

3. Aplicación de la complejidad en la inteligencia de negocios



DOI: <https://doi.org/10.52501/cc.395.03>

JOSUE-MIGUEL FLORES-PARRA*

NORA DEL CARMEN OSUNA-MILLÁN**

RICARDO FERNANDO ROSALES-CISNEROS***

Resumen

Este capítulo explora cómo la teoría de la complejidad puede utilizarse como un marco de trabajo para la inteligencia de negocios (BI) en el ambiente organizacional. La complejidad, más que un reto, representa una característica representativa e innata de los datos, la información, los proyectos y los sistemas organizacionales. Se analiza la influencia de la complejidad en la multidimensionalidad, la heterogeneidad y las interacciones no lineales y dinámicas de los datos, así también cómo se maneja el uso de métodos analíticos avanzados como el Análisis de Componentes Principales (PCA) y el aprendizaje automático. Se realiza un comparativo entre la administración de proyectos tradicional y la ágil basado en las bondades u orientaciones de cada uno de los marcos de trabajo, donde se puede resaltar que la adaptabilidad, autoorganización y la automotivación, así como el conocimiento y aprendizaje emergente, representan un factor clave para el éxito de los proyectos en un entorno de alto grado de incertidumbre, caos o complejo. Además se presentan para cerrar el capítulo algunos casos de estudio de empresas internacionales representativas y casos de éxito que demuestran

* Maestro en Ciencias. Profesor-investigador en la Universidad Autónoma de Baja California, México. ORCID: <https://orcid.org/0000-0003-1424-4498> ; Scopus ID: 56031455600

** Doctora en Educación. Subdirectora de la FCA en la Universidad Autónoma de Baja California, México. ORCID: <https://orcid.org/0000-0001-5719-7682> ; Scopus ID: 56938932300

*** Doctor en Ciencias. Profesor-investigador en la Universidad Autónoma de Baja California, México. ORCID: <https://orcid.org/0000-0002-0266-2951> ; Scopus ID: 56938932300

que el uso y aplicación de la complejidad, inteligencia de negocios, así como el marco de trabajo de administración de proyectos ágiles y tradicionales les ha generado una ventaja competitiva, orientando así a la inteligencia de negocios a seguir una visión sistémica que proyecta un futuro próximo, basado en hechos históricos.

Palabras clave: *inteligencia de negocios, teoría de la complejidad, análisis de datos, administración de proyectos.*

Introducción: el paradigma de la complejidad en la inteligencia de negocios

Actualmente las organizaciones operan en entornos VUCA (Bennet y Le-moine, 2014), es decir, en entornos caracterizados por la volatilidad, la incertidumbre, la complejidad y la ambigüedad. Gracias a esto, la inteligencia de negocios (BI) ha logrado pasar de un conjunto de herramientas a convertirse en una disciplina que ayuda a transformar grandes volúmenes de datos en información que ayude a la toma de decisiones dentro de las organizaciones. Desde esta perspectiva y de acuerdo con Chiang y Storey (2012), su efectividad no reside únicamente en la tecnología, sino en la capacidad de comprender y gestionar la complejidad de los datos, procesos y sistemas del negocio.

Este capítulo, muestra cómo la teoría de la complejidad puede utilizarse como un marco conceptual para analizar y optimizar proyectos de BI. De acuerdo con nuestras investigaciones, la complejidad se puede manifestar en tres distintos niveles: en la naturaleza intrínseca de los datos, en los desafíos de la gestión de proyectos y en la dinámica de la toma de decisiones. Además, al adoptar un enfoque de complejidad, las organizaciones pueden pasar de una visión lineal y predictiva a una perspectiva sistémica y adaptativa (Dooley y Van de Ven, 2007). El objetivo de este capítulo es presentar cómo la complejidad impacta en cada uno de estos niveles, proponer métodos y algoritmos ya existentes que permitan a la BI a desenvolverse y crecer en escenarios cambiantes.

La complejidad intrínseca de los datos en la inteligencia de negocios

Uno de los retos más importantes para el análisis de datos dentro de la inteligencia de negocios es que: los datos ya no son tan simples como solían ser. Actualmente, los conjuntos de datos forman parte de sistemas en los que distintos elementos se relacionan y afectan entre sí. De acuerdo con Emmert-Streib et al. (2024), este tipo de complejidad puede entenderse a través de varias características que ayudan a describir su naturaleza. Algunas de las más relevantes son: multidimensionalidad, heterogeneidad, interacciones no lineales, dinamismo y temporalidad, emergencia.

