar la estimación hacia valores inferiores, mientras que otras ejercieron un efecto en sentido contrario. De esta manera, la predicción se complementaría con información acerca de los factores utilizados por el modelo.

La plataforma podría transformar posteriormente estas contribuciones en representaciones visuales. El usuario no necesitaría interpretar directamente los cálculos internos, sino observar cuáles variables presentaron mayor incidencia algorítmica y en qué dirección se produjo su contribución.

Esta integración permitiría establecer la secuencia:

Predicción → contribución de variables → explicación visual → interpretación empresarial.

La explicación no determinaría automáticamente qué acción debe adoptar la empresa. Su función sería proporcionar información adicional para que el gerente evalúe el resultado considerando también experiencia, contexto y otras evidencias disponibles.

6.9. LIME como explicación local

LIME, correspondiente a *Local Interpretable Model-Agnostic Explanations*, es una metodología orientada principalmente a explicar

predicciones individuales. Su lógica consiste en aproximar localmente el comportamiento de un modelo complejo mediante una representación más sencilla alrededor de la observación que se desea interpretar (Riccio Anastacio et al., 2025).

La característica *model-agnostic* indica que el método puede aplicarse a diferentes tipos de algoritmos siempre que sea posible consultar sus predicciones. Esta flexibilidad permite utilizar una capa de explicación sobre modelos con estructuras distintas.

En un contexto empresarial, LIME puede emplearse para estudiar por qué una determinada empresa, cliente u observación recibió una predicción particular. El procedimiento identifica qué características tuvieron mayor relevancia dentro de la aproximación local generada para ese caso.

No obstante, la explicación obtenida debe interpretarse dentro del entorno específico para el cual fue construida. Una explicación local no debe generalizarse automáticamente al comportamiento completo del modelo, debido a que su propósito es representar una región particular del espacio de datos.

6.10. SHAP y LIME: complementariedad y precauciones

SHAP y LIME comparten el objetivo de proporcionar información sobre modelos complejos, pero emplean fundamentos diferentes. LIME genera aproximaciones interpretables en torno a observaciones particulares, mientras que SHAP asigna contribuciones a las características mediante un enfoque de atribución que puede utilizarse tanto para interpretaciones locales como para análisis agregados (Riccio Anastacio et al., 2025).

Ninguna técnica debe considerarse automáticamente superior para todos los problemas. La selección depende del modelo utilizado, características

de los datos, costo computacional, estabilidad de las explicaciones y necesidades del usuario.

Además, una explicación debe evaluarse por su fidelidad al comportamiento del modelo. Una representación visual sencilla puede resultar comprensible, pero perder valor si no refleja adecuadamente la lógica de la predicción que pretende explicar. Por ello, comprensibilidad y fidelidad deben analizarse conjuntamente.

En el proyecto se propone evaluar experimentalmente SHAP y LIME sobre los modelos predictivos seleccionados. SHAP puede utilizarse principalmente para analizar contribuciones globales y locales, mientras que LIME puede actuar como mecanismo complementario para estudiar casos individuales cuando resulte pertinente.

6.11. Estabilidad de las explicaciones

Una dimensión importante de XAI corresponde a la estabilidad. Si pequeñas modificaciones que no cambian sustancialmente una observación producen explicaciones completamente diferentes, la interpretación proporcionada al usuario puede resultar difícil de utilizar.

La estabilidad adquiere especial importancia en aplicaciones empresariales porque los gerentes pueden comparar períodos, empresas o clientes con características semejantes. Explicaciones extremadamente variables podrían generar mensajes contradictorios y reducir la utilidad del sistema.

Por ello, la evaluación del componente XAI no debe limitarse a determinar si una explicación puede generarse técnicamente. También resulta conveniente comprobar si presenta un comportamiento suficientemente consistente bajo condiciones similares.



Esta consideración permitirá seleccionar mecanismos explicativos no solamente por su popularidad, sino por su adecuación al modelo, estabilidad y utilidad para los usuarios finales.

6.12. Transparencia algorítmica

La transparencia algorítmica comprende la disponibilidad de información suficiente para comprender las características fundamentales de un sistema inteligente. Esto incluye el propósito del modelo, naturaleza de los datos, variables utilizadas, criterios de evaluación, limitaciones conocidas y mecanismos empleados para producir y explicar sus resultados (Robles-Zambrano et al., 2026).

La transparencia no significa necesariamente exponer toda la complejidad matemática al usuario final. Una plataforma puede ser transparente proporcionando diferentes niveles de información según las necesidades de cada perfil de usuario.

Para el responsable empresarial puede resultar suficiente conocer qué modelo se utiliza, qué información considera, cuál es su desempeño, qué variables influyeron en una predicción y qué nivel de incertidumbre presenta. Un especialista técnico puede requerir información adicional sobre parámetros, versiones, entrenamiento y métricas.

La transparencia debe concebirse, por tanto, como una característica de diseño del sistema y no como una explicación añadida después de finalizar el desarrollo. Este enfoque favorece la trazabilidad y facilita revisar posteriormente el comportamiento de los modelos (Ortega Ovalle, 2026; Robles-Zambrano et al., 2026).

6.13. Trazabilidad de las decisiones algorítmicas

La trazabilidad permite reconstruir el recorrido seguido desde los datos hasta el resultado presentado al usuario. En un sistema empresarial



inteligente, esto implica registrar información relacionada con los datos utilizados, versión del modelo, momento de ejecución, predicción obtenida y explicación generada.

Esta capacidad resulta relevante cuando las predicciones cambian a medida que se incorporan nuevos datos o se actualizan los modelos. Mantener un registro permite determinar qué versión produjo cada resultado y bajo qué condiciones.

Dentro del proyecto, la trazabilidad también puede extenderse a las recomendaciones. Cada alternativa estratégica presentada por la plataforma debería mantener una relación identificable con los segmentos, predicciones e indicadores que contribuyeron a generarla.

La arquitectura propuesta puede representar este proceso mediante la cadena:

Dato → procesamiento → modelo → predicción → explicación → recomendación → evaluación humana.

6.14. Explicaciones orientadas al usuario

La calidad de una explicación depende no solamente de su rigor técnico, sino también de su adecuación a la persona que debe utilizarla. Un científico de datos, un gerente y un propietario de una microempresa pueden requerir diferentes niveles de detalle para interpretar el mismo resultado (Robles-Zambrano et al., 2026).

Una explicación orientada al usuario empresarial debe priorizar claridad, pertinencia y conexión con indicadores conocidos. Presentar exclusivamente coeficientes o valores técnicos puede dificultar la comprensión y limitar la utilización de la plataforma.

Por esta razón, los resultados de SHAP o LIME pueden traducirse en representaciones visuales acompañadas de descripciones breves. El



usuario podría conocer cuáles factores incrementaron o redujeron una predicción y posteriormente acceder a información técnica adicional cuando lo considere necesario.

Este enfoque puede implementarse mediante una arquitectura de explicación progresiva: primero se presenta la información esencial para la decisión y posteriormente se habilitan niveles adicionales de detalle. De esta manera se evita tanto la simplificación excesiva como la saturación informativa.

6.15. Visualización de las explicaciones

La visualización constituye un mecanismo importante para transformar resultados XAI en información interpretable. Los gráficos pueden representar importancia de variables, contribuciones individuales, diferencias entre observaciones y cambios en el comportamiento de los factores relevantes (Lalama Freire, 2025).

Para el análisis global, la plataforma puede ordenar las variables según su contribución al comportamiento general del modelo. Esta representación permite reconocer rápidamente qué características participan con mayor frecuencia en las predicciones.

Para el análisis local pueden mostrarse los factores que desplazaron una estimación respecto de un valor de referencia. Una visualización de este tipo facilita identificar qué elementos contribuyeron positiva o negativamente al resultado.

El diseño del *dashboard* deberá evitar que la explicación se convierta en una reproducción directa de salidas técnicas difíciles de interpretar. Las visualizaciones deben responder a preguntas empresariales concretas y permitir acceder al detalle únicamente cuando sea necesario.

6.16. Confianza informada y confianza calibrada en la IA



La explicabilidad suele relacionarse con la confianza en los sistemas inteligentes. Sin embargo, el objetivo de XAI no debería consistir en persuadir al usuario para que acepte automáticamente una predicción, sino en proporcionarle información suficiente para evaluar cuándo el resultado parece razonable y cuándo requiere una revisión adicional (Ortega Ovalle, 2026).

Esta perspectiva puede entenderse como **confianza calibrada**. El usuario debe conocer tanto las fortalezas como las limitaciones del modelo y evitar dos extremos: rechazo sistemático de los resultados algorítmicos y aceptación automática de cualquier recomendación producida por la inteligencia artificial.

Una explicación adecuada puede incluso disminuir justificadamente la confianza cuando revela que una predicción depende de información insuficiente, variables poco estables o condiciones alejadas de los datos utilizados durante el entrenamiento. Esta función crítica resulta tan importante como la capacidad de incrementar la aceptación del modelo.

Por consiguiente, el *dashboard* deberá presentar conjuntamente predicción, explicación, desempeño e incertidumbre cuando esta información resulte pertinente. La combinación permitirá que el usuario valore el resultado de manera más completa.

6.17. Explicabilidad como mecanismo de validación del modelo

XAI también puede utilizarse durante el desarrollo y evaluación de los modelos. Una predicción puede presentar un error estadístico reducido y, al mismo tiempo, depender de variables que no resulten razonables desde la perspectiva del problema empresarial.

Las herramientas de explicación permiten examinar qué características utiliza el modelo y detectar relaciones inesperadas. Esto puede contribuir



a identificar problemas de preparación de datos, variables espurias, posibles filtraciones de información o patrones que requieren investigación adicional.

La explicación funciona, así como una capa complementaria de validación. No sustituye las métricas predictivas, pero permite examinar aspectos del comportamiento del modelo que pueden permanecer ocultos cuando únicamente se evalúan medidas agregadas de error.

Dentro del proyecto, los modelos deberán superar tanto una evaluación cuantitativa de desempeño como una revisión de coherencia de sus explicaciones antes de incorporarse al sistema de recomendación.

6.18. Explicabilidad y sesgos algorítmicos

Los modelos de aprendizaje automático aprenden relaciones a partir de los datos disponibles. Cuando estos datos contienen desequilibrios, errores o patrones poco representativos, el algoritmo puede reproducirlos en sus resultados. La explicabilidad puede contribuir a identificar algunos comportamientos problemáticos, aunque no constituye por sí misma una garantía de ausencia de sesgo (Robles-Zambrano et al., 2026).

El análisis de importancia y contribución de variables puede revelar dependencias inesperadas y facilitar investigaciones posteriores. Sin embargo, detectar una característica influyente no permite concluir automáticamente que el modelo es justo o injusto.

La evaluación responsable requiere complementar XAI con análisis de calidad de datos, desempeño por grupos relevantes, estabilidad y criterios apropiados para el contexto de aplicación.

Esta precaución resulta importante para evitar presentar la explicabilidad como una solución automática para todos los problemas asociados con la

inteligencia artificial. XAI aumenta la capacidad de inspección del sistema, pero continúa requiriendo evaluación humana y metodológica.

6.19. Explicabilidad aplicada a la segmentación empresarial

La necesidad de explicación también alcanza a los modelos de aprendizaje no supervisado desarrollados en el capítulo anterior. Obtener varios clústeres carece de suficiente utilidad empresarial si los usuarios no comprenden qué características distinguen a cada segmento.

Después de ejecutar K-means, clustering jerárquico o DBSCAN, la plataforma deberá caracterizar los grupos mediante las variables que presentan valores diferenciadores. Este procedimiento permitirá transformar agrupaciones matemáticas en perfiles empresariales interpretables.

La explicación de los segmentos puede incluir valores promedio, distribuciones, indicadores representativos y variables que diferencien cada clúster. Las etiquetas deberán establecerse después de examinar estas características y no imponerse antes de ejecutar el algoritmo.

De esta manera, la segmentación podrá seguir una secuencia transparente:

Clúster → características predominantes → perfil interpretable → comportamiento esperado → posible estrategia diferenciada.

6.20. Explicabilidad aplicada a la analítica predictiva

En el componente predictivo, XAI permitirá complementar las estimaciones desarrolladas en el Capítulo 4. Cada predicción relevante podrá acompañarse de información sobre los principales factores que contribuyeron al resultado.



Una predicción de ventas, por ejemplo, podría presentarse junto con sus variables más influyentes, dirección de sus contribuciones, intervalo de predicción cuando corresponda y desempeño histórico del modelo.

Esta combinación evita transmitir una falsa sensación de certeza. El usuario podrá reconocer que la estimación constituye un resultado probabilístico o predictivo sujeto a error y que su explicación describe el comportamiento del modelo bajo la información disponible.

La integración de predicción y explicación fortalecerá la capacidad del gerente para contrastar los resultados del algoritmo con información contextual que posiblemente no se encuentre incorporada en la base de datos.

6.21. Explicabilidad de las recomendaciones estratégicas

Una recomendación empresarial generada mediante inteligencia artificial adquiere mayor utilidad cuando el usuario puede reconocer la evidencia que la sustenta. Una instrucción aislada puede resultar difícil de evaluar, mientras que una recomendación acompañada de su fundamento permite valorar su coherencia.

Por ello, el sistema propuesto deberá vincular cada recomendación con los resultados analíticos que participaron en su generación. Estos pueden incluir segmento empresarial, tendencia identificada, predicción, escenario y variables explicativas.

La lógica puede representarse mediante la secuencia:

Segmento → predicción → factores explicativos → escenario → recomendación → decisión humana.

Esta estructura permite diferenciar claramente una predicción de una recomendación. El modelo puede anticipar determinado comportamiento, mientras que el componente estratégico propone



alternativas que el responsable empresarial deberá valorar antes de actuar.

La explicabilidad también permitirá evitar recomendaciones genéricas. Cuando las alternativas se relacionan explícitamente con características del segmento y factores asociados con la predicción, pueden desarrollarse sugerencias mejor contextualizadas.

6.22. De los resultados algorítmicos al conocimiento empresarial

Los algoritmos producen resultados expresados mediante probabilidades, valores numéricos, distancias, clústeres, contribuciones y otras representaciones matemáticas. Para un sistema de apoyo gerencial, estos resultados necesitan transformarse en información comprensible y posteriormente en conocimiento susceptible de ser utilizado en una decisión (Lalama Freire, 2025).

La primera transformación ocurre cuando el resultado matemático se contextualiza. Una probabilidad se relaciona con un evento; un clúster se convierte en un perfil; una contribución se interpreta como influencia dentro del modelo; y una predicción se vincula con un período y una medida de incertidumbre.

La segunda transformación consiste en relacionar esta información con el problema empresarial. El usuario necesita comprender qué significa el resultado para ventas, clientes, demanda, competitividad u otra dimensión de gestión.

Finalmente, la información explicada puede vincularse con alternativas estratégicas. La plataforma no sustituye el conocimiento del gerente, sino que organiza evidencia analítica para facilitar su evaluación.

El proceso completo puede representarse de la siguiente forma:



DATOS → PATRONES → MODELO → RESULTADO → XAI → EXPLICACIÓN → CONOCIMIENTO EMPRESARIAL → ALTERNATIVAS ESTRATÉGICAS → DECISIÓN HUMANA.

6.23. Supervisión humana y decisión gerencial

La incorporación de explicabilidad permite establecer una relación más equilibrada entre inteligencia artificial y decisión humana. El sistema procesa información y proporciona estimaciones, mientras que el responsable empresarial incorpora experiencia, contexto, conocimiento del mercado y factores que pueden no encontrarse representados en los datos (Ortega Ovalle, 2026).

Este enfoque mantiene al gerente dentro del proceso de decisión. La plataforma actúa como mecanismo de apoyo analítico y no como sustituto automático de la responsabilidad empresarial.

La supervisión humana resulta especialmente importante cuando la recomendación presenta consecuencias significativas, existe elevada incertidumbre o las condiciones actuales difieren sustancialmente de los datos utilizados durante el entrenamiento.

Por ello, la arquitectura propuesta deberá permitir aceptar, cuestionar o descartar las recomendaciones y, cuando sea posible, registrar esta interacción como información útil para evaluar posteriormente la utilidad del sistema.

6.24. Arquitectura de Inteligencia Artificial Explicable propuesta

A partir de los fundamentos analizados, se propone integrar XAI mediante la siguiente arquitectura:

Datos empresariales → preparación de información → segmentación/modelo predictivo → validación → resultado algorítmico → SHAP/LIME → explicación global/local →

visualización → recomendación estratégica → evaluación gerencial → decisión.

La primera capa corresponde al procesamiento de datos y construcción de los modelos. En ella se desarrollan los componentes de segmentación y predicción previamente definidos.

La segunda capa corresponde a la explicabilidad. Dependiendo del algoritmo seleccionado, se aplicarán técnicas apropiadas para determinar la importancia y contribución de las variables.

La tercera capa transforma los resultados técnicos en información orientada al usuario. Esta fase incorpora visualizaciones, lenguaje empresarial y diferentes niveles de detalle.

La cuarta capa integra las explicaciones con el sistema de recomendaciones. Cada alternativa deberá conservar trazabilidad respecto de los resultados analíticos que contribuyeron a generarla.

La quinta capa corresponde a la decisión humana. El gerente o empresario recibe predicción, explicación y alternativas estratégicas, pero conserva la responsabilidad sobre la acción finalmente seleccionada.

6.25. Modelo de explicabilidad empresarial propuesto

Para operacionalizar XAI dentro de la plataforma se propone considerar seis dimensiones:

Transparencia: comunicar qué información y qué tipo de modelo intervienen en el proceso.

Interpretabilidad: facilitar la comprensión del comportamiento general del modelo.

Explicabilidad: proporcionar información sobre los factores asociados con predicciones específicas.



Trazabilidad: conservar evidencia del recorrido desde los datos hasta las recomendaciones.

Comprensibilidad: adaptar la presentación al conocimiento y necesidades del usuario empresarial.

Supervisión humana: mantener la evaluación y decisión final bajo responsabilidad de las personas.

Estas dimensiones permiten tratar la explicabilidad como una propiedad integral de la arquitectura y no simplemente como una visualización adicional incorporada al finalizar el desarrollo.

6.26. Integración de segmentación, predicción, XAI y recomendación

La propuesta desarrollada en los capítulos anteriores puede integrarse en una arquitectura analítica progresiva. La segmentación automatizada permite reconocer perfiles; la analítica predictiva estima comportamientos; XAI identifica los principales factores relacionados con esos resultados; y el módulo estratégico transforma la información en alternativas susceptibles de evaluación.

La integración puede expresarse mediante el siguiente flujo:

DATOS EMPRESARIALES

↓

SEGMENTACIÓN AUTOMATIZADA

↓

PERFILES EMPRESARIALES

↓

ANALÍTICA PREDICTIVA

↓

PREDICCIÓN + INCERTIDUMBRE

↓



XAI: SHAP / LIME

↓

EXPLICACIÓN DE VARIABLES Y PATRONES

↓

ESCENARIOS

↓

RECOMENDACIÓN ESTRATÉGICA

↓

DASHBOARD GERENCIAL

↓

EVALUACIÓN Y DECISIÓN HUMANA

Esta arquitectura permite que la inteligencia artificial no permanezca como una estructura tecnológica aislada. Cada resultado se conecta progresivamente con una explicación y posteriormente con información útil para la gestión.

6.27. Síntesis del capítulo

La Inteligencia Artificial Explicable constituye un componente relevante para desarrollar sistemas empresariales capaces de combinar capacidad predictiva con comprensión humana. Su propósito no consiste únicamente en simplificar algoritmos, sino en proporcionar mecanismos que permitan examinar y comunicar los factores asociados con sus resultados (Ortega Ovalle, 2026; Robles-Zambrano et al., 2026).

La necesidad de XAI aumenta cuando las organizaciones utilizan modelos complejos para apoyar decisiones estratégicas. Una predicción aislada informa sobre un posible resultado; una predicción explicada proporciona además elementos para comprender qué características contribuyeron al comportamiento del modelo (Lalama Freire, 2025).



SHAP y LIME constituyen técnicas relevantes dentro de este campo. SHAP permite analizar contribuciones de variables desde perspectivas locales y agregadas, mientras que LIME se orienta principalmente hacia aproximaciones interpretables alrededor de predicciones particulares. Ambas herramientas requieren una evaluación cuidadosa de estabilidad, fidelidad y utilidad para el usuario (Riccio Anastacio et al., 2025).

La explicabilidad también contribuye a la validación de los modelos, debido a que permite identificar variables inesperadamente influyentes y relaciones que requieren revisión. Sin embargo, una explicación algorítmica no debe confundirse con una demostración causal ni considerarse automáticamente una garantía de ausencia de sesgo.

La transparencia y trazabilidad complementan la dimensión técnica de XAI. Documentar modelos, datos, métricas, versiones y explicaciones permite comprender mejor la procedencia de los resultados y facilita su revisión posterior (Robles-Zambrano et al., 2026).

En el ámbito empresarial, las explicaciones deben diseñarse considerando las necesidades del usuario. Los gerentes y empresarios requieren información clara y vinculada con sus indicadores, evitando tanto una simplificación que elimine información relevante como una presentación excesivamente técnica que dificulte su utilización.

Dentro del proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, XAI funcionará como la capa que conecta los modelos algorítmicos con la comprensión gerencial. Los segmentos podrán caracterizarse, las predicciones podrán explicarse y las recomendaciones podrán mantener trazabilidad respecto de la evidencia que las originó.



En consecuencia, la propuesta no se limita a desarrollar una plataforma capaz de producir predicciones. Su arquitectura busca integrar **segmentación, predicción, explicabilidad y recomendación estratégica**, manteniendo al ser humano como responsable de la evaluación final. La inteligencia artificial aporta capacidad analítica; XAI contribuye a comprender sus resultados; y el conocimiento empresarial permite contextualizarlos antes de convertirlos en decisiones.



CAPÍTULO 7.

SISTEMAS INTELIGENTES DE RECOMENDACIÓN ESTRATÉGICA.

7.1. Inteligencia artificial y recomendación estratégica empresarial

La transformación digital ha incrementado significativamente la cantidad de información disponible para las organizaciones. Datos relacionados con clientes, ventas, demanda, productos, comportamiento comercial, operaciones y condiciones del mercado pueden ser procesados mediante herramientas analíticas para obtener conocimiento útil. Sin embargo, disponer de información o generar predicciones no garantiza que una empresa conozca qué acciones debe considerar frente a los resultados obtenidos. Esta necesidad ha favorecido el desarrollo de sistemas de recomendación capaces de filtrar información y presentar alternativas relevantes para apoyar procesos de decisión (Bron Fonseca & Mar Cornelio, 2022).

Los sistemas de recomendación constituyen mecanismos computacionales diseñados para seleccionar, ordenar o sugerir alternativas a partir de información relacionada con usuarios, elementos, preferencias, comportamientos y otros atributos disponibles. Aunque su utilización se ha extendido ampliamente en plataformas digitales para recomendar productos o contenidos, sus principios también pueden adaptarse a contextos empresariales donde el objeto recomendado no sea un producto, sino una posible acción estratégica (Guevara Fernandez & Coral Ygnacio, 2023).



Desde esta perspectiva, un sistema inteligente de recomendación estratégica puede concebirse como una arquitectura capaz de integrar información empresarial, resultados de segmentación, predicciones y conocimiento previamente estructurado para generar alternativas de actuación ajustadas a determinadas condiciones. Su finalidad no consiste en reemplazar al responsable empresarial, sino en reducir la complejidad informativa y proporcionar opciones fundamentadas que puedan ser evaluadas antes de tomar una decisión (Bron Fonseca & Mar Cornelio, 2022).

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, el sistema recomendador representa la etapa que conecta los resultados analíticos con posibles acciones. Los segmentos identificados, las predicciones generadas y sus respectivas explicaciones constituyen entradas que permitirán producir recomendaciones diferenciadas de acuerdo con la situación observada en cada empresa.

7.2. De la analítica descriptiva a la prescriptiva

La evolución de la analítica empresarial puede comprenderse mediante diferentes niveles de utilización de los datos. La analítica descriptiva permite conocer acontecimientos pasados; la analítica diagnóstica intenta identificar factores relacionados con esos resultados; la analítica predictiva estima posibles comportamientos futuros; y la analítica prescriptiva incorpora un nivel adicional al analizar qué acciones podrían considerarse frente a determinados escenarios (Schab et al., 2020).



Esta evolución no implica que un nivel sustituya a los anteriores. La prescripción necesita información descriptiva para comprender la situación inicial y resultados predictivos para anticipar posibles comportamientos. Su principal diferencia radica en que incorpora alternativas de actuación, restricciones y objetivos para transformar conocimiento analítico en información orientada hacia la decisión (Schab et al., 2020).

En términos empresariales, un sistema descriptivo podría señalar que las ventas disminuyeron durante los últimos meses; un modelo predictivo podría estimar que esta tendencia continuará durante el período siguiente; mientras que un componente prescriptivo analizaría alternativas que podrían considerarse ante dicho escenario. Esta transición representa el paso desde conocer y anticipar hacia apoyar la selección de posibles cursos de acción (Schab et al., 2020).

Por ello, la recomendación estratégica propuesta en esta investigación se sitúa conceptualmente dentro de una lógica prescriptiva. La plataforma no deberá limitarse a mostrar indicadores o predicciones, sino relacionar los resultados obtenidos con alternativas estratégicas pertinentes para cada condición empresarial.

7.3. De la predicción a la recomendación

La predicción y la recomendación representan funciones diferentes dentro de una arquitectura inteligente. Un modelo predictivo estima el comportamiento esperado de una variable utilizando patrones identificados en información histórica, mientras que un sistema de

recomendación selecciona o prioriza alternativas que pueden resultar pertinentes considerando determinados datos, preferencias o condiciones (Bron Fonseca & Mar Cornelio, 2022).

Esta diferencia resulta fundamental para evitar que una predicción sea interpretada directamente como una estrategia. Predecir una reducción de ventas no determina automáticamente cuál debe ser la respuesta empresarial. Antes de recomendar una acción resulta necesario considerar el segmento al que pertenece la empresa, las variables relacionadas con la predicción, sus recursos, condiciones comerciales y posibles restricciones.

El sistema propuesto utilizará, por tanto, los resultados predictivos como una de las entradas del motor de recomendación. Las predicciones proporcionarán información sobre comportamientos esperados y el sistema recomendador relacionará esa información con alternativas estratégicas previamente definidas, aprendidas o derivadas de diferentes fuentes de conocimiento.

La secuencia conceptual puede representarse de la siguiente manera:
Predicción → explicación → contexto empresarial → alternativas → priorización → recomendación → evaluación humana.
Esta estructura evita confundir la capacidad predictiva con la prescriptiva y mantiene una separación metodológica entre anticipar un comportamiento y sugerir posibles respuestas empresariales (Schab et al., 2020).



7.4. Sistemas de recomendación como apoyo a la toma de decisiones

Los sistemas recomendadores surgieron como mecanismos para gestionar situaciones en las cuales el volumen de alternativas disponibles dificulta que el usuario identifique aquellas que presentan mayor relevancia. Su funcionamiento permite filtrar información y reducir el conjunto de opciones, proporcionando elementos seleccionados de acuerdo con determinadas características o preferencias (Bron Fonseca & Mar Cornelio, 2022).

La utilidad de estos sistemas puede extenderse hacia los procesos de decisión empresarial. En este contexto, el problema no consiste necesariamente en seleccionar un producto, sino en identificar cuáles acciones presentan mayor pertinencia frente a una situación determinada. El motor de recomendación puede procesar diferentes evidencias y generar una lista priorizada de alternativas.

La literatura científica reconoce diferentes aproximaciones para construir sistemas recomendadores, entre ellas técnicas basadas en contenido, conocimiento, comportamiento de usuarios y combinaciones híbridas. Cada metodología utiliza diferentes fuentes de información y presenta ventajas y limitaciones particulares (Guevara Fernandez & Coral Ygnacio, 2023).

En la plataforma propuesta, esta lógica será adaptada hacia la recomendación estratégica. El sistema analizará características empresariales y resultados algorítmicos para seleccionar estrategias potencialmente compatibles con las condiciones identificadas.



7.5. Motores inteligentes de recomendación

Un motor de recomendación puede entenderse como el componente encargado de procesar información disponible y establecer un orden de relevancia entre diferentes alternativas. Para ello puede utilizar reglas, similitudes, perfiles, patrones históricos o modelos de aprendizaje automático, dependiendo de la arquitectura implementada (Salgado Reyes & Trujillo Moreno, 2024).

El funcionamiento general comprende tres componentes fundamentales: información de entrada, mecanismo de recomendación y resultados. Las entradas pueden incluir características del usuario o empresa, comportamientos anteriores, información contextual y atributos de las alternativas; el algoritmo procesa estas características y genera posteriormente un conjunto de recomendaciones ordenadas.

En aplicaciones empresariales, el motor puede incorporar información procedente de diferentes componentes analíticos. El segmento identificado mediante clustering, la predicción de ventas, los factores explicativos obtenidos mediante XAI y determinados indicadores de desempeño pueden actuar conjuntamente como entradas para generar recomendaciones.

Esta integración convierte al motor recomendador en un componente articulador dentro de la plataforma. Su función consiste en transformar diferentes resultados analíticos en alternativas comprensibles que puedan ser evaluadas por el usuario empresarial.

7.6. Sistemas de recomendación basados en reglas

Los sistemas basados en reglas representan una aproximación particularmente útil cuando existe conocimiento explícito sobre las condiciones que justifican determinadas recomendaciones. Su funcionamiento puede estructurarse mediante relaciones del tipo **SI condición → ENTONCES recomendación**, permitiendo vincular situaciones identificables con alternativas previamente definidas. Las reglas pueden construirse utilizando conocimiento especializado, evidencia científica, políticas empresariales o combinaciones de indicadores. Esta estructura proporciona un alto nivel de trazabilidad porque resulta posible determinar qué condición produjo una determinada recomendación.

En el contexto del proyecto, una regla podría establecer que cuando una empresa pertenece a determinado segmento, presenta una disminución persistente de ventas y determinados indicadores muestran deterioro, el sistema debe evaluar un conjunto específico de alternativas estratégicas. La recomendación no dependería de una única variable, sino de una combinación previamente establecida.

Una ventaja importante de esta metodología reside en su interpretabilidad. El usuario puede conocer cuáles condiciones activaron la recomendación, facilitando la conexión con la capa XAI desarrollada en el capítulo anterior.

Sin embargo, un sistema exclusivamente basado en reglas puede presentar limitaciones cuando aumenta considerablemente el número de



variables y combinaciones posibles. Por ello, en aplicaciones complejas resulta pertinente complementar este enfoque con mecanismos de aprendizaje automático o arquitecturas híbridas (Bron Fonseca & Mar Cornelio, 2022).

7.7. Recomendación basada en contenido

Los sistemas basados en contenido generan recomendaciones utilizando características de los elementos y perfiles asociados con las preferencias o necesidades del usuario. La lógica consiste en identificar alternativas cuyas características presenten correspondencia con aquellas consideradas relevantes para un determinado perfil (Guevara Fernandez & Coral Ygnacio, 2023).

Trasladado al ámbito empresarial, el "contenido" puede estar representado por atributos de las estrategias. Una alternativa puede caracterizarse según su finalidad, área funcional, recursos requeridos, horizonte temporal, nivel de inversión, tipo de empresa y problema que busca abordar.

Paralelamente, cada empresa puede disponer de un perfil generado a partir de sus características, segmento, indicadores y predicciones. El motor puede comparar el perfil empresarial con los atributos de las estrategias y establecer cuáles presentan mayor correspondencia. Esta aproximación resulta especialmente interesante para la investigación porque no exige que exista una gran cantidad de empresas que hayan utilizado previamente la plataforma. Las recomendaciones pueden



comenzar a generarse a partir de las características de las estrategias y del perfil de cada organización.

No obstante, los modelos basados en contenido pueden tender a recomendar alternativas semejantes a las ya consideradas compatibles con el perfil, reduciendo potencialmente la diversidad de opciones. Esta limitación constituye una de las razones para evaluar mecanismos híbridos (Guevara Fernandez & Coral Ygnacio, 2023).

7.8. Sistemas basados en conocimiento

Los sistemas recomendadores basados en conocimiento utilizan información explícita acerca del dominio, necesidades del usuario y características de las alternativas para establecer relaciones entre problemas y posibles soluciones. Este enfoque resulta especialmente útil cuando no existe suficiente historial de interacciones para utilizar técnicas basadas exclusivamente en comportamiento previo (Bron Fonseca & Mar Cornelio, 2022).

