



Módulo 2: Product analytics, datos y desarrollo de software



1. Product analytics y data literacy para product managers



2. Inteligencia artificial aplicada al producto y desarrollo de software



Referencias

1. Product analytics y data literacy para product managers

El *product analytics* se configura como un campo de conocimiento orientado al análisis sistemático de los datos generados por la interacción de los usuarios con productos digitales. Desde una perspectiva teórica, este enfoque se apoya en la analítica de datos aplicada a contextos de uso, lo que permite describir, explicar y evaluar comportamientos observables dentro de un sistema. En este sentido, el *product analytics* se diferencia de otras ramas de la analítica digital por su énfasis en eventos, flujos de uso y patrones de interacción, más que en métricas agregadas de alcance o exposición (Provost & Fawcett, 2013).

En línea con lo anterior, el rol del *product manager* incorpora progresivamente competencias vinculadas a la interpretación y uso de datos como parte de los procesos de toma de decisiones. La disponibilidad de grandes volúmenes de datos no garantiza, por sí misma, una mejora en la comprensión del producto, dado que resulta necesario contar con marcos conceptuales que

orienten su lectura. Por lo tanto, el *product analytics* se articula con la *data literacy* como un conjunto de saberes que permiten formular preguntas analíticas pertinentes y evaluar la calidad de la información disponible (Davenport & Harris, 2017).

La *data literacy* puede definirse como la capacidad de leer, interpretar, analizar y comunicar datos en contextos específicos. Este concepto no se limita al dominio técnico de herramientas, sino que incluye la comprensión de conceptos estadísticos básicos, la identificación de supuestos analíticos y el reconocimiento de sesgos en la producción de información. En estas circunstancias, la alfabetización en datos se presenta como un requisito para sostener análisis coherentes y conceptualmente consistentes en entornos organizacionales basados en evidencia (UNESCO, 2018).

Desde una perspectiva teórica, la relación entre *product analytics* y *data literacy* es de carácter complementario. Mientras el *product analytics* aporta métodos y estructuras para la recolección y análisis de datos de uso, la *data literacy* permite contextualizar dichos resultados dentro de marcos interpretativos más amplios. De este modo, el análisis de métricas adquiere sentido únicamente cuando se vincula con hipótesis explícitas, definiciones operativas claras y criterios analíticos previamente establecidos.

Asimismo, el uso de datos en la gestión de productos digitales requiere distinguir entre diferentes niveles de análisis. Existen métricas descriptivas orientadas a caracterizar el comportamiento observado, métricas diagnósticas que permiten identificar relaciones entre variables y métricas evaluativas que se emplean para contrastar cambios en el producto. Esta clasificación analítica contribuye a evitar interpretaciones reduccionistas y favorece una lectura más sistemática de la información disponible (Marr, 2016).

Teniendo en cuenta lo mencionado, el *product analytics* no debe entenderse como un conjunto aislado de indicadores, sino como un sistema analítico que se construye a partir de decisiones conceptuales previas. Estas decisiones incluyen la definición de eventos relevantes, la selección de ventanas temporales de análisis y la segmentación de usuarios según criterios teóricos explícitos. En este marco, la calidad del análisis depende tanto de la infraestructura de datos como de la claridad conceptual con la que se aborda el fenómeno de estudio.

Finalmente, la integración entre *product analytics* y *data literacy* permite sostener procesos analíticos más rigurosos y coherentes

en el estudio de productos digitales. Esta integración favorece la construcción de conocimiento basado en datos, siempre que se respeten criterios de validez, consistencia y trazabilidad analítica. Es por ello que ambas dimensiones constituyen un eje central en el desarrollo teórico de la analítica aplicada a productos digitales, dando continuidad al análisis específico de herramientas y conceptos que se abordarán en los subtemas correspondientes.

Amplitude

Amplitude es una herramienta de *product analytics* orientada al análisis del comportamiento de usuarios a partir de eventos registrados en productos digitales. Desde una perspectiva teórica, este tipo de plataformas se inscribe dentro del paradigma de la analítica basada en eventos, en el cual las acciones de los usuarios se modelizan como unidades discretas de observación que permiten reconstruir trayectorias de uso. Este enfoque se diferencia de la analítica tradicional centrada en páginas vistas, ya que privilegia la secuencia y recurrencia de interacciones como objeto de análisis (Provost & Fawcett, 2013).

El modelo conceptual que sustenta herramientas como *Amplitude* parte de la definición explícita de eventos, propiedades y usuarios. Un evento representa una acción específica realizada dentro del producto, mientras que las propiedades permiten

contextualizar dicha acción mediante atributos adicionales. En este sentido, la estructura de datos responde a un esquema analítico que busca maximizar la trazabilidad de los comportamientos observados, permitiendo su posterior agregación, segmentación y comparación en distintos marcos temporales (Marr, 2016).

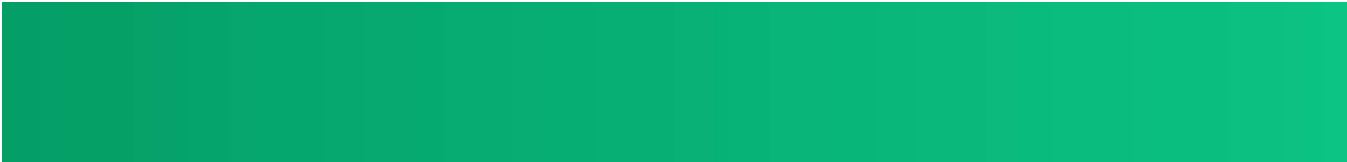
En línea con lo anterior, la analítica de eventos requiere una conceptualización previa rigurosa, dado que la calidad del análisis depende directamente de cómo se definen y registran las interacciones. La literatura sobre analítica aplicada a sistemas de información señala que una mala definición de eventos puede generar interpretaciones erróneas o inconsistentes, incluso cuando la infraestructura tecnológica es adecuada (Davenport & Harris, 2017). Por lo tanto, el uso de *Amplitude* debe entenderse como parte de un proceso analítico más amplio, y no como un recurso aislado.

Desde el punto de vista de la *data literacy*, herramientas como *Amplitude* exigen competencias analíticas que van más allá del uso instrumental de la plataforma. La interpretación de gráficos, cohortes y métricas de retención implica comprender supuestos estadísticos básicos, así como reconocer patrones de variación y tendencias. En estas circunstancias, la alfabetización en datos se vuelve necesaria para evaluar críticamente los resultados

obtenidos y evitar lecturas simplificadas de los comportamientos de los usuarios (UNESCO, 2018).

