



# Módulo 3. Perfiles profesionales del dato y dinámicas de trabajo

☰ 1. Roles y funciones en equipos de análisis y gestión de datos

☰ 2. Producción de valor a partir del análisis de datos

☰ Referencias

# 1. Roles y funciones en equipos de análisis y gestión de datos

---

En el módulo 1 se presentó una primera aproximación al ecosistema de datos, reconociendo a los actores que participan en la creación, gestión y uso de la información. A partir de perfiles como generadores, gestores, usuarios organizacionales y consumidores, se logró una visión general sobre cómo circulan los datos desde su origen hasta su aprovechamiento práctico. Esta perspectiva permitió comprender que la información no se produce ni se utiliza de forma aislada, sino que es el resultado de múltiples intervenciones articuladas en contextos sociales, institucionales y tecnológicos diversos.

En este módulo se retoma esa mirada, pero se la traslada a un plano más específico: el de los equipos técnicos que trabajan con datos en organizaciones públicas y privadas. El foco estará puesto en los perfiles profesionales que integran estos equipos y en las funciones que desempeñan dentro de los proyectos de análisis y gestión. A través del estudio de tres figuras ampliamente reconocidas —*data engineer*, *data scientist* y *data product manager*

— se busca entender cómo se diseñan las infraestructuras, cómo se desarrollan modelos analíticos y cómo se orientan los productos basados en datos hacia objetivos estratégicos. Esta unidad ofrece así una aproximación concreta a las dinámicas internas del trabajo con datos, aportando herramientas para identificar roles, responsabilidades y formas de colaboración interdisciplinaria.

### ***Data engineer: diseño de arquitecturas, pipelines y flujos de datos***


En las organizaciones que trabajan con grandes volúmenes de datos, una de las tareas más complejas no es el análisis en sí, sino la preparación previa que hace posible ese análisis. Los datos provienen de múltiples fuentes, tienen distintos formatos y no siempre llegan con la calidad necesaria para ser aprovechados. Por eso, dentro de los equipos técnicos de datos, una figura especializada se ocupa de garantizar que esa información sea accesible, confiable y utilizable: el *data engineer* (Data Scientist, 2025).

Este perfil profesional diseña la arquitectura que permite mover los datos desde su origen hasta su destino final, que puede ser un sistema de visualización, un modelo predictivo o una base de datos de consulta. Para eso, construye lo que se conoce como *pipeline* de datos, es decir, un conjunto de procesos

automatizados que permiten extraer, transformar y cargar la información (*extract, transform, load* o ETL). En términos simples, se encarga de que los datos viajen de forma segura, organizada y estructurada por los distintos sistemas de la organización.

Una parte fundamental de su trabajo es decidir cómo se van a almacenar los datos. Existen dos enfoques principales.

### Figura 1. Principales enfoques para el almacenamiento de datos



Made with Napkin

Fuente: elaboración propia

---

El primero es el ***data warehouse*** o almacén de datos, que organiza la información en estructuras ordenadas, como tablas, lo que facilita su uso por parte de analistas y herramientas de consulta. El segundo es el ***data lake***, que permite guardar grandes volúmenes de datos en bruto, sin procesar ni estructurar, lo cual es útil cuando se necesita flexibilidad o cuando todavía no se sabe cómo se va a usar esa información. La decisión sobre cuál usar depende del tipo de datos, el objetivo del análisis y la infraestructura disponible.

Además de estas tareas técnicas, el *data engineer* debe comprender las necesidades del resto del equipo. Por ejemplo, si una analista necesita consultar datos de ventas por semana y región, el *data engineer* tiene que asegurarse de que esa información esté disponible, limpia y en el formato adecuado. Esto implica validar la calidad de los datos, eliminar duplicaciones, completar valores faltantes y estandarizar formatos. También debe aplicar medidas de seguridad, como la anonimización de datos personales, para cumplir con la normativa vigente (Data Scientist, 2025).

Todas estas competencias pueden agruparse en tres dimensiones: técnicas, analíticas y personales. En la siguiente tabla se resumen las más relevantes para el desempeño del rol.