En la recomendación estratégica empresarial, el conocimiento puede representarse mediante relaciones entre situaciones empresariales y posibles acciones. Por ejemplo, determinadas características de demanda, comportamiento de clientes o desempeño comercial pueden relacionarse con diferentes familias de estrategias.

El conocimiento incorporado debe estar sustentado y mantenerse actualizado. Una recomendación no debería establecerse únicamente porque parece intuitivamente razonable, sino porque existe una



justificación empresarial, científica o analítica que permita defender su pertinencia.

Dentro del proyecto, este componente permitirá construir una **base de conocimiento estratégico** que relacione perfiles, indicadores, predicciones y acciones. Esta base constituirá uno de los recursos principales del motor recomendador.

7.9. Sistemas híbridos de recomendación

Los sistemas híbridos combinan diferentes mecanismos de recomendación con el propósito de aprovechar sus fortalezas y reducir algunas de sus limitaciones individuales. La literatura identifica la hibridación como una estrategia relevante para integrar diferentes fuentes de información y mejorar la pertinencia de las sugerencias (Guevara Fernandez & Coral Ygnacio, 2023).

Una arquitectura híbrida puede combinar reglas empresariales con modelos basados en contenido y técnicas de aprendizaje automático. Las reglas proporcionan control y trazabilidad, mientras que los modelos basados en datos permiten adaptar progresivamente las recomendaciones conforme aumenta la información disponible.

Para la plataforma propuesta, el enfoque híbrido resulta particularmente adecuado. En las primeras etapas, cuando existe un volumen limitado de interacciones históricas, las recomendaciones pueden apoyarse principalmente en reglas, perfiles y contenido estratégico.



Posteriormente, la retroalimentación de los usuarios permitirá incorporar patrones derivados de experiencias anteriores.

De esta forma, la arquitectura no dependerá completamente de un único algoritmo. El motor podrá combinar diferentes fuentes de evidencia y asignar mayor o menor importancia a cada una dependiendo de la disponibilidad y calidad de la información.

7.10. Recomendación contextual

Una misma estrategia no necesariamente resulta pertinente en todas las situaciones. La recomendación contextual busca incorporar información adicional relacionada con las condiciones específicas bajo las cuales se genera una sugerencia, permitiendo aumentar su grado de personalización.

En un entorno empresarial, el contexto puede incluir sector económico, tamaño de la organización, comportamiento reciente de ventas, temporada, nivel de digitalización, recursos disponibles, situación de la demanda y otras variables relevantes para la decisión.

La incorporación del contexto permite diferenciar entre empresas que podrían pertenecer al mismo segmento, pero enfrentar situaciones coyunturales distintas. Una recomendación que resulta apropiada durante un período de crecimiento puede no ser igualmente pertinente cuando existe reducción de demanda.



Por ello, la arquitectura propuesta deberá considerar el contexto como una capa adicional del proceso. La recomendación final no dependerá únicamente del perfil histórico, sino también de las condiciones actuales identificadas mediante los indicadores y modelos analíticos.

7.11. Segmentación como base para la personalización

La segmentación automatizada desarrollada en el Capítulo 5 proporciona una estructura especialmente útil para personalizar recomendaciones. Los clústeres identifican grupos con características semejantes y permiten construir perfiles diferenciados que posteriormente pueden utilizarse como entrada del sistema recomendador.

La personalización por segmentos evita aplicar las mismas estrategias a todas las organizaciones. Dos empresas pueden presentar problemas aparentemente similares, pero pertenecer a perfiles distintos y disponer de capacidades diferentes para implementar una determinada acción.
Cada segmento puede asociarse inicialmente con un conjunto de estrategias potencialmente pertinentes. Posteriormente, el contexto y las predicciones permitirán realizar una selección más específica dentro de ese conjunto.

Esta integración permite construir una recomendación multinivel:
Segmento → perfil → situación actual → predicción → recomendación personalizada.



El enfoque combina aprendizaje no supervisado, analítica predictiva y sistemas de recomendación dentro de una misma arquitectura de apoyo a decisiones.

7.12. Generación automatizada de estrategias

La generación automatizada de estrategias debe diferenciarse de la generación libre de instrucciones. En un sistema empresarial responsable, las recomendaciones deberían construirse a partir de alternativas previamente estructuradas, evidencia disponible y condiciones verificables.

Una estrategia puede representarse mediante diferentes atributos: objetivo, problema al que responde, segmento aplicable, requisitos, recursos necesarios, horizonte temporal, indicadores de seguimiento y posibles restricciones. Esta representación permite que el motor compare sistemáticamente alternativas.

El sistema puede generar una recomendación seleccionando y combinando acciones compatibles con el perfil y las condiciones detectadas. La automatización no implica que la estrategia deba ejecutarse sin revisión; significa que el algoritmo reduce el espacio de búsqueda y presenta opciones potencialmente pertinentes.

Esta aproximación mantiene la responsabilidad empresarial en manos del usuario. La inteligencia artificial organiza y prioriza alternativas, mientras que el gerente determina si resultan compatibles con las condiciones reales de la organización.



7.13. Base de conocimiento estratégico

Para que el sistema pueda recomendar estrategias de manera estructurada resulta necesario disponer de una base de conocimiento. Esta deberá almacenar las alternativas disponibles junto con información suficiente para determinar cuándo pueden resultar pertinentes.

Cada estrategia podría contener atributos relacionados con área empresarial, objetivo, problema, segmento, nivel de recursos, horizonte temporal, indicadores y condiciones de aplicación. Esta estructura facilitará la comparación automática entre necesidades y alternativas.
La base de conocimiento deberá ser dinámica. Las estrategias pueden modificarse, nuevas evidencias pueden incorporarse y determinadas recomendaciones pueden demostrar mayor o menor utilidad con el tiempo.

La actualización sistemática evitará que el motor permanezca limitado a un conjunto estático de acciones y permitirá incorporar conocimiento derivado tanto de literatura especializada como de la experiencia acumulada durante la utilización de la plataforma.

7.14. Personalización de recomendaciones

La personalización constituye una característica fundamental de los sistemas recomendadores contemporáneos. Su propósito consiste en evitar que todos los usuarios reciban exactamente las mismas sugerencias, adaptando los resultados a características y necesidades particulares (Salgado Reyes & Trujillo Moreno, 2024).



En el ámbito empresarial, personalizar implica reconocer que las organizaciones presentan diferencias en recursos, mercados, clientes, nivel tecnológico, desempeño y capacidad para implementar estrategias. Estas características deben incorporarse al proceso de recomendación.
La plataforma podrá utilizar los perfiles derivados del clustering y combinarlos con indicadores actuales para construir una representación individual de cada empresa. Las estrategias posteriormente serán evaluadas según su compatibilidad con dicho perfil.

Este enfoque permitirá avanzar desde recomendaciones generales hacia alternativas diferenciadas, aumentando potencialmente su utilidad para micro y pequeñas empresas con condiciones heterogéneas.

7.15. Priorización inteligente de acciones

Un sistema de recomendación estratégica puede identificar múltiples acciones potencialmente pertinentes. Sin embargo, presentar una cantidad excesiva de alternativas puede trasladar nuevamente al usuario el problema de sobrecarga de información que el sistema pretende resolver (Bron Fonseca & Mar Cornelio, 2022).

Por esta razón, resulta necesario incorporar mecanismos de priorización. Cada estrategia puede recibir una puntuación calculada a partir de diferentes criterios como compatibilidad con el segmento, relación con la predicción, urgencia, recursos requeridos, factibilidad y evidencia disponible.



La priorización no debe interpretarse como una orden automática. Su finalidad consiste en organizar las alternativas para que el usuario pueda concentrarse inicialmente en aquellas que presentan mayor correspondencia con las condiciones analizadas.

La plataforma deberá mostrar los factores que contribuyeron al posicionamiento de cada recomendación. De esta manera, la priorización permanecerá conectada con los principios de explicabilidad y transparencia desarrollados en el Capítulo 6.

7.16. Recomendación estratégica explicable

La recomendación estratégica debe ser explicable para que el usuario pueda comprender por qué una alternativa fue seleccionada. Una recomendación sin justificación puede producir aceptación automática o rechazo, mientras que una explicación proporciona elementos para evaluarla.

La explicación puede integrar información sobre el segmento, indicadores relevantes, predicción, variables influyentes y reglas activadas. Esto permite reconstruir el razonamiento analítico que condujo hasta la alternativa sugerida.

Por ejemplo, la plataforma podría presentar una recomendación acompañada de una estructura como:

Situación identificada: disminución prevista de ventas.
Perfil: segmento empresarial determinado.



Factores principales: variables identificadas mediante XAI.

Alternativa sugerida: estrategia compatible con dichas condiciones.

Prioridad: calculada según pertinencia y factibilidad.

Esta estructura mantiene continuidad entre la Inteligencia Artificial Explicable y el sistema recomendador, evitando que la recomendación aparezca como una conclusión aislada.

7.17. Priorización multicriterio

Las decisiones empresariales suelen involucrar diferentes criterios que pueden entrar en conflicto. Una estrategia puede presentar elevada utilidad potencial, pero requerir recursos considerables; otra puede ofrecer un impacto más limitado, pero resultar inmediatamente factible.

Por ello, la priorización puede incorporar una lógica multicriterio. Factores como impacto esperado, urgencia, costo, recursos disponibles, complejidad, horizonte temporal y compatibilidad con el segmento pueden utilizarse para construir una valoración conjunta.

La ponderación de estos criterios debe ser transparente y ajustable cuando sea necesario. Diferentes empresas pueden otorgar distinta importancia a liquidez, crecimiento, reducción de costos o captación de clientes.

La incorporación de criterios explícitos permitirá que el motor de recomendación no dependa exclusivamente de similitudes estadísticas, sino que integre condiciones relacionadas con la realidad de implementación de las estrategias.



7.18. Escenarios y recomendación estratégica

La recomendación puede enriquecerse mediante la evaluación de escenarios desarrollada dentro del componente predictivo. En lugar de utilizar únicamente una predicción central, el sistema puede analizar diferentes condiciones posibles y asociar alternativas específicas con cada una.

Un escenario favorable puede requerir estrategias orientadas a aprovechar crecimiento, mientras que un escenario adverso puede justificar acciones relacionadas con protección de liquidez, optimización de recursos o retención de clientes.

La recomendación basada en escenarios permite evitar que el sistema presente una única estrategia como si el futuro estuviera completamente determinado. Las alternativas pueden organizarse condicionalmente según diferentes comportamientos posibles.

De esta manera, la plataforma podrá comunicar: **si se mantiene el escenario base, estas acciones presentan mayor pertinencia; si se materializa un escenario adverso, deben evaluarse estas otras alternativas**. Este enfoque fortalece la planificación bajo incertidumbre.

7.19. Retroalimentación del usuario

Los sistemas inteligentes pueden mejorar cuando disponen de información sobre la respuesta de los usuarios a las recomendaciones. La retroalimentación permite conocer si una sugerencia fue considerada



pertinente, aceptada, descartada o aplicada (Salgado Reyes & Trujillo Moreno, 2024).

Dentro de la plataforma, el empresario podría valorar las recomendaciones mediante mecanismos sencillos. Esta información no debe utilizarse automáticamente como prueba de efectividad, pero constituye una señal relevante sobre la utilidad percibida.

También puede registrarse la decisión adoptada. Si el usuario selecciona una estrategia diferente a la primera recomendación, esta interacción proporciona información que puede utilizarse posteriormente para revisar el mecanismo de priorización.

La retroalimentación convierte al sistema en una arquitectura interactiva. En lugar de producir recomendaciones de manera unilateral, la plataforma incorpora la respuesta humana como nueva información para evaluar y mejorar su comportamiento.

7.20. Aprendizaje continuo

El aprendizaje continuo representa la capacidad del sistema para actualizar progresivamente sus mecanismos utilizando nueva información. Los entornos empresariales son dinámicos y una estrategia que resulta pertinente bajo determinadas condiciones puede perder relevancia cuando cambian los mercados o el comportamiento de los clientes. La plataforma deberá registrar nuevas observaciones, resultados predictivos, recomendaciones presentadas y retroalimentación recibida. Esta información permitirá evaluar periódicamente el desempeño del



motor. Sin embargo, aprendizaje continuo no significa modificar automáticamente las reglas después de cada interacción. Las actualizaciones deben someterse a mecanismos de validación para evitar que información insuficiente o decisiones particulares produzcan cambios inestables.

Por ello, se propone una lógica de actualización periódica y supervisada. Los datos acumulados podrán utilizarse para recalibrar puntuaciones, revisar reglas y evaluar nuevas relaciones, manteniendo trazabilidad sobre las modificaciones realizadas.

7.21. Evaluación del sistema recomendador

La calidad de un sistema recomendador no debe evaluarse únicamente mediante precisión matemática. También es necesario considerar si las recomendaciones resultan pertinentes, diversas, comprensibles y útiles para los usuarios. La literatura señala que la evaluación de sistemas recomendadores puede incorporar diferentes dimensiones según la finalidad de la aplicación (Guevara Fernandez & Coral Ygnacio, 2023).
En el contexto empresarial, una recomendación puede considerarse técnicamente compatible con un perfil pero resultar difícil de implementar debido a restricciones que el modelo no conoce. La evaluación humana continúa siendo indispensable.

El proyecto puede incorporar indicadores relacionados con aceptación de recomendaciones, utilidad percibida, frecuencia de utilización y correspondencia entre estrategias sugeridas y condiciones empresariales. Estos resultados permitirán complementar la evaluación algorítmica.



Posteriormente, cuando exista suficiente información longitudinal, también podrá analizarse la relación entre recomendaciones aplicadas y evolución de determinados indicadores empresariales, manteniendo cautela respecto de la atribución causal.

7.22. Recomendación y supervisión humana

La automatización de recomendaciones no implica automatización completa de las decisiones. La plataforma propuesta debe funcionar como un sistema de apoyo que organiza información, identifica alternativas y proporciona evidencia, mientras que la decisión final corresponde al responsable empresarial.

La intervención humana permite incorporar conocimiento contextual que puede no encontrarse representado en los datos. Cambios regulatorios, acontecimientos locales, restricciones financieras o decisiones internas pueden modificar la conveniencia de una estrategia.

Por ello, el usuario deberá poder aceptar, modificar, posponer o descartar las recomendaciones. Esta interacción mantiene el principio de supervisión humana establecido en la arquitectura XAI.

El sistema inteligente funciona, así como un **copiloto analítico para la gestión empresarial**, proporcionando conocimiento procesado sin sustituir la responsabilidad del gerente o empresario.

7.23. Arquitectura propuesta del sistema inteligente de recomendación

A partir de los fundamentos desarrollados, el sistema recomendador del proyecto puede estructurarse mediante la siguiente arquitectura:



DATOS EMPRESARIALES

↓

SEGMENTACIÓN AUTOMATIZADA

↓

PERFIL EMPRESARIAL

↓

ANALÍTICA PREDICTIVA

↓

PREDICCIÓN + INCERTIDUMBRE

↓

XAI: EXPLICACIÓN DE FACTORES

↓

CONTEXTO EMPRESARIAL

↓

BASE DE CONOCIMIENTO ESTRATÉGICO

↓

MOTOR HÍBRIDO DE RECOMENDACIÓN

↓

PRIORIZACIÓN DE ALTERNATIVAS

↓

RECOMENDACIÓN EXPLICABLE

↓

DASHBOARD GERENCIAL

↓

DECISIÓN HUMANA

↓

RETROALIMENTACIÓN



↓

APRENDIZAJE Y ACTUALIZACIÓN

Esta arquitectura representa la integración de los componentes desarrollados progresivamente en los capítulos anteriores. La segmentación determina perfiles, la analítica predictiva anticipa comportamientos, XAI explica los factores asociados y el sistema recomendador transforma estos resultados en alternativas estratégicas.

7.24. Modelo conceptual de recomendación estratégica

El modelo conceptual propuesto puede sintetizarse mediante seis dimensiones: **perfil, predicción, contexto, conocimiento, priorización y retroalimentación**.

El **perfil** representa las características particulares de la empresa y su segmento; la **predicción** proporciona información prospectiva; el **contexto** incorpora las condiciones actuales; el **conocimiento** contiene las estrategias y reglas disponibles; la **priorización** ordena las alternativas; y la **retroalimentación** proporciona información para evaluar posteriormente el comportamiento del sistema.

La interacción de estas dimensiones permite evitar recomendaciones genéricas. Cada sugerencia será el resultado de combinar diferentes fuentes de evidencia y no únicamente de aplicar una regla aislada.

La estructura propuesta también favorece la trazabilidad. El usuario podrá conocer qué características de su empresa, qué predicciones y qué criterios participaron en la selección de una estrategia.



7.25. De la inteligencia predictiva a la inteligencia estratégica

La integración de los componentes desarrollados permite avanzar progresivamente desde el procesamiento de datos hacia un sistema de apoyo estratégico. La segmentación identifica estructuras, la predicción anticipa comportamientos, XAI proporciona explicaciones y el sistema recomendador organiza alternativas de actuación.

Esta evolución puede representarse conceptualmente mediante cuatro niveles:

INTELIGENCIA DESCRIPTIVA: ¿qué está ocurriendo?

INTELIGENCIA PREDICTIVA: ¿qué podría ocurrir?

INTELIGENCIA EXPLICABLE: ¿qué factores están relacionados con el resultado del modelo?

INTELIGENCIA PRESCRIPTIVA: ¿qué alternativas podrían considerarse?

La integración de estos niveles proporciona una estructura más completa para apoyar decisiones empresariales. Ninguna etapa funciona de manera aislada; cada una proporciona información utilizada por el componente siguiente (Schab et al., 2020).

7.26. Aplicación a micro y pequeñas empresas

La recomendación estratégica puede resultar especialmente útil para micro y pequeñas empresas que no siempre disponen de departamentos especializados en analítica o planificación. Una plataforma capaz de sintetizar datos y presentar alternativas puede facilitar el acceso a herramientas analíticas que tradicionalmente requieren conocimientos técnicos especializados.



Sin embargo, las recomendaciones deben considerar las restricciones propias de estas organizaciones. Estrategias que requieren inversiones elevadas o capacidades tecnológicas avanzadas pueden resultar poco factibles para determinados perfiles empresariales.

Por esta razón, la base de conocimiento deberá incluir atributos de factibilidad y recursos. La plataforma podrá priorizar estrategias compatibles con las capacidades del segmento y evitar presentar sistemáticamente alternativas que se encuentren fuera de sus posibilidades.

Esta característica refuerza la importancia de integrar segmentación y recomendación. La personalización no debe limitarse al comportamiento comercial, sino considerar también la capacidad real de implementación de las empresas.

7.27. Síntesis del capítulo

Los sistemas inteligentes de recomendación representan una evolución desde el análisis de información hacia la generación estructurada de alternativas. Su utilidad reside en reducir la sobrecarga informativa, identificar opciones relevantes y apoyar a los usuarios durante procesos de decisión (Bron Fonseca & Mar Cornelio, 2022).

La transición desde predicción hacia prescripción constituye uno de los fundamentos del modelo propuesto. La analítica predictiva permite estimar posibles comportamientos, mientras que la dimensión prescriptiva incorpora alternativas de actuación relacionadas con dichos resultados (Schab et al., 2020).

Los motores de recomendación pueden construirse mediante diferentes enfoques. Los sistemas basados en contenido utilizan características de perfiles y alternativas; los sistemas basados en conocimiento establecen relaciones entre necesidades y soluciones; y los modelos híbridos combinan diferentes mecanismos para aprovechar fuentes complementarias de información (Guevara Fernandez & Coral Ygnacio, 2023).

La recomendación contextual permite incorporar condiciones específicas existentes en el momento de generar la sugerencia. Esta característica resulta particularmente relevante en entornos empresariales dinámicos, donde una misma estrategia puede presentar distinta pertinencia dependiendo del segmento, período, recursos y comportamiento esperado.

La segmentación automatizada proporciona una base para personalizar las recomendaciones. Los perfiles identificados mediante aprendizaje no supervisado permiten establecer conjuntos diferenciados de alternativas y evitar estrategias homogéneas para organizaciones que presentan características distintas.

La priorización permite ordenar las acciones potencialmente pertinentes mediante criterios relacionados con compatibilidad, urgencia, impacto y factibilidad. Este procedimiento debe mantenerse transparente para que el usuario comprenda por qué una alternativa aparece antes que otra.
La retroalimentación permite incorporar la respuesta de los usuarios y evaluar progresivamente la utilidad del sistema. Su integración con



mecanismos de actualización controlada proporciona las bases para desarrollar aprendizaje continuo sin renunciar a la validación y supervisión humana.

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, el sistema recomendador constituye la capa que transforma los resultados analíticos en alternativas orientadas hacia la gestión. Su funcionamiento integra perfil empresarial, predicción, explicabilidad, contexto y conocimiento estratégico.

En consecuencia, la propuesta completa puede sintetizarse mediante la secuencia:
DATOS → SEGMENTACIÓN → PREDICCIÓN → EXPLICACIÓN → CONTEXTO → RECOMENDACIÓN → PRIORIZACIÓN → DECISIÓN HUMANA → RETROALIMENTACIÓN → APRENDIZAJE.

Esta arquitectura permite evolucionar desde una plataforma que únicamente analiza información hacia un sistema inteligente capaz de generar conocimiento y alternativas estratégicas personalizadas. La inteligencia artificial no sustituye la decisión del gerente o empresario; proporciona evidencia, organiza alternativas y facilita que las acciones puedan evaluarse de manera más informada.



CAPÍTULO 8.

ANALÍTICA PRESCRIPTIVA Y SIMULACIÓN DE ESCENARIOS COMPETITIVOS.

8.1. Analítica prescriptiva en la gestión empresarial

La transformación digital ha incrementado la capacidad de las organizaciones para utilizar información histórica y actual como soporte de sus procesos gerenciales. En este contexto, la analítica empresarial ha evolucionado desde la descripción de acontecimientos hacia modelos capaces de anticipar comportamientos y evaluar posibles cursos de acción. La analítica prescriptiva representa una etapa orientada a vincular datos, predicciones, restricciones, objetivos y alternativas para apoyar decisiones empresariales de mayor complejidad (Schab et al., 2020; Santos Samaniego et al., 2025).

La característica diferenciadora de la analítica prescriptiva consiste en que no se limita a indicar qué ocurrió o qué podría suceder. Su finalidad es analizar alternativas frente a diferentes condiciones y proporcionar información que permita determinar cuáles acciones presentan mayor correspondencia con los objetivos establecidos. Para ello puede integrar técnicas de optimización, simulación, inteligencia artificial y análisis de decisiones (Schab et al., 2020).

Esta perspectiva resulta especialmente relevante en entornos empresariales caracterizados por incertidumbre, restricciones presupuestarias, cambios en la demanda y múltiples alternativas

estratégicas. En estas circunstancias, una decisión no depende únicamente de identificar el escenario más probable, sino también de analizar qué acciones podrían producir resultados aceptables bajo diferentes condiciones (Rodríguez Tejada et al., 2020).

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, la analítica prescriptiva constituye la capa que permitirá relacionar los resultados generados por los componentes anteriores con escenarios y alternativas de actuación. Su función será apoyar al empresario en la comparación de opciones antes de adoptar una decisión.

8.2. De la predicción a la prescripción

La analítica predictiva y la prescriptiva cumplen funciones complementarias. Mientras la primera utiliza patrones históricos para estimar posibles comportamientos futuros, la segunda incorpora objetivos, restricciones y alternativas para analizar qué acciones podrían considerarse frente a los resultados anticipados. La prescripción utiliza, por tanto, información predictiva como uno de sus insumos, pero amplía el análisis hacia el terreno de la decisión (Schab et al., 2020; Santos Samaniego et al., 2025).

Por ejemplo, un modelo predictivo puede anticipar una reducción de la demanda para un determinado período. La analítica prescriptiva incorpora preguntas adicionales: ¿qué alternativas podrían evaluarse?, ¿qué ocurriría si se modifica una variable controlable?, ¿qué estrategia



requiere menos recursos?, ¿cuál presenta mayor compatibilidad con las restricciones existentes? y ¿qué riesgos acompañan a cada alternativa? (Schab et al., 2020).

Esta transición resulta fundamental para la arquitectura propuesta porque evita considerar la predicción como una decisión. Un algoritmo puede estimar que determinado acontecimiento posee una probabilidad elevada, pero esta información no establece automáticamente cuál es la acción empresarial apropiada. La decisión requiere incorporar contexto, restricciones, objetivos y criterios de valoración (Rodríguez Tejada et al., 2020).

Por consiguiente, la plataforma propuesta seguirá una secuencia analítica progresiva: **comprender → anticipar → explicar → recomendar → simular → evaluar → decidir**. Cada nivel proporciona información adicional sin sustituir la responsabilidad del gerente o empresario sobre la decisión final.

8.3. Optimización empresarial basada en datos

La optimización empresarial consiste en buscar configuraciones o alternativas que permitan mejorar el cumplimiento de determinados objetivos considerando simultáneamente las restricciones existentes. Desde la perspectiva de la analítica prescriptiva, los datos permiten representar con mayor precisión el problema, mientras que los modelos matemáticos facilitan evaluar posibles combinaciones de decisiones (Schab et al., 2020).



Los problemas empresariales pueden involucrar objetivos relacionados con ventas, costos, rentabilidad, inventarios, utilización de recursos, satisfacción de clientes o eficiencia. Sin embargo, estos objetivos pueden encontrarse condicionados por restricciones presupuestarias, disponibilidad de personal, capacidad productiva, tiempo, demanda o recursos tecnológicos (Santos Samaniego et al., 2025).

La optimización no debe interpretarse únicamente como la búsqueda de un máximo o mínimo matemático. En aplicaciones empresariales, una alternativa óptima desde un criterio cuantitativo puede resultar poco factible cuando se consideran condiciones organizacionales no representadas completamente en el modelo. Por esta razón, los resultados deben analizarse conjuntamente con criterios empresariales y conocimiento contextual (Rodríguez Tejada et al., 2020).

En el proyecto, la optimización podrá incorporarse al sistema recomendador mediante funciones de priorización. Las alternativas estratégicas podrán evaluarse considerando diferentes objetivos y restricciones, proporcionando al usuario una lista organizada de acciones potencialmente compatibles con su situación.

8.4. Formulación de objetivos y restricciones

Todo problema prescriptivo requiere establecer claramente qué se pretende mejorar. La formulación del objetivo constituye una fase crítica porque determina qué resultados serán considerados deseables por el modelo. Una empresa puede priorizar crecimiento de ventas, reducción



de costos, aumento de clientes, eficiencia en inventarios o combinaciones de diferentes metas (Schab et al., 2020).

Las restricciones representan las condiciones que delimitan el conjunto de alternativas factibles. Una estrategia puede resultar atractiva desde el punto de vista comercial y, simultáneamente, ser inviable debido a limitaciones financieras, tecnológicas, temporales o de capacidad operativa (Santos Samaniego et al., 2025).

Incorporar explícitamente estas restricciones permite evitar recomendaciones desconectadas de la realidad empresarial. En micro y pequeñas empresas esta consideración resulta particularmente importante porque la disponibilidad de recursos puede determinar la posibilidad efectiva de implementar una estrategia.

La arquitectura propuesta deberá permitir que determinadas restricciones sean configurables. Presupuesto disponible, horizonte temporal, capacidad operativa y prioridad estratégica pueden funcionar como parámetros que modifiquen las alternativas presentadas por el sistema.

8.5. Análisis *what-if*

El análisis *what-if* o análisis "¿qué pasaría si?" permite explorar cómo podrían modificarse determinados resultados cuando se alteran uno o varios supuestos del modelo. Su utilidad consiste en experimentar virtualmente con diferentes condiciones antes de realizar cambios en la organización (Rodríguez Tejada et al., 2020).



Este enfoque permite transformar una predicción estática en un espacio de exploración. En lugar de aceptar una única estimación, el usuario puede modificar variables controlables y observar cómo cambia el resultado calculado por el modelo.

Por ejemplo, una empresa podría analizar qué ocurriría con un determinado indicador si aumenta su presupuesto promocional, modifica una variable comercial o enfrenta una reducción de demanda. Estas simulaciones no garantizan que el resultado real vaya a coincidir exactamente con la estimación, pero proporcionan información útil para comparar posibles condiciones antes de intervenir (Rodríguez Tejada et al., 2020).

El análisis *what-if* debe diferenciarse de una afirmación causal. Modificar artificialmente una variable dentro de un modelo y observar un cambio en la predicción muestra el comportamiento del modelo bajo ese supuesto, pero no demuestra necesariamente que una intervención real vaya a producir exactamente el mismo efecto.

Esta precaución resulta particularmente importante para el proyecto, porque la plataforma deberá presentar las simulaciones como resultados condicionados a determinados supuestos y no como certezas sobre acontecimientos futuros.

8.6. Simulación de escenarios

La simulación constituye una herramienta que permite representar el comportamiento de sistemas y evaluar diferentes condiciones sin intervenir inmediatamente sobre el entorno real. En la gestión

empresarial puede utilizarse para explorar escenarios, analizar incertidumbre y comparar posibles consecuencias antes de comprometer recursos (Rodríguez Tejada et al., 2020).

La principal ventaja de la simulación reside en proporcionar un entorno controlado para experimentar. Las organizaciones pueden modificar parámetros, incorporar restricciones y observar resultados potenciales sin asumir inicialmente los costos o riesgos asociados con la implementación real (Izurieta et al., 2024).

Los escenarios no deben entenderse como predicciones independientes y ciertas del futuro. Constituyen representaciones condicionales construidas a partir de supuestos. Su utilidad se encuentra precisamente en permitir analizar diferentes configuraciones y preparar respuestas antes de que las condiciones se materialicen (Rodríguez Tejada et al., 2020).

Dentro de la plataforma, la simulación permitirá relacionar predicciones y estrategias. El usuario podrá observar cómo diferentes alternativas modifican los indicadores esperados bajo determinadas condiciones, facilitando una comparación estructurada antes de seleccionar una acción.

8.7. Construcción de escenarios competitivos

Los escenarios competitivos permiten explorar cómo podrían evolucionar determinados indicadores empresariales bajo diferentes combinaciones de condiciones internas y externas. Su construcción



requiere identificar variables relevantes, establecer supuestos y definir horizontes temporales coherentes con el problema analizado (Rodríguez Tejada et al., 2020).

Una estructura práctica puede considerar al menos tres configuraciones: escenario base, escenario favorable y escenario adverso. El escenario base representa la continuidad de las condiciones consideradas más plausibles; el favorable incorpora supuestos que mejoran determinados indicadores; y el adverso considera condiciones que podrían deteriorar el desempeño.

Sin embargo, estos escenarios no deben construirse mediante porcentajes arbitrarios. Las variaciones deberían fundamentarse, cuando sea posible, en información histórica, intervalos predictivos, tendencias, conocimiento especializado o rangos plausibles de las variables.

La utilización de escenarios permite que la estrategia empresarial no dependa exclusivamente de una única estimación. Una alternativa puede presentar buenos resultados en el escenario favorable y comportarse deficientemente en condiciones adversas; otra puede producir beneficios más moderados, pero mantener un desempeño estable en diferentes situaciones.

8.8. Escenario base

El escenario base funciona como punto de referencia para comparar las demás configuraciones. Generalmente se construye utilizando las

condiciones actuales, las tendencias predominantes y los resultados centrales de los modelos predictivos.

Su finalidad no consiste en afirmar que representa exactamente el futuro, sino establecer una referencia coherente que permita evaluar cuánto cambian los resultados cuando se modifican determinados supuestos.
Dentro de la plataforma, el escenario base podrá utilizar las predicciones generadas por los modelos desarrollados previamente y mantener sin cambios determinadas variables controlables.

Las estrategias simuladas podrán compararse respecto de este escenario, facilitando que el usuario observe qué diferencias aparecen cuando se implementan distintas alternativas.

8.9. Escenario favorable

El escenario favorable representa una configuración en la cual determinadas condiciones evolucionan de manera beneficiosa para la organización. Puede incluir crecimiento de demanda, mayor respuesta de clientes, mejoras operativas o disponibilidad adicional de recursos.
Este escenario no debe confundirse con una expectativa optimista sin fundamento. Las variaciones utilizadas necesitan mantenerse dentro de rangos plausibles para evitar que los resultados produzcan una imagen poco realista.