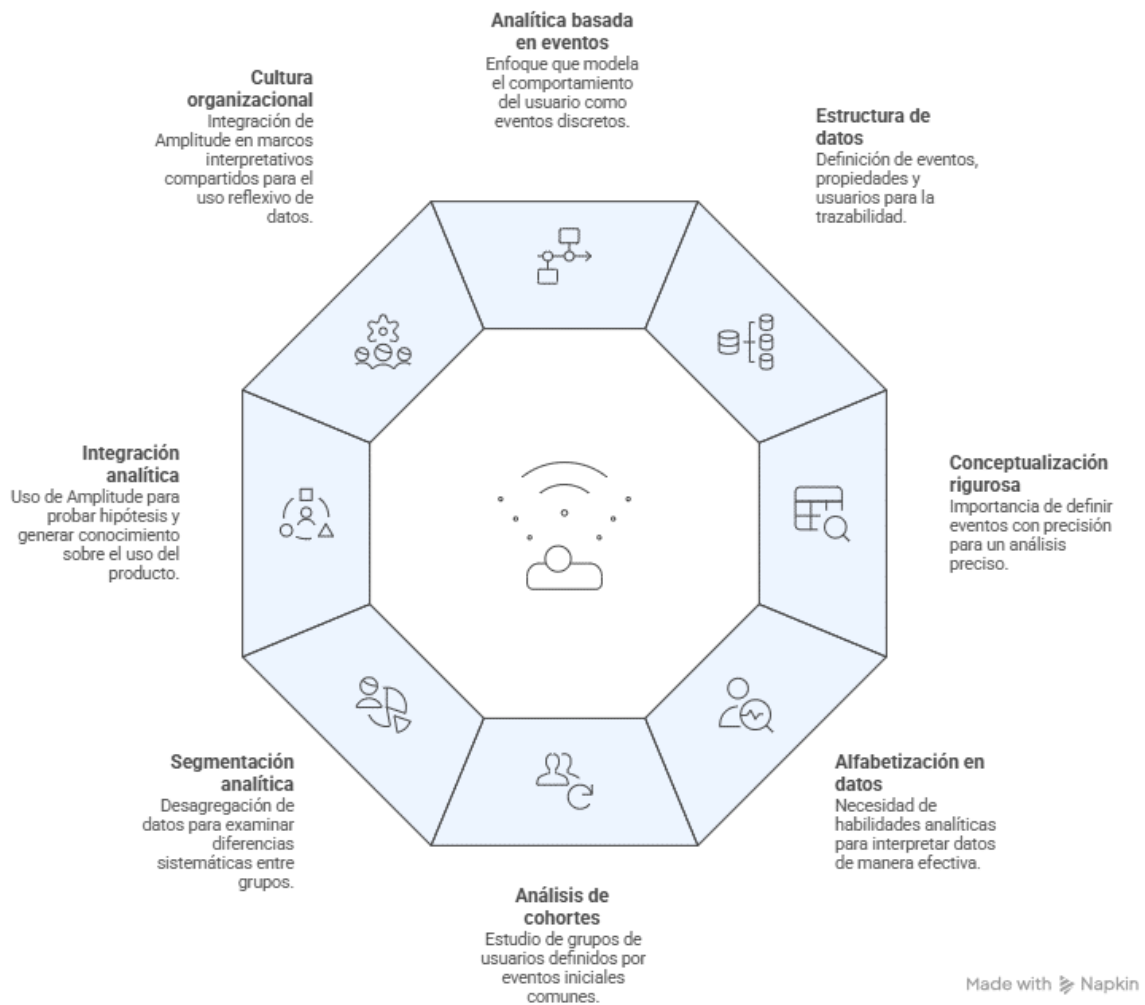
Asimismo, *Amplitude* incorpora modelos analíticos que permiten observar la evolución del comportamiento de los usuarios a lo largo del tiempo, particularmente mediante análisis de cohortes. Este tipo de análisis se apoya en la comparación de grupos definidos por un evento inicial común, lo que facilita el estudio de la permanencia, recurrencia o abandono. Desde un enfoque teórico, las cohortes constituyen una herramienta para aislar efectos temporales y reducir el ruido analítico asociado a la heterogeneidad de los usuarios (Hair et al., 2019).

Otro aspecto relevante es la posibilidad de segmentar usuarios según atributos conductuales o contextuales. La segmentación analítica permite desagregar los datos y examinar diferencias sistemáticas entre grupos, lo que contribuye a una comprensión más fina del uso del producto. Sin embargo, la literatura advierte que una segmentación excesiva puede derivar en análisis fragmentados y difíciles de interpretar, por lo que resulta necesario establecer criterios conceptuales claros para su aplicación (Marr, 2016).



En este marco, *Amplitude* puede ser entendida como una herramienta que operacionaliza principios teóricos de la analítica de datos aplicados a productos digitales. Su valor analítico no reside únicamente en la visualización de métricas, sino en la posibilidad de contrastar hipótesis sobre el comportamiento de los usuarios a partir de evidencia empírica estructurada. De este modo, la plataforma se integra dentro de un enfoque analítico orientado a la generación de conocimiento sobre el uso del producto.

Figura 1. Fundamentos de *Amplitude*



Fuente: elaboración propia.

El uso de *Amplitude* requiere una articulación coherente entre objetivos analíticos, definición de métricas y capacidades interpretativas. La plataforma no sustituye el razonamiento teórico ni la formulación de preguntas analíticas, sino que actúa como un medio para ponerlas a prueba. En este sentido, su

utilización se inscribe dentro de prácticas analíticas basadas en criterios de validez y consistencia conceptual.

El análisis mediante *Amplitude* se vincula estrechamente con el desarrollo de una cultura organizacional orientada al uso reflexivo de datos. La literatura sobre analítica organizacional destaca que las herramientas adquieren sentido cuando se integran en marcos interpretativos compartidos y en procesos de análisis sistemáticos. Por lo tanto, *Amplitude* debe comprenderse como parte de un ecosistema analítico más amplio, en el cual la *data literacy* cumple una función articuladora entre datos, interpretación y conocimiento.