**Tabla 1. Competencias del *data engineer***

Tipo de competencia	Competencias específicas
<b>Técnicas</b>	Lenguajes de programación (Python, Java)
	Modelado de datos
	Bases de datos relacionales y no relacionales (SQL/NoSQL)
	Plataformas de procesamiento de datos (Hadoop, Spark)
	Automatización de flujos (ETL, DevOps)
	Herramientas de <i>cloud computing</i> (AWS, Azure, Google cloud)
<b>Analíticas</b>	Comprensión del ciclo de vida del dato
	Conocimientos básicos de inteligencia artificial ( <i>machine learning, deep learning</i> )
	Principios matemáticos aplicados

<b>Personales</b>	Adaptación tecnológica
	Comunicación con otros perfiles
	Resolución de problemas

Fuente: elaboración propia

Como puede observarse, el *data engineer* no se limita a una función técnica. Su trabajo impacta directamente en el rendimiento de todo el equipo, ya que asegura que la infraestructura de datos sea confiable, eficiente y alineada con los objetivos del análisis. Es una figura que combina conocimiento técnico con pensamiento estratégico, y cuya intervención marca la diferencia entre un conjunto de datos dispersos y una base informativa útil para tomar decisiones.

## **Data scientist: análisis, experimentación y modelado predictivo**

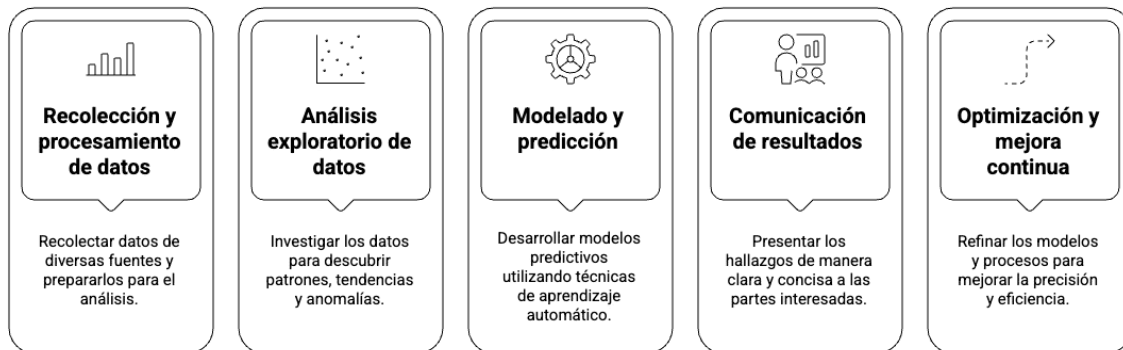
Una vez que los datos están disponibles gracias al trabajo previo del *data engineer*, el *data scientist* comienza a intervenir de manera más activa. Sin embargo, su tarea no se limita al análisis: también participa en etapas anteriores como la selección y preparación de los datos que serán utilizados. Aunque no es responsable directo de la infraestructura técnica, debe saber

identificar fuentes relevantes de información, evaluar la calidad de los datos disponibles y realizar transformaciones que los vuelvan útiles para el análisis.

Este perfil combina competencias en programación, estadística y *machine learning*, con un enfoque orientado a resolver problemas concretos dentro de las organizaciones. Su rol es convertir grandes volúmenes de datos en conocimiento útil, ya sea para anticipar escenarios, descubrir relaciones entre variables o aportar argumentos que faciliten la toma de decisiones. En muchos casos, trabaja en conjunto con equipos de *marketing*, producto, salud o finanzas, dependiendo del sector.

En la siguiente figura se presentan las funciones principales que este perfil desempeña en los proyectos de análisis de datos.

**Figura 2. Funciones principales del *data scientist***



Made with Napkin

Fuente: elaboración propia con base en Aragón, 2025

Cada una de estas funciones se vincula con necesidades concretas de las organizaciones y responde a situaciones prácticas donde los datos ayudan a resolver problemas o tomar decisiones. A continuación, se describen en detalle.