Su utilidad consiste en analizar oportunidades. Si las condiciones evolucionan favorablemente, la organización puede evaluar previamente qué estrategias permitirían aprovechar mejor la situación.



El escenario favorable puede utilizarse, por tanto, para identificar alternativas orientadas al crecimiento, expansión, captación de clientes o utilización de capacidad disponible.

8.10. Escenario adverso

El escenario adverso incorpora condiciones que podrían afectar negativamente el desempeño empresarial. Entre ellas pueden encontrarse reducciones de demanda, incremento de costos, pérdida de clientes o restricciones adicionales de recursos.

La finalidad de este escenario no consiste en predecir una crisis, sino analizar la capacidad de respuesta de las estrategias bajo condiciones desfavorables. Este ejercicio permite identificar vulnerabilidades antes de que se conviertan en problemas operativos.

Las alternativas que mantienen resultados aceptables en condiciones adversas pueden considerarse más robustas frente a la incertidumbre, aunque la elección final dependerá de los objetivos y preferencias de la empresa.

En la plataforma, el escenario adverso permitirá asociar determinados riesgos con estrategias preventivas o de contingencia, fortaleciendo la capacidad anticipatoria del sistema.

8.11. Evaluación de alternativas estratégicas

La evaluación estratégica consiste en comparar diferentes cursos de acción considerando los resultados que podrían generar y los recursos



necesarios para implementarlos. La simulación permite realizar esta comparación bajo condiciones homogéneas antes de adoptar una decisión (Rodríguez Tejada et al., 2020).

Una alternativa puede evaluarse mediante indicadores relacionados con impacto esperado, costo, factibilidad, tiempo, riesgo y compatibilidad con los objetivos empresariales. La combinación de estas dimensiones proporciona una visión más completa que utilizar únicamente el resultado económico.

Este enfoque resulta relevante porque una estrategia puede producir un beneficio potencial elevado y simultáneamente presentar costos o riesgos que dificulten su implementación. Comparar diferentes dimensiones permite identificar estas compensaciones.

El sistema propuesto presentará las alternativas junto con sus principales consecuencias estimadas, permitiendo que el gerente valore no solamente cuál produce el mayor resultado esperado, sino cuál presenta una relación adecuada entre beneficios, restricciones y riesgos.

8.12. Análisis multicriterio para decisiones empresariales

Las decisiones empresariales raramente dependen de un único criterio. Costo, rentabilidad, tiempo, riesgo, recursos y factibilidad pueden intervenir simultáneamente y presentar diferentes niveles de importancia. Los métodos de decisión multicriterio permiten estructurar esta complejidad mediante la evaluación sistemática de alternativas según varios criterios (Romo-Nava et al., 2024).



La utilidad del análisis multicriterio consiste en hacer explícitos los elementos utilizados para comparar las opciones. En lugar de seleccionar una estrategia exclusivamente mediante intuición, el responsable puede conocer qué criterios fueron considerados y qué ponderación recibió cada uno.

Existen diferentes metodologías multicriterio. El Proceso Analítico Jerárquico (AHP) permite estructurar problemas mediante jerarquías y comparaciones entre criterios, mientras que métodos como ELECTRE permiten analizar relaciones de preferencia entre alternativas. La selección del procedimiento debe depender de las características del problema y no únicamente de la disponibilidad de una herramienta (Romo-Nava et al., 2024).

La aplicación combinada de pronóstico y análisis multicriterio también ha demostrado utilidad en contextos de pequeñas empresas. Investigaciones aplicadas a PYMES han integrado predicción de demanda con métodos multicriterio para seleccionar alternativas de proveedores, mostrando la posibilidad de conectar información prospectiva con procesos estructurados de decisión (Hernández et al., 2023).

8.13. Definición de criterios estratégicos

La calidad del análisis multicriterio depende de la selección adecuada de los criterios. Incorporar demasiadas variables puede dificultar la interpretación, mientras que utilizar un conjunto excesivamente reducido puede omitir dimensiones importantes de la decisión.



Para la plataforma propuesta pueden considerarse criterios como impacto esperado, costo de implementación, tiempo, riesgo, factibilidad, recursos necesarios, compatibilidad con el segmento empresarial y contribución a los objetivos estratégicos.

Los criterios deberán definirse claramente para evitar duplicidades. Por ejemplo, costo y recursos financieros pueden representar dimensiones muy similares si no se establece una diferencia conceptual precisa.

Además, el sistema deberá permitir ajustar determinadas ponderaciones según las prioridades de cada empresa. Una organización puede otorgar mayor importancia a liquidez, mientras otra puede priorizar crecimiento o captación de clientes.

8.14. Ponderación de criterios

La ponderación permite representar la importancia relativa que los responsables asignan a diferentes criterios. Este procedimiento resulta relevante porque las prioridades empresariales no son necesariamente iguales para todas las organizaciones.

Métodos como AHP permiten estructurar comparaciones entre criterios para obtener pesos relativos que posteriormente se utilizan durante la evaluación de alternativas (Romo-Nava et al., 2024).

Sin embargo, los pesos no deben presentarse como valores completamente objetivos cuando proceden de preferencias humanas. La plataforma deberá indicar cuándo una ponderación fue establecida por el usuario, derivada de expertos o calculada mediante otro procedimiento.



Esta transparencia permitirá que el gerente comprenda por qué determinada alternativa obtuvo una posición superior y pueda modificar los pesos para analizar cómo cambian los resultados.

8.15. Análisis de sensibilidad

El análisis de sensibilidad estudia cómo varían los resultados cuando se modifican determinados parámetros o supuestos. Su finalidad consiste en identificar qué elementos ejercen mayor influencia sobre las conclusiones obtenidas.

En un análisis multicriterio, por ejemplo, puede modificarse la ponderación de los criterios para determinar si la alternativa priorizada permanece estable. Si pequeñas variaciones producen cambios importantes en el orden de las estrategias, la decisión puede considerarse sensible a los supuestos utilizados.

Esta información resulta particularmente útil para evitar presentar una recomendación como inequívoca cuando existen varias alternativas con resultados semejantes.

En la plataforma, el análisis de sensibilidad complementará la recomendación prescriptiva al mostrar al usuario qué tan estable resulta una estrategia frente a cambios razonables en los parámetros.

8.16. Identificación de riesgos mediante escenarios

El análisis de escenarios permite identificar riesgos antes de implementar una estrategia. Una alternativa puede producir resultados satisfactorios



bajo condiciones normales y mostrar un deterioro considerable cuando cambian determinadas variables.

La simulación permite explorar estas condiciones y detectar qué factores generan mayor vulnerabilidad. Este conocimiento puede utilizarse para diseñar medidas preventivas, límites de exposición o estrategias alternativas (Rodríguez Tejada et al., 2020).

El riesgo no debe reducirse únicamente a una probabilidad. También es necesario considerar la magnitud de sus consecuencias y la capacidad empresarial para responder si el evento se materializa.

La plataforma podrá relacionar los riesgos identificados con indicadores de alerta, permitiendo que el sistema recomiende revisar una estrategia cuando determinadas variables superen umbrales previamente establecidos.

8.17. Identificación de oportunidades

La simulación no solamente permite estudiar riesgos; también facilita reconocer oportunidades. Un cambio favorable en demanda, comportamiento de clientes o condiciones de mercado puede generar escenarios en los cuales determinadas estrategias presenten mayor potencial.

La identificación de oportunidades consiste en analizar qué condiciones permitirían obtener mejores resultados y qué recursos serían necesarios para aprovecharlas.



Este enfoque permite que la analítica prescriptiva adopte una función proactiva. La organización no espera únicamente a que aparezca un problema, sino que explora anticipadamente situaciones en las cuales podría fortalecer su posición.

En el proyecto, las oportunidades podrán vincularse con segmentos empresariales específicos, permitiendo que las recomendaciones sean diferenciadas según características y capacidades.

8.18. Riesgo, oportunidad y competitividad

La competitividad empresarial depende parcialmente de la capacidad para responder a cambios y aprovechar oportunidades antes de que desaparezcan. El análisis prescriptivo puede contribuir a esta capacidad mediante la comparación sistemática de alternativas bajo diferentes escenarios.

La integración entre riesgo y oportunidad permite evitar una visión exclusivamente defensiva. Una estrategia puede presentar determinado nivel de riesgo y simultáneamente generar oportunidades de crecimiento que justifiquen su evaluación.

El sistema deberá mostrar ambas dimensiones para que el usuario pueda analizar las compensaciones existentes. Una recomendación no debería presentarse únicamente por su rendimiento esperado, sino acompañada de información sobre riesgos y condiciones necesarias para alcanzar dicho resultado.



Esta perspectiva resulta especialmente relevante para micro y pequeñas empresas, donde decisiones incorrectas pueden tener efectos proporcionalmente mayores debido a la disponibilidad limitada de recursos.

8.19. Recomendaciones prescriptivas

Las recomendaciones prescriptivas constituyen el resultado de integrar predicciones, escenarios, restricciones, objetivos y criterios de decisión. Su finalidad consiste en presentar alternativas que hayan sido evaluadas sistemáticamente antes de llegar al usuario (Schab et al., 2020; Santos Samaniego et al., 2025).

Una recomendación prescriptiva debe diferenciarse de una instrucción. El sistema puede indicar que una alternativa presenta determinadas ventajas bajo ciertos supuestos, pero la decisión de implementarla continúa correspondiendo al responsable empresarial.

La recomendación también debe incluir las condiciones que sustentan su pertinencia. Si una estrategia ocupa una posición favorable únicamente bajo un escenario específico, esta información debe presentarse claramente.

Por ello, la plataforma podrá estructurar cada recomendación mediante cinco elementos: **acción propuesta, escenario, resultado esperado, principales riesgos y condiciones de aplicación**.

8.20. Priorización prescriptiva de estrategias



Cuando existen múltiples alternativas factibles, el sistema necesita establecer un mecanismo para organizarlas. La priorización puede realizarse combinando resultados de simulación, análisis multicriterio y restricciones empresariales.

Cada alternativa puede recibir una valoración relativa basada en impacto, factibilidad, riesgo, costo, urgencia y compatibilidad con el perfil empresarial. Esta puntuación permitirá ordenar las estrategias sin afirmar que la primera opción constituye automáticamente una decisión correcta para todos los casos.

La priorización debe ser explicable. El usuario necesita conocer qué criterios produjeron el orden obtenido y cómo cambiaría si se modifican determinadas prioridades.
Esta característica conecta la analítica prescriptiva con la Inteligencia Artificial Explicable desarrollada en el Capítulo 6, manteniendo trazabilidad entre datos, análisis y recomendación.

8.21. Apoyo algorítmico a la toma de decisiones

Los algoritmos permiten procesar una cantidad de alternativas y combinaciones superior a la que una persona podría evaluar manualmente en períodos reducidos. Esta capacidad convierte a la analítica prescriptiva en un mecanismo de apoyo especialmente útil para problemas complejos (Schab et al., 2020).

Sin embargo, mayor capacidad computacional no equivale automáticamente a una mejor decisión. Los resultados dependen de la



calidad de los datos, los supuestos incorporados, las restricciones establecidas y la correspondencia entre el modelo y el problema empresarial.

El apoyo algorítmico debe concebirse como una ampliación de la capacidad analítica del gerente. El sistema puede comparar escenarios y ordenar alternativas, mientras que la persona incorpora conocimiento contextual, experiencia y factores que no necesariamente se encuentran representados en los datos.

La decisión final mantiene así una estructura colaborativa: **el algoritmo procesa y compara; el gerente interpreta, contextualiza y decide**.

8.22. Incertidumbre en la analítica prescriptiva

Toda prescripción basada en información predictiva se encuentra afectada por incertidumbre. Si la predicción inicial presenta un rango de posibles resultados, las recomendaciones derivadas de ella también deben interpretarse considerando dicha variabilidad.

La plataforma no debería transformar una estimación incierta en una recomendación aparentemente exacta. Por el contrario, debe conservar información sobre intervalos, escenarios y sensibilidad cuando estos elementos sean relevantes.

Una estrategia que mantiene resultados favorables bajo diferentes valores plausibles puede considerarse más robusta que otra cuya conveniencia depende de un supuesto extremadamente específico.



Esta lógica permite pasar de buscar únicamente la alternativa con mejor resultado esperado hacia identificar estrategias capaces de mantener un desempeño aceptable bajo incertidumbre.

8.23. Estrategias robustas frente a estrategias óptimas

La alternativa matemáticamente óptima bajo un único escenario no necesariamente constituye la estrategia más conveniente cuando existe incertidumbre. Una solución puede alcanzar un resultado elevado en condiciones específicas y deteriorarse significativamente cuando cambian los supuestos.

Una estrategia robusta busca mantener resultados razonables en un conjunto más amplio de condiciones. Este criterio resulta especialmente relevante cuando las variables empresariales presentan elevada volatilidad.

La plataforma podrá comparar tanto el rendimiento esperado como la estabilidad de las alternativas entre escenarios. Esta información permitirá que el usuario conozca si una recomendación depende fuertemente de condiciones particulares.

La elección entre maximizar rendimiento y priorizar robustez constituye una decisión empresarial que deberá permanecer bajo control del usuario.

8.24. Integración con la Inteligencia Artificial Explicable

La analítica prescriptiva debe mantener continuidad con los mecanismos XAI desarrollados previamente. Si una estrategia es priorizada, el

sistema deberá proporcionar información sobre los factores que influyeron en su selección.

La explicación puede incluir predicciones utilizadas, variables relevantes, escenario analizado, criterios de decisión, ponderaciones y restricciones aplicadas.

Esta trazabilidad permite evitar recomendaciones opacas. El usuario podrá reconstruir el proceso desde la información original hasta la alternativa presentada.

La integración puede expresarse mediante la secuencia:

Datos → predicción → explicación → escenario → simulación → evaluación multicriterio → recomendación prescriptiva → explicación de la recomendación → decisión humana.

8.25. Integración con los sistemas inteligentes de recomendación

El sistema recomendador desarrollado en el capítulo anterior genera alternativas estratégicas compatibles con determinados perfiles y contextos. La analítica prescriptiva amplía esta capacidad al evaluar qué podría ocurrir si dichas alternativas se implementaran.

La relación entre ambos componentes puede entenderse como un proceso de generación y evaluación. El motor recomendador identifica estrategias candidatas; el componente prescriptivo las somete a escenarios, restricciones y criterios de decisión.

Posteriormente, las alternativas pueden ordenarse de acuerdo con sus resultados esperados y su comportamiento bajo diferentes condiciones.



Esta integración permite evitar que una recomendación sea presentada únicamente porque coincide con un perfil. Antes de llegar al usuario, puede ser evaluada respecto de factibilidad, riesgos y resultados potenciales.

8.26. Simulación para micro y pequeñas empresas

Las micro y pequeñas empresas enfrentan decisiones estratégicas con recursos generalmente más limitados. En estas condiciones, experimentar directamente mediante prueba y error puede generar costos difíciles de absorber.

La simulación ofrece la posibilidad de explorar virtualmente determinadas alternativas antes de comprometer recursos. Aunque los resultados no eliminan la incertidumbre, permiten comparar condiciones y detectar posibles consecuencias (Rodríguez Tejada et al., 2020).
La complejidad del modelo deberá adaptarse a la calidad y cantidad de información disponible. Una simulación excesivamente sofisticada no necesariamente produce mejores resultados cuando los datos son limitados o presentan problemas de calidad.

Por ello, la plataforma propuesta priorizará modelos comprensibles y escenarios plausibles, incrementando progresivamente la complejidad cuando la disponibilidad de información lo justifique.

8.27. Dashboard prescriptivo

El *dashboard* constituye el punto de interacción entre los resultados analíticos y el usuario empresarial. Su función no deberá limitarse a



presentar indicadores históricos, sino integrar predicciones, escenarios y recomendaciones.

Una sección prescriptiva puede mostrar el escenario base, favorable y adverso; las estrategias evaluadas; los principales criterios utilizados; riesgos identificados; resultados estimados y nivel de prioridad.

El usuario podrá modificar determinados supuestos y observar cómo cambian las alternativas mediante análisis *what-if*. Esta capacidad convierte el *dashboard* en un espacio interactivo de exploración estratégica.

La visualización deberá mantener simplicidad suficiente para que empresarios sin formación especializada en ciencia de datos puedan interpretar los resultados, conservando la posibilidad de acceder a información metodológica adicional.

8.28. Arquitectura propuesta de analítica prescriptiva

A partir de los fundamentos desarrollados, el componente prescriptivo del proyecto puede estructurarse mediante la siguiente arquitectura:

DATOS EMPRESARIALES

↓

SEGMENTACIÓN AUTOMATIZADA

↓

PERFIL EMPRESARIAL

↓

ANALÍTICA PREDICTIVA

↓



PREDICCIÓN + INCERTIDUMBRE

↓

XAI: EXPLICACIÓN

↓

MOTOR DE RECOMENDACIÓN

↓

ALTERNATIVAS ESTRATÉGICAS

↓

ANÁLISIS WHAT-IF

↓

SIMULACIÓN DE ESCENARIOS

↓

EVALUACIÓN MULTICRITERIO

↓

ANÁLISIS DE RIESGOS Y OPORTUNIDADES

↓

PRIORIZACIÓN PRESCRIPTIVA

↓

RECOMENDACIÓN EXPLICABLE

↓

DASHBOARD

↓

DECISIÓN HUMANA

↓

RETROALIMENTACIÓN Y APRENDIZAJE



Esta arquitectura integra progresivamente las capacidades desarrolladas en los capítulos anteriores y convierte la analítica prescriptiva en una capa de evaluación estratégica antes de que las recomendaciones lleguen al responsable empresarial.

8.29. Modelo conceptual de simulación competitiva

El modelo propuesto puede organizarse mediante seis dimensiones interrelacionadas: **objetivo, alternativas, escenarios, criterios, riesgos y decisión**.

El **objetivo** establece qué pretende mejorar la organización; las **alternativas** representan posibles acciones; los **escenarios** permiten estudiar diferentes condiciones futuras; los **criterios** proporcionan dimensiones para comparar las opciones; los **riesgos** muestran posibles resultados desfavorables; y la **decisión** corresponde a la selección realizada por el responsable empresarial.

La interacción de estas dimensiones evita que la recomendación dependa únicamente de una predicción. Una alternativa necesita analizarse respecto de diferentes escenarios y objetivos antes de ser considerada estratégicamente pertinente.

La estructura también facilita la explicabilidad porque permite mostrar al usuario qué componentes participaron en la priorización final.

8.30. Del dato a la decisión estratégica

La arquitectura completa propuesta en esta investigación puede entenderse como una cadena progresiva de transformación del dato. Los



registros empresariales inicialmente poseen valor informativo limitado hasta que son procesados, contextualizados e integrados con mecanismos analíticos.

La segmentación permite reconocer perfiles; la analítica predictiva anticipa comportamientos; XAI proporciona información sobre los factores utilizados por los modelos; los sistemas recomendadores generan alternativas; y la analítica prescriptiva evalúa dichas opciones bajo diferentes escenarios.

La simulación incorpora un espacio intermedio entre recomendación y acción. En lugar de implementar inmediatamente una estrategia, el sistema permite explorar qué resultados podrían producirse bajo diferentes supuestos.

De esta forma, la plataforma propuesta transforma progresivamente **datos en información, información en conocimiento analítico y conocimiento en alternativas estratégicas evaluables**, manteniendo la decisión final bajo responsabilidad humana.

8.31. Síntesis del capítulo

La analítica prescriptiva amplía las capacidades de la analítica empresarial al incorporar alternativas de actuación, restricciones, objetivos y métodos de evaluación. Su propósito consiste en apoyar decisiones mediante la comparación sistemática de posibles cursos de acción y no simplemente proporcionar una predicción sobre el futuro (Schab et al., 2020; Santos Samaniego et al., 2025).



La optimización basada en datos permite formalizar objetivos empresariales y considerar simultáneamente restricciones que condicionan las alternativas disponibles. Sin embargo, una solución matemáticamente favorable requiere interpretación empresarial antes de convertirse en una decisión.

El análisis *what-if* permite explorar el comportamiento de los modelos cuando se modifican determinados supuestos. Esta capacidad facilita experimentar virtualmente sin asumir inmediatamente las consecuencias económicas de una intervención, aunque sus resultados no deben confundirse con evidencia causal.

La simulación de escenarios amplía este enfoque mediante la construcción de configuraciones base, favorables y adversas. Estas representaciones permiten evaluar cómo se comportan las estrategias bajo diferentes condiciones y contribuyen a reconocer alternativas sensibles o robustas (Rodríguez Tejada et al., 2020).

El análisis multicriterio permite incorporar simultáneamente diferentes dimensiones de la decisión. Métodos como AHP y ELECTRE proporcionan procedimientos estructurados para comparar alternativas cuando intervienen criterios cuantitativos y cualitativos (Romo-Nava et al., 2024).

La identificación conjunta de riesgos y oportunidades permite ampliar el análisis estratégico. La plataforma no solamente deberá advertir sobre

posibles amenazas, sino reconocer condiciones en las cuales una empresa podría aprovechar oportunidades de crecimiento o mejora.

Las recomendaciones prescriptivas representan el resultado de integrar predicción, contexto, simulación, restricciones y criterios de decisión. Estas recomendaciones deberán presentarse como alternativas fundamentadas y no como instrucciones automáticas.

La explicabilidad continuará siendo un principio transversal. El usuario deberá poder comprender qué predicciones, escenarios, criterios y restricciones originaron la priorización de una determinada estrategia.

Dentro del proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, la analítica prescriptiva constituye la etapa que permite evaluar las estrategias generadas antes de presentarlas como alternativas de decisión.

En consecuencia, el modelo integral propuesto puede sintetizarse mediante la siguiente secuencia:

DATOS → SEGMENTACIÓN → PREDICCIÓN → EXPLICACIÓN → RECOMENDACIÓN → SIMULACIÓN → EVALUACIÓN MULTICRITERIO → RIESGOS Y OPORTUNIDADES → PRESCRIPCIÓN → DECISIÓN HUMANA → RETROALIMENTACIÓN.

Esta arquitectura permite evolucionar desde el análisis retrospectivo hacia un sistema inteligente capaz de explorar escenarios, comparar estrategias y proporcionar recomendaciones contextualizadas. Su



finalidad no consiste en automatizar completamente las decisiones empresariales, sino en ampliar la capacidad de análisis de gerentes y empresarios mediante evidencia cuantitativa, simulación y evaluación estructurada de alternativas.



CAPÍTULO 9.

DASHBOARDS INTELIGENTES Y VISUALIZACIÓN AVANZADA PARA LA COMPETITIVIDAD

9.1. Transformación de los dashboards empresariales

La creciente disponibilidad de datos empresariales ha modificado la manera en que las organizaciones supervisan sus operaciones y fundamentan sus decisiones. Los sistemas de inteligencia de negocios permiten integrar información procedente de diferentes fuentes, procesarla y transformarla en representaciones que facilitan el análisis gerencial. Dentro de esta arquitectura, los dashboards constituyen interfaces que sintetizan indicadores y permiten observar de forma estructurada el comportamiento de variables relevantes para la organización (García-Jiménez et al., 2021; Cruz Osorio et al., 2022).

Los dashboards contemporáneos superan progresivamente la función de mostrar indicadores históricos mediante gráficos estáticos. La incorporación de herramientas analíticas, automatización, modelos predictivos e inteligencia artificial permite construir entornos interactivos capaces de combinar información histórica con estimaciones, alertas y recomendaciones. Esta evolución amplía la utilidad de Business Intelligence como soporte para decisiones operativas y estratégicas (Alvarado Apodaca et al., 2025; Fasanando-Trigoso et al., 2025).

La visualización desempeña un papel fundamental dentro de este proceso porque reduce la dificultad de interpretar grandes cantidades de datos.

Una representación adecuadamente diseñada facilita reconocer tendencias, comparaciones, valores atípicos y relaciones que pueden permanecer ocultas cuando la información se presenta exclusivamente mediante tablas extensas o registros individuales (Grisales Aguirre et al., 2024).

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, el dashboard constituirá la capa de interacción entre los modelos analíticos y el empresario. Su función será integrar resultados descriptivos, segmentos, predicciones, explicaciones, escenarios y recomendaciones dentro de una interfaz orientada a la decisión.

9.2. Business Intelligence como fundamento de los dashboards

Business Intelligence puede comprenderse como un conjunto articulado de procesos, tecnologías y herramientas destinados a convertir datos organizacionales en información susceptible de ser utilizada en la gestión. Su aporte no se limita al almacenamiento de datos, sino que comprende procesos de integración, análisis y representación que permiten mejorar el acceso a información relevante para las decisiones (García-Jiménez et al., 2021).

La utilización de BI adquiere particular importancia cuando la información empresarial se encuentra distribuida entre diferentes fuentes. Ventas, clientes, inventarios, operaciones y otros registros pueden permanecer separados, dificultando una interpretación integral



del desempeño. Las arquitecturas de inteligencia de negocios permiten consolidar estos datos y construir indicadores comunes para diferentes niveles de gestión (Weis Filho et al., 2021; Cruz Osorio et al., 2022).

La relación entre inteligencia de negocios y competitividad también ha sido analizada en pequeñas y medianas empresas. La disponibilidad oportuna de información y la capacidad para convertirla en conocimiento gerencial pueden contribuir a responder con mayor rapidez a cambios internos y externos, aunque sus resultados dependen de factores como calidad de los datos, capacidades tecnológicas y utilización efectiva de la información (Pérez Jesús et al., 2024).

En el contexto ecuatoriano, investigaciones recientes destacan que la implementación de modelos de BI en PYMES puede fortalecer el proceso decisorio al proporcionar información organizada para analizar el desempeño empresarial. Esta evidencia resulta particularmente relevante para el proyecto debido a su orientación hacia organizaciones de menor tamaño y con diferentes niveles de madurez analítica (Chinchuña et al., 2026).

9.3. De Business Intelligence tradicional a Business Intelligence aumentado

La inteligencia de negocios tradicional se ha concentrado principalmente en consolidar datos históricos y representarlos mediante reportes e indicadores. Sin embargo, la integración de inteligencia artificial y aprendizaje automático amplía estas capacidades al incorporar análisis predictivo, automatización y mecanismos capaces de identificar patrones

que no necesariamente son evidentes mediante análisis manuales (Fasanando-Trigoso et al., 2025).

Esta evolución puede conceptualizarse como una transición hacia un **Business Intelligence aumentado**, en el cual las capacidades convencionales de integración y visualización se complementan con modelos inteligentes. La plataforma deja de limitarse a responder qué ocurrió y comienza a incorporar información sobre qué podría suceder, qué factores contribuyen a una predicción y qué alternativas pueden evaluarse.

El carácter aumentado no significa eliminar la participación humana. Por el contrario, la finalidad consiste en reducir tareas analíticas repetitivas y presentar información procesada para que el responsable empresarial concentre su atención en la interpretación y evaluación de alternativas. La tecnología amplía la capacidad de análisis, mientras que el conocimiento contextual permanece bajo responsabilidad del usuario (Fasanando-Trigoso et al., 2025).

En la arquitectura propuesta, Business Intelligence aumentado integrará cinco capacidades: **descripción del desempeño, segmentación automatizada, predicción, explicación y prescripción**. El dashboard funcionará como espacio de convergencia de estas capacidades.

9.4. Indicadores clave de desempeño empresarial

Los indicadores clave de desempeño o KPI permiten representar de manera cuantificable aspectos considerados relevantes para los objetivos de una organización. Su función consiste en facilitar el seguimiento del



desempeño y detectar desviaciones que requieren atención, evitando que el gerente tenga que examinar permanentemente grandes cantidades de registros individuales (Cedeño-Mendoza & Zambrano-Santos, 2026).

Un KPI adquiere utilidad cuando mantiene una relación clara con una finalidad empresarial. Incorporar una gran cantidad de indicadores sin jerarquía puede producir sobrecarga informativa y reducir la capacidad del dashboard para orientar la atención hacia los aspectos verdaderamente relevantes. Por ello, la selección debe considerar objetivos, usuarios y nivel de decisión (Cedeño-Mendoza & Zambrano-Santos, 2026).

Los indicadores también necesitan disponer de contexto. Mostrar únicamente el valor actual limita su interpretación; resulta más útil relacionarlo con períodos anteriores, metas, variaciones, tendencias o rangos esperados. Esta comparación permite determinar si el comportamiento observado representa estabilidad, mejora o una posible desviación (Cruz Osorio et al., 2022).

Para las micro y pequeñas empresas consideradas en el proyecto, los KPI deberán seleccionarse procurando equilibrio entre utilidad analítica y disponibilidad real de información. Un sistema excesivamente complejo podría requerir datos que estas organizaciones no generan regularmente, disminuyendo la sostenibilidad del dashboard.



9.5. Diseño de KPI para la competitividad

La competitividad constituye un fenómeno multidimensional, por lo que no debería representarse mediante un único indicador. El dashboard puede incorporar KPI asociados con ventas, clientes, comportamiento comercial, eficiencia y otras dimensiones que dispongan de datos suficientes para ser medidas de forma consistente (Pérez Jesús et al., 2024).

Entre los indicadores comerciales podrían considerarse variación de ventas, crecimiento, frecuencia de compra, valor promedio de transacción, retención de clientes y comportamiento de productos. La selección definitiva deberá depender del modelo conceptual del proyecto y de la información obtenida durante el levantamiento de datos.

Los KPI también pueden clasificarse según su orientación temporal. Algunos describen resultados ya observados, mientras que otros pueden incorporar información anticipatoria procedente de modelos predictivos. Esta distinción permite construir un tablero que no solamente informe sobre el desempeño pasado, sino que también muestre posibles cambios futuros.

El dashboard inteligente propuesto combinará indicadores históricos con indicadores derivados de los modelos analíticos. De esta manera, el empresario podrá contrastar la situación actual con las estimaciones y escenarios generados por la plataforma.



9.6. Visualización de datos empresariales

La visualización de datos constituye un proceso de representación que busca facilitar la comprensión de estructuras, tendencias y relaciones presentes en conjuntos de información. Su valor no reside simplemente en transformar números en gráficos, sino en seleccionar representaciones que permitan interpretar de forma más eficiente el fenómeno analizado (Grisales Aguirre et al., 2024).

Los gráficos de líneas facilitan el análisis temporal; las barras permiten realizar comparaciones; los diagramas de dispersión ayudan a reconocer relaciones y agrupamientos; mientras que mapas y otras representaciones pueden ser apropiados cuando existe una dimensión geográfica. La selección visual debe responder a la pregunta analítica y no únicamente a criterios estéticos (Cruz Osorio et al., 2022; Grisales Aguirre et al., 2024).

Una visualización inadecuada puede producir interpretaciones equivocadas incluso cuando los datos son correctos. Escalas poco claras, exceso de elementos, colores sin función analítica o gráficos innecesariamente complejos pueden dificultar la comprensión. Por ello, el diseño del dashboard debe priorizar claridad y consistencia.

En la plataforma propuesta, cada visualización deberá responder a una necesidad empresarial concreta: identificar una tendencia, comparar segmentos, reconocer una anomalía, comprender una predicción, explorar un escenario o evaluar una recomendación.



9.7. Dashboards como sistemas de apoyo a decisiones

Un dashboard empresarial no debería concebirse únicamente como un conjunto de gráficos ubicados dentro de una misma pantalla. Su valor surge de la capacidad para organizar información de acuerdo con las necesidades del usuario y facilitar el acceso oportuno a los indicadores que intervienen en una decisión (Dorado Bastidas et al., 2023).

La evidencia empírica muestra que los dashboards apoyados en BI pueden integrar datos y facilitar análisis estratégicos. Su desarrollo requiere comprender primero el problema del negocio y posteriormente preparar, modelar, evaluar y desplegar la información de manera coherente con las necesidades de los usuarios (Dorado Bastidas et al., 2023).

Investigaciones recientes sobre dashboards interactivos también señalan que la usabilidad constituye una dimensión relevante. Una plataforma técnicamente sofisticada puede perder utilidad cuando la navegación es confusa o la información resulta difícil de interpretar para el usuario final (Alvarado Apodaca et al., 2025).

Por esta razón, el dashboard del proyecto deberá diseñarse simultáneamente desde una perspectiva analítica y de experiencia de usuario. La calidad del modelo y la calidad de la interfaz deben considerarse componentes complementarios del sistema.