Mixpanel —

Mixpanel es una plataforma de *product analytics* centrada en el análisis del comportamiento de los usuarios a partir de eventos, que se inscribe dentro de los enfoques teóricos de la analítica de uso aplicada a productos digitales. Desde esta perspectiva, la herramienta se orienta a la observación sistemática de acciones individuales, permitiendo reconstruir patrones de interacción a partir de datos empíricos. Este enfoque se vincula con los desarrollos teóricos de la analítica descriptiva y diagnóstica, en los que el énfasis se coloca en la comprensión de cómo y cuándo los usuarios interactúan con un sistema (Provost & Fawcett, 2013).

El marco conceptual que sustenta *Mixpanel* se apoya en la noción de evento como unidad básica de análisis. Cada evento representa una acción concreta realizada por un usuario y se encuentra asociado a un

conjunto de propiedades que aportan contexto analítico. En este sentido, la estructura de datos responde a un modelo relacional que permite articular acciones, atributos y temporalidad, favoreciendo análisis longitudinales del comportamiento de los usuarios (Marr, 2016).

La definición conceptual de eventos constituye una instancia teórica previa al uso de la herramienta. La literatura sobre sistemas de información señala que la calidad del análisis depende de la coherencia entre los conceptos analíticos y su operacionalización en datos observables (Davenport & Harris, 2017). Por lo tanto, el uso de *Mixpanel* supone decisiones analíticas que anteceden a la visualización de métricas y que condicionan la interpretación posterior de los resultados.

Desde la perspectiva de la *data literacy*, *Mixpanel* requiere competencias analíticas orientadas a la lectura e interpretación de métricas de comportamiento. La comprensión de indicadores como la frecuencia de uso, la recurrencia o la permanencia implica reconocer supuestos estadísticos básicos y criterios de agregación. En estas circunstancias, la alfabetización en datos se presenta como un requisito para sostener análisis consistentes y evitar conclusiones basadas en correlaciones superficiales (UNESCO, 2018).

Uno de los aportes teóricos más relevantes asociados al uso de *Mixpanel* es el análisis de flujos de comportamiento, que permite observar las secuencias de acciones realizadas por los usuarios dentro del producto. Este tipo de análisis se vincula con enfoques procesuales de la analítica, en los que el interés se centra en la dinámica de las interacciones más que en eventos aislados. Desde este marco, los flujos permiten identificar regularidades, desvíos y patrones recurrentes en el uso del sistema (Hair et al., 2019).

Asimismo, la herramienta facilita el análisis de cohortes, entendido como la comparación de grupos de usuarios definidos por un criterio temporal o conductual común. Este enfoque analítico permite controlar la variabilidad asociada a la incorporación de nuevos usuarios y observar cambios en el

comportamiento a lo largo del tiempo. Desde una perspectiva teórica, las cohortes constituyen un recurso para fortalecer la validez interna de los análisis longitudinales (Marr, 2016).

Otro aspecto relevante es la segmentación de usuarios basada en atributos observables, que posibilita desagregar los datos y examinar diferencias sistemáticas entre grupos. Sin embargo, la literatura advierte que la segmentación debe responder a criterios conceptuales claros, dado que una fragmentación excesiva puede dificultar la interpretación y generar lecturas parciales del fenómeno analizado (Davenport & Harris, 2017).

En este marco, *Mixpanel* puede comprenderse como una herramienta que operacionaliza principios teóricos de la analítica del comportamiento en entornos digitales. Su aporte no reside únicamente en la generación de métricas, sino en la posibilidad de articular datos empíricos con hipótesis analíticas previamente formuladas. De este modo, la plataforma se integra en un enfoque analítico orientado a la construcción de conocimiento sobre el uso del producto.

El uso de *Mixpanel* se vincula con procesos organizacionales orientados al análisis sistemático de datos. La literatura sobre analítica organizacional sostiene que las herramientas adquieren sentido cuando se insertan en marcos interpretativos compartidos y en prácticas analíticas consistentes. Por lo tanto, *Mixpanel* debe entenderse como parte de un ecosistema analítico más amplio, en el cual la *data literacy* cumple una función articuladora entre datos, interpretación y producción de conocimiento.

GA4 —

Google Analytics 4 (GA4) es una plataforma de analítica digital que introduce un modelo de medición basado en eventos, alineándose conceptualmente con los enfoques contemporáneos del *product analytics*.

A diferencia de modelos previos centrados en sesiones, **GA4** propone una estructura analítica que prioriza la observación de acciones individuales realizadas por los usuarios, lo que permite describir el comportamiento de uso desde una perspectiva más granular y longitudinal. Este enfoque se vincula con los desarrollos teóricos de la analítica de datos orientada a la comprensión de trayectorias de interacción (Provost & Fawcett, 2013).

Desde el punto de vista conceptual, el modelo de datos de **GA4** se organiza en torno a eventos, parámetros y usuarios. Cada evento representa una acción específica y puede enriquecerse mediante parámetros que aportan contexto analítico. En este sentido, la herramienta adopta una lógica similar a la de otras plataformas de *product analytics*, lo que facilita el análisis comparativo de comportamientos y la construcción de métricas orientadas al uso del producto más que al tráfico agregado (Marr, 2016).

En línea con lo anterior, la definición de eventos en **GA4** constituye una decisión analítica de carácter teórico. La literatura sobre analítica de sistemas de información sostiene que la coherencia entre los conceptos analíticos y su representación en datos observables es una condición necesaria para sostener interpretaciones válidas (Davenport & Harris, 2017). Por lo tanto, el uso de **GA4** requiere una conceptualización previa que oriente qué acciones resultan relevantes para el análisis del producto.