## Recolección y procesamiento de datos

Aunque los datos ya estén disponibles, el *data scientist* debe prepararlos según las necesidades del análisis. Por ejemplo, si se quiere analizar el abandono de clientes en un servicio de streaming, primero hay que identificar cuáles variables son relevantes (edad, historial de visualización, frecuencia de uso, etc.) y transformar esos datos en un formato adecuado para el modelado. Esta etapa también incluye eliminar registros incompletos, corregir errores o unificar formatos.

## **Análisis exploratorio de datos** —

Antes de aplicar modelos predictivos, se realiza una exploración que permite conocer la estructura y características de los datos. Por ejemplo, si se está analizando el rendimiento académico en una plataforma educativa, se pueden detectar diferencias por región, por tipo de dispositivo o por frecuencia de conexión. Esta exploración ayuda a detectar patrones iniciales y ajustar los supuestos del análisis.

## **Modelado y predicción** —

A través de algoritmos estadísticos o de *machine learning*, se desarrollan modelos que permiten anticipar resultados. Por ejemplo, en el sector financiero, un modelo puede predecir el riesgo de impago de un crédito; en salud, se pueden estimar probabilidades de reingreso hospitalario. Estos modelos se entrenan con datos históricos y luego se aplican a casos nuevos para generar estimaciones.

## **Comunicación de resultados** —

Una vez construidos los modelos, los resultados deben presentarse de forma comprensible para otras áreas de la organización. Esto puede implicar construir tableros interactivos, gráficos comparativos o reportes ejecutivos. En un contexto de ventas, por ejemplo, el *data scientist* puede mostrar cómo ciertas campañas afectan el comportamiento de compra en distintas regiones.

## Optimización y mejora continua —

Los modelos no son estáticos. A medida que ingresan nuevos datos o cambian las condiciones, es necesario evaluar su desempeño. Por ejemplo, un modelo de recomendación de productos puede perder efectividad si se modifican las preferencias de los usuarios. En esos casos, el *data scientist* debe revisar, ajustar o incluso rediseñar los algoritmos para mantener su utilidad.

Estas funciones muestran que el trabajo del *data scientist* requiere tanto dominio técnico como una mirada analítica orientada a la resolución de problemas. Su intervención permite extraer valor de los datos disponibles, generar predicciones y construir herramientas que apoyan la toma de decisiones en distintos contextos. De este modo, los datos se convierten en un recurso para mejorar procesos, identificar oportunidades o anticipar escenarios.

### ***Data product manager: enfoque estratégico y visión de producto basada en datos***

A medida que los datos se integran en más procesos organizacionales, dejan de ser solo un insumo para el análisis y se convierten en parte estructural de productos, servicios y herramientas internas. Esta transformación requiere no solo

capacidades técnicas para construir modelos o plataformas, sino también una gestión estratégica que garantice su utilidad y sostenibilidad. En este marco aparece el rol del *data product manager* (DPM), responsable de orientar el desarrollo de soluciones basadas en datos con una mirada de producto alineada a las necesidades del negocio.

Aunque guarda ciertas similitudes con el *product manager* tradicional —sobre todo en lo relativo a la gestión del ciclo de vida de un producto—, el DPM trabaja sobre objetos menos visibles o tangibles: modelos, tableros, plataformas, conjuntos de datos o APIs que sirven de insumo para otros usuarios. A continuación, se presenta una comparación entre ambos perfiles.

**Tabla 2. Diferencias entre *data product manager* y *product manager* tradicional**

<b>Aspecto</b>	<b><i>Product manager</i> tradicional</b>	<b><i>Data product manager</i></b>
Tipo de producto	Aplicaciones, sitios web, servicios	Modelos, tableros, plataformas, APIs
Usuarios principales	Externos (clientes o consumidores)	Internos y externos (analistas, socios,

		equipos)
Éxito del producto	Métricas de uso, satisfacción, ingresos	Precisión, confiabilidad, accesibilidad, impacto en decisiones
Enfoque principal	Experiencia del usuario final	Aprovechamiento estratégico de los datos
Valor generado	Propuesta de valor directa al cliente	Mejora de procesos, eficiencia, reducción de riesgos

Fuente: elaboración propia con base en Arregui, 2025

Esta tabla permite observar que, aunque comparten marcos de trabajo similares, los objetivos y criterios de evaluación de cada rol son diferentes. Mientras que el *product manager* se orienta a la entrega de productos visibles y con contacto directo con usuarios finales, el *data product manager* se enfoca en diseñar soluciones que permitan a otros aprovechar los datos de manera eficiente y alineada con los objetivos del negocio.