9.8. Tableros descriptivos

Los tableros descriptivos presentan información sobre acontecimientos que ya ocurrieron. Ventas acumuladas, variaciones mensuales, número de clientes, comportamiento de productos y otros indicadores históricos permiten construir una representación general de la situación empresarial (García-Jiménez et al., 2021).

Esta información constituye la base del sistema porque permite contextualizar los resultados de modelos más avanzados. Una predicción de disminución de ventas adquiere mayor significado cuando el usuario puede observar simultáneamente la evolución histórica de dicho indicador.

Los tableros descriptivos también permiten identificar tendencias y anomalías mediante comparación temporal. La automatización de gráficos facilita actualizar estas representaciones conforme se incorporan nuevos registros (Cruz Osorio et al., 2022).

En la plataforma, la capa descriptiva funcionará como punto de entrada. Desde ella, el usuario podrá profundizar progresivamente hacia segmentos, predicciones, explicaciones y recomendaciones.

9.9. Tableros predictivos

Los tableros predictivos incorporan resultados de modelos que estiman comportamientos futuros. Esta capacidad transforma el dashboard desde una herramienta retrospectiva hacia un entorno que también proporciona información prospectiva.

Una visualización predictiva debe distinguir claramente los datos observados de las estimaciones. Presentar ambos elementos sin diferenciación puede inducir al usuario a interpretar una predicción como si fuera un valor ya conocido.

Además de la estimación central, resulta conveniente representar la incertidumbre cuando el modelo permita calcularla. Intervalos o rangos proporcionan una imagen más realista que una cifra aislada y reducen la falsa impresión de exactitud.

En el proyecto, los tableros predictivos podrán mostrar ventas o demanda esperada, dirección de la tendencia y otros resultados obtenidos mediante los modelos desarrollados en el Capítulo 4.

9.10. Visualización de incertidumbre

La incertidumbre constituye una propiedad inherente de las predicciones. Por esta razón, una interfaz responsable no debería ocultarla mediante representaciones que transmitan una certeza inexistente.

Los rangos de predicción pueden representarse mediante bandas, intervalos o escenarios. Estas visualizaciones permiten observar simultáneamente el valor central esperado y el espacio dentro del cual podrían encontrarse otros resultados plausibles.

La comunicación de incertidumbre también debe utilizar lenguaje comprensible. Los usuarios empresariales no necesariamente poseen formación estadística, por lo que la explicación visual puede



complementarse con mensajes que indiquen el grado de variabilidad asociado con la estimación.

La plataforma evitará presentar las predicciones como certezas. Cada resultado predictivo relevante deberá conservar información suficiente para que el usuario comprenda que se trata de una estimación sujeta a error.

9.11. Visualización inteligente de segmentos empresariales

Los resultados obtenidos mediante algoritmos de clustering necesitan representarse de forma que permitan comprender las características de los grupos identificados. Mostrar únicamente etiquetas como “Clúster 1” o “Clúster 2” proporciona poca información estratégica.

La visualización de segmentos debe combinar tamaño, características diferenciadoras y comportamiento de cada grupo. Gráficos comparativos pueden utilizarse para mostrar diferencias en ventas, clientes, frecuencia, digitalización u otras variables incluidas en el modelo.

Cuando la dimensionalidad de los datos lo permita, los diagramas de dispersión pueden contribuir a visualizar la proximidad entre observaciones y los patrones de agrupamiento. Sin embargo, una representación bidimensional constituye una simplificación y no necesariamente reproduce toda la estructura utilizada por el algoritmo.

En el dashboard propuesto, cada segmento estará acompañado de un perfil interpretable. Esto permitirá pasar de una agrupación matemática



hacia una representación empresarial que facilite comprender qué distingue a cada conjunto.

9.12. Perfil visual de los segmentos

El perfil visual constituye una síntesis de las características predominantes de un segmento. Su finalidad es permitir que el usuario reconozca rápidamente qué variables diferencian a un grupo respecto de los demás.

Una tarjeta de segmento puede presentar denominación, tamaño, principales características, indicadores relevantes, comportamiento histórico y predicciones asociadas. Esta estructura facilita conectar los resultados del clustering con los demás componentes analíticos.

Las denominaciones asignadas a los segmentos deberán surgir después del análisis de sus características. Utilizar nombres previamente definidos puede introducir interpretaciones que no se encuentran respaldadas por los datos.

La visualización de segmentos se convertirá así en un mecanismo de conexión entre clustering y personalización. Cada perfil podrá relacionarse posteriormente con predicciones y recomendaciones diferenciadas.

9.13. Alertas inteligentes

Un dashboard inteligente debe ayudar a dirigir la atención hacia acontecimientos que requieren revisión. Las alertas cumplen esta función



al identificar desviaciones, cambios significativos o condiciones que superan determinados criterios.

Los sistemas tradicionales pueden generar alertas mediante umbrales fijos. Sin embargo, una arquitectura analítica avanzada puede incorporar tendencias, predicciones y patrones históricos para contextualizar las señales.

Por ejemplo, una reducción de ventas no necesariamente requiere una alerta cuando corresponde a una variación estacional esperada. En cambio, una disminución significativamente diferente del patrón histórico podría justificar una advertencia de mayor prioridad.
La plataforma combinará reglas y resultados analíticos para producir alertas contextualizadas. De esta manera, el usuario recibirá señales asociadas con situaciones que requieren análisis y no simplemente notificaciones por cualquier variación.

9.14. Priorización de alertas

La generación excesiva de alertas puede producir saturación y disminuir la atención del usuario. Por ello, el sistema debe distinguir entre acontecimientos informativos, situaciones que requieren seguimiento y condiciones de mayor prioridad.

La priorización puede considerar magnitud de la desviación, persistencia, impacto estimado y relación con objetivos empresariales. Una señal pequeña pero persistente puede resultar estratégicamente más relevante que una variación elevada pero aislada.



Cada alerta deberá incluir una explicación mínima sobre su origen. El usuario necesita conocer qué indicador cambió, respecto de qué referencia y por qué el sistema considera relevante la situación.

Esta estructura conecta las alertas con XAI y la analítica prescriptiva, permitiendo que una señal pueda conducir posteriormente hacia una explicación y, cuando corresponda, hacia una recomendación.

9.15. Explicación visual de predicciones

La integración de XAI en los dashboards permite complementar una predicción con información acerca de las variables que contribuyeron a generarla. Esta capacidad resulta relevante porque evita que los resultados aparezcan como estimaciones aisladas.

Las explicaciones globales pueden representarse mediante gráficos que ordenen las variables según su influencia general sobre el modelo. Las explicaciones locales, en cambio, pueden mostrar los factores que contribuyeron a una predicción específica.

Para un gerente, la visualización debe traducir la salida técnica hacia un lenguaje empresarial. En lugar de mostrar exclusivamente valores algorítmicos, el sistema puede indicar qué factores ejercieron mayor influencia y en qué dirección.

La plataforma integrará estas explicaciones dentro del mismo entorno visual de las predicciones, evitando que el usuario necesite desplazarse



hacia herramientas técnicas independientes para comprender los resultados.

9.16. Visualización de SHAP y explicaciones locales

Los valores SHAP desarrollados en el Capítulo 6 pueden transformarse en representaciones que muestren la contribución de diferentes características a una predicción individual. Esta visualización permite observar cuáles variables desplazaron el resultado respecto de un valor de referencia.

En una aplicación empresarial, el usuario podría seleccionar una predicción y observar inmediatamente los principales factores que contribuyeron positiva o negativamente a la estimación.

El número de variables mostrado deberá mantenerse limitado a aquellas que proporcionan información relevante. Presentar decenas de contribuciones simultáneamente puede dificultar la interpretación y reducir el valor de la explicación.

El dashboard utilizará, por tanto, una lógica de detalle progresivo: primero presentará los factores principales y permitirá consultar posteriormente información técnica adicional.

9.17. Dashboards adaptativos

Los usuarios de una plataforma empresarial no necesariamente requieren la misma información. Un propietario puede concentrarse en ventas y



liquidez, mientras que un responsable comercial puede necesitar mayor detalle sobre clientes, segmentos y comportamiento de productos.

Un dashboard adaptativo modifica el contenido, nivel de detalle o disposición de la información según el perfil, contexto o interacción del usuario. Esta capacidad permite reducir información irrelevante y priorizar aquellos indicadores relacionados con las necesidades específicas.

La adaptación también puede relacionarse con la situación empresarial. Cuando el sistema identifica una alerta importante, determinados indicadores pueden adquirir mayor visibilidad para facilitar su análisis.

En el proyecto, la adaptación deberá mantener límites de transparencia. El usuario debe comprender por qué determinados elementos son priorizados y conservar la posibilidad de acceder al conjunto completo de información disponible.

9.18. Personalización por segmento empresarial

La segmentación desarrollada previamente también puede utilizarse para personalizar el dashboard. Empresas pertenecientes a diferentes perfiles pueden requerir indicadores, comparaciones y recomendaciones distintas.

Una microempresa con comportamiento comercial estable podría recibir mayor énfasis en oportunidades de crecimiento, mientras que un perfil caracterizado por deterioro reciente podría requerir mayor visibilidad de alertas y riesgos. Estas diferencias deberán fundamentarse en información analítica y no en etiquetas subjetivas.



La personalización por segmentos permite mantener una arquitectura común y, simultáneamente, adaptar la experiencia de análisis a las características de cada organización.

De esta forma, el clustering deja de ser únicamente una técnica estadística y se convierte en un mecanismo que también orienta la presentación de información y recomendaciones.

9.19. Integración de analítica descriptiva y diagnóstica

La primera capa del dashboard deberá permitir comprender qué está ocurriendo y cómo evolucionaron los principales indicadores. Esta información proporciona contexto para los análisis posteriores.

La comparación temporal, filtros y desagregación permiten profundizar desde un indicador agregado hacia información más específica. Este proceso facilita explorar posibles factores relacionados con una variación observada.

Aunque la visualización puede revelar asociaciones y patrones, estas relaciones no deben interpretarse automáticamente como causalidad. El dashboard constituye una herramienta exploratoria y analítica, pero las conclusiones causales requieren diseños metodológicos apropiados.

Esta precaución deberá mantenerse en toda la plataforma para evitar que correlaciones visuales sean presentadas como explicaciones causales del comportamiento empresarial.



9.20. Integración de analítica predictiva

La segunda capa incorporará los modelos predictivos. Las series históricas podrán complementarse con valores estimados para períodos futuros y medidas de incertidumbre.

El usuario podrá comparar el comportamiento observado con el pronóstico, identificar posibles cambios de tendencia y reconocer anticipadamente situaciones que requieren atención.

Las predicciones deberán estar conectadas con su desempeño histórico. Mostrar métricas seleccionadas permite proporcionar información sobre la capacidad del modelo sin saturar al usuario con detalles técnicos.
Esta integración transforma el dashboard en una herramienta prospectiva, debido a que combina la situación actual con información acerca de comportamientos futuros plausibles.

9.21. Integración de analítica prescriptiva

La tercera capa incorporará los resultados de simulación y recomendación desarrollados en los capítulos 7 y 8. Su finalidad será conectar la información analítica con alternativas de actuación.

El usuario podrá observar diferentes escenarios y comparar estrategias mediante criterios como impacto esperado, factibilidad, riesgo y recursos necesarios.



La recomendación priorizada deberá aparecer acompañada de sus fundamentos. Esto permitirá comprender qué escenario, indicadores y criterios influyeron en su posición.

El dashboard evolucionará así desde un sistema que muestra información hacia un entorno de apoyo a decisiones capaz de integrar evidencia histórica, prospectiva y prescriptiva.

9.22. Visualización de escenarios competitivos

Los escenarios base, favorable y adverso pueden representarse conjuntamente para facilitar su comparación. Esta estructura permite observar cómo varían los indicadores bajo diferentes supuestos.

La visualización deberá evitar presentar los escenarios como futuros determinados. Cada uno representa una configuración condicional que depende de supuestos explícitos.

El usuario podrá modificar determinadas variables mediante funciones *what-if* y observar cómo cambian los resultados simulados. Esta interacción transforma el dashboard en un espacio de experimentación estratégica.

La representación de escenarios también permitirá identificar estrategias robustas, es decir, aquellas que mantienen resultados aceptables bajo diferentes condiciones.

9.23. Visualización de riesgos y oportunidades

Los riesgos identificados mediante simulación pueden representarse según probabilidad, impacto o prioridad. Sin embargo, el diseño debe



evitar representaciones que simplifiquen excesivamente situaciones complejas.

Las oportunidades también deberán incorporarse al dashboard. Un sistema orientado a competitividad no debe concentrarse únicamente en advertir problemas, sino ayudar a reconocer condiciones favorables que pueden justificar determinadas acciones.

Una matriz de riesgos y oportunidades puede proporcionar una visión general, mientras que elementos interactivos permiten profundizar en cada situación.

Esta estructura contribuye a que el dashboard adopte una función estratégica y no únicamente de control operativo.

9.24. Storytelling de datos para la gestión empresarial

La visualización avanzada puede complementarse mediante principios de narrativa de datos. Su finalidad consiste en organizar indicadores y gráficos siguiendo una secuencia que facilite comprender un problema y sus posibles implicaciones.

Una narrativa empresarial puede comenzar mostrando una variación relevante, continuar con los factores relacionados, incorporar la predicción y finalizar con escenarios o alternativas. Esta estructura facilita recorrer progresivamente el proceso analítico.

El *storytelling* no debe utilizarse para persuadir al usuario hacia una conclusión previamente seleccionada. Su función consiste en organizar

información compleja para facilitar su comprensión manteniendo visibles las evidencias y la incertidumbre.

En el proyecto, esta lógica permitirá transformar conjuntos de gráficos independientes en recorridos analíticos vinculados con problemas empresariales concretos.

9.25. Interactividad y exploración de datos

La interactividad constituye una característica central de los dashboards modernos. Filtros, selecciones y funciones de profundización permiten que el usuario explore los datos según sus necesidades (Alvarado Apodaca et al., 2025).

La interacción facilita pasar desde una visión agregada hacia información específica. Un gerente puede comenzar observando ventas generales y posteriormente analizar un período, segmento o categoría particular.

Sin embargo, una cantidad excesiva de controles puede incrementar la complejidad de uso. El diseño deberá proporcionar únicamente aquellas interacciones que aporten valor analítico.

La plataforma combinará filtros básicos con opciones avanzadas accesibles progresivamente, manteniendo una experiencia adecuada para usuarios con distintos niveles de experiencia tecnológica.

9.26. Actualización y calidad de los datos

La utilidad de un dashboard depende directamente de la información que lo alimenta. Datos incompletos, duplicados o desactualizados pueden producir indicadores incorrectos independientemente de la calidad visual de la interfaz.

Por esta razón, la arquitectura de BI debe incorporar procesos de validación, limpieza y transformación antes de presentar la información. El usuario también necesita conocer la fecha de actualización para interpretar correctamente los indicadores (Dorado Bastidas et al., 2023). Los modelos predictivos requieren controles adicionales debido a que cambios en la distribución de los datos pueden reducir progresivamente su desempeño.

El dashboard podrá incluir indicadores técnicos simplificados sobre actualización y calidad de datos, aumentando la transparencia de la plataforma.

9.27. Usabilidad del dashboard

La usabilidad representa la capacidad del sistema para permitir que los usuarios alcancen sus objetivos de manera comprensible y eficiente. Estudios recientes sobre dashboards interactivos destacan que la utilidad analítica debe complementarse con interfaces que faciliten navegación e interpretación (Alvarado Apodaca et al., 2025).

Para empresarios sin formación especializada en analítica, resulta especialmente importante evitar terminología innecesariamente técnica. Las denominaciones deberán relacionarse con conceptos conocidos dentro de la gestión empresarial.

La jerarquía visual también debe orientar la atención. Los indicadores prioritarios ocuparán posiciones predominantes, mientras que los detalles metodológicos permanecerán disponibles en niveles secundarios.



La evaluación del prototipo deberá incluir pruebas con usuarios para determinar si las representaciones realmente permiten comprender los resultados y no únicamente si funcionan técnicamente.

9.28. Dashboards para micro y pequeñas empresas

Las micro y pequeñas empresas pueden beneficiarse de BI al disponer de mecanismos que integren información y faciliten decisiones, aunque enfrentan restricciones relacionadas con recursos, capacidades digitales y calidad de los registros (Chinchuña et al., 2026).

Estas condiciones obligan a evitar arquitecturas innecesariamente complejas. El dashboard debe concentrarse inicialmente en indicadores que puedan obtenerse de manera confiable y ampliar progresivamente sus capacidades.

La simplicidad no significa reducir la capacidad analítica. Una interfaz sencilla puede estar respaldada por modelos complejos siempre que los resultados se traduzcan adecuadamente para el usuario.

Esta característica resulta central para el proyecto, cuyo propósito consiste en acercar herramientas de segmentación, predicción y recomendación a empresas que no necesariamente disponen de equipos internos de ciencia de datos.

9.29. Dashboard inteligente propuesto para la plataforma

El dashboard central de la plataforma puede organizarse mediante seis módulos principales:



Módulo 1. Situación empresarial: KPI actuales, evolución histórica y comparaciones.

Módulo 2. Segmentación: segmento identificado, perfil y variables diferenciadoras.

Módulo 3. Predicción: pronósticos, tendencias e incertidumbre.

Módulo 4. Explicabilidad: variables relevantes y explicaciones globales/locales.

Módulo 5. Prescripción: escenarios, riesgos, oportunidades y estrategias priorizadas.

Módulo 6. Alertas: desviaciones relevantes, nivel de prioridad y acciones sugeridas.

Esta organización permite que el usuario avance desde una visión general hacia niveles progresivamente más analíticos sin abandonar una interfaz común.

9.30. Arquitectura integral del dashboard inteligente

La arquitectura propuesta puede representarse mediante el siguiente flujo:

FUENTES DE DATOS EMPRESARIALES

↓

INTEGRACIÓN, LIMPIEZA Y VALIDACIÓN

↓

BUSINESS INTELLIGENCE

↓

KPI Y ANALÍTICA DESCRIPTIVA

↓

SEGMENTACIÓN AUTOMATIZADA

↓



PERFILES EMPRESARIALES

↓

ANALÍTICA PREDICTIVA

↓

PREDICCIONES + INCERTIDUMBRE

↓

XAI: EXPLICACIÓN VISUAL

↓

ALERTAS INTELIGENTES

↓

MOTOR DE RECOMENDACIÓN

↓

SIMULACIÓN DE ESCENARIOS

↓

ANALÍTICA PRESCRIPTIVA

↓

RECOMENDACIONES PRIORIZADAS

↓

DASHBOARD ADAPTATIVO

↓

DECISIÓN GERENCIAL

↓

RETROALIMENTACIÓN Y APRENDIZAJE

La arquitectura evidencia que el dashboard no constituye el punto inicial del proceso analítico, sino la interfaz final donde convergen diferentes componentes de procesamiento, modelado y recomendación.



9.31. Modelo conceptual del dashboard para competitividad

El modelo conceptual puede organizarse mediante seis dimensiones: **información, anticipación, explicación, alerta, prescripción e interacción**.

La dimensión de **información** presenta KPI y resultados históricos; la **anticipación** incorpora predicciones; la **explicación** comunica los factores asociados con los resultados algorítmicos; la **alerta** identifica condiciones que requieren atención; la **prescripción** muestra escenarios y recomendaciones; y la **interacción** permite explorar la información.
Estas dimensiones convierten el dashboard en una arquitectura analítica multidimensional y evitan reducirlo a un conjunto de gráficos descriptivos.

La integración también permite conservar trazabilidad desde los datos originales hasta las recomendaciones presentadas al usuario.

9.32. Dashboard como interfaz entre inteligencia artificial e inteligencia empresarial

Los modelos de inteligencia artificial pueden producir resultados difíciles de utilizar directamente por usuarios sin formación especializada. El dashboard funciona como una capa de traducción entre los resultados computacionales y el lenguaje empresarial.

Una probabilidad puede convertirse en una alerta; un clúster en un perfil; una contribución SHAP en una explicación visual; una simulación en un



escenario; y el resultado del motor prescriptivo en una alternativa estratégica.

Esta transformación debe conservar la información esencial del modelo. Simplificar la presentación no significa eliminar incertidumbre, limitaciones o condiciones necesarias para interpretar adecuadamente los resultados.

El dashboard inteligente constituye, por tanto, el espacio donde convergen inteligencia artificial e inteligencia empresarial para proporcionar información analítica comprensible al responsable de la decisión.

9.33. Contribución del dashboard a la competitividad empresarial

La contribución de un dashboard a la competitividad no procede únicamente de disponer de gráficos en tiempo real. Su valor depende de que la información permita detectar cambios, anticipar problemas, reconocer oportunidades y evaluar alternativas con suficiente anticipación (Pérez Jesús et al., 2024; Cedeño-Mendoza & Zambrano-Santos, 2026).

Los dashboards también pueden reducir el tiempo necesario para localizar y consolidar información, permitiendo que los responsables dediquen mayor atención a su interpretación. Estudios recientes han encontrado beneficios de los tableros interactivos en la integración y disponibilidad de información para decisiones empresariales (Alvarado Apodaca et al., 2025).



Sin embargo, la tecnología por sí sola no garantiza competitividad. Calidad de datos, capacidad organizacional para interpretar resultados y utilización efectiva de las recomendaciones continúan siendo condiciones fundamentales.

Por esta razón, el proyecto concibe el dashboard como un sistema de apoyo y no como un sustituto de la gestión. Su finalidad consiste en aumentar la capacidad informativa y analítica disponible para el empresario.

9.34. Síntesis del capítulo

Los dashboards constituyen un componente fundamental de las arquitecturas contemporáneas de inteligencia de negocios porque permiten integrar indicadores y visualizaciones dentro de un entorno orientado a la interpretación. Su evolución reciente incorpora interactividad y capacidades analíticas que amplían su función tradicional de reporte (Cruz Osorio et al., 2022; Alvarado Apodaca et al., 2025).

Business Intelligence proporciona la infraestructura necesaria para transformar datos empresariales en información organizada. La evidencia reciente muestra su relevancia para la toma de decisiones y su potencial aplicación en PYMES, aunque los resultados dependen de la calidad de los datos y de las capacidades organizacionales para utilizar las herramientas analíticas (Pérez Jesús et al., 2024; Chinchuña et al., 2026). Los KPI constituyen mecanismos de síntesis que permiten monitorear dimensiones relevantes del desempeño. Su selección debe responder a objetivos empresariales y evitar la acumulación de indicadores que no



aporten información significativa para la decisión (Cedeño-Mendoza & Zambrano-Santos, 2026).

La visualización transforma datos y resultados algorítmicos en representaciones que facilitan reconocer tendencias, diferencias y anomalías. Una visualización efectiva requiere seleccionar el gráfico según la pregunta analítica y reducir elementos que dificulten la interpretación (Grisales Aguirre et al., 2024).

Los tableros predictivos incorporan una dimensión prospectiva al integrar estimaciones y tendencias futuras. Para evitar interpretaciones excesivamente deterministas, estas representaciones deberán distinguir claramente entre valores observados y predicciones e incorporar incertidumbre cuando sea posible.

La visualización de segmentos permitirá transformar los resultados del clustering en perfiles empresariales interpretables. Cada segmento podrá relacionarse con indicadores, predicciones y recomendaciones diferenciadas.

Las alertas inteligentes dirigirán la atención hacia desviaciones relevantes, combinando reglas con resultados analíticos. Su priorización evitará saturar al usuario con señales de escaso valor estratégico.

La incorporación de XAI permitirá explicar visualmente las predicciones. Los factores asociados con cada resultado podrán



presentarse mediante gráficos y lenguaje empresarial, fortaleciendo la transparencia del sistema.

Los dashboards adaptativos permitirán modificar la información presentada según el perfil y contexto del usuario. Esta personalización deberá mantener transparencia y conservar el acceso a información relevante.

La integración de analítica descriptiva, predictiva y prescriptiva constituye el principal elemento diferenciador del dashboard propuesto. El sistema permitirá conocer el desempeño histórico, anticipar comportamientos y evaluar alternativas estratégicas dentro de un mismo entorno.

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, el dashboard representa la interfaz que conecta todos los componentes tecnológicos desarrollados durante los capítulos anteriores.

La arquitectura integral puede sintetizarse mediante la secuencia:

DATOS → KPI → VISUALIZACIÓN → SEGMENTACIÓN → PREDICCIÓN → EXPLICACIÓN → ALERTA → RECOMENDACIÓN → SIMULACIÓN → PRESCRIPCIÓN → DASHBOARD ADAPTATIVO → DECISIÓN HUMANA → RETROALIMENTACIÓN.



De esta manera, el dashboard deja de funcionar únicamente como un mecanismo de consulta y se transforma en un entorno inteligente de apoyo a decisiones empresariales, capaz de integrar información histórica, conocimiento predictivo, explicaciones algorítmicas y alternativas estratégicas. Su contribución a la competitividad dependerá finalmente de la calidad de los datos, desempeño de los modelos, claridad de las visualizaciones y capacidad del usuario para incorporar la evidencia analítica a sus decisiones.



CAPÍTULO 10.

INTELIGENCIA ARTIFICIAL GENERATIVA COMO ASISTENTE ESTRATÉGICO EMPRESARIAL.

10.1. Inteligencia artificial generativa en el contexto empresarial

La inteligencia artificial generativa constituye una evolución relevante dentro del desarrollo contemporáneo de la inteligencia artificial debido a su capacidad para producir nuevo contenido a partir de patrones aprendidos durante el entrenamiento. A diferencia de sistemas orientados exclusivamente hacia clasificación o predicción, los modelos generativos pueden producir texto, código, imágenes, resúmenes y otras representaciones, ampliando las posibilidades de interacción entre personas y sistemas computacionales (Cortés Hernández et al., 2024; Mora-Delgado et al., 2026).

En el ámbito empresarial, esta capacidad permite concebir la IA generativa como una interfaz entre información compleja y usuarios que no necesariamente poseen conocimientos especializados en ciencia de datos. Mediante instrucciones expresadas en lenguaje natural, los responsables empresariales pueden solicitar síntesis, explicaciones, comparaciones o alternativas construidas a partir de la información disponible, siempre que la arquitectura tecnológica controle adecuadamente las fuentes utilizadas y la calidad de las respuestas (Álava Naranjo et al., 2026).

El interés empresarial por estas tecnologías no debería reducirse a la automatización de redacción. Su potencial estratégico aparece cuando la capacidad generativa se conecta con datos, indicadores, modelos predictivos y conocimiento organizacional, permitiendo convertir resultados técnicos en explicaciones y alternativas más accesibles para los responsables de decisión (Segura Ibarra, 2026).

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, la IA generativa se propone como una capa conversacional que complementará los modelos desarrollados en capítulos anteriores. Su función no será sustituir los algoritmos predictivos, sino facilitar la consulta, interpretación y comunicación de sus resultados.

10.2. Diferencia entre inteligencia artificial predictiva y generativa

La inteligencia artificial predictiva utiliza información histórica para estimar resultados futuros o clasificar nuevas observaciones. Modelos de regresión, clasificación, series temporales y otros algoritmos de aprendizaje automático pueden identificar patrones y generar estimaciones cuantitativas acerca del comportamiento esperado de una variable.

La IA generativa cumple una función diferente. Su fortaleza principal reside en generar contenido coherente a partir de instrucciones y contexto. Cuando se integra con un modelo predictivo, puede explicar en lenguaje natural una predicción previamente calculada, pero no debe suponerse que la generación textual constituye por sí misma un



procedimiento predictivo estadísticamente validado (Mora-Delgado et al., 2026).

Esta diferencia resulta fundamental para la arquitectura propuesta. El modelo de series temporales será responsable, por ejemplo, de calcular una predicción de ventas; las herramientas XAI determinarán los factores relacionados con determinados resultados; mientras que la IA generativa podrá convertir esos elementos en una explicación comprensible para el empresario.

La separación de responsabilidades permite evitar que un modelo de lenguaje improvise cifras que deberían proceder de algoritmos especializados. La IA generativa deberá trabajar sobre información proporcionada por componentes analíticos validados, conservando la trazabilidad entre datos, resultados y explicación.

10.3. Modelos de lenguaje de gran tamaño

Los modelos de lenguaje de gran tamaño, conocidos como LLM por la expresión *Large Language Models*, constituyen una de las tecnologías fundamentales de la IA generativa contemporánea. Estos modelos aprenden patrones lingüísticos mediante grandes volúmenes de información y utilizan representaciones matemáticas para procesar secuencias de lenguaje y generar nuevas respuestas (Mora-Delgado et al., 2026).

La capacidad de los LLM para trabajar con lenguaje natural permite desarrollar interfaces conversacionales considerablemente más flexibles



que los sistemas tradicionales basados exclusivamente en comandos predefinidos. El usuario puede formular preguntas utilizando expresiones cercanas a su forma habitual de comunicación y recibir respuestas adaptadas al contexto proporcionado (Cortés Hernández et al., 2024).

Sin embargo, la fluidez lingüística de un LLM no garantiza la exactitud de sus afirmaciones. El modelo genera respuestas utilizando relaciones aprendidas y contexto disponible, por lo que puede producir información incorrecta, incompleta o aparentemente convincente sin suficiente respaldo. Esta característica obliga a establecer mecanismos de validación cuando la tecnología se utiliza en procesos empresariales (Mora-Delgado et al., 2026).

En consecuencia, el proyecto no utilizará el modelo de lenguaje como fuente autónoma de verdad empresarial. Su función será interpretar y comunicar información obtenida de bases de datos, modelos analíticos y conocimiento empresarial previamente estructurado.

10.4. IA generativa como asistente estratégico

La noción de asistente estratégico implica utilizar IA generativa como una herramienta que acompaña al responsable empresarial durante el proceso de análisis. En lugar de limitarse a responder preguntas generales, el sistema puede contextualizar sus respuestas utilizando información específica de la organización (Álava Naranjo et al., 2026).

Un asistente de estas características podría explicar indicadores, resumir tendencias, describir segmentos, interpretar predicciones y presentar alternativas generadas por el sistema recomendador. Esta integración



reduce la distancia existente entre la complejidad técnica de los modelos y las necesidades informativas del gerente (Segura Ibarra, 2026).

La IA generativa puede contribuir especialmente en pequeñas y medianas empresas, donde las capacidades internas de análisis especializado pueden ser limitadas. La literatura reciente identifica oportunidades para utilizar estas herramientas en dimensiones operativas, estratégicas, comunicativas y adaptativas de las PYMES (Segura Ibarra, 2026).

No obstante, denominar al sistema "asistente estratégico" implica mantener claramente diferenciadas la asistencia y la decisión. El modelo puede sintetizar información y generar alternativas, pero la responsabilidad sobre las decisiones continúa correspondiendo al gerente o empresario (Álava Naranjo et al., 2026).

10.5. Interacción conversacional con datos empresariales

Una de las aplicaciones más relevantes de los modelos de lenguaje consiste en permitir que los usuarios interactúen con sistemas tecnológicos mediante lenguaje natural. En un entorno empresarial, esta capacidad puede utilizarse para consultar datos sin requerir que el usuario conozca lenguajes de programación o procedimientos técnicos especializados (Cortés Hernández et al., 2024).

En lugar de navegar por múltiples tablas, el gerente podría formular preguntas como: **¿cómo evolucionaron mis ventas durante los últimos seis meses?**, **¿qué segmento presenta mayor crecimiento?**, **¿qué productos redujeron su demanda?** o **¿qué indicadores requieren atención?**. El sistema convertiría estas consultas en solicitudes estructuradas hacia las fuentes autorizadas.

La respuesta conversacional deberá generarse a partir de datos recuperados de la plataforma y no exclusivamente del conocimiento general del modelo. Esta separación permite reducir el riesgo de presentar cifras empresariales que no procedan de registros verificables. Por consiguiente, la arquitectura conversacional deberá mantener trazabilidad entre pregunta, fuente consultada, resultado analítico y respuesta generada. Esta característica resulta fundamental para utilizar IA generativa de forma responsable en procesos empresariales.

10.6. De los dashboards a la inteligencia empresarial conversacional

Los dashboards desarrollados en el capítulo anterior permiten explorar visualmente indicadores, segmentos, predicciones y recomendaciones. Sin embargo, determinados usuarios pueden requerir una forma todavía más directa de consultar la información.

La IA generativa puede complementar la visualización mediante una interfaz conversacional. El usuario puede observar un indicador y preguntar inmediatamente por su significado, evolución o relación con otros resultados, sin abandonar el entorno analítico.