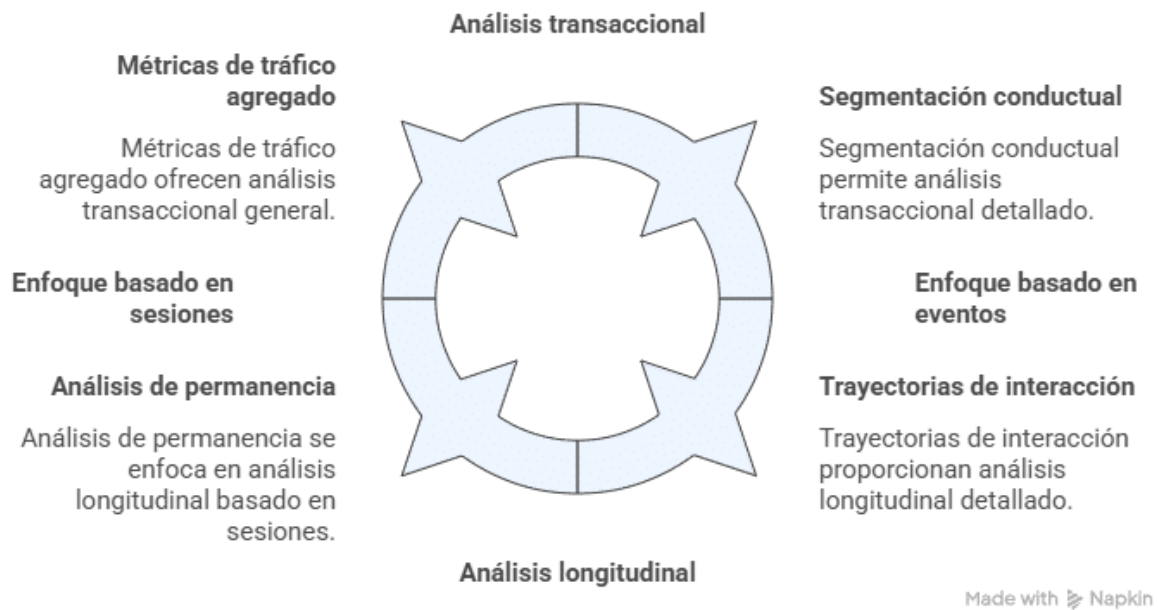
Desde la perspectiva de la *data literacy*, **GA4** demanda competencias orientadas a la lectura e interpretación de métricas basadas en eventos. La comprensión de indicadores como la participación, la retención o la recurrencia implica reconocer los criterios de agregación y los supuestos que subyacen a su cálculo. En estas circunstancias, la alfabetización en datos resulta necesaria para evaluar críticamente los resultados y evitar interpretaciones simplificadas del comportamiento de los usuarios (UNESCO, 2018).

Asimismo, **GA4** incorpora funcionalidades orientadas al análisis del comportamiento a lo largo del tiempo, permitiendo observar la evolución

de los usuarios desde su primer contacto con el producto. Este tipo de análisis se relaciona con enfoques longitudinales de la analítica, en los cuales el interés se centra en identificar patrones de permanencia, abandono o cambio. Desde una perspectiva teórica, estos enfoques permiten reducir la influencia de variaciones coyunturales y fortalecer la consistencia del análisis (Hair et al., 2019).

Otro aspecto relevante es la posibilidad de segmentar usuarios según criterios conductuales, tecnológicos o demográficos. La segmentación analítica permite desagregar los datos y examinar diferencias sistemáticas entre grupos, contribuyendo a una comprensión más precisa del uso del producto. Sin embargo, la literatura advierte que la segmentación debe responder a criterios conceptuales claros, ya que una proliferación de segmentos puede dificultar la interpretación de los resultados (Marr, 2016).

Figura 2. Enfoques analíticos en GA4



Fuente: elaboración propia.

En este marco, *GA4* puede entenderse como una herramienta que articula principios teóricos de la analítica digital con enfoques propios del *product analytics*. Su aporte no reside únicamente en la medición de interacciones, sino en la posibilidad de integrar datos de comportamiento dentro de marcos analíticos más amplios orientados a la comprensión del uso del producto.

El uso de *GA4* requiere una articulación coherente entre objetivos analíticos, definición de eventos y capacidades interpretativas. La herramienta no sustituye el razonamiento teórico ni la formulación de hipótesis analíticas, sino que actúa como un

medio para su contrastación empírica. De este modo, *GA4* se integra dentro de prácticas analíticas orientadas a la producción de conocimiento basado en datos.

El análisis mediante *GA4* se inscribe en procesos organizacionales que buscan sostener decisiones informadas a partir de evidencia empírica. La literatura sobre analítica organizacional señala que las herramientas adquieren sentido cuando se integran en prácticas analíticas sistemáticas y en marcos interpretativos compartidos. Por lo tanto, *GA4* debe comprenderse como parte de un ecosistema analítico más amplio, en el cual la *data literacy* cumple una función articuladora entre datos, interpretación y conocimiento.

***Data literacy* esencial: análisis de cohortes, retención y embudos de conversión**

La *data literacy* aplicada al análisis de productos digitales comprende un conjunto de capacidades orientadas a interpretar datos de comportamiento de manera estructurada y conceptualmente consistente. En este marco, el análisis de cohortes, la retención y los embudos de conversión no constituyen técnicas aisladas, sino dimensiones analíticas interrelacionadas que permiten comprender la evolución del uso

de un producto a lo largo del tiempo. Desde una perspectiva teórica, estos enfoques se inscriben en modelos analíticos longitudinales que priorizan la observación de patrones de comportamiento antes que la simple agregación de métricas descriptivas (Provost & Fawcett, 2013).


El análisis de cohortes se basa en la comparación de grupos de usuarios que comparten una característica inicial común, generalmente asociada a un evento de ingreso o activación. Este enfoque permite aislar efectos temporales y observar cómo se modifica el comportamiento de los usuarios a lo largo del tiempo. En términos conceptuales, las cohortes funcionan como un recurso analítico que reduce la heterogeneidad de los datos y favorece interpretaciones más estables, evitando lecturas distorsionadas por variaciones coyunturales en el volumen de usuarios (Hair et al., 2019).

La retención se configura como una métrica analítica que expresa la permanencia de los usuarios en el producto a través del tiempo. Desde una perspectiva teórica, la retención no debe entenderse únicamente como un porcentaje agregado, sino como un fenómeno dinámico que varía según el momento de incorporación, el tipo de interacción y las condiciones de uso. Por lo tanto, su análisis adquiere mayor sentido cuando se articula con cohortes, ya que estas permiten observar diferencias

sistemáticas en la continuidad del uso entre distintos grupos de usuarios (Marr, 2016).

La relación entre cohortes y retención pone de manifiesto la importancia de la temporalidad en el análisis de datos de producto. La literatura sobre analítica de sistemas de información destaca que los comportamientos de uso no son estáticos, sino que evolucionan en función de múltiples variables contextuales. En estas circunstancias, el análisis longitudinal permite identificar tendencias, puntos de inflexión y patrones de abandono que no resultan visibles mediante métricas agregadas de corto plazo (Davenport & Harris, 2017).