El DPM no necesariamente domina todos los aspectos técnicos, pero sí debe entender lo suficiente de infraestructura de datos, análisis y herramientas de visualización como para tomar

decisiones informadas y coordinar equipos multidisciplinarios. Su tarea consiste en asegurar que los productos basados en datos respondan a una necesidad concreta, sean sostenibles en el tiempo y se integren de forma coherente con el entorno tecnológico de la organización.

Entre sus principales funciones se encuentran las siguientes:

- Definir la visión y estrategia del producto de datos, en línea con los objetivos organizacionales.
- Identificar y priorizar requerimientos de usuarios internos o socios estratégicos.
- Colaborar con equipos de ingeniería y ciencia de datos para validar la viabilidad técnica de las soluciones.
- Establecer métricas de éxito adaptadas al tipo de producto (por ejemplo, calidad del dato, frecuencia de uso, estabilidad del modelo).
- Coordinar iteraciones de mejora continua en función del uso y la retroalimentación recibida.

Este perfil actúa como un puente entre quienes generan datos, quienes los procesan y quienes los utilizan para tomar decisiones. Su intervención permite que la inversión en datos se traduzca en herramientas concretas, adaptadas a contextos específicos y pensadas desde una lógica de producto sostenible.

### **Interacción operativa entre *data engineer*, *data scientist* y *data product manager***

A partir de lo explicado anteriormente, podemos delimitar las funciones principales de cada uno de estos perfiles del siguiente modo:

**Figura 3. Funciones generales del *data engineer*, *data scientist* y *data product manager***



### **Data engineer**

Diseña e implementa la infraestructura para procesar y almacenar los datos.

### **Data scientist**

Analiza los datos y desarrolla modelos predictivos o explicativos.

### **Data product manager**

Define la estrategia, requisitos y objetivos del producto basado en datos.

Fuente: elaboración propia

---

Si bien estas tareas se pueden abordar por separado, en los proyectos reales suelen estar estrechamente conectadas. El *data engineer* se encarga de que los datos estén disponibles en condiciones adecuadas; el *data scientist* utiliza esos datos para crear modelos o análisis; y el *data product manager* se asegura de que todo ese trabajo responda a una necesidad concreta de la organización, planteando prioridades, métricas y mejoras. La colaboración entre estos perfiles no es secuencial, sino iterativa:

se retroalimentan entre sí, ajustan sus tareas en función de los avances del otro y toman decisiones en conjunto.

Por ejemplo, supongamos que una empresa quiere reducir la rotación de personal mediante un sistema que anticipe posibles renuncias. El *data product manager* define el objetivo del producto (anticipar riesgos de salida), identifica a los usuarios que lo van a utilizar (recursos humanos y dirección) y establece qué tipo de salida visual sería más útil (dashboard con alertas). Luego, el *data engineer* prepara los datos: extrae información de ausentismo, desempeño, encuestas internas y carga horaria. Una vez que esos datos están listos, el *data scientist* analiza las variables asociadas a las renuncias pasadas y construye un modelo que predice la probabilidad de que una persona deje su puesto. Finalmente, el equipo valida los resultados, ajusta parámetros y despliega el producto en el entorno operativo.

Este ejemplo muestra cómo el trabajo colaborativo entre perfiles técnicos del dato permite pasar de una necesidad concreta a una solución funcional, manteniendo la coherencia entre lo que se puede hacer técnicamente, lo que se necesita analizar y lo que debe aportar el producto final.