Esta combinación no implica sustituir los dashboards. Las visualizaciones resultan apropiadas para identificar tendencias y realizar comparaciones, mientras que la conversación puede facilitar explicaciones y consultas específicas. Ambas modalidades pueden funcionar de manera complementaria.



La plataforma propuesta integrará, por tanto, **inteligencia visual e inteligencia conversacional**. El usuario podrá explorar gráficamente la información y posteriormente utilizar lenguaje natural para profundizar en aquellos resultados que requieran mayor interpretación.

10.7. Consultas empresariales en lenguaje natural

La interacción mediante lenguaje natural puede reducir determinadas barreras de acceso a la analítica. Un empresario no necesita conocer el nombre técnico de un algoritmo para solicitar una explicación sobre el comportamiento de sus ventas o clientes (Cortés Hernández et al., 2024). El asistente deberá interpretar la intención del usuario y relacionarla con los componentes apropiados de la plataforma. Una consulta sobre ventas históricas requerirá información descriptiva; una pregunta sobre ventas futuras deberá consultar el modelo predictivo; y una pregunta sobre posibles acciones deberá recurrir al componente prescriptivo o recomendador.

Esta arquitectura evita que todas las preguntas sean respondidas directamente por el modelo generativo. El LLM funciona principalmente como mecanismo de interpretación y comunicación, mientras que los componentes especializados proporcionan la información analítica.

La respuesta podrá incluir simultáneamente texto, indicadores y visualizaciones. Esta combinación permite construir una experiencia de consulta más completa que una conversación exclusivamente textual.



10.8. Generación automática de informes empresariales

La elaboración de informes constituye otra aplicación relevante de la IA generativa. Los sistemas pueden transformar datos estructurados y resultados analíticos en borradores narrativos que describan tendencias, variaciones y acontecimientos relevantes (Segura Ibarra, 2026).

Un informe automatizado puede integrar indicadores del período, variaciones respecto de períodos anteriores, predicciones y alertas. El modelo generativo organiza estos elementos dentro de una narrativa coherente, reduciendo el trabajo manual necesario para preparar documentos periódicos.

La automatización no debe significar que el modelo invente interpretaciones para completar el informe. Los valores cuantitativos deberán obtenerse directamente de la plataforma y mantenerse vinculados con sus fuentes.

El usuario deberá disponer además de mecanismos para revisar y editar el documento antes de utilizarlo externamente. La IA generativa puede producir un borrador avanzado, pero la validación humana permanece necesaria cuando el contenido participa en decisiones o comunicaciones empresariales.

10.9. Informes gerenciales inteligentes

Los informes gerenciales pueden evolucionar desde documentos estáticos hacia productos personalizados según las necesidades del destinatario. Un propietario puede requerir una síntesis ejecutiva,



mientras que un responsable comercial puede necesitar información detallada sobre clientes y segmentos.

La IA generativa permite adaptar la profundidad, extensión y lenguaje del informe utilizando los mismos resultados analíticos. Esta capacidad evita generar manualmente diferentes versiones para distintos perfiles.
Un informe ejecutivo podría concentrarse en cinco componentes: situación actual, principales cambios, predicciones, riesgos y recomendaciones. Los detalles metodológicos podrían incorporarse como anexos o niveles adicionales.

La personalización deberá mantener consistencia factual. Cambiar el estilo o nivel de detalle no debe modificar los datos, resultados o incertidumbre asociados con los modelos.

10.10. Explicación automática de KPI

Los KPI proporcionan información sintética, pero su interpretación puede requerir contexto. Un indicador aislado muestra un valor; una explicación añade información sobre su evolución, comparación y posible relevancia.

La IA generativa puede convertir la información estructurada del dashboard en explicaciones narrativas. Si un KPI presenta una variación importante, el sistema puede describir cuánto cambió, respecto de qué período y qué otros indicadores presentan movimientos relacionados.



La explicación debe diferenciar cuidadosamente observación e interpretación. El hecho de que dos indicadores cambien simultáneamente no demuestra que uno haya causado al otro.

Por ello, el asistente deberá utilizar expresiones compatibles con la evidencia disponible, distinguiendo entre hechos observados, relaciones estadísticas, predicciones y recomendaciones.

10.11. Explicación conversacional de predicciones

Los resultados predictivos pueden resultar difíciles de interpretar cuando se presentan exclusivamente mediante valores numéricos. La IA generativa puede actuar como capa de comunicación para convertir esos resultados en explicaciones comprensibles.

El asistente podría comunicar la dirección de la predicción, horizonte temporal, incertidumbre y principales factores identificados mediante XAI. Esta información proporcionaría una respuesta más completa que una cifra aislada.

La explicación deberá provenir de resultados calculados previamente. El LLM no determinará por sí mismo cuáles variables son importantes; recibirá, por ejemplo, valores SHAP generados por la capa XAI y los transformará en una explicación narrativa.

La secuencia propuesta será:

Modelo predictivo → resultado → XAI → factores explicativos → IA generativa → explicación empresarial.

10.12. IA generativa e Inteligencia Artificial Explicable



La integración entre XAI e IA generativa representa una oportunidad para mejorar la comunicación de modelos complejos. Las herramientas explicativas generan resultados técnicos que posteriormente pueden traducirse mediante lenguaje natural.

SHAP puede identificar qué variables contribuyeron con mayor intensidad a una predicción; el modelo generativo puede convertir estas contribuciones en una explicación orientada al usuario, conservando el significado original del análisis.

Sin embargo, la generación narrativa introduce una nueva capa que también debe ser controlada. Una explicación técnicamente correcta puede distorsionarse si el modelo añade relaciones causales o conclusiones no contenidas en los resultados XAI.

Por esta razón, las instrucciones del sistema deberán limitar la explicación a la evidencia disponible y mantener una clara separación entre contribución predictiva y causalidad.

10.13. Generación asistida de estrategias empresariales

La IA generativa posee capacidad para producir alternativas textuales, lo que permite utilizarla como apoyo durante procesos de ideación estratégica. En el contexto empresarial puede contribuir a formular opciones a partir de objetivos, restricciones y resultados analíticos (Álava Naranjo et al., 2026).



Sin embargo, solicitar estrategias directamente a un modelo general puede producir recomendaciones genéricas o insuficientemente vinculadas con la realidad de la empresa. El valor aumenta cuando la generación se encuentra condicionada por información específica del negocio.

La plataforma proporcionará al asistente el segmento empresarial, indicadores, predicciones, factores explicativos, escenarios y restricciones. La generación estratégica se realizará, por tanto, dentro de un contexto previamente delimitado.

Las estrategias generadas podrán considerarse **alternativas candidatas**. Antes de presentarlas como recomendaciones prioritarias deberán ser evaluadas mediante las reglas, criterios y mecanismos prescriptivos desarrollados en capítulos anteriores.

10.14. IA generativa y sistemas de recomendación

Los sistemas recomendadores del Capítulo 7 seleccionan y priorizan alternativas mediante perfiles, reglas y conocimiento estructurado. La IA generativa puede complementar este proceso proporcionando explicaciones y desarrollando narrativamente las estrategias seleccionadas.

El motor recomendador puede determinar qué acción presenta mayor correspondencia con las condiciones empresariales, mientras que la IA generativa explica qué significa la estrategia, cuáles serían sus etapas y qué indicadores podrían utilizarse para monitorearla.



Esta separación resulta metodológicamente conveniente porque evita delegar todo el proceso de recomendación a un modelo lingüístico. El componente estructurado determina la pertinencia y el modelo generativo facilita la comunicación.

La arquitectura combina así la consistencia de un motor de recomendación con la flexibilidad comunicacional de los modelos generativos.

10.15. Integración con modelos predictivos

Una arquitectura empresarial avanzada puede combinar modelos predictivos especializados con IA generativa. Cada tecnología desempeña una función diferente dentro del flujo de análisis.

Los modelos predictivos calculan estimaciones mediante métodos estadísticos o aprendizaje automático. La IA generativa recibe los resultados y los contextualiza para el usuario, evitando reemplazar cálculos especializados por generación probabilística de lenguaje.

Por ejemplo, el modelo predictivo podría estimar una disminución de ventas del período siguiente. XAI identificaría los factores asociados; el motor prescriptivo evaluaría alternativas; y el modelo generativo produciría una explicación integrada.

La secuencia sería:

Predicción → explicación → simulación → recomendación → generación narrativa → evaluación humana.



10.16. IA generativa y simulación de escenarios

La IA generativa también puede facilitar la interacción con el componente de simulación. El usuario podría describir mediante lenguaje natural una situación que desea explorar y el sistema convertirla en parámetros estructurados.

Por ejemplo: **¿qué podría ocurrir si la demanda disminuye y mantengo el mismo presupuesto?**. La plataforma identificaría las variables correspondientes, ejecutaría la simulación y devolvería posteriormente los resultados.

La IA generativa no debería inventar el resultado del escenario. Su función consiste en interpretar la solicitud y explicar los resultados producidos por el motor de simulación.
Esta separación permite utilizar la flexibilidad del lenguaje natural sin sacrificar el rigor cuantitativo de los modelos prescriptivos.

10.17. Generación de recomendaciones contextualizadas

Las recomendaciones empresariales adquieren mayor utilidad cuando incorporan información contextual. Segmento, recursos, predicciones y restricciones pueden utilizarse para adaptar las alternativas a cada organización.

La IA generativa permite expresar estas recomendaciones de manera personalizada. Una misma estrategia puede explicarse con diferentes niveles de complejidad dependiendo de las características y necesidades del usuario.



La personalización, sin embargo, debe realizarse sobre una base analítica común. El estilo de comunicación puede cambiar, pero la evidencia que sustenta la recomendación debe conservarse.

El asistente podrá explicar no solamente **qué alternativa se recomienda**, sino también **por qué aparece, bajo qué condiciones podría aplicarse y qué indicadores deberían vigilarse**.

10.18. Recuperación aumentada por generación

Una estrategia relevante para mejorar la fundamentación de respuestas consiste en conectar el modelo generativo con fuentes de información seleccionadas. Esta arquitectura permite recuperar primero información pertinente y utilizarla posteriormente como contexto para generar una respuesta.

En un sistema empresarial, las fuentes pueden incluir datos internos, políticas, documentación, catálogos de estrategias y resultados analíticos. El modelo responde utilizando el contexto recuperado en lugar de depender exclusivamente del conocimiento adquirido durante su entrenamiento.

Esta arquitectura resulta particularmente apropiada para el proyecto porque permite construir un asistente conectado con información específica de cada empresa.

La recuperación contextual también mejora la trazabilidad, ya que el sistema puede identificar qué fuente empresarial fue utilizada para construir una determinada respuesta.



10.19. Base de conocimiento empresarial

El asistente estratégico necesitará una base de conocimiento estructurada que complemente los datos transaccionales. Esta base puede contener definiciones de KPI, reglas, estrategias, restricciones y documentación relevante.

La integración de conocimiento estructurado evita depender exclusivamente de respuestas abiertas generadas por el LLM. Cuando el usuario pregunta por un indicador, el sistema puede recuperar su definición institucional antes de construir la explicación.

La base también puede incorporar estrategias previamente validadas y condiciones de aplicación. De esta manera, la generación estratégica utiliza un repertorio controlado como punto de partida.

La combinación de base de conocimiento, datos empresariales y modelos analíticos constituye uno de los elementos centrales para desarrollar un asistente especializado en lugar de un chatbot genérico.

10.20. Agentes inteligentes

La evolución de la IA generativa ha impulsado arquitecturas en las que los modelos de lenguaje pueden interactuar con herramientas y ejecutar secuencias de tareas. Estos sistemas suelen conceptualizarse como agentes inteligentes cuando reciben objetivos, consultan recursos disponibles y coordinan acciones para completar determinadas actividades.



En el ámbito empresarial, un agente puede interpretar una solicitud, determinar qué información necesita, consultar un indicador, ejecutar un modelo y posteriormente sintetizar los resultados.

Esta arquitectura supera el modelo conversacional de pregunta-respuesta porque incorpora planificación y utilización coordinada de herramientas. Sin embargo, un mayor nivel de autonomía también incrementa la necesidad de controles. Las acciones que modifican datos generan compromisos o producen decisiones relevantes deben requerir niveles adecuados de autorización y supervisión humana.

10.21. Agentes especializados para la plataforma

La plataforma puede estructurar agentes especializados según diferentes funciones. Esta organización permite separar responsabilidades y facilitar la trazabilidad.

Un **agente analítico** podría consultar KPI y tendencias; un **agente predictivo** solicitar resultados de los modelos; un **agente explicativo** utilizaría información XAI; y un **agente estratégico** integraría escenarios y recomendaciones.

La coordinación entre estos componentes permitiría responder consultas complejas sin concentrar toda la lógica en un único modelo.

No obstante, la implementación debe mantenerse proporcional a la complejidad real del proyecto. Una arquitectura multiagente solamente se justifica cuando proporciona ventajas verificables respecto de una solución más sencilla.



10.22. Flujo de un agente estratégico empresarial

El agente estratégico puede seguir un proceso estructurado:

1. Interpretar la consulta.

2. Identificar la información necesaria.

3. Consultar fuentes autorizadas.

4. Solicitar resultados de modelos especializados.

5. Recuperar conocimiento empresarial.

6. Integrar la evidencia.

7. Generar una explicación o alternativa.

8. Mostrar fuentes y supuestos.

9. Solicitar evaluación humana cuando corresponda.

Esta secuencia permite diferenciar claramente recuperación, análisis y generación. El modelo lingüístico no sustituye cada componente, sino que coordina la interacción entre ellos.

10.23. Automatización de análisis periódicos

Los agentes también pueden utilizarse para revisar periódicamente determinados indicadores y generar resúmenes cuando aparecen cambios relevantes.

El sistema podría identificar nuevas alertas, consultar los modelos predictivos y preparar un informe ejecutivo que sintetice los principales acontecimientos del período.

Esta automatización puede reducir tareas repetitivas de seguimiento, especialmente cuando el empresario debe revisar múltiples indicadores. Sin embargo, la generación automática de un informe no debe implicar la ejecución automática de las estrategias sugeridas. El paso entre



recomendación y acción debe mantenerse sujeto a las reglas de autorización definidas por la plataforma.

10.24. Alucinaciones y confiabilidad de las respuestas

Uno de los principales desafíos de los modelos generativos corresponde a la posibilidad de producir afirmaciones incorrectas con apariencia lingüísticamente convincente. Esta característica resulta particularmente problemática cuando el usuario supone que una respuesta fluida es necesariamente verdadera (Mora-Delgado et al., 2026).

En una plataforma empresarial, una alucinación podría manifestarse mediante cifras inexistentes, relaciones no demostradas o estrategias sustentadas en información incorrecta. Por ello, los controles deben incorporarse desde el diseño.

Las respuestas cuantitativas deberán proceder de consultas verificables; las predicciones, de modelos especializados; y las recomendaciones, de componentes estructurados o evidencia recuperada.

Cuando la plataforma no disponga de información suficiente, el asistente deberá indicarlo explícitamente en lugar de completar la respuesta mediante información inventada.

10.25. Privacidad y seguridad de la información empresarial

La información utilizada por un asistente empresarial puede contener datos comerciales, financieros o estratégicos cuya exposición representa

un riesgo para la organización. Por ello, la incorporación de IA generativa requiere políticas claras de acceso y tratamiento de datos.

El sistema deberá limitar la información disponible para cada usuario según su autorización. No todas las personas necesitan acceder a la totalidad de los datos empresariales.

También deberá analizarse cuidadosamente qué información puede enviarse a servicios externos de modelos generativos y en qué condiciones contractuales y técnicas.

La privacidad debe considerarse una característica arquitectónica del sistema y no una corrección posterior a su implementación.

10.26. Gobernanza de la IA generativa

La incorporación de IA generativa requiere establecer responsabilidades sobre datos, modelos, respuestas y decisiones. La existencia de una herramienta capaz de producir recomendaciones no elimina la necesidad de gobernanza organizacional.

La plataforma deberá registrar aspectos como versión del modelo, fuentes consultadas, fecha de generación y componentes analíticos utilizados cuando una respuesta tenga relevancia estratégica.

La trazabilidad permite investigar posteriormente por qué el sistema produjo una determinada recomendación y facilita detectar errores.

La gobernanza también deberá establecer qué tipos de decisiones requieren necesariamente aprobación humana y cuáles pueden limitarse a funciones informativas.



10.27. Supervisión humana

La supervisión humana constituye un principio fundamental para el uso empresarial de IA generativa. La tecnología puede ampliar la capacidad para procesar información, pero continúa dependiendo de la calidad de los datos y del contexto proporcionado (Álava Naranjo et al., 2026).

El gerente deberá conservar la posibilidad de cuestionar, modificar o rechazar las recomendaciones. Esta capacidad evita convertir la automatización en una transferencia completa de responsabilidad hacia el algoritmo.

La plataforma deberá presentar suficiente evidencia para que la supervisión sea significativa. Pedir al usuario que apruebe una recomendación que no puede comprender no constituye una supervisión efectiva.

Por ello, explicación, trazabilidad y control humano deberán funcionar conjuntamente dentro de la arquitectura.

10.28. IA generativa para micro y pequeñas empresas

La IA generativa presenta oportunidades particulares para las PYMES porque permite acceder mediante interfaces relativamente sencillas a capacidades que anteriormente podían requerir conocimientos especializados. La literatura reciente identifica aplicaciones relacionadas con comunicación, análisis, apoyo estratégico y transformación empresarial (Segura Ibarra, 2026).



Esta accesibilidad no elimina las brechas relacionadas con datos, infraestructura y competencias digitales. Una empresa que no dispone de registros consistentes tendrá dificultades para obtener análisis personalizados confiables, aunque utilice modelos generativos avanzados.

Por ello, la adopción debe avanzar paralelamente con mejoras en gestión de datos y capacidades de los usuarios.

Para las microempresas consideradas en el proyecto, el principal valor del asistente residirá en simplificar la interacción con los componentes analíticos de la plataforma sin exigir conocimientos especializados de programación o ciencia de datos.

10.29. Asistente estratégico generativo propuesto

A partir de los componentes desarrollados, se propone un asistente capaz de responder a cinco categorías principales de consultas:

Consultas descriptivas: ¿qué está ocurriendo en mi empresa?

Consultas predictivas: ¿qué comportamiento se espera?

Consultas explicativas: ¿qué factores contribuyeron al resultado del modelo?

Consultas prescriptivas: ¿qué alternativas puedo evaluar?

Consultas estratégicas: ¿cómo puedo interpretar conjuntamente esta información para tomar una decisión?

Estas categorías permiten relacionar la conversación con los diferentes motores de la plataforma y evitar que el LLM intente responder todos los problemas mediante generación libre.



10.30. Ejemplo de interacción estratégica

Una interacción podría desarrollarse de la siguiente manera:

Empresario: ¿Cómo se comportarán mis ventas el próximo mes?

Sistema: consulta el modelo predictivo y recupera el pronóstico y su incertidumbre.

Empresario: ¿Por qué se espera ese comportamiento?

Sistema: consulta la capa XAI y explica los factores con mayor contribución.

Empresario: ¿Qué alternativas puedo evaluar?

Sistema: consulta el motor de recomendación y recupera estrategias compatibles.

Empresario: ¿Qué ocurriría si aplico la primera?

Sistema: ejecuta el componente de simulación y presenta escenarios.

Empresario: Resume todo para tomar una decisión.

Sistema: genera una síntesis que integra evidencia, incertidumbre, riesgos y alternativas.

Este ejemplo evidencia que la conversación constituye la interfaz, mientras que los resultados continúan siendo producidos por componentes especializados.

10.31. Arquitectura propuesta del asistente estratégico

La arquitectura integral puede representarse mediante el siguiente flujo:

USUARIO EMPRESARIAL

↓

INTERFAZ CONVERSACIONAL

↓

MODELO DE LENGUAJE / IA GENERATIVA



↓

ORQUESTADOR DE CONSULTAS

↓

FUENTES EMPRESARIALES + BASE DE CONOCIMIENTO

↓

BUSINESS INTELLIGENCE Y KPI

↓

SEGMENTACIÓN AUTOMATIZADA

↓

ANALÍTICA PREDICTIVA

↓

XAI

↓

MOTOR DE RECOMENDACIÓN

↓

SIMULACIÓN Y ANALÍTICA PRESCRIPTIVA

↓

IA GENERATIVA: SÍNTESIS Y EXPLICACIÓN

↓

DASHBOARD + RESPUESTA CONVERSACIONAL

↓

EVALUACIÓN HUMANA

↓

DECISIÓN EMPRESARIAL

↓

RETROALIMENTACIÓN



Esta arquitectura mantiene una separación explícita entre generación lingüística y cálculo analítico. El LLM actúa como interfaz y mecanismo de síntesis, mientras que los componentes especializados conservan responsabilidad sobre segmentación, predicción y simulación.

10.32. Modelo conceptual de IA generativa empresarial

El modelo conceptual puede organizarse mediante seis dimensiones: **conversación, recuperación, análisis, generación, validación y supervisión**.

La **conversación** permite expresar necesidades mediante lenguaje natural; la **recuperación** obtiene datos y conocimiento relevante; el **análisis** utiliza modelos especializados; la **generación** transforma resultados en contenido comprensible; la **validación** comprueba consistencia con las fuentes; y la **supervisión** mantiene la decisión bajo responsabilidad humana.

Estas dimensiones permiten evitar una concepción simplificada de la IA generativa como un chatbot aislado.

El valor estratégico aparece precisamente cuando el componente conversacional se integra de forma controlada con datos y modelos especializados.

10.33. Integración con la arquitectura general del libro

Los capítulos anteriores han desarrollado componentes complementarios que pueden integrarse progresivamente. La segmentación identifica



perfiles; la analítica predictiva anticipa comportamientos; XAI explica resultados; los motores de recomendación proponen alternativas; la analítica prescriptiva evalúa escenarios; y los dashboards presentan visualmente esta información.

La IA generativa incorpora una capa adicional: permite conversar con toda esta arquitectura y transformar los resultados técnicos en lenguaje natural.

El flujo completo puede representarse de la siguiente forma:

DATOS

↓

BUSINESS INTELLIGENCE

↓

SEGMENTACIÓN

↓

PREDICCIÓN

↓

EXPLICACIÓN XAI

↓

RECOMENDACIÓN

↓

SIMULACIÓN

↓

PRESCRIPCIÓN

↓

DASHBOARD INTELIGENTE

↓



IA GENERATIVA

↓

ASISTENTE ESTRATÉGICO

↓

DECISIÓN HUMANA

↓

RETROALIMENTACIÓN Y APRENDIZAJE

La IA generativa no reemplaza los componentes anteriores; funciona como una capa de interacción que facilita su utilización conjunta.

10.34. Del dashboard inteligente al copiloto empresarial

La incorporación de una interfaz generativa transforma conceptualmente el dashboard. El usuario deja de limitarse a navegar mediante filtros y puede establecer una conversación sobre los resultados.

Esta evolución permite concebir la plataforma como un **copiloto empresarial**, entendido como un sistema que acompaña al responsable durante la exploración de datos y alternativas.

El término copiloto también delimita adecuadamente su función: proporciona asistencia, pero no asume la responsabilidad final de conducción.

La combinación entre modelos especializados, IA explicable, simulación e IA generativa permite desarrollar un sistema con mayor capacidad de apoyo sin eliminar la intervención humana.



10.35. Síntesis del capítulo

La inteligencia artificial generativa representa una de las transformaciones recientes más relevantes dentro del desarrollo de sistemas inteligentes debido a su capacidad para producir contenido e interactuar mediante lenguaje natural. Los modelos de lenguaje constituyen una de las principales tecnologías que sustentan estas aplicaciones y permiten desarrollar interfaces conversacionales más flexibles (Mora-Delgado et al., 2026).

En el ámbito empresarial, su utilidad potencial supera la automatización de textos. La IA generativa puede facilitar análisis de información, preparación de informes, interpretación de resultados y formulación asistida de alternativas estratégicas, siempre que su implementación mantenga mecanismos adecuados de validación (Álava Naranjo et al., 2026).

La interacción conversacional puede reducir barreras técnicas al permitir que empresarios consulten información mediante lenguaje natural. Sin embargo, las respuestas sobre datos empresariales deberán generarse a partir de fuentes verificadas y no únicamente del conocimiento interno del modelo.

La generación automática de informes permite convertir KPI, tendencias, predicciones y alertas en narrativas adaptadas a diferentes perfiles. Estos documentos deben considerarse productos sujetos a revisión humana antes de su utilización en procesos relevantes.



La integración entre IA generativa y XAI permite transformar explicaciones técnicas en lenguaje empresarial. Para mantener fidelidad, el modelo generativo deberá limitarse a comunicar la evidencia producida por las técnicas explicativas sin añadir relaciones causales no demostradas.

La generación asistida de estrategias proporciona un espacio adicional para explorar alternativas. Su mayor utilidad se obtiene cuando las propuestas se condicionan mediante información sobre segmentos, predicciones, escenarios y restricciones en lugar de generarse de forma completamente abierta.

La integración con modelos predictivos permite establecer una separación funcional: los algoritmos especializados calculan resultados y la IA generativa los interpreta y comunica. Esta arquitectura reduce el riesgo de sustituir cálculos validados por respuestas lingüísticamente plausibles.

Los agentes inteligentes amplían esta capacidad al permitir que un sistema coordine consultas y herramientas. Sin embargo, mayores niveles de autonomía requieren controles adicionales de autorización, trazabilidad y supervisión.

Las alucinaciones representan una limitación crítica. Por esta razón, los datos cuantitativos, predicciones y recomendaciones deberán vincularse con fuentes y componentes verificables, mientras que el sistema deberá reconocer explícitamente cuando no dispone de información suficiente.



En las PYMES, la IA generativa puede contribuir a democratizar el acceso a capacidades analíticas mediante interfaces más sencillas. La evidencia reciente señala posibilidades de aplicación en dimensiones operativas, comunicativas, estratégicas y adaptativas, aunque los beneficios continúan dependiendo de calidad de datos, competencias digitales y utilización responsable (Segura Ibarra, 2026).

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, la IA generativa constituye la capa conversacional que integra los componentes tecnológicos desarrollados en los capítulos anteriores.
La propuesta completa evoluciona así desde una plataforma que procesa datos hacia un sistema capaz de **describir, segmentar, predecir, explicar, recomendar, simular, prescribir, visualizar y conversar** sobre la información empresarial.

La arquitectura final puede sintetizarse mediante:

DATOS → BI → SEGMENTACIÓN → PREDICCIÓN → XAI → RECOMENDACIÓN → SIMULACIÓN → PRESCRIPCIÓN → DASHBOARD → IA GENERATIVA → ASISTENTE ESTRATÉGICO → DECISIÓN HUMANA → RETROALIMENTACIÓN.

De esta manera, la IA generativa no constituye un elemento aislado incorporado únicamente por su actualidad tecnológica. Su función dentro



de la propuesta es actuar como **interfaz inteligente entre los modelos analíticos y el empresario**, transformando resultados computacionales complejos en explicaciones, consultas, informes y alternativas comprensibles. El valor estratégico continuará dependiendo de la calidad de los datos, la validez de los modelos, la trazabilidad de las respuestas y la capacidad humana para evaluar críticamente las recomendaciones antes de convertirlas en decisiones.



CAPÍTULO 11.

ÉTICA, GOBERNANZA Y CONFIANZA EN LA INTELIGENCIA ARTIFICIAL EMPRESARIAL.

11.1. Inteligencia artificial responsable en el ámbito empresarial

La incorporación de inteligencia artificial en las organizaciones amplía las posibilidades de automatización, predicción, personalización y apoyo a decisiones, pero simultáneamente introduce riesgos relacionados con equidad, privacidad, seguridad, transparencia y responsabilidad. Por esta razón, la adopción empresarial de IA no debería evaluarse exclusivamente en función de su precisión o eficiencia, sino también considerando las consecuencias que sus resultados pueden producir sobre personas, organizaciones y procesos de decisión (Ordoñez-Iturralde & Proaño-Piedra, 2024).

La ética aplicada a la inteligencia artificial proporciona principios para orientar el diseño, desarrollo y utilización de sistemas compatibles con valores humanos y responsabilidades organizacionales. En el ámbito empresarial, estos principios adquieren una dimensión práctica cuando se traducen en procedimientos relacionados con selección de datos, validación de modelos, protección de información, explicación de resultados, supervisión humana y gestión de riesgos (Parra Sepúlveda & Concha Machuca, 2025).

La gobernanza complementa esta dimensión ética mediante estructuras organizacionales que determinan quién puede desarrollar, aprobar,

modificar, utilizar y supervisar los sistemas inteligentes. De esta manera, los principios dejan de constituir únicamente declaraciones generales y se transforman en responsabilidades, controles, evidencias y mecanismos de seguimiento (ISO, 2023).

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación Automatizada, Predicción y Recomendación Estratégica**, la ética y la gobernanza constituyen una capa transversal. La plataforma deberá garantizar que los componentes de segmentación, predicción, explicación, recomendación, simulación e IA generativa funcionen dentro de criterios de responsabilidad, transparencia, seguridad y supervisión humana.

11.2. Ética de la inteligencia artificial

La ética de la IA estudia las implicaciones derivadas del desarrollo y utilización de sistemas capaces de influir sobre decisiones humanas. Entre sus principales preocupaciones se encuentran la posibilidad de producir discriminación, utilizar información de manera inapropiada, generar decisiones difíciles de explicar o trasladar indebidamente la responsabilidad desde las personas hacia los algoritmos (Ordoñez-Iturralde & Proaño-Piedra, 2024).

En una organización, la dimensión ética aparece desde las primeras etapas del ciclo de vida del sistema. Las decisiones sobre qué datos recopilar, qué variables incorporar, qué objetivo optimizar y qué resultados automatizar contienen elecciones que pueden producir



consecuencias posteriores sobre los usuarios (Parra Sepúlveda & Concha Machuca, 2025).

Por esta razón, la evaluación ética no debería realizarse únicamente después de implementar el sistema. Resulta metodológicamente más apropiado incorporar criterios responsables desde el diseño, continuar durante entrenamiento y validación y mantenerlos durante operación, actualización y eventual retiro del modelo (ISO, 2023).

La plataforma propuesta adoptará esta perspectiva de **ética por diseño**, procurando que transparencia, privacidad, seguridad, trazabilidad y supervisión humana formen parte de la arquitectura y no sean incorporadas únicamente como medidas correctivas posteriores.

11.3. Principios de inteligencia artificial responsable

La IA responsable puede comprenderse mediante un conjunto de principios que orientan la utilización de sistemas inteligentes. Aunque existen diferencias entre marcos institucionales, se observa convergencia alrededor de dimensiones como transparencia, equidad, privacidad, seguridad, responsabilidad y supervisión humana (Ordoñez-Iturralde & Proaño-Piedra, 2024).

Estos principios se encuentran estrechamente relacionados. Un modelo puede alcanzar elevada precisión y simultáneamente presentar problemas de discriminación; puede ser explicable y, sin embargo, utilizar datos sin una base legítima; o puede cumplir criterios de privacidad mientras presenta vulnerabilidades de seguridad.



Por consiguiente, la responsabilidad no puede reducirse a una única métrica. Requiere analizar el sistema como una arquitectura sociotécnica en la que interactúan datos, algoritmos, personas, procesos organizacionales y normas (ISO, 2023).

Para la plataforma empresarial se proponen como principios transversales: **legalidad, finalidad legítima, calidad de datos, equidad, privacidad, seguridad, transparencia, explicabilidad, trazabilidad, responsabilidad y supervisión humana**.

11.4. Sesgo algorítmico

Los modelos de aprendizaje automático identifican relaciones a partir de los datos utilizados durante su construcción. Cuando estos datos contienen desequilibrios, errores, exclusiones o patrones históricos problemáticos, el sistema puede reproducirlos o amplificarlos en sus resultados (Ordoñez-Iturralde & Proaño-Piedra, 2024).

El sesgo también puede introducirse mediante decisiones metodológicas. La selección de variables, definición del objetivo, procedimiento de muestreo, tratamiento de valores ausentes, construcción de etiquetas y elección de métricas pueden modificar el comportamiento del modelo.
Por esta razón, no resulta suficiente afirmar que un algoritmo es neutral porque realiza cálculos matemáticos. Sus resultados dependen de datos y decisiones humanas realizadas durante diferentes etapas del ciclo de desarrollo (Ordoñez-Iturralde & Proaño-Piedra, 2024).