Por su parte, los embudos de conversión constituyen un modelo analítico orientado a representar secuencias de acciones que los usuarios realizan dentro de un producto. Desde un enfoque teórico, los embudos permiten observar la progresión —o interrupción— de los usuarios a través de etapas definidas analíticamente. Esta representación secuencial se vincula con modelos procesuales del comportamiento, en los cuales el interés se centra en las transiciones entre estados más que en los eventos aislados (Hair et al., 2019).



La articulación entre embudos de conversión y análisis de cohortes permite enriquecer la interpretación de los datos. Mientras los embudos describen trayectorias posibles dentro del producto, las cohortes permiten comparar cómo distintos grupos recorren esas trayectorias a lo largo del tiempo. De este modo, la *data literacy* implica comprender que las métricas adquieren significado analítico cuando se combinan dentro de marcos conceptuales coherentes, y no cuando se interpretan de manera fragmentada (Marr, 2016).

Desde esta perspectiva, la *data literacy* no se limita al dominio técnico de herramientas analíticas, sino que supone la capacidad de relacionar métricas, modelos y supuestos teóricos. El análisis de cohortes, la retención y los embudos de conversión constituyen recursos conceptuales que, utilizados de manera integrada, permiten construir interpretaciones más consistentes sobre el uso del producto. En este sentido, la alfabetización en datos se presenta como una condición necesaria para sostener análisis rigurosos y conceptualmente fundamentados (UNESCO, 2018).

Teniendo en cuenta lo mencionado, el análisis del comportamiento de usuarios requiere una lectura crítica de los datos disponibles, así como una comprensión clara de los

modelos analíticos utilizados. La integración entre cohortes, retención y embudos contribuye a evitar interpretaciones simplificadas y favorece una comprensión más profunda de las dinámicas de uso. De este modo, estos enfoques se consolidan como componentes centrales de la *data literacy* aplicada al *product analytics*.

Finalmente, el desarrollo de competencias en *data literacy* implica reconocer los límites interpretativos de cada métrica y la necesidad de articularlas dentro de marcos analíticos más amplios. La literatura especializada señala que los datos adquieren valor analítico cuando se integran en procesos sistemáticos de análisis y reflexión conceptual. Por lo tanto, el uso combinado de cohortes, retención y embudos de conversión se inscribe dentro de una práctica analítica orientada a la producción de conocimiento basado en datos.

Consultas analíticas y queries básicas en SQL

La *data literacy* aplicada al análisis de productos digitales incluye la capacidad de formular consultas analíticas que permitan extraer información relevante a partir de conjuntos de datos estructurados. En este marco, el uso de *queries* y lenguajes de consulta como *SQL* se inscribe dentro de un enfoque conceptual

orientado a la interrogación sistemática de los datos, más que a su simple visualización. Desde una perspectiva teórica, consultar datos implica traducir preguntas analíticas en operaciones formales que permitan observar regularidades, diferencias y relaciones entre variables (Provost & Fawcett, 2013).

El lenguaje *SQL* se presenta como un estándar ampliamente difundido para la manipulación y consulta de bases de datos relacionales. Su relevancia en el contexto de la *data literacy* no reside únicamente en su sintaxis, sino en el modelo conceptual que lo sustenta. Dicho modelo se basa en la organización de la información en tablas, filas y columnas, lo que favorece una representación estructurada de los datos y permite establecer relaciones explícitas entre distintas entidades analíticas (Date, 2019).

Desde el punto de vista analítico, las *queries* básicas permiten seleccionar, filtrar, agrupar y ordenar datos según criterios definidos conceptualmente. Estas operaciones constituyen la base de numerosos análisis descriptivos y diagnósticos, ya que posibilitan transformar datos brutos en información interpretable. En este sentido, la literatura sobre analítica de datos señala que la capacidad de formular consultas adecuadas resulta determinante para la calidad del análisis, dado que condiciona qué información se hace visible y cuál permanece oculta (Davenport & Harris, 2017).

La formulación de consultas analíticas requiere una comprensión clara de los objetivos del análisis y de la estructura de los datos disponibles. La *data literacy* supone reconocer qué variables resultan relevantes, cómo se relacionan entre sí y bajo qué supuestos se construyen los indicadores. Por lo tanto, el uso de *SQL* no debe entenderse como una competencia meramente técnica, sino como una herramienta conceptual para operacionalizar preguntas analíticas previamente definidas (Marr, 2016).

Asimismo, las consultas analíticas permiten articular distintos niveles de análisis, desde descripciones generales hasta exploraciones más específicas del comportamiento de los usuarios. La posibilidad de agrupar datos, calcular agregaciones y establecer condiciones lógicas favorece la construcción de métricas orientadas a la comprensión del uso del producto. En estas circunstancias, las *queries* se convierten en un medio para conectar datos individuales con patrones colectivos observables (Hair et al., 2019).

Otro aspecto relevante es la relación entre las *queries* analíticas y la validación de supuestos. La literatura metodológica destaca que la formulación explícita de consultas contribuye a hacer visibles los criterios analíticos utilizados, lo que fortalece la transparencia y la trazabilidad del análisis. Desde esta perspectiva, el uso de *SQL* permite sostener prácticas analíticas

más controladas, en las cuales los resultados pueden ser replicados y evaluados críticamente (Date, 2019).

La *data literacy* también implica reconocer los límites de las consultas analíticas y las posibles fuentes de error en la interpretación de los datos. Consultas mal formuladas, relaciones mal definidas o supuestos implícitos no explicitados pueden conducir a conclusiones inconsistentes. Por ello, la alfabetización en datos incluye la capacidad de revisar, ajustar y contrastar consultas en función de los resultados obtenidos y de los marcos conceptuales utilizados (Davenport & Harris, 2017).

Teniendo en cuenta lo mencionado, las *queries* básicas y el uso de *SQL* se integran dentro de un enfoque analítico orientado a la construcción de conocimiento basado en datos. Su valor no radica en la complejidad técnica, sino en la posibilidad de estructurar el análisis de manera coherente con los objetivos conceptuales planteados. De este modo, las consultas analíticas se consolidan como un componente central de la *data literacy* aplicada al *product analytics*.

El desarrollo de competencias en consultas analíticas contribuye a fortalecer la autonomía interpretativa frente a los datos

disponibles. La literatura sobre analítica organizacional sostiene que la capacidad de interrogar directamente los datos favorece análisis más reflexivos y menos dependientes de visualizaciones predeterminadas. Por lo tanto, el dominio conceptual de *queries* y *SQL* se inscribe dentro de prácticas analíticas orientadas a la comprensión sistemática del comportamiento de los usuarios y del uso del producto.