CONTINUAR

## 2. Producción de valor a partir del análisis de datos

---

En la unidad anterior se caracterizaron los perfiles profesionales que conforman los equipos técnicos de análisis y gestión de datos. A partir de la descripción de sus funciones e interacciones, se abordó cómo el *data engineer*, el *data scientist* y el *data product manager* intervienen en distintas etapas del proceso analítico, desde la preparación de la infraestructura hasta la construcción de modelos y productos. Este recorrido permitió entender la dinámica de trabajo interna que hace posible que los datos se transformen en recursos útiles para la organización. Sin embargo, para que ese valor potencial se concrete, es necesario que los resultados del análisis sean interpretados, comunicados e integrados en las decisiones que se toman en diferentes niveles.

Esta unidad se enfoca precisamente en ese momento posterior al trabajo técnico. Se abordará cómo se implementan y utilizan los productos de datos dentro de entornos organizacionales, considerando tanto los aspectos operativos como las condiciones institucionales que facilitan o dificultan su aprovechamiento.

Además, se analizarán las estrategias de comunicación que permiten traducir los hallazgos del análisis en insumos comprensibles y accionables. En este sentido, la unidad recupera la perspectiva colaborativa trabajada anteriormente, pero traslada la atención hacia el uso concreto de los productos analíticos: cómo se insertan en los procesos de gestión, quiénes los interpretan, qué tipo de decisiones apoyan y qué criterios aseguran su utilidad en contextos reales.

## **Soluciones para integrar soluciones analíticas en el entorno organizacional**

Hasta el momento, sabemos que el *data engineer*, el *data scientist* y el *data product manager* trabajan en conjunto para diseñar infraestructuras, desarrollar modelos y convertir los datos en productos que aporten valor a la organización. Ahora bien, ¿cómo se hace para que ese valor no quede restringido al equipo técnico? ¿Qué tiene que pasar para que una herramienta basada en datos forme parte del trabajo diario y tenga un impacto real en las decisiones que se toman?

Aquí es donde entra en juego una serie de herramientas que permiten integrar las soluciones analíticas en los entornos organizacionales. Estas soluciones adoptan formas diversas, pero

comparten una misma lógica: **transformar información en insumos útiles para la acción**. Entre las más habituales se encuentran las siguientes:

## 1. Tableros de visualización —

Los tableros de visualización permiten transformar grandes volúmenes de datos en representaciones gráficas dinámicas y comprensibles. Están compuestos por indicadores clave —también conocidos como *key performance indicators* o KPI—, que son valores que resumen información relevante para monitorear procesos, seguir objetivos y tomar decisiones. Un indicador clave puede ser, por ejemplo, la tasa de finalización de cursos en una plataforma educativa, el nivel de *stock* disponible en un almacén o el porcentaje de satisfacción en encuestas a usuarios. La selección de estos indicadores depende del área, los objetivos y el contexto de la organización.

Estas soluciones se construyen con herramientas como Power BI, Tableau o Looker Studio. Todas permiten integrar datos de múltiples fuentes, aplicar filtros personalizados y presentar la información en distintos niveles de detalle según el perfil del usuario. Un tablero puede incluir gráficos, mapas, matrices o indicadores visuales que se actualizan de forma automática. Gracias a estas funcionalidades, se vuelve una herramienta de consulta constante para equipos de gestión, áreas técnicas o instancias de dirección.

Dentro de una organización, la implementación de tableros varía según el área y el tipo de decisiones que se deben tomar. Por ejemplo, en un sistema de salud a nivel nacional, un tablero puede mostrar en tiempo real la disponibilidad de camas, la tasa de ocupación por provincia o el

promedio de espera en emergencias. En una empresa de logística con operaciones regionales, se pueden visualizar en simultáneo los trayectos de las unidades, tiempos estimados de entrega y desvíos por zonas geográficas. En el ámbito educativo, una plataforma centralizada puede consolidar datos de múltiples instituciones para analizar la evolución de la matrícula, el abandono interanual o los resultados por tipo de oferta. En todos los casos, los tableros permiten ordenar información que sería difícil de interpretar en bruto y transformarla en un recurso operativo.

Implementar este tipo de herramienta implica decisiones organizativas. Se definen qué indicadores se priorizan, con qué frecuencia se actualizan, cómo se presentan y quiénes los consultan. También se establecen espacios de revisión: reuniones periódicas, tableros compartidos en la nube, informes exportables. Además, suele acompañarse con formación interna para asegurar que los equipos comprendan las visualizaciones, puedan interpretar los datos y utilicen los tableros como base para tomar decisiones.