La primera característica es la multidimensionalidad, la cual puede observarse cuando los sistemas de BI trabajan con una gran cantidad de variables a la vez. Esta alta dimensionalidad provoca problemas en la visualización y el modelado de relaciones simples. Un ejemplo de ello puede ser al analizar el comportamiento de un cliente, el cual puede requerir de miles de variables, desde su historial de compras, su demografía hasta sus interacciones en redes sociales y geolocalización. Debido a esto, la reducción de la dimensionalidad se convierte en un paso crítico para el análisis.

Otra característica es la heterogeneidad, que ocurre al combinar los datos de múltiples fuentes y formatos distintos, tanto estructurados (bases de datos SQL) como no estructurados (texto, imágenes, audio, datos de sensores, etc). Esta integración de datos presenta un desafío en proyectos de BI. Varian (2014) explica esto como el desafío de las “tres V” del Big Data: volumen, variedad y velocidad.

En los sistemas complejos, una pequeña variación en una variable puede tener efectos grandes en otras variables. Esta característica es llamada interacciones no lineales, ya que no siguen una lógica lineal predecible y varían con el tiempo. Un ejemplo son las dinámicas del mercado, donde un rumor en redes sociales puede provocar cambios impredecibles en el precio de una acción.

La siguiente característica presentada es el dinamismo y temporalidad, las cuales hablan acerca de cómo los datos evolucionan rápidamente, y como las tendencias pueden volverse obsoletas en poco tiempo. Esto exi-

ge que los modelos de BI sean capaces de aprender y adaptarse continuamente a las nuevas condiciones, una característica central de los sistemas adaptativos complejos (Kauffman, 1993).

La última característica que nos gustaría destacar en este capítulo es la emergencia, la cual destaca que los patrones y comportamientos relevantes no son programados, sino que emergen como resultado de las interacciones entre los elementos del sistema (Holland, 1995). Un ejemplo de ello es las nuevas tendencias de consumo, las cuales no son creadas por una autoridad central, sino que surgen de la autoorganización de los usuarios en una red social o un mercado.

Es necesario comprender todas estas características, para que proyectos de BI sean exitosos en esta nueva era. En lugar de buscar causas únicas, se debe reconocer que interactúan múltiples factores. Esto requiere un cambio de mentalidad y un conjunto de herramientas analíticas diferentes.

Análisis de datos complejos: métodos y algoritmos para la BI

La inteligencia de negocios (BI) necesita ir más allá de la estadística básica, para poder enfrentar la complejidad de los datos. Es necesario recurrir a métodos y algoritmos especializados para descubrir patrones ocultos en la información multidimensional.

Métodos de análisis de datos complejos

Uno de los problemas más grandes de la complejidad es la multidimensionalidad. Para ello podemos hacer uso de herramientas como el análisis de componentes principales (PCA). La cual tiene como función principal la reducción de la dimensionalidad. El PCA toma un gran número de variables y las reduce en un grupo mucho más pequeño llamados “componentes principales”, los cuales contienen la mayor parte de la información original (Jolliffe, 2002).

Esto puede lograr que, en lugar de analizar miles de variables para describir el comportamiento de un cliente, el PCA pueda resumirlas y así usar

unos pocos indicadores claves que representen sus hábitos de compra. Como resultado podemos visualizar, modelar y comprender las relaciones internas de los datos mucho más fácil.

En ocasiones, el objetivo es identificar grupos con características similares dentro de los datos, es aquí donde entran las técnicas de Clustering. Algoritmos como k-means, DBSCAN o el clustering jerárquico pueden ser usados para que las empresas logren segmentar clientes de manera efectiva, clasificar productos o detectar patrones de fraude emergentes, lo que les permite personalizar sus estrategias y ofertas con precisión (Han et al., 2012).

Otro enfoque poderoso es el análisis de redes y grafos, para estudiar cómo interactúan los elementos (nodos) dentro de un sistema complejo.