CONTINUAR

2. Inteligencia artificial aplicada al producto y desarrollo de software

La inteligencia artificial se ha incorporado de manera progresiva en los procesos vinculados al diseño, análisis y evolución de productos digitales, configurándose como un campo de reflexión teórica relevante para la gestión de producto y el desarrollo de *software*. Desde una perspectiva conceptual, la inteligencia artificial puede entenderse como un conjunto de enfoques algorítmicos orientados al procesamiento de grandes volúmenes de datos, la identificación de patrones y la automatización de inferencias. En este sentido, su incorporación al ámbito del producto no implica únicamente un cambio tecnológico, sino también una transformación en los marcos analíticos y decisionales utilizados (Russell & Norvig, 2021).

En línea con lo anterior, la aplicación de inteligencia artificial a la gestión de producto se vincula con la capacidad de ampliar y profundizar los procesos de análisis de información. Los modelos algorítmicos permiten procesar datos complejos y heterogéneos

que superan las capacidades de análisis manual, favoreciendo la generación de insumos analíticos para la comprensión del comportamiento de usuarios y del desempeño del producto. Por lo tanto, la inteligencia artificial se integra como un recurso cognitivo que complementa, pero no sustituye, el razonamiento analítico humano (Davenport & Ronanki, 2018).

Desde un enfoque teórico, resulta pertinente distinguir entre el uso de inteligencia artificial para la comprensión del producto y su uso para la toma de decisiones vinculadas al diseño y la priorización. En el primer caso, los sistemas algorítmicos se orientan a la identificación de patrones, segmentaciones y regularidades en los datos, mientras que en el segundo se emplean para evaluar alternativas, estimar impactos y organizar prioridades. Esta distinción permite estructurar el análisis conceptual de la inteligencia artificial en el ámbito del producto, evitando una visión homogénea de sus aplicaciones (Marr, 2019).

Asimismo, la incorporación de inteligencia artificial plantea interrogantes vinculados a la interpretación de los resultados generados por modelos algorítmicos. La literatura especializada advierte que los sistemas de inteligencia artificial operan a partir de supuestos, datos de entrenamiento y criterios de optimización que no siempre resultan transparentes. En estas circunstancias, la *data literacy* y la alfabetización algorítmica se presentan como condiciones necesarias para sostener un uso crítico y reflexivo de

estas tecnologías en contextos de gestión de producto (UNESCO, 2021).

Por otra parte, la inteligencia artificial también incide en los procesos de desarrollo de *software*, particularmente en la especificación funcional, la planificación del trabajo y la coordinación entre actores. Desde una perspectiva teórica, la integración de herramientas algorítmicas en estos procesos puede entenderse como una forma de mediación cognitiva que influye en cómo se formulan requisitos, se estructuran tareas y se evalúan avances. En este marco, la relación entre producto, desarrollo y sistemas inteligentes adquiere una dimensión analítica que trasciende lo meramente técnico (Pressman & Maxim, 2020).

La articulación entre inteligencia artificial y desarrollo de *software* requiere, además, considerar los flujos de trabajo y las prácticas organizacionales en las que estas tecnologías se insertan. La literatura sobre ingeniería de *software* y gestión de producto señala que las herramientas adquieren sentido en función de los marcos conceptuales y metodológicos que orientan su uso. Por lo tanto, el análisis de la inteligencia artificial en este ámbito debe contemplar tanto los aspectos algorítmicos como las estructuras organizativas y cognitivas que los sostienen (Sommerville, 2016).

La inteligencia artificial aplicada al producto y al desarrollo de *software* puede comprenderse como un campo en construcción, atravesado por debates teóricos sobre automatización, toma de decisiones y control humano. Su análisis requiere un abordaje conceptual que permita integrar dimensiones técnicas, analíticas y organizacionales. En este sentido, la presente unidad establece el marco teórico general para el desarrollo de los subtemas, en los cuales se profundizará en las distintas formas en que la inteligencia artificial se articula con la gestión de producto y el desarrollo de *software*.

IA aplicada al producto: Segmentación inteligente. UX Research con IA —

La inteligencia artificial aplicada al análisis y comprensión del producto se inscribe dentro de un marco teórico orientado a ampliar las capacidades de interpretación de fenómenos complejos asociados al comportamiento de los usuarios. Desde esta perspectiva, los sistemas algorítmicos permiten procesar grandes volúmenes de datos y detectar regularidades que no resultan evidentes mediante enfoques analíticos tradicionales. En este sentido, la inteligencia artificial se configura como un recurso analítico que complementa los procesos cognitivos humanos, aportando nuevas formas de representación y síntesis de la información (Russell & Norvig, 2021).

Uno de los aportes conceptuales más relevantes de la inteligencia artificial en la gestión de producto se vincula con la segmentación basada en patrones de comportamiento. A diferencia de las segmentaciones tradicionales, definidas a partir de criterios estáticos, los modelos

algorítmicos permiten identificar agrupamientos dinámicos a partir de múltiples variables simultáneas. Desde un enfoque teórico, este tipo de segmentación se apoya en técnicas de aprendizaje automático que buscan maximizar la homogeneidad interna de los grupos y la heterogeneidad entre ellos, favoreciendo interpretaciones más ajustadas del uso del producto (Marr, 2019).

En línea con lo anterior, la aplicación de inteligencia artificial al análisis de usuarios permite abordar la complejidad inherente a los datos de interacción digital. Los comportamientos de uso suelen ser no lineales, contextuales y altamente variables, lo que dificulta su interpretación mediante métricas agregadas. En estas circunstancias, los modelos algorítmicos facilitan la identificación de patrones recurrentes y relaciones latentes entre variables, contribuyendo a una comprensión más estructurada del fenómeno analizado (Davenport & Ronanki, 2018).

Otro ámbito relevante es la incorporación de inteligencia artificial en procesos de investigación de experiencia de usuario. Desde una perspectiva teórica, el uso de modelos algorítmicos en el análisis de datos cualitativos y cuantitativos permite sistematizar información proveniente de múltiples fuentes, como interacciones, textos o registros de comportamiento. Este enfoque no reemplaza la interpretación humana, sino que actúa como un soporte analítico que amplía la capacidad de procesamiento y organización de la información disponible (UNESCO, 2021).