#### **Figura 4. Ejemplo de tablero en Power BI**



Fuente: Martorello, 2023, <https://goo.su/XURuBy>

## 2. API de datos

Las API —sigla de *Application Programming Interface*— son conjuntos de reglas que permiten la comunicación entre distintos sistemas informáticos para intercambiar datos, funciones o servicios (Goodwin, 2024). A través de ellas, los desarrolladores pueden integrar datos de otras aplicaciones sin necesidad de crearlos desde cero, lo que acelera procesos, facilita el desarrollo de soluciones digitales y mejora la interoperabilidad entre plataformas. Dentro del ecosistema organizacional, se utilizan no solo para conectar sistemas internos, sino también para exponer información a otras áreas, socios estratégicos o servicios externos, bajo condiciones seguras y controladas.

Existen diferentes tipos de API, como las API web, las API de servicios y las API de datos. Estas últimas permiten acceder a conjuntos estructurados de información alojados en bases de datos. Habilitan operaciones como lectura, actualización o eliminación de registros, a través de comandos predefinidos que simplifican el acceso y la gestión de datos, incluso sin

necesidad de conocer en profundidad lenguajes de consulta como SQL, que normalmente se utilizan para interactuar directamente con bases de datos. Este nivel de abstracción es lo que convierte a las API de datos en herramientas particularmente útiles para equipos multidisciplinarios (Khan, 2024).

Desde el punto de vista técnico, las API de datos permiten operar con sistemas de gestión de bases de datos (DBMS) mediante operaciones CRUD —crear, leer, actualizar y eliminar— sin que el usuario tenga contacto directo con el esquema o lenguaje subyacente. Esto se traduce en ventajas como mayor seguridad, dado que pueden incorporarse mecanismos de autenticación, cifrado y control de acceso; interoperabilidad entre distintas aplicaciones; eficiencia operativa; y coherencia en el tratamiento de la información a lo largo del tiempo.

Una manera sencilla de entender cómo funciona una API de datos es pensar en una situación concreta dentro de una organización. Supongamos que un área de planificación necesita consultar un tablero que muestra en tiempo real la evolución de distintos indicadores. Ese tablero fue construido en una herramienta como Power BI, pero los datos que muestra no están cargados manualmente: provienen de un sistema interno donde se registra información de forma constante, como un sistema de gestión de proyectos.

Lo que hace Power BI, en este caso, es enviar una *solicitud automática* a una API de datos. Esa API está conectada al sistema que guarda la información original (por ejemplo, una base de datos donde se registran fechas, responsables, entregables, etc.). La herramienta no accede directamente a la base de datos, sino que le dice a la API: «mostrar los datos actualizados sobre estos proyectos». La API interpreta esa solicitud, busca los datos en el sistema de origen, los organiza según lo pedido y los devuelve a Power BI para que se muestren en el tablero.

Todo este proceso ocurre sin intervención manual. Quien consulta el tablero solo ve los resultados actualizados, sin saber que en segundo plano se activó una cadena de comunicación entre el tablero, la API y la base de datos. Por eso, las API de datos son fundamentales para automatizar el flujo de información dentro de las organizaciones: permiten conectar sistemas que no hablan el mismo lenguaje, mantener actualizados los datos y facilitar su uso por parte de distintos equipos.

### **3. Plataformas de análisis de autoservicio** —

Las plataformas de análisis de autoservicio permiten que personas de distintos sectores dentro de una organización accedan a datos, generen consultas y elaboren visualizaciones sin requerir conocimientos avanzados en programación ni depender constantemente de los equipos técnicos. Estas herramientas son parte de una arquitectura de datos moderna que busca ampliar el uso de la información en la toma de decisiones cotidianas, promoviendo una cultura más analítica en distintos niveles organizativos (Belcic y Stryker, 2025).