Al representar los datos como un grafo (un mapa de conexiones), podemos visualizar y analizar las relaciones entre clientes, productos, influenciadores sociales o incluso cadenas de suministro. De acuerdo con Batagelj y Mrvar (2003), este tipo de análisis puede revelar “comunidades”, identificar a los nodos más influyentes (como usuarios clave en redes sociales) o detectar puntos débiles en el flujo de información o la comunicación.

Algoritmos y aprendizaje automático

El aprendizaje automático (*machine learning*) es una herramienta fundamental para la inteligencia de negocios (BI). Porque permite que los sistemas no solo procesen datos, sino que aprendan de ellos de forma continua y adaptativa. Esta habilidad para ajustarse y mejorar constantemente encaja perfectamente con la naturaleza impredecible de los sistemas complejos del mundo real (Alpaydin, 2020).

Para lograr esta adaptación, el machine learning despliega una serie de técnicas especializadas:

Para abordar las relaciones más intrincadas, se emplean las Redes Neuronales Artificiales (ANN). Estos modelos, que simulan la estructura del cerebro humano, son capaces de capturar patrones no lineales y extremadamente complejos que la estadística tradicional no podría siquiera modelar. Las ANN se alimentan de datos brutos para generar predicciones de demanda, clasificar

clientes o procesar lenguaje natural, adaptándose y generando patrones emergentes a medida que aprenden (Goodfellow et al., 2016).

Mientras las ANN se enfocan en la complejidad profunda, otras herramientas ofrecen una interpretación más estructural. Los árboles de decisión y el *Random Forest*, por ejemplo, abordan los problemas de clasificación y regresión dividiendo los datos en subconjuntos lógicos y recursivos. El algoritmo *Random Forest* potencia esto al combinar múltiples árboles, lo que mejora la precisión, maneja datos inconsistentes y permite una comprensión clara de cómo interactúan las diversas variables (Hastie et al., 2009).

Para los desafíos donde el número de variables es masivo, los *Support Vector Machines* (svm) se convierten en la elección ideal. Estos clasificadores operan buscando el “hiperplano” óptimo (la mejor línea divisoria) para separar las distintas clases en el espacio de datos, lo que los hace excepcionalmente robustos en la clasificación de conjuntos de datos complejos (Hastie et al., 2009).

Finalmente, para la exploración pura y el descubrimiento, los modelos no supervisados son fundamentales. Algoritmos como k-means (para agrupar datos similares) o t-SNE (para visualizar estructuras de alta dimensión) son cruciales porque operan sin necesidad de etiquetas o categorías predefinidas (Han et al., 2012).

De esta manera, el machine learning permite a la BI no solo describir el pasado, sino anticipar el futuro, personalizar estrategias y descubrir estructuras ocultas en la complejidad.

Esta capacidad de autoorganización y adaptación es fundamental para una inteligencia de negocios que opera en la complejidad del mundo real.

Gestión de la complejidad en proyectos de BI: enfoques ágiles y tradicionales

La forma en que se gestiona un proyecto de BI debe reflejar la complejidad inherente al trabajo. La elección del enfoque de gestión, ya sea tradicional o ágil, debe ser estratégica y depender del grado de incertidumbre y de los objetivos del proyecto.

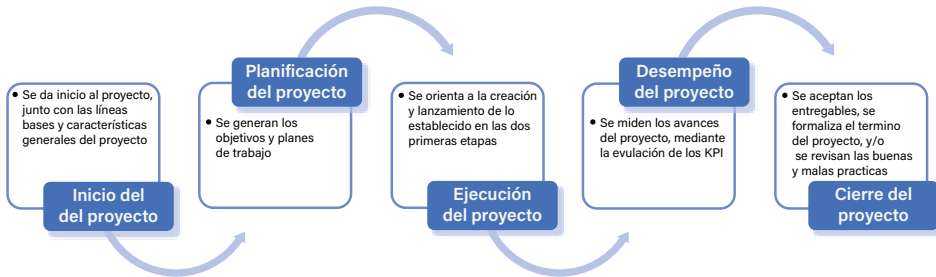
Los proyectos tradicionales tienden a ser más efectivos en proyectos donde el nivel de incertidumbre es bajo, ya que se tiene mayor experiencia, porque los procesos están bien establecidos y son conocidos o predecibles, también puede ser que se han desarrollado proyectos similares. Contrario a los proyectos tradicionales, los proyectos que son atendidos con el marco de trabajo de administración de proyectos ágil se distinguen por un alto nivel de incertidumbre porque son disruptivos; son proyectos en los que se tiene poca experiencia, porque nunca se han desarrollado o hay poca información o avances sobre el tema, por lo tanto, es necesario tener comunicación de banda ancha con el cliente, usuarios o involucrados en el proyecto.