La relación entre inteligencia artificial y análisis de experiencia de usuario también plantea desafíos conceptuales vinculados a la interpretación de los resultados. La literatura especializada advierte que los modelos algorítmicos operan a partir de supuestos implícitos y datos históricos que condicionan sus inferencias. Por lo tanto, la comprensión del producto mediada por inteligencia artificial requiere una lectura crítica de los resultados, así como la explicitación de los criterios analíticos utilizados en su construcción (Marr, 2019).

Desde el punto de vista de la *data literacy*, la incorporación de inteligencia artificial en el análisis del producto exige competencias orientadas a la interpretación de modelos y resultados algorítmicos. No se trata únicamente de acceder a nuevas formas de análisis, sino de comprender los límites, alcances y posibles sesgos de los sistemas utilizados. En este marco, la alfabetización algorítmica se integra como una dimensión necesaria para sostener análisis coherentes y conceptualmente fundados (UNESCO, 2021).

Asimismo, la inteligencia artificial contribuye a redefinir los marcos temporales del análisis de producto, al permitir evaluaciones continuas y dinámicas del comportamiento de los usuarios. Esta capacidad favorece una comprensión más situada y evolutiva del uso del producto, en contraste con enfoques estáticos o retrospectivos. Desde una perspectiva teórica, este desplazamiento temporal amplía las posibilidades de análisis, pero también incrementa la complejidad interpretativa del proceso analítico (Davenport & Ronanki, 2018).

Teniendo en cuenta lo mencionado, la inteligencia artificial aplicada al análisis y comprensión del producto puede entenderse como un conjunto de prácticas analíticas que amplían los marcos tradicionales de interpretación de datos. Su valor no reside únicamente en la sofisticación técnica de los modelos, sino en la posibilidad de integrar múltiples dimensiones de información dentro de esquemas conceptuales coherentes. De este modo, la inteligencia artificial se incorpora como un recurso analítico que fortalece la comprensión del producto cuando se utiliza de manera reflexiva y conceptualmente informada.

El análisis del producto mediado por inteligencia artificial se inscribe dentro de debates más amplios sobre el rol de los sistemas algorítmicos en la producción de conocimiento. La literatura académica destaca la necesidad de articular estos desarrollos con marcos teóricos claros que orienten su interpretación y uso. Por lo tanto, la inteligencia artificial aplicada al análisis del producto debe comprenderse como parte de un

proceso analítico más amplio, en el cual la interpretación humana mantiene un lugar central.

Prototipado asistido. Priorización predictiva —

La aplicación de la inteligencia artificial al diseño y la priorización del producto se inscribe dentro de un marco teórico orientado a la ampliación de las capacidades analíticas y evaluativas en los procesos de toma de decisiones. Desde esta perspectiva, los sistemas algorítmicos se incorporan como mediadores cognitivos que permiten analizar múltiples variables de manera simultánea, facilitando la comparación entre alternativas de diseño y la estimación de impactos potenciales. En este sentido, la inteligencia artificial no sustituye el juicio humano, sino que actúa como un soporte analítico que contribuye a estructurar decisiones complejas (Russell & Norvig, 2021).

En el ámbito del diseño de producto, la inteligencia artificial se vincula con la generación y evaluación de representaciones preliminares que permiten anticipar posibles configuraciones del producto. Desde un enfoque teórico, estos procesos pueden entenderse como instancias de simulación y exploración conceptual, en las cuales los modelos algorítmicos contribuyen a organizar información dispersa y a identificar patrones recurrentes en datos históricos. De este modo, la inteligencia artificial se integra en el diseño como un recurso analítico que amplía el espacio de alternativas consideradas (Marr, 2019).

En línea con lo anterior, la literatura especializada señala que el diseño asistido por inteligencia artificial se apoya en la capacidad de los modelos para aprender a partir de datos previos y generar inferencias sobre configuraciones posibles. Estas inferencias no constituyen predicciones deterministas, sino aproximaciones probabilísticas que orientan la reflexión sobre el producto. Por lo tanto, el valor teórico de estos enfoques

reside en su capacidad para informar el proceso de diseño, más que en la automatización completa de las decisiones (Davenport & Ronanki, 2018).

La priorización del producto constituye otro ámbito en el cual la inteligencia artificial adquiere relevancia conceptual. Desde una perspectiva teórica, la priorización implica ordenar iniciativas, funcionalidades o cambios en función de criterios múltiples, tales como impacto esperado, esfuerzo requerido o alineación estratégica. Los modelos algorítmicos permiten integrar estos criterios de manera sistemática, facilitando análisis comparativos que resultan complejos de realizar mediante enfoques exclusivamente cualitativos (Marr, 2019).

La priorización predictiva, en particular, se apoya en modelos que utilizan datos históricos para estimar posibles resultados futuros. Desde el punto de vista conceptual, estos modelos operan sobre supuestos explícitos acerca de la relación entre variables, lo que exige una lectura crítica de sus resultados. En estas circunstancias, la *data literacy* se vuelve necesaria para interpretar adecuadamente las estimaciones generadas y para comprender los límites de validez de las inferencias algorítmicas (UNESCO, 2021).

Asimismo, la incorporación de inteligencia artificial en procesos de diseño y priorización plantea desafíos vinculados a la transparencia y la explicabilidad de los modelos utilizados. La literatura académica advierte que los sistemas algorítmicos pueden generar recomendaciones difíciles de interpretar si no se explicitan los criterios y datos que las sustentan. Por lo tanto, el análisis teórico de estas aplicaciones debe contemplar la necesidad de marcos interpretativos que permitan comprender cómo y por qué se producen determinadas sugerencias (Russell & Norvig, 2021).

Desde una perspectiva organizacional, la inteligencia artificial aplicada al diseño y la priorización influye en la forma en que se estructuran los procesos decisionales. La disponibilidad de recomendaciones algorítmicas puede modificar los criterios de evaluación y los tiempos de decisión,

introduciendo nuevas dinámicas en la gestión del producto. En este marco, resulta pertinente analizar estas tecnologías no solo como herramientas técnicas, sino como elementos que inciden en las prácticas cognitivas y organizacionales (Davenport & Ronanki, 2018).

La integración entre diseño, priorización e inteligencia artificial también requiere considerar la relación entre creatividad y análisis. La literatura sobre gestión del producto señala que el diseño implica tanto la generación de ideas como su evaluación sistemática. En estas circunstancias, la inteligencia artificial puede contribuir a estructurar la evaluación de alternativas, mientras que la formulación de propuestas continúa dependiendo de procesos interpretativos y creativos humanos (Marr, 2019).