La evaluación del sesgo deberá incorporarse tanto durante el desarrollo como durante la operación. Un modelo inicialmente aceptable puede modificar su comportamiento cuando cambia la población o la distribución de los datos, por lo que el seguimiento debe mantenerse después del despliegue.

11.5. Sesgo en segmentación empresarial

Los algoritmos de clustering pueden producir segmentos estadísticamente diferenciados sin que estos grupos representen necesariamente categorías empresariales neutrales. La selección de variables y la forma de medir similitud condicionan las agrupaciones obtenidas.

Por ejemplo, excluir variables relevantes o utilizar información que represente indirectamente determinadas características puede generar perfiles poco representativos. Por ello, los clústeres deberán interpretarse considerando tanto su validez estadística como su significado empresarial.

Las denominaciones de los segmentos también requieren precaución. Etiquetas como “empresa poco competitiva”, “cliente de bajo valor” o expresiones semejantes pueden incorporar juicios que exceden los resultados del algoritmo.

En consecuencia, la plataforma utilizará denominaciones descriptivas basadas en características observables y evitará convertir una agrupación estadística en una valoración absoluta sobre una empresa.



11.6. Sesgo en modelos predictivos

En los modelos supervisados, el sesgo puede manifestarse cuando el desempeño varía considerablemente entre grupos de observaciones. Una métrica agregada satisfactoria puede ocultar errores concentrados en determinados subconjuntos.

Por ello, además de evaluar el desempeño general, resulta conveniente analizar la distribución de errores y determinar si existen patrones sistemáticos asociados con determinadas características.

La utilización de XAI puede contribuir a esta revisión al mostrar qué variables utiliza el modelo y detectar dependencias inesperadas. Sin embargo, una explicación no demuestra automáticamente que el modelo sea equitativo.

La evaluación responsable combinará métricas predictivas, análisis de datos, explicabilidad y revisión humana antes de considerar un modelo suficientemente confiable para su utilización empresarial.

11.7. Privacidad de los datos empresariales

La inteligencia artificial depende de datos y, en determinadas aplicaciones, estos pueden incluir información personal. La recopilación y procesamiento de datos debe realizarse respetando principios de finalidad, proporcionalidad, seguridad y protección de los derechos de sus titulares.



En Ecuador, la Ley Orgánica de Protección de Datos Personales establece un marco aplicable al tratamiento automatizado y no automatizado de información personal. Entre otros elementos, contempla principios, derechos, obligaciones y medidas de seguridad que deben observar responsables y encargados del tratamiento (Ley Orgánica de Protección de Datos Personales, 2021).

La utilización de datos para entrenar modelos no elimina estas obligaciones. El hecho de que una organización disponga técnicamente de información no significa que pueda utilizarla para cualquier finalidad. Por esta razón, el proyecto deberá determinar qué información es realmente necesaria para cada modelo, evitando recopilar datos personales que no aporten valor significativo al objetivo analítico.

11.8. Minimización de datos

El principio de minimización implica utilizar únicamente la información necesaria para alcanzar una finalidad definida. Esta práctica reduce exposición innecesaria de información y disminuye las consecuencias potenciales de una vulneración.

En un sistema empresarial, puede existir la tendencia a recopilar la mayor cantidad posible de variables bajo la expectativa de que posteriormente podrían resultar útiles. Sin embargo, esta práctica incrementa complejidad y riesgo.

La selección de variables deberá combinar pertinencia analítica con necesidad. Si una característica no aporta valor suficiente al modelo o no



resulta necesaria para el objetivo declarado, su incorporación deberá ser reconsiderada.

Esta lógica permite integrar privacidad y ciencia de datos desde la fase de preparación de la información.

11.9. Protección de datos personales e inteligencia artificial en Ecuador

El contexto regulatorio ecuatoriano ha avanzado hacia una regulación más específica de los tratamientos de datos realizados mediante IA. La normativa emitida por la Superintendencia de Protección de Datos Personales en 2026 establece disposiciones aplicables a organizaciones que desarrollen, entrenen, implementen, desplieguen o provean sistemas de IA que traten datos personales de titulares ecuatorianos (Superintendencia de Protección de Datos Personales [SPDP], 2026).

Este enfoque resulta particularmente relevante para plataformas empresariales porque determinados datos de clientes, empleados, proveedores o usuarios pueden quedar comprendidos dentro del ámbito de protección.

El cumplimiento no debe limitarse a incorporar avisos de privacidad. Es necesario examinar finalidades, bases aplicables al tratamiento, medidas de seguridad, acceso a información, conservación y mecanismos para garantizar derechos.

Por ello, la plataforma deberá incorporar una matriz específica que relacione **dato → finalidad → tratamiento → responsable → período de conservación → medidas de protección**.

11.10. Privacidad desde el diseño

La privacidad desde el diseño implica incorporar protección de datos durante la arquitectura del sistema y no solamente después de su implementación.

Esto puede traducirse en prácticas como minimización, separación de información, control de accesos, anonimización o seudonimización cuando corresponda, registro de actividades y definición de períodos de conservación.

En modelos analíticos, también resulta conveniente analizar si realmente es necesario utilizar identificadores personales. En determinados casos, el modelo puede trabajar con información agregada o seudonimizada sin perder utilidad.

La plataforma adoptará esta perspectiva para reducir la exposición de datos y mantener una correspondencia clara entre información utilizada y finalidad empresarial.

11.11. Seguridad de los sistemas de inteligencia artificial

La seguridad constituye otra dimensión esencial de la IA responsable. Los modelos pueden ser afectados por accesos no autorizados,

manipulación de datos, alteración de parámetros, exposición de información o utilización indebida de sus interfaces.

La Ley Orgánica de Protección de Datos Personales ecuatoriana exige adoptar medidas adecuadas para proteger los datos frente a riesgos, amenazas y vulnerabilidades, considerando naturaleza y contexto del tratamiento (Ley Orgánica de Protección de Datos Personales, 2021).
En una plataforma inteligente, la seguridad debe extenderse más allá de la base de datos. Deben protegerse modelos, credenciales, interfaces de programación, registros, archivos de entrenamiento y mecanismos de integración con servicios externos.

La arquitectura deberá adoptar controles proporcionales al riesgo, combinando medidas técnicas y organizativas.

11.12. Seguridad de la IA generativa

La incorporación de modelos generativos introduce riesgos adicionales. Las instrucciones proporcionadas por los usuarios pueden contener información sensible y determinadas integraciones pueden permitir que el modelo acceda a herramientas o fuentes empresariales.
Por esta razón, el asistente generativo no deberá disponer de acceso irrestricto a toda la información. Los permisos deberán determinar qué datos y herramientas puede utilizar cada usuario.

Las entradas también deberán ser tratadas como contenido potencialmente no confiable. Un sistema conectado con herramientas

empresariales requiere mecanismos que impidan que instrucciones manipuladas produzcan acciones no autorizadas.

La seguridad deberá diseñarse considerando conjuntamente usuario, modelo, datos, herramientas conectadas y acciones permitidas.

11.13. Transparencia algorítmica

La transparencia implica proporcionar información suficiente sobre la finalidad, funcionamiento y limitaciones de un sistema de IA. Esto no significa necesariamente exponer cada operación matemática o publicar código fuente, sino permitir que usuarios y responsables comprendan los elementos esenciales del proceso (Parra Sepúlveda & Concha Machuca, 2025).

En una aplicación empresarial, la transparencia puede incluir información sobre datos utilizados, modelo implementado, fecha de entrenamiento, desempeño, variables principales, limitaciones y mecanismos de explicación.

La transparencia debe adaptarse al usuario. Un científico de datos requiere información diferente a la de un gerente, aunque ambos necesitan elementos suficientes para evaluar el sistema.

La plataforma implementará niveles progresivos de transparencia: información ejecutiva para usuarios empresariales y documentación técnica más detallada para responsables de administración y auditoría.



11.14. Explicabilidad y confianza

La explicabilidad contribuye a que los usuarios comprendan los factores asociados con los resultados algorítmicos. Esta característica resulta especialmente relevante cuando los modelos participan en procesos de decisión (Parra Sepúlveda & Concha Machuca, 2025).

Sin embargo, una explicación no debería utilizarse únicamente para persuadir al usuario. Su finalidad consiste en proporcionar elementos que permitan aceptar, cuestionar o rechazar un resultado.

La confianza adecuada es, por tanto, una **confianza calibrada**. El usuario debe conocer cuándo un modelo posee evidencia suficiente y cuándo existen limitaciones que justifican una revisión adicional.

El sistema deberá presentar explicaciones juntamente con métricas, incertidumbre y advertencias cuando corresponda.

11.15. Responsabilidad humana

La utilización de IA no elimina la responsabilidad humana sobre las decisiones organizacionales. Un algoritmo puede proporcionar predicciones o recomendaciones, pero las personas continúan siendo responsables de establecer objetivos, seleccionar modelos y decidir cómo utilizar sus resultados (ISO, 2023).

Esta responsabilidad adquiere mayor importancia cuando las decisiones producen consecuencias significativas. Delegar una decisión al sistema sin mecanismos de supervisión puede generar dificultades para identificar quién debe responder ante errores.



Por ello, la arquitectura deberá establecer claramente qué procesos son informativos, cuáles producen recomendaciones y cuáles requieren aprobación humana.

La responsabilidad no deberá quedar distribuida de manera indefinida entre desarrolladores, proveedores y usuarios. Cada componente deberá disponer de roles organizacionales definidos.

11.16. Supervisión humana significativa

La supervisión humana requiere algo más que incorporar un botón de aprobación. Para que sea significativa, la persona debe disponer de información suficiente para comprender el resultado y autoridad real para modificarlo o rechazarlo.

Cuando un sistema presenta una recomendación altamente técnica sin explicación, pedir aprobación al usuario puede convertirse en un procedimiento formal sin verdadero control.

Por esta razón, la supervisión deberá combinar acceso a explicaciones, información sobre incertidumbre, alternativas y mecanismos de intervención.

En la plataforma, ninguna recomendación estratégica se ejecutará automáticamente. El empresario conservará la responsabilidad sobre la acción finalmente seleccionada.



11.17. Gobernanza de inteligencia artificial

La gobernanza de IA comprende políticas, responsabilidades, procesos y controles mediante los cuales una organización dirige y supervisa sus sistemas inteligentes. Su finalidad consiste en garantizar que la utilización de IA se mantenga alineada con objetivos empresariales, requisitos normativos y principios responsables (Ordoñez-Iturralde & Proaño-Piedra, 2024).

Una gobernanza efectiva requiere identificar quién aprueba los modelos, quién controla los datos, quién supervisa el desempeño y quién interviene cuando se detecta un problema.

La ausencia de estas responsabilidades puede generar situaciones en las que un sistema continúe funcionando aunque nadie supervise su deterioro o comprenda suficientemente sus resultados.

Por ello, el gobierno de IA debe considerarse parte de la gestión organizacional y no exclusivamente una responsabilidad del área tecnológica.

11.18. ISO/IEC 42001 y sistemas de gestión de IA

ISO/IEC 42001:2023 establece requisitos para crear, implementar, mantener y mejorar continuamente un sistema de gestión de inteligencia artificial. Su enfoque permite integrar políticas, objetivos, responsabilidades y procesos relacionados con el uso responsable de IA dentro de una organización (ISO, 2023).



La norma adopta una perspectiva de gestión de riesgos y oportunidades. Esto significa que la organización debe identificar posibles impactos asociados con sus sistemas, establecer controles y revisar periódicamente su eficacia.

ISO/IEC 42001 resulta aplicable a organizaciones de diferentes tamaños y sectores que desarrollen o utilicen productos o servicios basados en IA, lo que la convierte en una referencia pertinente para estructuras empresariales de distinta complejidad (ISO, 2023).

El proyecto utilizará sus principios como referencia conceptual para organizar gobernanza, riesgos, documentación, seguimiento y mejora continua, sin asumir que la construcción de la plataforma equivale automáticamente a una certificación de conformidad.

11.19. ISO/IEC 23894 y gestión de riesgos de IA

La gestión de riesgos de inteligencia artificial requiere reconocer que determinados riesgos difieren de aquellos presentes en sistemas informáticos convencionales. Calidad de datos, sesgo, cambios de distribución, opacidad y comportamiento inesperado del modelo constituyen ejemplos de factores que deben evaluarse.

ISO/IEC 23894 proporciona orientación para incorporar la gestión de riesgos asociados con IA dentro de los procesos organizacionales y puede complementarse con ISO/IEC 42001 para estructurar controles y responsabilidades (ISO, 2023).

La gestión debe abarcar todo el ciclo de vida. Un riesgo que no estaba presente durante el entrenamiento puede aparecer después del despliegue debido a cambios en datos, contexto o usuarios.

Por ello, la plataforma incorporará identificación, evaluación, tratamiento, seguimiento y revisión periódica de riesgos.



11.20. Clasificación de riesgos de IA

No todos los componentes de una plataforma inteligente presentan el mismo nivel de riesgo. Un gráfico descriptivo no produce las mismas consecuencias que una recomendación automatizada basada en información personal.

La clasificación debe considerar probabilidad, impacto, población afectada, sensibilidad de los datos, nivel de automatización y posibilidad de intervención humana.

Puede establecerse una estructura interna de riesgo **bajo, moderado, alto y crítico**, acompañada de controles progresivamente más estrictos.

Esta clasificación funcionará como mecanismo organizativo y no deberá confundirse automáticamente con categorías regulatorias externas que puedan utilizar definiciones diferentes.

11.21. Matriz de riesgos de IA

La gestión puede operacionalizarse mediante una matriz que registre cada riesgo identificado. Esta herramienta facilita establecer responsables, medidas de tratamiento y evidencias.

Una estructura básica puede incorporar: **componente de IA, riesgo, causa, consecuencia, probabilidad, impacto, nivel, control, responsable, evidencia y riesgo residual**.

Entre los riesgos de la plataforma podrían incluirse predicciones incorrectas, sesgos, exposición de datos, recomendaciones inapropiadas, alucinaciones generativas, pérdida de desempeño o accesos no autorizados.

La matriz deberá actualizarse durante el ciclo de vida del sistema y no considerarse un documento elaborado una sola vez.

11.22. Gobernanza de datos



La gobernanza de IA depende directamente de la gobernanza de datos. Modelos técnicamente avanzados no pueden compensar completamente información incorrecta, desactualizada o obtenida sin controles adecuados.

La organización deberá establecer responsabilidades sobre origen, calidad, actualización, acceso y conservación de los datos utilizados por la plataforma.

Cada conjunto de datos debería disponer de información sobre procedencia y transformaciones realizadas antes de incorporarse a un modelo.

Esta trazabilidad permitirá investigar posteriormente si un comportamiento inesperado se relaciona con el algoritmo o con problemas existentes en la información utilizada.

11.23. Gobernanza de modelos

La gobernanza de modelos comprende controles específicos sobre construcción, validación, aprobación, implementación y actualización de algoritmos.

Cada modelo deberá disponer de una identificación única y documentación mínima sobre propósito, versión, datos utilizados, variables, algoritmo, métricas, fecha de entrenamiento y limitaciones.

Cuando se implemente una nueva versión, deberá conservarse evidencia de las modificaciones realizadas y de las razones que justificaron el cambio.

Este procedimiento permite evitar que diferentes versiones funcionen sin control y facilita reconstruir qué modelo produjo un resultado específico.

11.24. Registro o inventario de modelos



Una organización que utiliza varios algoritmos necesita conocer qué modelos se encuentran activos. El inventario constituye un instrumento básico de gobernanza.

El registro puede incluir nombre, propietario, finalidad, versión, nivel de riesgo, estado, fecha de última validación y próxima revisión.

También deberá identificar dependencias con otros componentes. Un sistema recomendador, por ejemplo, puede depender de un modelo predictivo y de una capa XAI.

Esta visión facilita comprender la arquitectura completa y determinar qué componentes pueden verse afectados cuando se modifica un modelo.

11.25. Trazabilidad de decisiones automatizadas

La trazabilidad consiste en conservar información suficiente para reconstruir cómo se obtuvo un resultado. En sistemas de IA esta capacidad resulta esencial para auditoría, explicación y asignación de responsabilidades (ISO, 2023; Parra Sepúlveda & Concha Machuca, 2025).

Una predicción debería poder relacionarse con la versión del modelo, datos de entrada, momento de ejecución y explicación correspondiente.

En las recomendaciones, además, debe registrarse qué escenario, criterios y reglas participaron en su generación.

La arquitectura propuesta mantendrá la cadena:

Dato → transformación → modelo → predicción → explicación → recomendación → usuario → decisión.

11.26. Registro de decisiones humanas

La trazabilidad no debe finalizar cuando el algoritmo produce una recomendación. También resulta útil registrar qué hizo el usuario con esa información.



El responsable puede aceptar, modificar o descartar la alternativa presentada. Esta respuesta permite diferenciar claramente recomendación algorítmica y decisión humana.

Registrar esta interacción proporciona información para evaluar posteriormente la utilidad del sistema y detectar situaciones en las que las recomendaciones son rechazadas sistemáticamente.

Sin embargo, estos registros deberán respetar las reglas de privacidad y conservar únicamente la información necesaria para las finalidades establecidas.

11.27. Auditoría algorítmica

La auditoría permite examinar sistemáticamente si los sistemas funcionan de acuerdo con los criterios establecidos. Puede incluir revisión de datos, desempeño, seguridad, sesgo, documentación y cumplimiento de controles.

La auditoría no debe limitarse al momento previo al despliegue. Los sistemas de aprendizaje automático pueden perder desempeño cuando cambian las condiciones empresariales.

Por ello, resulta conveniente establecer revisiones periódicas y revisiones extraordinarias cuando se detecten incidentes, cambios relevantes o degradación del modelo.

La evidencia generada mediante trazabilidad facilita estas auditorías al permitir reconstruir procesos y resultados.

11.28. Monitoreo y deriva de modelos

Los modelos aprenden relaciones presentes en datos históricos. Cuando estas relaciones cambian, su desempeño puede disminuir.



Este fenómeno requiere monitorear variables de entrada, errores y comportamiento de las predicciones. Cambios importantes pueden indicar necesidad de revisar o reentrenar el modelo.

La actualización no debería producirse automáticamente sin validación. Un nuevo modelo necesita demostrar que mantiene o mejora el desempeño y que no introduce riesgos adicionales.

La gobernanza deberá establecer criterios para **mantener, recalibrar, reentrenar, sustituir o retirar** modelos.

11.29. Gobernanza de IA generativa

Los modelos generativos requieren controles específicos debido a su capacidad para producir contenido nuevo y utilizar fuentes externas.

La organización deberá definir qué información puede incorporarse a las instrucciones, qué fuentes puede consultar el asistente y qué acciones puede ejecutar.

Las respuestas estratégicas deberán mantener registro de las fuentes utilizadas y distinguir información recuperada de contenido generado.

Asimismo, los sistemas deberán estar preparados para reconocer situaciones en las que no disponen de evidencia suficiente, evitando producir respuestas especulativas como si fueran hechos.

11.30. Gestión de alucinaciones

Las alucinaciones constituyen un riesgo específico de los modelos generativos. Una respuesta puede resultar lingüísticamente coherente y, sin embargo, contener información inexistente o incorrecta.

Para reducir este riesgo, la plataforma deberá utilizar fuentes controladas, recuperación de información, validaciones y restricciones sobre determinados tipos de respuestas.

Los valores empresariales nunca deberán ser generados libremente por el modelo. Ventas, KPI, predicciones y resultados de simulación deberán proceder de componentes verificables.

Cuando la información no se encuentre disponible, la respuesta apropiada será comunicar esta limitación en lugar de completar los datos mediante inferencias no sustentadas.

11.31. Gestión de incidentes relacionados con IA

Los sistemas inteligentes también requieren procedimientos para responder cuando ocurre un incidente. Estos pueden incluir exposición de datos, comportamiento inesperado, resultados discriminatorios, recomendaciones incorrectas o fallas de seguridad.

La respuesta deberá establecer mecanismos para detectar, registrar, contener, investigar y corregir el incidente.

Cuando corresponda, el modelo afectado puede requerir suspensión temporal mientras se determina la causa.

Posteriormente, el aprendizaje obtenido deberá incorporarse a la matriz de riesgos y a los controles para reducir la posibilidad de repetición.

11.32. Seguridad, privacidad y ética como dimensiones integradas

Seguridad, privacidad y ética no deben gestionarse como componentes completamente independientes. Una vulnerabilidad de seguridad puede producir una violación de privacidad y, simultáneamente, consecuencias éticas.

De forma similar, un modelo puede cumplir técnicamente con controles de seguridad y aun producir resultados discriminatorios.

La gobernanza debe proporcionar una visión integrada que permita analizar conjuntamente estas dimensiones.



Esta perspectiva evita reducir la IA responsable al cumplimiento de una lista aislada de requisitos.

11.33. Confianza empresarial en sistemas de IA

La confianza constituye una condición importante para la adopción de sistemas inteligentes. Sin embargo, una confianza excesiva puede resultar tan problemática como el rechazo sistemático.

La finalidad debe ser desarrollar confianza sustentada en evidencia. Desempeño conocido, transparencia, trazabilidad, seguridad y mecanismos de intervención proporcionan elementos para evaluar razonablemente el sistema (ISO, 2023).

Una plataforma confiable también debe reconocer sus limitaciones. Comunicar incertidumbre o indicar ausencia de información fortalece una relación más realista entre usuario y tecnología.

La confianza empresarial deberá construirse mediante comportamiento verificable y no exclusivamente mediante la apariencia de sofisticación tecnológica.

11.34. Gobernanza para micro y pequeñas empresas

Las micro y pequeñas empresas pueden presentar limitaciones para implementar estructuras complejas de gobernanza. Sin embargo, esto no significa que deban utilizar IA sin controles.

Un modelo proporcional puede concentrarse en prácticas esenciales: inventario de sistemas, responsables identificados, protección de datos, validación periódica, registro de cambios y supervisión humana.

Los controles pueden aumentar conforme aumenta el riesgo. Un sistema exclusivamente informativo requiere una estructura diferente a un algoritmo utilizado para decisiones de mayor impacto.



Esta proporcionalidad permitirá aplicar IA responsable sin imponer una estructura administrativa incompatible con la realidad de las microempresas consideradas en el proyecto.

11.35. Modelo de gobernanza propuesto para la plataforma

A partir de los principios desarrollados se propone una estructura integrada mediante ocho dimensiones:

1. Gobernanza de datos: calidad, procedencia, privacidad y acceso.

2. Gobernanza de modelos: desarrollo, validación, versionamiento y monitoreo.

3. Ética y equidad: evaluación de sesgos e impactos.

4. Seguridad: protección de infraestructura, información y modelos.

5. Transparencia y XAI: documentación y explicación de resultados.

6. Gestión de riesgos: identificación, evaluación, tratamiento y monitoreo.

7. Responsabilidad humana: roles, autorizaciones y supervisión.

8. Trazabilidad y auditoría: registros y evidencias del ciclo de vida.

La interacción de estas dimensiones permite incorporar gobernanza dentro de la arquitectura tecnológica en lugar de tratarla como una actividad independiente.

11.36. Arquitectura de IA responsable propuesta

La arquitectura transversal puede representarse mediante el siguiente flujo:

DATOS EMPRESARIALES

↓

PRIVACIDAD + CALIDAD + SEGURIDAD

↓

SEGMENTACIÓN / PREDICCIÓN / IA GENERATIVA



↓

VALIDACIÓN DEL MODELO

↓

EVALUACIÓN DE SESGO

↓

XAI + TRANSPARENCIA

↓

EVALUACIÓN DE RIESGO

↓

RECOMENDACIÓN / PRESCRIPCIÓN

↓

SUPERVISIÓN HUMANA

↓

DECISIÓN

↓

TRAZABILIDAD

↓

MONITOREO + AUDITORÍA

↓

RETROALIMENTACIÓN Y MEJORA CONTINUA

De esta manera, los principios responsables acompañan todo el ciclo analítico y no únicamente el resultado final.

11.37. Matriz de control para IA responsable

La implementación práctica puede apoyarse mediante una matriz de control con los siguientes campos:

Sistema/modelo | Finalidad | Datos utilizados | Responsable | Nivel de riesgo | Sesgo evaluado | Privacidad | Seguridad | Explicabilidad |



Supervisión humana | Última validación | Próxima revisión | Evidencia.

Esta matriz permitirá disponer de una visión consolidada sobre los principales controles asociados con cada componente de la plataforma.

Además, puede convertirse en evidencia documental para procesos internos de evaluación y mejora.

Su actualización deberá formar parte del mantenimiento regular del sistema y no limitarse al momento inicial de desarrollo.

11.38. Ciclo de vida responsable de la inteligencia artificial

La gobernanza puede estructurarse siguiendo el ciclo de vida del sistema:

1. Definición: establecer finalidad y responsables.

2. Datos: evaluar procedencia, calidad, privacidad y pertinencia.

3. Desarrollo: seleccionar algoritmos y documentar decisiones.

4. Validación: comprobar desempeño, sesgo, seguridad y explicabilidad.

5. Aprobación: determinar si el riesgo residual resulta aceptable.

6. Despliegue: controlar versión y accesos.

7. Monitoreo: supervisar desempeño, incidentes y cambios.

8. Actualización: revalidar modificaciones.

9. Retiro: desactivar modelos obsoletos conservando la trazabilidad necesaria.

Esta perspectiva evita considerar el cumplimiento ético como una revisión única y reconoce que los riesgos pueden cambiar durante la vida útil del sistema.

11.39. Integración con los capítulos anteriores

Los principios desarrollados en este capítulo se aplican transversalmente a toda la arquitectura del libro. La segmentación del Capítulo 5 requiere evaluación de perfiles y posibles sesgos; los modelos predictivos



necesitan validación y monitoreo; XAI proporciona explicabilidad; los motores recomendadores requieren trazabilidad; y la analítica prescriptiva necesita mantener supervisión humana.

Los dashboards del Capítulo 9 deberán comunicar incertidumbre y evitar representaciones engañosas, mientras que la IA generativa del Capítulo 10 requiere controles adicionales sobre privacidad, fuentes, alucinaciones y acciones autorizadas.

Esta integración demuestra que la gobernanza no constituye un módulo independiente situado al final del sistema.

Por el contrario, **ética, seguridad, privacidad, transparencia y responsabilidad atraviesan cada etapa de la arquitectura inteligente empresarial**.

11.40. Síntesis del capítulo

La incorporación empresarial de inteligencia artificial genera oportunidades para mejorar análisis y decisiones, pero simultáneamente introduce riesgos relacionados con sesgo, privacidad, seguridad, transparencia y responsabilidad. Una estrategia de adopción responsable requiere gestionar ambas dimensiones de manera integrada (Ordoñez-Iturralde & Proaño-Piedra, 2024).

El sesgo algorítmico puede originarse en los datos, decisiones metodológicas o cambios posteriores al despliegue. Su evaluación debe realizarse durante todo el ciclo de vida y complementarse con análisis de desempeño, explicabilidad y revisión humana.

La privacidad adquiere particular importancia cuando los sistemas procesan datos personales. En Ecuador, la Ley Orgánica de Protección de Datos Personales establece obligaciones sobre el tratamiento de esta información y el marco regulatorio de 2026 incorpora disposiciones

específicas relacionadas con sistemas de inteligencia artificial (Ley Orgánica de Protección de Datos Personales, 2021; SPDP, 2026).

La seguridad debe proteger datos, modelos, infraestructura e interfaces. La incorporación de IA generativa amplía la superficie de riesgo y requiere controlar permisos, herramientas conectadas e información que puede ser proporcionada a los modelos.

La transparencia permite que usuarios y responsables conozcan finalidad, características y limitaciones del sistema. Cuando se combina con explicabilidad, proporciona mejores condiciones para evaluar críticamente las predicciones y recomendaciones (Parra Sepúlveda & Concha Machuca, 2025).

La responsabilidad humana permanece como principio central. Los algoritmos pueden apoyar decisiones, pero las organizaciones deben establecer claramente quién desarrolla, valida, autoriza, supervisa y utiliza sus resultados.

La gobernanza proporciona la estructura necesaria para operacionalizar estos principios. ISO/IEC 42001:2023 constituye una referencia internacional para establecer sistemas de gestión de IA orientados hacia responsabilidad, riesgos, transparencia y mejora continua (ISO, 2023).

La trazabilidad permite reconstruir el recorrido desde los datos hasta la decisión. Esta capacidad resulta fundamental para explicación, auditoría y aprendizaje organizacional.

La gestión de riesgos deberá mantenerse activa durante todo el ciclo de vida. Los modelos pueden degradarse, aparecer nuevas vulnerabilidades y cambiar las condiciones bajo las cuales fueron validados.

En el proyecto **Inteligencia Artificial y Analítica Predictiva para la Competitividad Empresarial: Modelos de Segmentación**



Automatizada, Predicción y Recomendación Estratégica, la gobernanza funcionará como una capa transversal que protege y controla todos los componentes de la plataforma.

El modelo integral puede sintetizarse mediante:

DATOS RESPONSABLES → MODELOS VALIDADOS → EVALUACIÓN DE SESGO → PRIVACIDAD Y SEGURIDAD → XAI → GESTIÓN DE RIESGOS → RECOMENDACIÓN TRAZABLE → SUPERVISIÓN HUMANA → DECISIÓN → AUDITORÍA → MEJORA CONTINUA.

La competitividad basada en inteligencia artificial no debería construirse sacrificando privacidad, seguridad o confianza. Por el contrario, una arquitectura empresarial sostenible necesita combinar **capacidad analítica, innovación tecnológica y gobernanza responsable**, de manera que los sistemas inteligentes contribuyan a las decisiones sin eliminar la responsabilidad humana que debe acompañarlas.



CAPÍTULO 12.

MODELO INTEGRAL INTELIGENTE PARA FORTALECER LA COMPETITIVIDAD EMPRESARIAL.

12.1. Introducción

La transformación digital ha provocado que la competitividad empresarial dependa progresivamente de la capacidad de las organizaciones para convertir sus datos en conocimiento útil. Sin embargo, disponer de información, dashboards o algoritmos aislados no garantiza una mejor decisión. El verdadero valor de la analítica aparece cuando los datos son integrados dentro de una arquitectura capaz de describir el comportamiento empresarial, descubrir patrones, anticipar acontecimientos, explicar los resultados obtenidos y generar alternativas estratégicas comprensibles para los responsables de la organización (García-Jiménez et al., 2021; Fasanando-Trigoso et al., 2025).

La inteligencia artificial amplía esta capacidad mediante algoritmos de aprendizaje automático, modelos predictivos, técnicas de segmentación, sistemas de recomendación e inteligencia artificial generativa. No obstante, la utilización fragmentada de estas tecnologías puede producir soluciones técnicamente avanzadas pero desconectadas del proceso real de decisión empresarial. Por esta razón, resulta necesario desarrollar modelos integradores que articulen datos, algoritmos, conocimiento empresarial y participación humana dentro de un mismo ciclo analítico (Ordoñez-Iturralde & Proaño-Piedra, 2024).



Las micro, pequeñas y medianas empresas presentan un desafío adicional, debido a que suelen disponer de diferentes niveles de madurez tecnológica, calidad de información y capacidades analíticas. La adopción de inteligencia de negocios e inteligencia artificial debe, por tanto, considerar estas características y evitar arquitecturas excesivamente complejas que no correspondan con la realidad organizacional (Chinchuña et al., 2026).

A partir de esta necesidad, el presente capítulo propone un modelo conceptual propio denominado **MICE-IA: Modelo Inteligente de Competitividad Empresarial basado en Inteligencia Artificial**, diseñado para articular adquisición y preparación de datos, inteligencia empresarial, segmentación automatizada, analítica predictiva, inteligencia artificial explicable, analítica prescriptiva, recomendación estratégica, visualización inteligente, inteligencia artificial generativa y aprendizaje continuo.

12.2. Fundamentación del modelo MICE-IA

El modelo MICE-IA parte de una premisa central: **la competitividad empresarial no se fortalece únicamente acumulando información, sino aumentando progresivamente la capacidad de convertir los datos en decisiones estratégicas contextualizadas**. En consecuencia, el dato constituye el insumo inicial, pero el resultado esperado corresponde a conocimiento empresarial susceptible de apoyar decisiones.

La inteligencia de negocios proporciona mecanismos para integrar información, construir indicadores y facilitar su interpretación. Su contribución a la toma de decisiones ha sido ampliamente reconocida, particularmente cuando los sistemas consiguen transformar datos



dispersos en información estructurada y accesible para los responsables empresariales (García-Jiménez et al., 2021; Pérez Jesús et al., 2024).