Enfoque tradicional (predictivo)

La gestión de proyectos tradicional se basa en una planificación detallada desde el inicio y en una ejecución lineal o secuencial, una especie de carrera de relevos, y así una vez que termina cada una etapa, esta entrega la estafeta, para que la siguiente etapa inicie y así sucesivamente hasta que concluya el proyecto, las etapas se pueden listar de manera general (ver figura 3.1) como: inicio del proyecto, planificación del proyecto, ejecución del proyecto, desempeño y cierre del proyecto (Asana, 2025).

En proyectos de inteligencia de negocios con requerimientos estables y procesos bien definidos, como la consolidación de un sistema centralizado de data warehouse, este enfoque puede ser efectivo. Pero, en contextos de alta complejidad, la rigidez de un modelo predictivo puede convertirse en una limitación, al impedir la adaptación a los cambios en los nuevos o existentes requerimientos del usuario, así como en la aparición de nuevas tecnologías. Según Mir y Pinnington (2014), los enfoques tradicionales pueden mostrar mayor desempeño en proyectos, áreas o etapas con baja incertidumbre y alta regulación.

Figura 3.1. Fases de la gestión de proyectos (Asana 2025)



Fuente: elaborado con base en Asana, 2025.¹

Enfoque ágil (adaptativo)

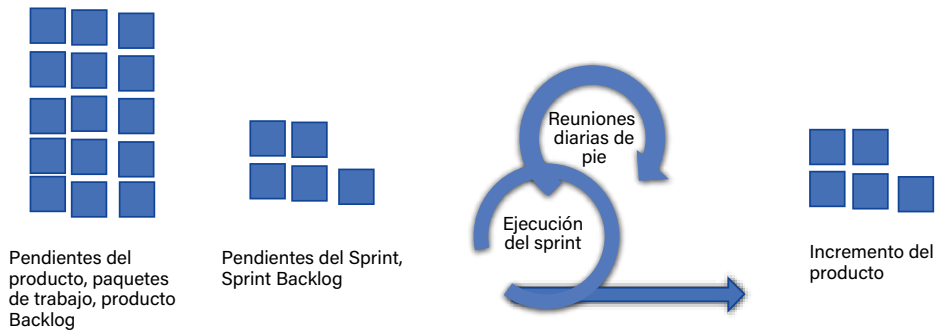
En contraste, la gestión ágil de proyectos es más adecuada para ambientes complejos, ambiguos y cambiantes, como los proyectos de BI orientados a la exploración de datos, el desarrollo de modelos de machine learning o el diseño de dashboards interactivos. El enfoque ágil promueve la iteración, la entrega incremental basada en las entregas tempranas de valor y la colaboración constante con los interesados, lo que permite manejar la incertidumbre de forma más eficiente, al tener una relación cercana al cliente y la aceptación de manera gradual de las funcionalidades o pequeños incrementos del producto del proyecto. Highsmith (2009) sostiene que “la agilidad es una respuesta directa a la complejidad y al cambio continuo del entorno empresarial”. El PMBOK® séptima edición (PMI, 2021), por su parte con su orientación basada en principios como la adaptabilidad, la entrega de valor y la colaboración, se alinea con los fundamentos ágiles para enfrentar la complejidad.