La IA aplicada al diseño y la priorización del producto puede entenderse como un campo en desarrollo, atravesado por tensiones entre automatización y control humano. Su análisis teórico exige reconocer tanto sus aportes analíticos como sus limitaciones interpretativas. De este modo, estas aplicaciones se integran dentro de un enfoque reflexivo de la gestión de producto, en el cual la tecnología actúa como un soporte para la toma de decisiones informadas, y no como un sustituto del razonamiento conceptual.

IA y desarrollo de *software* desde la perspectiva del *product manager*

La relación entre inteligencia artificial y desarrollo de software puede analizarse desde una perspectiva teórica que considera a los sistemas algorítmicos como mediadores en los procesos de coordinación, especificación y planificación del trabajo. En el

ámbito de la gestión de producto, esta relación no se limita a la automatización de tareas técnicas, sino que involucra transformaciones en la forma en que se estructuran los flujos de desarrollo y se comunican los requerimientos. En este sentido, la inteligencia artificial se incorpora como un recurso que influye en la organización cognitiva y operativa del proceso de construcción de *software* (Pressman & Maxim, 2020).

Desde un enfoque conceptual, el flujo de desarrollo de *software* puede entenderse como una secuencia de actividades interrelacionadas que articulan análisis, diseño, implementación y validación. La incorporación de inteligencia artificial en este flujo introduce nuevas formas de asistencia en la organización del trabajo, permitiendo analizar información histórica, detectar patrones en ciclos de desarrollo y anticipar posibles cuellos de botella. Por lo tanto, estos sistemas se integran como soportes analíticos que contribuyen a la gestión de la complejidad inherente al desarrollo de *software* (Sommerville, 2016).

La especificación funcional constituye otro ámbito central en el que la inteligencia artificial adquiere relevancia teórica. La formulación de *user stories* implica traducir necesidades y objetivos en descripciones estructuradas que orientan el trabajo de desarrollo. Desde esta perspectiva, los sistemas algorítmicos pueden asistir en la organización, revisión y coherencia de dichas especificaciones, actuando como mediadores que facilitan la

claridad conceptual y la consistencia interna de los requerimientos, sin reemplazar la interpretación humana (Pressman & Maxim, 2020).

La calidad de las *user stories* depende de la explicitación de criterios claros que delimiten su alcance y condiciones de cumplimiento. La literatura sobre ingeniería de *software* señala que la ambigüedad en la especificación constituye una fuente frecuente de desviaciones y retrabajo. En estas circunstancias, la inteligencia artificial puede contribuir a identificar inconsistencias, redundancias o vacíos conceptuales en las descripciones funcionales, fortaleciendo la trazabilidad entre objetivos de producto y desarrollo técnico (Sommerville, 2016).

Otro proceso relevante es el *backlog grooming*, entendido como la revisión y organización sistemática de los elementos que componen el trabajo futuro. Desde una perspectiva teórica, este proceso implica decisiones continuas de ordenamiento, priorización y reformulación. La incorporación de inteligencia artificial permite analizar grandes volúmenes de información asociados al historial del producto, aportando criterios analíticos

que facilitan la evaluación de dependencias y la coherencia del conjunto de requerimientos (Davenport & Ronanki, 2018).

La asistencia algorítmica en el *backlog grooming* no elimina la necesidad de juicio humano, sino que introduce nuevas formas de mediación cognitiva. Los sistemas de inteligencia artificial operan a partir de datos históricos y reglas inferenciales que condicionan sus recomendaciones. Por lo tanto, su uso requiere una lectura crítica de los resultados y una comprensión clara de los supuestos que los sustentan, integrando la *data literacy* y la alfabetización algorítmica como competencias necesarias en la gestión del desarrollo (UNESCO, 2021).

Desde el punto de vista organizacional, la inteligencia artificial aplicada al desarrollo de *software* incide en la coordinación entre roles y en la distribución de responsabilidades. La literatura académica advierte que la introducción de nuevas tecnologías puede modificar las dinámicas de comunicación y toma de decisiones. En este marco, resulta pertinente analizar estas herramientas no solo como recursos técnicos, sino como elementos que influyen en las prácticas colectivas de producción de *software* (Sommerville, 2016).

Asimismo, la integración de inteligencia artificial en los procesos de desarrollo plantea desafíos vinculados a la transparencia y la explicabilidad de las recomendaciones generadas. Cuando los

sistemas algorítmicos participan en la organización del trabajo, se vuelve necesario comprender cómo se producen sus sugerencias y bajo qué criterios operan. Desde una perspectiva teórica, esta exigencia se relaciona con la necesidad de sostener procesos de desarrollo comprensibles y controlables por los actores involucrados (Russell & Norvig, 2021).

La inteligencia artificial y el desarrollo de *software*, analizados desde la perspectiva del *product manager*, pueden entenderse como un campo de articulación entre análisis, coordinación y toma de decisiones. Su incorporación no redefine únicamente las herramientas disponibles, sino también los marcos conceptuales que orientan la gestión del trabajo técnico. En este sentido, el análisis teórico de estas prácticas permite comprender cómo los sistemas algorítmicos se integran en procesos de desarrollo complejos, manteniendo al mismo tiempo la centralidad del criterio humano en la definición del producto.

CONTINUAR

Referencias

Davenport, T. H., & Harris, J. G. (2017). *Competing on analytics: The new science of winning*. Harvard Business Review Press.

Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.

Date, C. J. (2019). *An introduction to database systems* (8th ed.). Pearson.

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (8th ed.). Cengage Learning.

Marr, B. (2016). *Big data in practice: How 45 successful companies used big data analytics to deliver extraordinary results*. Wiley.

Marr, B. (2019). *Artificial intelligence in practice: How 50 successful companies used AI and machine learning to solve problems*. Wiley.

Pressman, R. S., & Maxim, B. R. (2020). *Software engineering: A practitioner's approach* (9th ed.). McGraw-Hill Education.

Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media.

Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

Sommerville, I. (2016). *Software engineering* (10th ed.). Pearson Education.

UNESCO. (2018). *A global framework of reference on digital literacy skills for indicator 4.4.2*. UNESCO Institute for Statistics.

UNESCO. (2021). *AI and education: Guidance for policy-makers*. UNESCO Publishing.

CONTINUAR