La analítica predictiva incorpora una dimensión prospectiva al utilizar información histórica para estimar comportamientos futuros. Sin embargo, una predicción aislada posee utilidad limitada cuando el usuario desconoce las variables relacionadas con el resultado o las alternativas que podría evaluar posteriormente. Esta limitación justifica la incorporación de explicabilidad y analítica prescriptiva dentro de una arquitectura integrada (Schab et al., 2020).

La inteligencia artificial explicable proporciona mecanismos para comprender el comportamiento de modelos complejos y constituye un elemento relevante para construir sistemas transparentes y auditables. Su incorporación permite que la predicción deje de funcionar como una salida opaca y pueda relacionarse con factores interpretables por el responsable empresarial (Parra Sepúlveda & Concha Machuca, 2025).

Finalmente, los sistemas de recomendación y la analítica prescriptiva permiten avanzar desde la anticipación hacia la evaluación de posibles acciones. De esta manera, el modelo propuesto articula progresivamente **información, conocimiento, anticipación, explicación y acción**, manteniendo la decisión definitiva bajo responsabilidad humana (Bron Fonseca & Mar Cornelio, 2022; Schab et al., 2020).

12.3. Definición del modelo MICE-IA

El **Modelo Inteligente de Competitividad Empresarial basado en Inteligencia Artificial (MICE-IA)** se define como una arquitectura conceptual, analítica y tecnológica de ciclo cerrado que transforma datos empresariales heterogéneos en conocimiento estratégico mediante la integración secuencial de inteligencia de negocios, segmentación

automatizada, analítica predictiva, explicabilidad, simulación, prescripción, recomendación y visualización, incorporando retroalimentación para favorecer el aprendizaje continuo y manteniendo transversalmente principios de gobernanza, seguridad, privacidad y supervisión humana.

La expresión **ciclo cerrado** constituye una característica fundamental del modelo. En arquitecturas tradicionales, los datos son procesados hasta producir un informe o una predicción y el proceso termina en ese punto. MICE-IA incorpora posteriormente la respuesta del usuario y los nuevos resultados empresariales, permitiendo que la información obtenida después de una decisión vuelva a alimentar el sistema.

En consecuencia, MICE-IA no debe entenderse como una sucesión lineal de algoritmos independientes. Constituye un ecosistema de componentes especializados conectados mediante flujos de datos, conocimiento y retroalimentación.

El modelo se fundamenta en cuatro principios estructurales: **integración analítica, inteligencia explicable, decisión centrada en el ser humano y aprendizaje continuo responsable**.

12.4. Problema que busca resolver MICE-IA

Uno de los principales problemas de la transformación digital empresarial consiste en la fragmentación tecnológica. Una organización puede disponer de hojas de cálculo, sistemas de ventas, dashboards, modelos predictivos y herramientas de inteligencia artificial sin que exista una arquitectura capaz de conectar coherentemente sus resultados. Esta fragmentación genera lo que en el presente modelo se conceptualiza como **brecha dato-decisión**, entendida como la distancia existente entre



disponer de información y convertirla en una acción empresarial fundamentada.

La brecha puede aparecer en diferentes momentos. Una empresa puede tener datos, pero no indicadores; disponer de indicadores, pero no predicciones; generar predicciones, pero no comprenderlas; comprenderlas, pero desconocer qué acciones evaluar; o recibir recomendaciones sin conocer la evidencia que las sustenta.

MICE-IA pretende reducir progresivamente esta brecha mediante una cadena de transformación que conecte cada nivel analítico con el siguiente.

12.5. Hipótesis conceptual del modelo

La hipótesis conceptual que sustenta MICE-IA establece que:

La integración sistemática de calidad de datos, inteligencia empresarial, segmentación automatizada, analítica predictiva, explicabilidad, prescripción y recomendación estratégica, mediada por visualización inteligente, supervisión humana y aprendizaje continuo, incrementa la capacidad analítica empresarial para anticipar cambios, diferenciar perfiles y evaluar alternativas estratégicas orientadas al fortalecimiento de la competitividad.

Esta proposición no implica asumir que la utilización de IA produce automáticamente mayor competitividad. El efecto esperado depende de la calidad de los datos, desempeño de los modelos, pertinencia de las recomendaciones y capacidad de la organización para transformar información analítica en acciones.

Por esta razón, el modelo diferencia claramente entre **capacidad tecnológica** y **resultado empresarial**. MICE-IA proporciona



capacidades analíticas; la organización continúa siendo responsable de convertirlas en decisiones y resultados.

12.6. Principio de inteligencia progresiva

Una de las innovaciones conceptuales de MICE-IA consiste en organizar la inteligencia empresarial mediante niveles progresivos. Cada nivel responde a una pregunta diferente y proporciona información al siguiente.

Nivel 1 – Inteligencia descriptiva: ¿qué está ocurriendo?

Nivel 2 – Inteligencia segmentativa: ¿qué perfiles o patrones existen?

Nivel 3 – Inteligencia predictiva: ¿qué podría ocurrir?

Nivel 4 – Inteligencia explicable: ¿qué factores intervienen en el resultado del modelo?

Nivel 5 – Inteligencia prescriptiva: ¿qué alternativas pueden evaluarse?

Nivel 6 – Inteligencia estratégica: ¿qué alternativa resulta más pertinente bajo determinadas condiciones?

Nivel 7 – Inteligencia adaptativa: ¿qué puede aprenderse de los resultados obtenidos?

Esta estructura permite evitar que la inteligencia artificial sea considerada como una única tecnología. MICE-IA la concibe como un conjunto de capacidades analíticas progresivas que transforman el dato en conocimiento cada vez más próximo a la decisión.

12.7. Principio de doble inteligencia

MICE-IA propone además el concepto de **doble inteligencia**, entendido como la interacción entre inteligencia algorítmica e inteligencia empresarial humana.



La **inteligencia algorítmica** identifica patrones, procesa grandes volúmenes de información, genera predicciones, compara alternativas y detecta relaciones estadísticas.

La **inteligencia empresarial humana** incorpora experiencia, conocimiento contextual, interpretación del mercado, restricciones no representadas en los datos y responsabilidad sobre las decisiones.

Ninguna de las dos dimensiones sustituye completamente a la otra. La innovación del modelo reside en establecer un mecanismo de colaboración:

IA calcula → XAI explica → sistema recomienda → empresario interpreta → empresario decide → sistema aprende.

12.8. Estructura general de MICE-IA

El modelo está constituido por **nueve capas funcionales** y **tres ejes transversales**.

Las nueve capas funcionales son:

Capa 1. Inteligencia de datos.

Capa 2. Inteligencia empresarial descriptiva.

Capa 3. Inteligencia de segmentación.

Capa 4. Inteligencia predictiva.

Capa 5. Inteligencia explicable.

Capa 6. Inteligencia prescriptiva y simulación.

Capa 7. Inteligencia de recomendación estratégica.

Capa 8. Inteligencia visual y conversacional.

Capa 9. Inteligencia adaptativa y aprendizaje continuo.

Los tres ejes transversales son:

Gobernanza y ética.

Seguridad y privacidad.



Supervisión y decisión humana.

Esta organización diferencia entre capacidades que transforman progresivamente la información y principios que deben acompañar permanentemente todo el ciclo.

12.9. Capa 1: Inteligencia de datos

La primera capa constituye la base de MICE-IA. Su finalidad es adquirir, integrar, depurar y preparar los datos necesarios para los componentes posteriores.

Las fuentes pueden incluir ventas, clientes, productos, comportamiento comercial, información operativa, registros históricos y otras variables pertinentes según la disponibilidad de cada empresa.

La calidad de los resultados posteriores dependerá directamente de esta etapa. Valores ausentes, duplicados, errores, inconsistencias o información desactualizada pueden alterar tanto los indicadores como las predicciones.

Por esta razón, la capa incorpora cinco procesos:

Adquisición → integración → limpieza → transformación → validación.

El resultado será un conjunto analítico preparado y documentado para alimentar las demás capas.

12.10. Índice de Calidad Analítica de Datos

Como componente propio del modelo se propone un **Índice de Calidad Analítica de Datos (ICAD)** destinado a evaluar si la información disponible posee condiciones suficientes para alimentar los modelos.

Conceptualmente:

ICAD = f(Completitud, Consistencia, Actualidad, Validez, Disponibilidad).



Cada dimensión puede normalizarse posteriormente en una escala común y ponderarse según las características de la implementación.

La finalidad del ICAD no consiste en declarar que los datos son absolutamente correctos, sino proporcionar una señal sobre su preparación para procesos analíticos.

MICE-IA incorpora así una regla fundamental:

si la calidad de los datos es insuficiente, el sistema no incrementa artificialmente la confianza de las predicciones posteriores.

12.11. Capa 2: Inteligencia empresarial descriptiva

La segunda capa transforma los datos preparados en indicadores empresariales. Su finalidad consiste en responder qué está ocurriendo y cómo evolucionan las variables relevantes.

Los KPI pueden incluir ventas, crecimiento, clientes, frecuencia de compra, ticket promedio, retención y otros indicadores definidos según la disponibilidad de información.

Esta capa proporciona el contexto necesario para interpretar los modelos posteriores. Una predicción resulta más comprensible cuando el usuario conoce previamente el comportamiento histórico de la variable.

La salida de esta capa será el **perfil descriptivo empresarial**, compuesto por indicadores actuales, tendencias históricas y desviaciones relevantes.

12.12. Capa 3: Inteligencia de segmentación

La tercera capa utiliza aprendizaje no supervisado para descubrir estructuras dentro de los datos empresariales. Técnicas como K-means, clustering jerárquico o DBSCAN permiten identificar grupos de observaciones con características semejantes.



MICE-IA no utiliza el clustering únicamente para producir agrupaciones estadísticas. Cada segmento deberá convertirse posteriormente en un **perfil empresarial interpretable**.

El perfil incorporará las variables que diferencian al segmento, comportamiento de sus indicadores y características relevantes para posteriores predicciones y recomendaciones.

La salida será:

Empresa → segmento → perfil → características diferenciadoras.

Esta capa introduce personalización dentro del modelo, evitando que todas las organizaciones reciban exactamente el mismo análisis.

12.13. Índice de Perfil Competitivo

Como elemento innovador se propone construir un **Índice de Perfil Competitivo (IPC)** que sintetice dimensiones empresariales seleccionadas según el instrumento y los datos disponibles.

El IPC no sustituirá los indicadores originales ni constituirá una medida universal de competitividad. Funcionará como una representación sintética que facilite comparar el perfil actual de una empresa respecto de referencias previamente definidas.

Su composición deberá validarse empíricamente antes de implementarse. Variables, ponderaciones y escalas no deben establecerse arbitrariamente.

El índice podrá utilizarse posteriormente como uno de los insumos del componente integral de competitividad.

12.14. Capa 4: Inteligencia predictiva

La cuarta capa incorpora modelos capaces de estimar comportamientos futuros utilizando patrones presentes en los datos históricos.



Dependiendo del objetivo, podrán emplearse regresión, clasificación, series temporales u otros algoritmos de aprendizaje automático.

La selección no deberá realizarse únicamente por complejidad tecnológica. MICE-IA establece como criterio seleccionar el modelo que presente equilibrio entre desempeño fuera de muestra, estabilidad, interpretabilidad y utilidad empresarial.

La salida de esta capa no será únicamente una predicción puntual:

Predicción = estimación + horizonte + error + incertidumbre.

Este principio evita presentar el futuro como un valor determinista.

12.15. Capa 5: Inteligencia explicable

La quinta capa responde a una pregunta fundamental: **¿por qué el modelo produjo este resultado?**

Las técnicas XAI permitirán analizar importancia de variables y contribuciones locales mediante procedimientos como SHAP y, cuando corresponda, LIME.

MICE-IA incorpora la explicabilidad antes de la recomendación. Esta posición es deliberada: una estrategia no debería derivarse de una predicción que el sistema no puede interpretar suficientemente.

El flujo será:

Predicción → explicación → factores relevantes → interpretación empresarial.

De esta manera, la explicación funciona como puente entre capacidad algorítmica y conocimiento empresarial.

12.16. Índice de Confianza Analítica

Se propone un segundo componente propio denominado **Índice de Confianza Analítica (ICA)**.

El ICA pretende sintetizar evidencia relacionada con:



Calidad de datos + desempeño predictivo + estabilidad + incertidumbre + explicabilidad.

Su finalidad será proporcionar una señal sobre la solidez analítica disponible para sustentar una recomendación.

Una predicción con buen desempeño histórico pero alimentada por datos deteriorados no debería presentar el mismo nivel de confianza que otra construida sobre información consistente y reciente.

El ICA permitirá introducir esta diferenciación dentro de la interfaz de la herramienta.

12.17. Capa 6: Inteligencia prescriptiva y simulación

La sexta capa transforma la predicción explicada en un espacio de exploración estratégica.

El análisis *what-if* permitirá modificar variables controlables y observar cómo cambian determinados resultados del modelo.

La simulación incorporará escenarios **base, favorable y adverso**, permitiendo evaluar estrategias bajo diferentes configuraciones.

El análisis multicriterio permitirá considerar simultáneamente impacto, costo, riesgo, factibilidad, recursos y horizonte temporal.

Esta capa genera un conjunto de alternativas evaluadas y no una única respuesta automática.

12.18. Capa 7: Inteligencia de recomendación estratégica

La séptima capa recibe las alternativas procedentes del componente prescriptivo y determina cuáles presentan mayor correspondencia con el perfil y contexto empresarial.

Se propone un motor híbrido que combine:

Reglas empresariales + perfil de segmento + predicción + escenario + criterios multicriterio + conocimiento estratégico.



Esta combinación permite reducir la dependencia de un único mecanismo de recomendación.

Cada recomendación deberá contener cinco componentes:

Acción propuesta.

Justificación.

Escenario de aplicación.

Riesgos principales.

Indicadores de seguimiento.

MICE-IA transforma así la recomendación desde una sugerencia genérica hacia una **recomendación estratégica trazable**.

12.19. Índice de Prioridad Estratégica

Para organizar las alternativas se propone el **Índice de Prioridad Estratégica (IPE)**.

Conceptualmente:

IPE = f(Impacto esperado, Factibilidad, Urgencia, Riesgo, Recursos, Compatibilidad con el segmento).

Las ponderaciones deberán establecerse mediante validación experta y análisis multicriterio.

El IPE no pretende decidir automáticamente por el empresario. Su función consiste en ordenar las alternativas según criterios explícitos y transparentes.

El usuario podrá modificar determinadas ponderaciones y observar cómo cambia la priorización, incorporando análisis de sensibilidad.

12.20. Capa 8: Inteligencia visual y conversacional

La octava capa constituye la interfaz entre el sistema y el usuario.

El dashboard integrará KPI, segmentos, predicciones, explicaciones, escenarios, alertas y recomendaciones dentro de una misma arquitectura visual.

La IA generativa incorporará una interfaz conversacional que permita formular preguntas en lenguaje natural.

El usuario podrá preguntar, por ejemplo:

¿Qué está ocurriendo?

¿Qué se espera para el próximo período?

¿Por qué el modelo predice ese comportamiento?

¿Qué estrategias puedo evaluar?

¿Qué riesgos presenta cada alternativa?

La respuesta será construida utilizando los componentes analíticos correspondientes y no mediante generación libre de información.

12.21. Capa 9: Inteligencia adaptativa

La novena capa constituye uno de los principales elementos diferenciadores de MICE-IA: la retroalimentación.

Después de recibir una recomendación, el usuario podrá:

Aceptar.

Modificar.

Posponer.

Rechazar.

El sistema registrará esta interacción y, posteriormente, podrá incorporar información sobre los resultados observados.

Se genera así el ciclo:

Recomendación → decisión → resultado → evaluación → aprendizaje.



La plataforma evoluciona desde un sistema estático hacia una arquitectura adaptativa.

12.22. Bucle de Aprendizaje Estratégico Empresarial

Se propone denominar este mecanismo **Bucle de Aprendizaje Estratégico Empresarial (BAEE)**.

El BAEE conecta cuatro elementos:

Recomendación emitida → decisión adoptada → resultado observado → actualización del conocimiento.

Su finalidad consiste en evaluar progresivamente si las recomendaciones proporcionadas están generando utilidad para los usuarios.

El aprendizaje no deberá realizarse automáticamente después de cada interacción. Los nuevos patrones deberán acumular evidencia suficiente y pasar por procesos de validación antes de modificar reglas o modelos.

Este principio evita que decisiones aisladas alteren de manera inestable el comportamiento del sistema.

12.23. Los tres ejes transversales de MICE-IA

Las nueve capas se encuentran atravesadas permanentemente por tres ejes.

Eje A. Gobernanza y ética

Controla sesgo, trazabilidad, documentación, versiones, responsabilidades y gestión de riesgos.

Eje B. Seguridad y privacidad

Protege datos, modelos, usuarios, credenciales e integraciones, aplicando principios de minimización y control de acceso.

Eje C. Supervisión humana



Garantiza que el empresario conserve capacidad para interpretar, cuestionar y decidir.

Estos ejes impiden que el incremento de automatización produzca una reducción equivalente del control humano.

12.24. El principio de recomendación responsable

MICE-IA establece que ninguna recomendación estratégica debe presentarse sin proporcionar información suficiente sobre su origen.

Por esta razón se propone el principio:

No recomendar sin explicar; no explicar sin evidencia; no automatizar sin supervisar.

Este principio resume la relación entre analítica, XAI, gobernanza y decisión humana.

Cada recomendación deberá poder reconstruirse mediante:

Datos → modelo → predicción → explicación → escenario → criterios → recomendación.

Esta cadena constituye la **trazabilidad estratégica** del modelo.

12.25. Índice Inteligente de Competitividad Empresarial

Como innovación integradora, se propone desarrollar posteriormente un **Índice Inteligente de Competitividad Empresarial (IICE)**.

A diferencia de un indicador convencional basado exclusivamente en variables históricas, el IICE integraría diferentes dimensiones producidas por MICE-IA.

Conceptualmente:

IICE = f(DP, CC, AP, CA, AE)

donde:

DP = desempeño empresarial;

CC = capacidad competitiva;



AP = perspectiva analítica/predictiva;

CA = capacidad adaptativa;

AE = preparación estratégica.

Las dimensiones y ponderaciones deberán ser operacionalizadas y validadas estadísticamente durante el desarrollo empírico del proyecto.

Por esta razón, el capítulo propone el constructo, pero no asigna arbitrariamente pesos definitivos.

12.26. Naturaleza dinámica del IICE

El IICE se concibe como un indicador dinámico. Su valor podrá modificarse cuando cambien los indicadores empresariales, predicciones, riesgos y capacidad de respuesta.

Esto permitirá observar no solamente la situación competitiva actual, sino también su trayectoria.

El dashboard podrá mostrar:

IICE actual.

Evolución histórica.

Tendencia esperada.

Factores que influyen en su variación.

Escenarios posibles.

Acciones estratégicas relacionadas.

De esta manera, el índice funcionará como mecanismo integrador entre medición, predicción y recomendación.

12.27. Radar Inteligente de Competitividad

Como representación visual del IICE se propone un **Radar Inteligente de Competitividad (RIC)**.



El radar mostrará las dimensiones que conforman el perfil competitivo y permitirá identificar fortalezas y áreas que requieren atención.

Su diferencia respecto de un radar tradicional consiste en incorporar tres estados:

Estado observado.

Estado predictivo.

Estado potencial bajo estrategia.

Esto permitirá que el usuario visualice no solamente dónde se encuentra la empresa, sino hacia dónde podría dirigirse y cómo determinadas estrategias podrían modificar su trayectoria.

El RIC constituirá uno de los componentes visuales distintivos de la herramienta tecnológica.

12.28. Semáforo Estratégico Inteligente

Se propone adicionalmente un **Semáforo Estratégico Inteligente (SEI)** para facilitar la interpretación de resultados.

El sistema podrá clasificar situaciones en niveles de atención definidos mediante criterios validados:

Verde: comportamiento dentro de rangos esperados.

Amarillo: cambio que requiere seguimiento.

Naranja: riesgo relevante o deterioro previsto.

Rojo: condición prioritaria que requiere evaluación.

La clasificación no dependerá únicamente de umbrales fijos. Podrá combinar desviación histórica, predicción, incertidumbre e impacto potencial.

Cada señal deberá ir acompañada de una explicación para evitar simplificaciones excesivas.



12.29. MICE-IA como sistema de inteligencia competitiva aumentada

La integración de las nueve capas permite conceptualizar MICE-IA como un sistema de **Inteligencia Competitiva Aumentada**.

La expresión "aumentada" significa que la capacidad humana para interpretar el negocio se complementa con capacidades algorítmicas para procesar información, descubrir patrones y explorar escenarios.

El sistema no reemplaza al empresario. Amplía la cantidad y calidad de evidencia que puede considerar durante una decisión.

La fórmula conceptual es:

Inteligencia Competitiva Aumentada = Inteligencia Algorítmica + Inteligencia Empresarial Humana + Aprendizaje Organizacional.

12.30. Arquitectura conceptual integral de MICE-IA

La arquitectura central del modelo puede representarse mediante:

FUENTES DE DATOS

↓

INTELIGENCIA DE DATOS

Adquisición → integración → calidad → ICAD

↓

INTELIGENCIA EMPRESARIAL

KPI → tendencias → perfil descriptivo

↓

INTELIGENCIA DE SEGMENTACIÓN

Clustering → perfiles → IPC

↓

INTELIGENCIA PREDICTIVA



Modelos → validación → predicción → incertidumbre

↓

INTELIGENCIA EXPLICABLE

XAI → SHAP/LIME → factores → ICA

↓

INTELIGENCIA PRESCRIPTIVA

What-if → escenarios → multicriterio → riesgos/oportunidades

↓

INTELIGENCIA DE RECOMENDACIÓN

Motor híbrido → IPE → estrategias priorizadas

↓

INTELIGENCIA VISUAL Y CONVERSACIONAL

Dashboard → RIC → SEI → IA generativa

↓

DECISIÓN HUMANA

↓

INTELIGENCIA ADAPTATIVA

BAEE → retroalimentación → resultados → aprendizaje

↓

ACTUALIZACIÓN DE DATOS, MODELOS Y CONOCIMIENTO

Todo el sistema se encuentra atravesado transversalmente por:

GOBERNANZA + ÉTICA + PRIVACIDAD + SEGURIDAD + TRAZABILIDAD + SUPERVISIÓN HUMANA.

12.31. Arquitectura tecnológica derivada del modelo

MICE-IA permite posteriormente traducir el modelo conceptual hacia una arquitectura tecnológica.



La **capa de datos** estará constituida por bases de datos, procesos de integración y mecanismos de validación.

La **capa analítica** contendrá algoritmos de clustering, modelos predictivos y procedimientos de evaluación.

La **capa XAI** generará explicaciones globales y locales.

La **capa prescriptiva** incorporará simulación, escenarios y evaluación multicriterio.

La **capa recomendadora** contendrá reglas, conocimiento estratégico y mecanismos de priorización.

La **capa de interacción** estará constituida por dashboards y el asistente generativo.

Finalmente, la **capa de gobernanza** administrará usuarios, permisos, versiones, trazabilidad, seguridad y monitoreo.

De esta forma, el modelo conceptual puede convertirse directamente en especificaciones funcionales para la herramienta tecnológica.

12.32. Flujo de una decisión dentro de MICE-IA

Para comprender su funcionamiento puede plantearse el siguiente ejemplo.

Una empresa registra información de ventas. La capa descriptiva identifica una reducción sostenida.

El modelo predictivo estima que el comportamiento podría continuar durante el siguiente período.

XAI identifica los factores que contribuyeron a la estimación.

El sistema determina el segmento empresarial y recupera estrategias compatibles con dicho perfil.

La capa prescriptiva simula las alternativas bajo escenarios base, favorable y adverso.



El motor multicriterio calcula el IPE de cada estrategia.

El dashboard presenta las alternativas y el asistente generativo explica los resultados.

El empresario selecciona una acción.

Posteriormente, los resultados obtenidos regresan mediante el BAEE y se utilizan como nueva evidencia.

Este ejemplo demuestra que MICE-IA no produce una decisión mediante un único algoritmo. La decisión emerge de una cadena analítica trazable.

12.33. Matriz de operacionalización tecnológica

Dimensión MICE-IA	**Entrada**	**Tecnología principal**	**Salida**
Inteligencia de datos	Datos empresariales	ETL/preprocesamiento	Dataset validado + ICAD
Inteligencia descriptiva	Dataset	BI/KPI	Perfil empresarial
Segmentación	Variables empresariales	Clustering	Segmento + IPC
Predicción	Datos históricos	ML/series temporales	Pronóstico
Explicabilidad	Modelo + predicción	XAI	Factores + ICA
Prescripción	Predicción + restricciones	Simulación/MCDA	Escenarios



Recomendación	Perfil + escenarios	Motor híbrido	Estrategias + IPE
Visualización	Resultados integrados	Dashboard	RIC + SEI
Conversación	Resultados + conocimiento	IA generativa	Explicación
Adaptación	Decisión + resultados	BAEE	Aprendizaje

Esta matriz constituye el puente entre el modelo conceptual desarrollado en el libro y la posterior construcción del software.

12.34. Indicadores de evaluación del modelo

La evaluación de MICE-IA deberá realizarse en diferentes dimensiones y no exclusivamente mediante precisión algorítmica.

La dimensión **técnica** puede considerar desempeño predictivo, estabilidad, calidad de clustering y tiempos de respuesta.

La dimensión **analítica** evaluará utilidad de las explicaciones, pertinencia de escenarios y consistencia de las recomendaciones.

La dimensión **empresarial** podrá analizar utilidad percibida, comprensión, aceptación de recomendaciones y contribución al proceso decisorio.

La dimensión **responsable** incorporará trazabilidad, privacidad, seguridad, sesgo y cumplimiento de controles.

Finalmente, la dimensión **adaptativa** evaluará si la retroalimentación mejora progresivamente el comportamiento del sistema.

12.35. Validación científica propuesta



El carácter propio del modelo exige validación empírica antes de afirmar su efectividad. Se propone desarrollar esta validación mediante etapas sucesivas.

Primera etapa: validación conceptual. Expertos en inteligencia artificial, analítica empresarial y gestión podrán evaluar pertinencia, claridad y coherencia de las dimensiones.

Segunda etapa: validación de contenido. Los indicadores e instrumentos asociados podrán evaluarse mediante juicio de expertos y procedimientos como V de Aiken.

Tercera etapa: validación algorítmica. Se compararán modelos y métricas utilizando procedimientos de entrenamiento y validación apropiados.

Cuarta etapa: validación tecnológica. Se evaluará funcionamiento, usabilidad y desempeño del prototipo.

Quinta etapa: validación empresarial. Empresas participantes utilizarán la herramienta y valorarán utilidad, comprensión y pertinencia.

Sexta etapa: evaluación longitudinal. Cuando exista información suficiente, podrán analizarse cambios en indicadores y utilización de recomendaciones a través del tiempo.

Esta estructura permite diferenciar claramente entre **modelo propuesto** y **modelo empíricamente validado**.

12.36. Innovaciones aportadas por MICE-IA

La primera innovación corresponde a la **integración analítica completa**. El modelo no termina en Business Intelligence ni en machine learning, sino que conecta descripción, segmentación, predicción, explicación, prescripción y recomendación.



La segunda innovación es la incorporación de **XAI antes de la prescripción**, de manera que las recomendaciones se apoyen en predicciones previamente interpretadas.

La tercera corresponde al **Índice de Confianza Analítica**, que evita presentar todas las predicciones con el mismo grado implícito de seguridad.

La cuarta es el **Índice de Prioridad Estratégica**, destinado a transparentar la jerarquización de recomendaciones.

La quinta innovación es el **Bucle de Aprendizaje Estratégico Empresarial**, que conecta la recomendación con el resultado observado.

La sexta corresponde al **Índice Inteligente de Competitividad Empresarial**, concebido como indicador dinámico y susceptible de incorporar información prospectiva.

La séptima es el **Radar Inteligente de Competitividad**, que compara estado observado, esperado y potencial.

La octava innovación corresponde al **Semáforo Estratégico Inteligente**, que transforma resultados analíticos en señales comprensibles acompañadas de explicaciones.

La novena es la integración de **inteligencia visual y conversacional**, permitiendo interactuar con toda la arquitectura mediante dashboards e IA generativa.

La décima innovación es la concepción de **Inteligencia Competitiva Aumentada**, donde algoritmo y empresario forman un sistema colaborativo de decisión.



12.37. Diferenciación frente a una plataforma convencional de Business Intelligence

Una plataforma convencional de BI responde principalmente:

¿Qué ocurrió?

MICE-IA amplía progresivamente las preguntas:

¿Qué ocurrió?

¿Qué perfiles existen?

¿Qué podría ocurrir?

¿Por qué el modelo estima ese resultado?

¿Qué alternativas pueden evaluarse?

¿Qué ocurriría bajo diferentes escenarios?

¿Qué estrategia presenta mayor prioridad?

¿Qué nivel de confianza sustenta la recomendación?

¿Qué ocurrió después de implementarla?

¿Qué debe aprender el sistema?

Esta evolución constituye el principal elemento diferenciador de la propuesta.

12.38. Aporte científico del modelo

Desde la perspectiva científica, MICE-IA propone una estructura conceptual susceptible de operacionalización y contrastación empírica.

Su aporte no consiste en afirmar la creación de nuevos algoritmos de clustering, predicción o XAI. Estas tecnologías poseen fundamentos científicos previamente desarrollados.

La originalidad se encuentra en **la arquitectura de integración, los constructos propuestos y las relaciones funcionales establecidas entre ellos**.



Particularmente, ICAD, ICA, IPE, IICE, RIC, SEI y BAEE constituyen componentes conceptuales propios que deberán ser posteriormente operacionalizados y validados.

Esta precisión resulta importante para diferenciar innovación conceptual de innovación algorítmica y evitar atribuir al modelo aportes que todavía no hayan sido demostrados experimentalmente.

12.39. Proposición científica central de MICE-IA

El modelo permite formular la siguiente proposición:

P1. Una arquitectura empresarial que integre calidad de datos, segmentación, predicción, explicabilidad, simulación, recomendación, visualización y retroalimentación puede proporcionar mayor capacidad de apoyo analítico a la decisión que la utilización aislada de herramientas descriptivas.

De ella pueden derivarse proposiciones secundarias:

P2. Una mayor calidad de datos favorece la confiabilidad de los resultados analíticos.

P3. La segmentación mejora la capacidad de personalizar predicciones y recomendaciones cuando existen perfiles empresariales diferenciables.

P4. La explicabilidad mejora la capacidad del usuario para comprender y evaluar las predicciones.

P5. La simulación permite comparar alternativas antes de su implementación.

P6. La recomendación contextualizada incrementa la pertinencia percibida frente a recomendaciones generales.



P7. La retroalimentación proporciona evidencia para mejorar progresivamente modelos y reglas.

Estas proposiciones pueden convertirse posteriormente en hipótesis contrastables durante las fases de validación del proyecto.

12.40. Síntesis del capítulo

La competitividad empresarial contemporánea requiere capacidades que superan el análisis descriptivo tradicional. Las organizaciones necesitan interpretar información, anticipar cambios y evaluar alternativas utilizando datos de manera sistemática (Pérez Jesús et al., 2024; Fasanando-Trigoso et al., 2025).

La inteligencia artificial proporciona herramientas para ampliar estas capacidades, pero su utilización aislada puede generar fragmentación tecnológica. Por esta razón, el presente capítulo propuso una arquitectura que articula los diferentes componentes desarrollados durante el libro.

El **Modelo Inteligente de Competitividad Empresarial basado en Inteligencia Artificial (MICE-IA)** constituye una propuesta propia organizada mediante nueve capas funcionales y tres ejes transversales.

Las capas transforman progresivamente los datos en conocimiento mediante inteligencia de datos, BI, segmentación, predicción, XAI, prescripción, recomendación, visualización y aprendizaje.

Los ejes de gobernanza, seguridad y supervisión humana atraviesan toda la arquitectura y establecen límites responsables para el funcionamiento del sistema.



La propuesta incorpora además siete constructos propios: **ICAD, IPC, ICA, IPE, IICE, RIC y SEI**, complementados mediante el **Bucle de Aprendizaje Estratégico Empresarial (BAEE)**.

El modelo introduce el concepto de **Inteligencia Competitiva Aumentada**, definida como la integración entre inteligencia algorítmica, inteligencia empresarial humana y aprendizaje organizacional.