Uno de los estándares de las metodologías de administración de proyectos Ágil más reconocidos y utilizados es scrum (ver figura 2), el cual inicia estableciendo los pendientes del producto del proyecto, posteriormente los pendientes se distribuyen para desarrollar pequeñas funcionalidades o incrementos del proyecto y son desarrollados en un periodo de tiempo establecido llamado *sprint* que ir de dos a cuatro semanas; en el

¹ Véase en <https://asana.com/es/resources/project-management-phases>

tiempo de ejecución se puede desarrollar una reunión diaria de pie donde se revisa el avance del proyecto mediante el apoyo de tres preguntas básicas: ¿qué es lo que hiciste ayer?, ¿qué vas a hacer hoy? y ¿qué impedimentos o problemas tienes o puedes tener para avanzar en tu trabajo?, así todo el equipo está enterado del avance y se puede trabajar en la gestión de las condiciones idóneas para no interrumpir el avance del trabajo, cada sprint es planeado, el resultado de este es revisado, aceptado o se generan solicitudes de cambios, también se reflexiona sobre lo que funcionó y lo que no también se revisa (Sbok Guide, 2022).

Figura 3.2. Funcionamiento de Scrum SBOK Guide (2022)



Fuente: Adaptado de Scrum Body of Knowledge (SBOK Guide) (figura 6-8, p. 140), por SCRUMstudy (2022), VMEdU, I.

El Sbok (Scrum Body of Knowledge [Sbok Guide, 2022]) mediante el control del proceso empírico basado en la transparencia, inspección y adaptación, permite llevar a cabo una mejor colaboración en el equipo, al tener la información disponible y visible para todos los integrantes del equipo y los stakeholders o grupos de interés; esto permite que al revisar o visualizar todos los avances, se puedan emitir opiniones sobre mejores prácticas, técnicas o herramientas a utilizar y así generar mejores resultados; por lo tanto, la transparencia permite la inspección, y a su vez ellas dos generan cambios que permiten o impulsan a los proyectos ágiles a adaptarse a ellos.

Conceptos claves en el marco de trabajo ágil, entre ellos colaboración, auto-organización, automotivación, adaptación, entregas tempranas basadas

en el valor (incrementos del producto o funcionalidades), son elementos que permiten minimizar la incertidumbre y la complejidad de la emergencia de situaciones no previstas en los proyectos de desarrollo de software, análisis de datos, modelos de machine learning o en el diseño de dashboards, por lo tanto el desarrollo de proyectos de BI se puede apoyar en un marco de trabajo tradicional (predictivo) o ágil (adaptativo) dependiendo del tipo de proyecto que se desarrollará.

Casos de estudio: la complejidad como ventaja competitiva

La teoría de la complejidad es un marco de trabajo, ideologías, técnicas y tareas que convergen para permitir que las organizaciones tengan una perspectiva interdisciplinaria de la manera en que se pueden atender los problemas, puesto que una sola disciplina no puede atender todos los problemas, y será mucho más enriquecedor atender las emergencias y entornos complejos desde el dinamismo, aprendizaje automático, apoyados en redes neuronales, agentes inteligentes que permiten predecir un futuro posible basado en patrones de comportamiento históricos o emergentes, lo cual permite avanzar más rápido o de manera más ágil que la competencia. Sin duda los siguientes casos captan a algunas de las empresas más sobresalientes a nivel internacional y casos de éxito en la innovación y atención del negocio mediante técnicas de inteligencia de negocios, ciencia de datos y sin duda teoría de la complejidad.

El primer caso de éxito que se presenta es Amazon. Esta empresa realizó trabajos basados en redes complejas: donde el análisis de grafos apoyó en el análisis de millones de transacciones entre productos, usuarios y búsquedas. Proporcionando como resultado la detección de grupos de productos o clientes con patrones de comportamiento similares. Los algoritmos de aprendizaje automático utilizados son claros ejemplos de un sistema adaptativo complejo, al permitir que las recomendaciones evolucionen en tiempo real, al adaptarse a los diversos patrones de comportamientos de los usuarios (Smith y Linden, 2017).

Walmart como segundo caso de éxito en el manejo de la predicción de demanda con aprendizaje automático, al utilizar modelos adaptativos

de aprendizaje automático se adelanta a la demanda de productos en tiempo real por medio de la predicción, para ello considera variables interconectadas como ventas históricas, condiciones climatológicas, la temporada, los eventos locales, fechas conmemorativas y otros. Por lo tanto, podemos vislumbrar que la inclusión de la complejidad permite optimizar un sistema de negocio. Por lo anterior se ha mejorado la logística, al reducir pérdidas, permitiendo así que la eficiencia en la cadena de suministro tenga un aumento significativo (ProjectPro, n.d.).

En tercer lugar, se da introducción sin duda a uno de los más grandes éxitos de la actualidad (Netflix), que permitieron la personalización dinámica del contenido. Netflix utiliza redes neuronales para analizar patrones de visualización y así generar una clasificación personalizada de acuerdo con los gustos del catálogo de usuario. Sus algoritmos permiten detectar patrones de comportamiento emergentes orientados al consumo de acuerdo con culturas y estos pueden cambiar por ubicación geográfica, zona horaria o día de la semana. Esta aplicación demuestra cómo la comprensión de la complejidad sistémica genera una personalización masiva y efectiva que podría ser muy difícil llegar a este resultado con métodos tradicionales (Netflix, 2025).

Por último, y no menos importante, está el caso de Procter & Gamble, por medio de simulaciones complejas del mercado; la empresa P&G utiliza modelos de agentes para predecir cómo los consumidores se comportan ante nuevos precios, productos o campañas. Estas simulaciones permiten identificar y comprender el comportamiento colectivo emergente del mercado antes del lanzamiento o relanzamiento de un producto, lo que elimina, minimiza, o transfiere el riesgo, al mismo tiempo que optimiza la toma de decisiones estratégicas (P&G, 2025).

Conclusión y perspectivas futuras

La complejidad no debe ser vista como un obstáculo a superar, sino como una característica o estrategia intrínseca de los sistemas empresariales modernos que nos genera una ventaja competitiva ante nuestros competidores o la calidad de la solución de problemas, atención a clientes, servicios, pro-

ductos, etcétera. El éxito de cualquier iniciativa de inteligencia de negocios (BI) reside en adoptar una postura adaptativa, con atención a la emergencia de comportamiento o situaciones, donde la solución nos la puede brindar la implementación y seguimiento de enfoques ágiles y herramientas analíticas como lo puede ser machine learning.

La teoría de la complejidad ofrece una perspectiva que permite entender los negocios como sistemas dinámicos, emergentes y adaptativos (Kauffman, 1993). Al aplicar el análisis de datos complejos y los algoritmos adecuados, la inteligencia de negocios supera la descripción de los datos, como solo aprender del presente y prepararse para el futuro. Esta capacidad de entender e integrar la complejidad sistémica genera en las organizaciones que las adoptan la capacidad de transformarse en una fuente de innovación y adaptabilidad, al mismo tiempo que garantiza su supervivencia y crecimiento en un mundo de negocios en constante cambio.

Con proyección al futuro, la inteligencia de negocios (BI) dará un paso adelante al crecer de un enfoque predictivo a uno prescriptivo y simulativo, internándose en el centro del negocio, esto es en el área de la toma de decisiones estratégicas.

1. El primer punto por resaltar es el de simulación y gemelos digitales (*digital twins*): El siguiente paso en la gestión de la complejidad, puesto que es la capacidad de crear sistemas complejos virtuales que permitan anticipar escenarios de crecimiento y beneficio para las organizaciones. De acuerdo con Axelrod y Cohen (2000), el uso de modelos basados en agentes y la simulación ha logrado que la inteligencia de negocios no solo se limite a reaccionar ante los cambios, sino que también pueda probar distintas estrategias en un “gemelo digital” del negocio o del mercado. Esto convierte la complejidad en un laboratorio controlado para la toma de decisiones, facilitando la optimización de la gestión de riesgos (Emmert-Streib et al., 2024).
2. En cuanto a la aplicación de la inteligencia artificial explicable (XAI): permite entender en que medida los algoritmos de aprendizaje profundo se vuelven más complejos, lo anterior permite el surgimiento de un riesgo significativo: la opacidad o falta de transparencia, también llamado el problema de la “caja negra”, ya que resulta complicado

comprender o visualizar su lógica de comportamiento al no mostrar información relacionada (Doshi-Velez y Kim, 2017). Para que la inteligencia de negocios sea una herramienta confiable y estratégica, requiere explicar en qué se basó para tomar decisiones o como detectó un patrón de comportamiento. Por lo tanto, la investigación futura deberá centrarse en desarrollar métodos más eficaces, los cuales permitan el equilibrio entre la exactitud predictiva de los modelos complejos, así como la manera de interpretar, y también la ética, es así como se debe asegurar que la inteligencia de negocios no solo brinde respuestas, sino también confianza en su proceso.