La arquitectura puede sintetizarse mediante:

DATOS

↓

ICAD – CALIDAD ANALÍTICA

↓

BUSINESS INTELLIGENCE + KPI

↓

SEGMENTACIÓN + IPC

↓

PREDICCIÓN

↓

XAI + ICA

↓

SIMULACIÓN Y PRESCRIPCIÓN

↓

RECOMENDACIÓN + IPE

↓

IICE + RIC + SEI

↓

DASHBOARD + IA GENERATIVA

↓



DECISIÓN HUMANA

↓

BAEE – RETROALIMENTACIÓN

↓

APRENDIZAJE

↓

NUEVO CICLO ANALÍTICO

Todo ello se desarrolla bajo:

ÉTICA + GOBERNANZA + PRIVACIDAD + SEGURIDAD + TRAZABILIDAD + SUPERVISIÓN HUMANA.

En consecuencia, MICE-IA plantea una evolución desde una herramienta que simplemente presenta información hacia un **ecosistema inteligente, explicable, prescriptivo, adaptativo y centrado en la decisión humana**. Su finalidad consiste en reducir la brecha entre datos y decisiones mediante una arquitectura que no solamente identifica qué ocurre en una empresa, sino que permite reconocer perfiles, anticipar comportamientos, comprender predicciones, explorar escenarios, priorizar estrategias y aprender de los resultados obtenidos.

El aporte central del modelo puede expresarse finalmente mediante una relación conceptual:

DATOS → CONOCIMIENTO → ANTICIPACIÓN → EXPLICACIÓN → SIMULACIÓN → ESTRATEGIA → DECISIÓN → APRENDIZAJE → COMPETITIVIDAD.



REFERENCIAS BIBLIOGRÁFICAS

Dini, M., Gligo, N., & Patiño, A. (2021). Transformación digital de las MiPymes: elementos para el diseño de políticas (LC/TS.2021/99). Comisión Económica para América Latina y el Caribe.

Jung, J., & Katz, R. L. (2026). Impacto económico de la inteligencia artificial en América Latina: transformación tecnológica y rezago en materia de inversión y capacidades laborales (LC/TS.2025/37/Rev.2). Comisión Económica para América Latina y el Caribe.

Soto, Á., Durán, R., Moreno, A., Adasme, S., Rovira, S., Jordán, V., & Poveda, L. (Coords.). (2026). Índice Latinoamericano de Inteligencia Artificial (ILIA) 2025. Hallazgos principales, IA aplicada y talento humano (Documentos de Proyectos, LC/TS.2026/1). Comisión Económica para América Latina y el Caribe y Centro Nacional de Inteligencia Artificial. https://doi.org/10.65730/maolsdjpr

Latorre, L., Muro, V., Rego, E., Gutierrez, M., Cerrato, I., & Zarate, J. D. (2024). Reporte de tecnología: inteligencia artificial. Banco Interamericano de Desarrollo. https://doi.org/10.18235/0013015

Berrío-Meneses, C. M., Sanguino-García, V., & Isaza-Álvarez, J. (2025). Inteligencia artificial, analítica de datos y big data en el márketing y las segmentaciones de cliente y consumidor. Revisión sistemática de literatura. Revista Galega de Economía, 34(3), 10108. https://doi.org/10.15304/rge.34.3.10108

González-Samaniego, A., & Valenzo-Jiménez, M. A. (2020). Capacidades dinámicas como factor de competitividad en las

PYME. Revista de la Facultad de Contaduría y Ciencias Administrativas, 5(10), 81–91.

González-Arellano, L. A., & Acosta-Gonzaga, E. (2021). Capacidades dinámicas de gestión de los gerentes de las pymes en la adopción del comercio electrónico nacional y transfronterizo. Nova Scientia, 13(27), 00020. https://doi.org/10.21640/ns.v13i27.2770

Sánchez-Rodríguez, A., García-Vidal, G., Fernández-Ochoa, Y., Martínez-Vivar, R., Gavilanes-Venegas, A. E., & Pérez-Campdesuñer, R. (2025). Navigating uncertainty through AI adoption: Dynamic capabilities, strategic innovation performance, and competitiveness in Ecuadorian SMEs. Administrative Sciences, 15(12), 468. https://doi.org/10.3390/admsci15120468

Horta Lázaro, A. M., Uribe Macías, M. E., & Rubio Guerrero, G. (2025). Análisis de la relación de las capacidades dinámicas y la productividad y competitividad de las empresas industriales. Revista CEA, 11(26), e3372 https://doi.org/10.22430/24223182.3372

Suárez Alemán, P. M. (2024). Desbloqueando valor: cómo la analítica y la big data refuerzan la cadena de suministro. Revista Científica de Ingeniería y Arquitectura_iyA, 3(3), 66–76. https://doi.org/10.62407/rciya.v3i3.158

Departamento Administrativo de la Función Pública. (2022). Analítica institucional: el poder de los datos en el sector público (Versión 1). Función Pública.

Soto, Á., Durán, R., Moreno, A., Adasme, S., Rovira, S., Jordán, V., & Poveda, L. (Coords.). (2025). Índice Latinoamericano de

Inteligencia Artificial (ILIA) 2025 (Documentos de Proyectos, LC/TS.2025/68/Rev.1). Comisión Económica para América Latina y el Caribe y Centro Nacional de Inteligencia Artificial.

Porras Sandoval, M. I., Solano Rosales, G. F., Rincón Montero, R. I., Rodríguez Zúñiga, M. A., & Pérez Esparza, E. (2025). Transformación digital en las PyMEs mexicanas: Un paradigma emergente de la inteligencia artificial para la competitividad empresarial. Ciencia Latina Revista Científica Multidisciplinar, 9(2). https://doi.org/10.37811/cl_rcm.v9i2.16847

Capítulo 2 – referencias que aparecen por primera vez

Patiño, A., Cabello, S. M., Ros, D., & Urtasun, M. (2025). Transformación digital productiva: análisis de políticas, estrategias e instrumentos para impulsarla en América Latina (Documentos de Proyectos, LC/TS.2025/97). Comisión Económica para América Latina y el Caribe.

Jung, J., & Katz, R. L. (2025). Factores determinantes de la adopción de la inteligencia artificial en las empresas: un estudio empírico del caso del Brasil (Documentos de Proyectos, LC/TS.2025/38). Comisión Económica para América Latina y el Caribe.

Kejsefman, I., Harracá, M., Carreira, T., Castro, R., Rovira, S., Patiño, A., & Seiffarth, F. (2026). Simulador de la transformación digital productiva: una herramienta para el diseño de políticas basadas en datos (Documentos de Proyectos, LC/TS.2026/71). Comisión Económica para América Latina y el Caribe.

Martorell, P., & Porrúa, M. (2026). Modelo de referencia para políticas de IA en el sector público de América Latina y el Caribe. Banco Interamericano de Desarrollo. https://doi.org/10.18235/0014418

Katz, R. L. (2024). Oportunidades para la transformación digital productiva: evidencia estadística sobre el nivel de digitalización sectorial en América Latina y el Caribe (Documentos de Proyectos, LC/TS.2023/176). Comisión Económica para América Latina y el Caribe.

Bajaña Rosado, J. M., & Romero Riera, J. M. (2023). *Software de predicción de ventas en una PYME basado en técnicas de aprendizaje automático* [Trabajo de titulación de maestría, Universidad Politécnica Salesiana]. Repositorio Institucional de la Universidad Politécnica Salesiana.

Bender, A., Nicolet, S., & Macrino, M. (2020). Automatización del aprendizaje de máquinas ("AutoML"): logros y obstáculos. *Anuario de Investigación USAL*, (7).

Chambi Condori, P. P. (2023). Segmentación de mercado: Machine Learning en marketing en contextos de COVID-19. *Industrial Data, 26*(1), 275–301. https://doi.org/10.15381/idata.v26i1.23623

Chapa Zumba, C. V. (2023). *Segmentación de clientes (socios) para la recomendación de productos de colocación y/o captación para institución financiera en Ecuador* [Trabajo de maestría, Pontificia Universidad Católica del Ecuador]. Repositorio Institucional PUCE.

Hidalgo Bailón, S. P., & Cedeño-Valarezo, L. (2025). Análisis de clúster para la segmentación de clientes en la concesión de créditos otorgados por la Corporación Financiera Nacional. *REFCalE: Revista Electrónica Formación y Calidad Educativa, 13*(2). https://doi.org/10.56124/refcale.v13i2.004

Molina Villacís, M., Molina Miranda, M., Acaro Chacón, X., Jiménez Villao, A., et al. (2024). Inteligencia artificial explicable en una aplicación en sistemas de recomendación. *Ecuadorian Science Journal, 8*(2), 28–35. https://doi.org/10.46480/esj.8.2.180

Pezzini, M. C. (2024). *Inteligencia artificial explicable: análisis de metodologías y aplicaciones* [Trabajo de especialización, Universidad Nacional de La Plata]. Facultad de Informática, Universidad Nacional de La Plata.

Ramírez Lemus, L., Rodríguez Gutiérrez, M., & Rodríguez Rodríguez, C. (2026). Impacto de la inteligencia artificial en la competitividad empresarial y los negocios internacionales. *Horizonte Empresarial*. https://doi.org/10.26495/b9fyjg93

Tomak, K. (2026). *Aprender AutoML*. O'Reilly Media.

Alonso-Rodríguez, A. (2021). La predicción de series temporales mediante el modelo de regresión. *Anuario Jurídico y Económico Escurialense*, (54), 261–280. https://doi.org/10.54571/ajee.480

Calle García, A. J., Aviles Barcia, E. M., Baque Reina, E. A., & Muñiz Rodríguez, F. S. (2024). El papel de la analítica predictiva en la anticipación de cambios en el entorno empresarial. *Ciencia y Desarrollo, 27*(2). https://doi.org/10.21503/cyd.v27i2.2601

Casanova-Villalba, C. I., Herrera-Sánchez, M. J., & Proaño-González, E. A. (2023). Impacto de la analítica predictiva en la toma de decisiones gerenciales. *Revista Científica Ciencia y Método, 1*(3), 16–30. https://doi.org/10.55813/gaea/rcym/v1/n3/17

Fernández López, R., Vilalta Alonso, J. A., Quintero Silverio, A., & Díaz González, L. R. (2020). La demanda turística en una cadena hotelera. Series temporales para un modelo de predicción. *Revista Científica Visión de Futuro, 25*(1).

Mendoza Arce, C. G., Mendoza Haro, I., Camacho Gavilanes, J. A., & Mendoza Arce, E. X. (2024). La inteligencia artificial como motor de innovación en los negocios. *Magazine de las Ciencias: Revista de Investigación e Innovación, 9*(4). https://doi.org/10.33262/rmc.v9i4.3263

Moraes, F. S., Gonçalves de Souza, B., & Mazia Enami, L. (2023). Aplicación del suavizado exponencial para la predicción de la demanda en una empresa de impresión de tazas pequeñas. *Brazilian Journal of Production Engineering, 9*(5). https://doi.org/10.47456/bjpe.v9i5.42590

Murillo Valverde, R. I., Sarmiento Oyola, D. H., Mendoza Santillán, A. B., Vergara Velasquez, H. Y., & Bustamante León, A. N. (2024). Análisis del uso de la inteligencia artificial en las microempresas del cantón Guayaquil 2024. *Ciencia Latina Revista Científica Multidisciplinar, 8*(4), 3887–3902.

Rahmer, B. de J., Garzón Saénz, H., & Solana Garzón, J. (2022). Aplicación de modelos de difusión y de series temporales para pronóstico de demanda agregada. *Revista de Ciencias Sociales, 28*(3), 142–159. https://doi.org/10.31876/rcs.v28i3.38458

Ramírez Lemus, L., Rodríguez Gutiérrez, M., & Rodríguez Rodríguez, C. (2026). Impacto de la inteligencia artificial en la competitividad empresarial y los negocios internacionales. *Horizonte Empresarial*.

https://doi.org/10.26495/b9fyjg93

Viteri, C. G., Herrera, L. M., & colaboradores. (2022). Métodos de predicción de demanda: Una revisión de la literatura. *Innovar, Revista de Ciencias Administrativas y Sociales*.

Calle García, A. J., Aviles Barcia, E. M., Baque Reina, E. A., & Muñiz Rodríguez, F. S. (2024). El papel de la analítica predictiva en la anticipación de cambios en el entorno empresarial. *Ciencia y Desarrollo, 27*(2). https://doi.org/10.21503/cyd.v27i2.2601

Casanova-Villalba, C. I., Herrera-Sánchez, M. J., & Proaño-González, E. A. (2023). Impacto de la analítica predictiva en la toma de decisiones gerenciales. *Revista Científica Ciencia y Método, 1*(3), 16–30. https://doi.org/10.55813/gaea/rcym/v1/n3/17

Chambi Condori, P. P. (2023). Segmentación de mercado: Machine Learning en marketing en contextos de COVID-19. *Industrial Data, 26*(1), 275–301. https://doi.org/10.15381/idata.v26i1.23623

Cueva Estrada, J. M., Sumba Nacipucha, N. A., & Delgado Figueroa, S. P. (2023). Marketing predictivo: aplicación de inteligencia artificial en el cliente. *Revista Venezolana de Gerencia, 28*(103).

Mendoza Arce, C. G., Mendoza Haro, I., Camacho Gavilanes, J. A., & Mendoza Arce, E. X. (2024). La inteligencia artificial como motor de innovación en los negocios. *Magazine de las Ciencias: Revista de Investigación e Innovación, 9*(4). https://doi.org/10.33262/rmc.v9i4.3263

Murillo Valverde, R. I., Sarmiento Oyola, D. H., Mendoza Santillán, A. B., Vergara Velasquez, H. Y., & Bustamante León, A. N. (2024). Análisis del uso de la inteligencia artificial en las microempresas del cantón Guayaquil 2024. *Ciencia Latina Revista Científica Multidisciplinar, 8*(4), 3887–3902.

Ramírez Lemus, L., Rodríguez Gutiérrez, M., & Rodríguez Rodríguez, C. (2026). Impacto de la inteligencia artificial en la competitividad empresarial y los negocios internacionales. *Horizonte Empresarial*. https://doi.org/10.26495/b9fyjg93

Lalama Freire, D. P. (2025). Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo. *Dominio de las Ciencias, 11*(4), 1229–1247. doi:10.23857/dc.v11i4.4613.

Ortega Ovalle, M. T. (2026). Inteligencia Artificial Explicable (XAI) como marco para la transparencia en la ciencia de datos: interpretabilidad, toma de decisiones ética y responsabilidad algorítmica. *Revista Científica de Salud y Desarrollo Humano, 7*(1). doi:10.61368/r.s.d.h.v7i1.978.

Riccio Anastacio, F. R., Gavilánez Ortega, M. I., & Carrasco Agraces, O. O. (2025). El rol de la Inteligencia Artificial Explicable: revisión sistemática de sus tendencias y líneas de investigación emergentes. *Revista Científica Multidisciplinar G-nerando*.

Robles-Zambrano, G. K., Diaz-Basurto, I. J., Ros-Álvarez, D., & Ramírez-Bósquez, V. Z. (2026). Inteligencia artificial explicable y transparencia algorítmica: desafíos y progresos en decisiones automatizadas. *Revista UGC, 4*(2), 175–180.

Bron Fonseca, B., & Mar Cornelio, O. (2022). Sistemas de recomendación para la toma de decisiones. Estado del arte. *UNESUM-Ciencias. Revista Científica Multidisciplinaria, 6*(1). doi:10.47230/unesum-ciencias.v6.n1.2022.289.

Guevara Fernández, A., & Coral Ygnacio, M. A. (2023). Una revisión de métodos, técnicas y algoritmos para sistemas de recomendación de productos tecnológicos. *Interfases*, (18). doi:10.26439/interfases2023.n018.6357.

Pérez-Almaguer, Y., Martín-Dueñas, N., Carballo-Cruz, E., & Yera, R. (2021). Una revisión de los sistemas recomendadores grupales como herramienta innovadora en el área del turismo. *Revista de Ciencia y Tecnología*, (35). doi:10.36995/j.recyt.2021.35.006.

Salgado Reyes, N., & Trujillo Moreno, G. E. (2024). Sistemas de recomendación personalizados: implementación de sistemas de recomendación utilizando técnicas de machine learning para mejorar la experiencia del usuario en plataformas en línea. *Polo del Conocimiento, 9*(1), 1986–1997.

Schab, E. A., Piccoli, M. F., & Casanova Pietroboni, C. A. (2020). Analítica prescriptiva en sistemas con grandes flujos de eventos. *AJEA (Actas de Jornadas y Eventos Académicos de UTN)*, (5). doi:10.33414/ajea.5.737.2020.

Torres-Herrera, M., Cuaya-Simbro, G., & Canales-Castillo, C. (2024). Sistemas recomendadores como herramienta en la labor docente: una revisión sistemática. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI, 11*(22), 34–42. doi:10.29057/icbi.v11i22.11032.

Tsunoda, D. F., Ribeiro, P. F. R., Pires, J. de L., Hubner, K. V., Reis, M. H. A. dos, Bastos, P. A., & Rigo, R. (2026). Sistemas de recomendación y procesamiento de lenguaje natural: una revisión estructurada y tendencias emergentes con el soporte de herramientas de inteligencia artificial. *Investigación Bibliotecológica: Archivonomía, Bibliotecología e Información, 40*(106), 79–108 doi:10.22201/iibi.24488321xe.2026.106.59106.

Hernández, [autores del artículo]. (2023). Método de pronóstico y multicriterio para analizar la demanda y selección de proveedores en una PYME. *Ingeniería, Investigación y Tecnología, 24*(2).

Izurieta, C., Buenaño, S., & Rivera, M. (2024). El diseño industrial y la simulación como herramienta para mejorar los procesos. *Polo del Conocimiento, 9*(3).

Rodríguez Tejada, A. H., Marín Betancur, A., Melo Hidalgo, Á. M., & Ávila Bohorquez, R. E. (2020). Herramientas de simulación para la toma de decisiones empresariales. *Documentos de Trabajo ECACEN*, (2), 1–10. doi:10.22490/ECACEN.4262.

Romo-Nava, M., Ayala-Muñoz, D., & Flores-Sierra, J. de J. (2024). Aplicación de (AHP) análisis jerárquico multicriterio para el análisis de adquisición de una termobalanza. *C&T Riqchary Revista de Investigación en Ciencia y Tecnología, 6*(1). doi:10.57166/riqchary.v6.n1.2024.116.

Santos Samaniego, F. P., Parra Vélez, G. J., Caicedo Valencia, J. R., Reina Tello, S. S., & Reina Tello, M. E. (2025). Del Excel a la inteligencia artificial: un marco estratégico para la analítica de

datos prescriptiva y la transformación de la toma de decisiones empresariales. *Polo del Conocimiento, 10*(12).

Schab, E. A., Piccoli, M. F., & Casanova Pietroboni, C. A. (2020). Analítica prescriptiva en sistemas con grandes flujos de eventos. *AJEA (Actas de Jornadas y Eventos Académicos de UTN)*, (5). doi:10.33414/ajea.5.737.2020.

Alvarado Apodaca, J., Ramírez Noriega, A., & Álvarez Sánchez, I. (2025). Implementación de dashboards interactivos para la mejora en la toma de decisiones empresariales. *Revista de Investigación en Tecnologías de la Información, 13*(32). doi:10.36825/RITI.13.32.008.

Alvarez Gonzaga, B. R. (2021). Inteligencia de negocios para la toma de decisiones: Un enfoque desde la dirección estratégica de instituciones educativas. *Revista Scientific, 6*(19), 295–312. doi:10.29394/Scientific.issn.2542-2987.2021.6.19.15.295-312.

Cedeño-Mendoza, A. M., & Zambrano-Santos, R. O. (2026). Uso del Power BI en el monitoreo de indicadores clave de desempeño (KPIs) para la competitividad empresarial. *Código Científico Revista de Investigación, 7*(N.E.1). doi:10.55813/gaea/ccri/v7/nE1/1357.

Chinchuña, E., Mejía, J., & Baldéon, J. (2026). Implementación de modelos de inteligencia de negocios para la toma de decisiones en pymes ecuatorianas. *Caminos de Investigación, 7*(2). doi:10.59773/ci.v7i2.131.

Cruz Osorio, K. G., Garzón Montealegre, V. J., Quezada Campoverde, J., & Carvajal Romero, H. (2022). Tableros y gráficos automatizados: un enfoque a la visualización de datos e

inteligencia de negocio. *Ciencia Latina Revista Científica Multidisciplinar, 6*(4), 2624–2641. doi:10.37811/cl_rcm.v6i4.2784.

Dorado Bastidas, C. A., Córdoba Campos, E. Y., & Chanchí Golondrino, G. E. (2023). Dashboard apoyado en inteligencia de negocios para toma de decisiones en el sector salud. *Gestión y Desarrollo Libre, 8*(16). doi:10.18041/2539-669/gestionlibre.16.2023.10226.

Fasanando-Trigoso, D. C., Ramírez-Pezo, Y. E., & Murrieta-Patow, G. B. (2025). Impacto de la inteligencia de negocios en la mejora de la toma de decisiones: una revisión sistemática de la literatura. *Revista Amazonía Digital, 4*(2). doi:10.55873/rad.v4i2.370.

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). doi:10.33975/riuq.vol33n1.514.

Grisales Aguirre, A. M., Espinosa Villa, L. M., & Alzate, P. (2024). La evolución de la visualización de datos: campos de aplicación y herramientas de Business Intelligence. *Revista de Ingenierías Interfaces, 7*(1).

Pérez Jesús, D. E., Arceo Moheno, G., de los Santos Torres, G., & Ramos Méndez, E. (2024). Inteligencia de negocios, toma de decisiones y competitividad en empresas de Villahermosa, México. *RISTI: Revista Ibérica de Sistemas e Tecnologias de Informação*, (E70), 342–355.

Verdezoto-Naveda, J. E. (2024). Business Intelligence en la toma de decisiones en empresas turísticas de la ciudad de Puyo. *ISTE Scientist, 3*(1), 44–53.

Weis Filho, M. A., Medianeira Bolzan, L., & Iriondo, W. R. (2021). Visualización de datos de Business Intelligence para la toma de decisiones: un caso de estudio con la herramienta Power BI. *EducaT: Educación Virtual, Innovación y Tecnologías, 2*(2), 35–49. doi:10.22490/27452115.5307.

Zegarra-Chamorro, L. G., & Ormeño-Audante, A. G. (2025). Dashboards en SAP Business Intelligence para la toma de decisiones en la industria automotriz: una revisión sistemática. *Epistemia Revista Científica, 9*(1). doi:10.26495/erc.2863.

Álava Naranjo, E. E., Ruiz Briones, M. G., & Vera Basurto, J. J. (2026). Inteligencia artificial generativa y toma de decisiones estratégicas: Implicaciones para la eficiencia y competitividad en la gestión empresarial. *Ibero Ciencias, 5*(1), 3360–3372. doi:10.63371/ic.v5.n1.a833.

Bone Vera, J., Arca Zavala, J., Sinchiguano Chiriboga, C., & Arévalo Hermida, R. (2026). La inteligencia artificial generativa en la ingeniería de software: Nuevas metodologías, herramientas y paradigmas de desarrollo. *Revista Tse'de, 9*(1) doi:10.60100/tsede.v9i1.296.

Cortés Hernández, A., Hernández Hernández, C. A., García Torres, A. B., & Mata Quezadas, M. (2024). La inteligencia artificial generativa como un asistente estratégico en la era del aprendizaje digital. *Ciencia Latina Revista Científica Multidisciplinar, 8*(4), 2159–2178.

Mora-Delgado, J., Ramos-Ruperto, L., Pardilla, M. J., Sicilia, M. Á., Rodríguez-González, A., Sempere, J. M., & Puchades, R. (2026). Inteligencia artificial generativa: los modelos fundacionales. Procesamiento del lenguaje natural y modelos de lenguaje grandes. *Revista Clínica Española, 226*(1), 502413. doi:10.1016/j.rce.2025.502413.

Segura Ibarra, H. (2026). Inteligencia artificial generativa y potencialización de las Pymes: un análisis del uso de ChatGPT en la transformación empresarial. *Espacio Científico de Contabilidad y Administración, 4*(2). doi:10.58493/ecca.2026.4.2.02.

Uparela-Barragán, H., Gaspar-López, J., Salas Álvarez, D., & Parodi-Camaño, T. (2025). Automatización inteligente para PYMEs mediante chatbots con IA generativa. *Transformar, 6*(4), 22–32.

Asamblea Nacional del Ecuador. (2021). *Ley Orgánica de Protección de Datos Personales*. Registro Oficial, Quinto Suplemento N.º 459, 26 de mayo de 2021.

International Organization for Standardization [ISO]. (2023). *ISO/IEC 42001:2023. Tecnología de la información. Inteligencia artificial. Sistema de gestión*. ISO.

International Organization for Standardization [ISO]. (2023). *ISO/IEC 23894:2023. Tecnología de la información. Inteligencia artificial. Orientación sobre la gestión de riesgos*. ISO.

Ordoñez-Iturralde, D. D., & Proaño-Piedra, C. X. (2024). Gobernanza y desafíos éticos en la adopción empresarial de la inteligencia artificial. *Innovación Empresarial, 4*(2). doi:10.37711/rcie.2024.4.2.633.

Parra Sepúlveda, D., & Concha Machuca, R. (2025). La inteligencia artificial explicable como fundamento para la gobernanza de la IA. Sus implicancias en la responsabilidad civil. *Revista Chilena de Derecho y Tecnología, 14*. doi:10.5354/0719-2584.2025.74040.

Bron Fonseca, B., & Mar Cornelio, O. (2022). Sistemas de recomendación para la toma de decisiones. Estado del arte. *UNESUM-Ciencias. Revista Científica Multidisciplinaria, 6*(1). doi:10.47230/unesum-ciencias.v6.n1.2022.289.

Chinchuña, E., Mejía, J., & Baldéon, J. (2026). Implementación de modelos de inteligencia de negocios para la toma de decisiones en pymes ecuatorianas. *Caminos de Investigación, 7*(2). doi:10.59773/ci.v7i2.131.

Fasanando-Trigoso, D. C., Ramírez-Pezo, Y. E., & Murrieta-Patow, G. B. (2025). Impacto de la inteligencia de negocios en la mejora de la toma de decisiones: una revisión sistemática de la literatura. *Revista Amazonía Digital, 4*(2). doi:10.55873/rad.v4i2.370.

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). doi:10.33975/riuq.vol33n1.514.

International Organization for Standardization [ISO]. (2023). *ISO/IEC 42001:2023. Tecnología de la información. Inteligencia artificial. Sistema de gestión*. ISO.

Ordoñez-Iturralde, D. D., & Proaño-Piedra, C. X. (2024). Gobernanza y desafíos éticos en la adopción empresarial de la inteligencia



artificial. *Innovación Empresarial, 4*(2). doi:10.37711/rcie.2024.4.2.633.

Parra Sepúlveda, D., & Concha Machuca, R. (2025). La inteligencia artificial explicable como fundamento para la gobernanza de la IA. Sus implicancias en la responsabilidad civil. *Revista Chilena de Derecho y Tecnología, 14*. doi:10.5354/0719-2584.2025.74040.

Pérez Jesús, D. E., Arceo Moheno, G., de los Santos Torres, G., & Ramos Méndez, E. (2024). Inteligencia de negocios, toma de decisiones y competitividad en empresas de Villahermosa, México. *RISTI: Revista Ibérica de Sistemas e Tecnologias de Informação*, (E70), 342–355.

Schab, E. A., Piccoli, M. F., & Casanova Pietroboni, C. A. (2020). Analítica prescriptiva en sistemas con grandes flujos de eventos. *AJEA (Actas de Jornadas y Eventos Académicos de UTN)*, (5). doi:10.33414/ajea.5.737.2020.

ANEXO 1
Revisión de pares ciegos.

EDITORIAL M.S.
Av. Ernest Rutherford y John Dalton. Tlf: +593 960677758
Ambato – Ecuador

INFORME DE EVALUACIÓN DE REVISORES CIEGOS

Datos de la obra	
Nombre de la Obra	INTELIGENCIA ARTIFICIAL Y ANALÍTICA PREDICTIVA PARA LA COMPETITIVIDAD EMPRESARIAL. Modelos de segmentación automatizada, predicción y recomendación estratégica.
Fecha de Evaluación	Octubre 12 del 2026

Datos del revisor		
Nombre	GUSTAVO EDUARDO	
Apellidos	FERNANDEZ VILLACRES	Cédula: 1801589191
Grado académico	Maestría	Doctorado X
Título pregrado	Licenciado en INFORMATICA	
Área de posgrado	PHD EN EDUCACION, MASTER EN INGENIERIA DE SISTEMAS Y MASTER EN ADMINISTRACION DE EMPRESAS	

Contenido del texto		
N°	**Descripción**	**Observaciones**
1	Título, prólogo e introducción (claridad y estructura)	Se da a entender de manera clara y concisa los temas abordados en el documento.
2	Relevancia, Originalidad Revisión de literatura	Documento que muestra texto muy explícito en el área abordada, mostrando una recopilación de información apropiada.
3	Estructura metodológica. Diseño experimental	Explicada de forma clara y concisa.
4	Resultados, Discusión , Conclusiones.	Recopilación de datos obtenidos concretos, mostrando aportes de vital importancia a la investigación realizada por parte de los autores.
5	Referencia (variedad y claridad	Muy bien establecidas de acuerdo a los lineamientos establecidos.

Dictamen			
Descripción	**Sí**	**No**	**Observaciones**
Publicable	**X**		
Publicar con correcciones			
No publicar			

Atentamente,

Gustavo Eduardo Fernandez Villacres
Time Stamping Security Data

PhD. Eduardo Fernández V.
Revisor

INFORME DE EVALUACIÓN DE REVISORES CIEGOS

Datos de la obra	
Nombre de la Obra	INTELIGENCIA ARTIFICIAL Y ANALÍTICA PREDICTIVA PARA LA COMPETITIVIDAD EMPRESARIAL Modelos de segmentación automatizada, predicción y recomendación estratégica.
Fecha de Evaluación	Octubre 5 /2026

Datos del revisor		
Nombre	Roberto Rolando	
Apellidos	López López	Cédula: 1802301562
Grado académico	Maestría	Doctorado X
Título pregrado	Ingeniero en sistemas	
Area de posgrado	Master en Administración de empresas. **PhD. en educación**	

Contenido del texto		
N°	**Descripción**	**Observaciones**
1	Título, prólogo e introducción (claridad y estructura)	Se da a entender de manera clara y concisa los temas abordados en el documento.
2	Relevancia Originalidad Revisión de literatura	Documento que muestra texto muy explícito en el área abordada, mostrando una recopilación de información apropiada.
3	Estructura metodológica Diseño experimental	Explicada de forma clara y concisa.
4	Resultados Discusión Conclusiones	Recopilación de datos obtenidos concretos, mostrando aportes de vital importancia a la investigación realizada por parte de los autores.
5	Referencia (variedad y claridad)	Muy bien establecidas de acuerdo a los lineamientos establecidos.

Dictamen			
Descripción	**Sí**	**No**	**Observaciones**
Publicable	**X**		
Publicar con correcciones			
No publicar			

Atentamente,

Validar únicamente en FirmaEC.
Firmado electrónicamente por:
ROBERTO ROLANDO LOPEZ LOPEZ

PhD. López López Roberto Rolando
Revisor

ANEXO 2

Revisión anti plagio.



De los datos a la decisión estratégica

La inteligencia artificial adquiere valor empresarial cuando sus resultados se convierten en conocimiento útil para decidir. Esta obra examina cómo integrar datos, modelos analíticos y criterio gerencial para fortalecer la competitividad de las organizaciones.

A lo largo de doce capítulos, aborda la segmentación automatizada, la analítica predictiva, la inteligencia artificial explicable y los sistemas de recomendación estratégica. Incorpora la simulación de escenarios, los dashboards inteligentes y la IA generativa, con especial atención a las micro, pequeñas y medianas empresas.

El recorrido culmina con la propuesta conceptual MICE-IA, que articula estas capacidades con el aprendizaje organizacional. La calidad de los datos, la privacidad, la transparencia y la supervisión humana orientan una adopción responsable y contextualizada.

Gissela Alexandra Arcos Naranjo

INTELIGENCIA ARTIFICIAL · ANALÍTICA PREDICTIVA · GESTIÓN EMPRESARIAL