Se puede concluir que la inteligencia de negocios se enriquece no solo por el análisis de los datos y su procesamiento, sino también por la capacidad de descubrir los patrones de comportamiento emergentes y las dinámicas que definen este comportamiento de los sistemas organizacionales, lo anterior permite que se consolide como una capacidad estratégica, dinámica y adaptativa esencial.

Referencias

- Asana. (2025). *Las 5 fases de la gestión de proyectos para que mejores el flujo de trabajo de tu equipo*. <https://asana.com/es/resources/project-management-phases>
- Alpaydin, E. (2020). *Introduction to Machine Learning* (4a ed.). MIT Press.
- Axelrod, R., y Cohen, M. D. (2000). *Harnessing Complexity: Organizational Implications of A Scientific Frontier*. Free Press.
- Batagelj, V., y Mrvar, A. (2003). Pajek: Analysis and Visualization of Large Networks. En M. Jünger y G. Reinelt (Eds.), *Combinatorial Optimization: Eureka, You Have Found It!* (pp. 165–181). Springer.
- Bennet, N., y Lemoine, G. J. (2014). What VUCA Really Means for You. *Harvard Business Review*, 92(1/2), 23-28.
- Chen, H., Chiang, R. H. L., y Storey, V. C. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, 36(4), 1165–1188. <https://doi.org/10.2307/41703503>
- De Toni, A. F., y De Zan, M. (2021). The VUCA World: Business Agility and Managerial Competences. *Management Research and Practice*, 13(2), 5-16.
- Dooley, K. J., y Van de Ven, A. H. (2007). Complexity Theory and Organizational Change.

- En R. A. Swanson y E. F. Holton III (Eds.), *Foundations of Human Resource Development* (2da ed.) (pp. 279-296). Berrett-Koehler Publishers.
- Doshi-Velez, F., y Kim, B. (2017). Towards a Rigorous Science of Interpretable Machine Learning. arXiv preprint arXiv:1702.08608.
- Emmert-Streib, F., Cherifi, H., Kaski, K., Kauffman, S., y Yli-Harja, O. (2024). Complexity Data Science: A Spin-off From Digital Twins. *PNAS Nexus*, 3(11), pgae456. <https://doi.org/10.1093/pnasnexus/pgae456>
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep Learning*. MIT Press.
- Han, J., Kamber, M., y Pei, J. (2012). *Data mining: Concepts and techniques* (3a ed.). Morgan Kaufmann.
- Hastie, T., Tibshirani, R., y Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2a ed.). Springer.
- Holland, J. H. (1995). *Hidden Order: How Adaptation Builds Complexity*. Addison-Wesley.
- Jolliffe, I. T. (2002). *Principal Component Analysis* (2a ed.). Springer.
- Kauffman, S. A. (1993). *The Origins of Order: Self-Organization and Selection in Evolution*. Oxford University Press.
- Netflix (2025). Áreas de investigación - Aprendizaje automático - Aprendiendo a entretener al mundo. <https://research.netflix.com/research-area/machine-learning>
- Smith, B., y Linden, G. (2017). Two Decades of Recommender Systems at Amazon.com. *IEEE Internet Computing*, 21(3), 12-18. <https://assets.amazon.science/76/9e/7eac-89c14a838746e91dde0a5e9f/two-decades-of-recommender-systems-at-amazon.pdf>.
- P&G (2025), *Más de 100 Años de transformación tecnológica en la investigación del consumidor de P&G*. <https://es.pg.com/blogs/100-anos-innovacion/>
- Project Management Institute (PMI). (2021). *Guía de los Fundamentos para la Dirección de Proyectos* (Guía del PBMBOK, 7ª ed.). Project Management Institute.
- ProjectPro. (n.d.). *How Big Data Analysis Helped Increase Walmart's Sales Turnover*. <https://www.projectpro.io/article/how-big-data-analysis-helped-increase-walmarts-sales-turnover/109>
- SBOK Guide (2022) *Scrum Body of Knowledge*, (p. 7-134)
- Varian, H. R. (2014). Big data: New Tricks for Econometrics. *Journal of Economic Perspectives*, 28(2), 3-28.