Su funcionamiento se apoya en una estructura previa: las canalizaciones de datos. Estas canalizaciones son desarrolladas por equipos de ingeniería y se encargan de recopilar, transformar y trasladar datos desde múltiples fuentes hasta sistemas donde pueden ser consultados por otras herramientas. Desde allí, las plataformas de autoservicio toman esa información y la ponen a disposición de los usuarios mediante entornos intuitivos, con opciones de búsqueda, filtros, paneles y herramientas de visualización.

Estas plataformas presentan ventajas para equipos de áreas como planificación, finanzas, logística o recursos humanos, ya que permiten adaptar las consultas a sus necesidades específicas, personalizar los formatos de salida y obtener respuestas en menor tiempo. Algunos

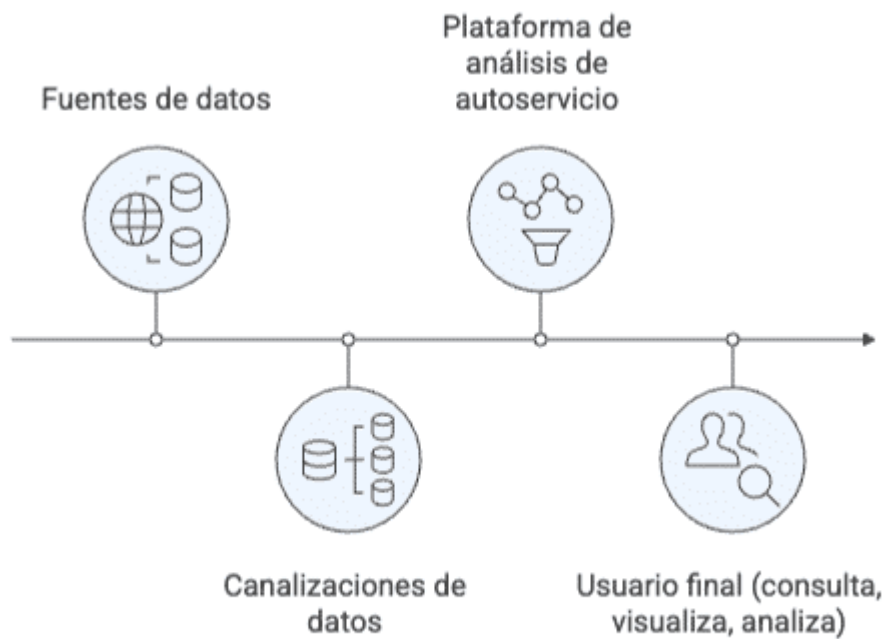
ejemplos de herramientas que ofrecen estas funcionalidades son Qlik Sense, Tableau con funciones de autoservicio o Microsoft Power BI en su versión enfocada en usuarios de negocio.

La incorporación de este tipo de soluciones suele ir acompañada por capacitaciones internas, guías interactivas o bibliotecas de datos compartidas que orientan a los equipos en el uso de los recursos disponibles. De este modo, se promueve que los datos sean parte del trabajo diario de cada área, con un enfoque práctico y accesible.

A lo largo de este apartado vimos cómo distintas herramientas permiten acercar los datos a las operaciones diarias de una organización. Estas soluciones no solo automatizan procesos, sino que también amplían las posibilidades de uso y análisis por parte de diversos equipos. Sin embargo, que los datos estén disponibles no garantiza que se comprendan ni que se traduzcan en decisiones concretas. En este sentido, el siguiente tema se centrará en las estrategias necesarias para comunicar hallazgos de manera efectiva y facilitar procesos de toma de decisiones basados en evidencia.

El proceso puede representarse como una secuencia integrada:

**Figura 6. Flujo de datos desde las canalizaciones hasta el usuario final**



Fuente: elaboración propia con base en Belcic y Stryker, 2025

## Estrategias para comunicar hallazgos y facilitar decisiones

Cuando una organización produce análisis con datos, parte del desafío está en cómo presentar esos hallazgos para que sean comprensibles y útiles en la toma de decisiones. La manera en que se comunica un resultado puede marcar una diferencia significativa: no es lo mismo mostrar un gráfico en una reunión técnica que redactar un informe para un comité directivo. Cada formato y cada contexto requiere un enfoque particular para que la información se transforme en insumo concreto para la acción.

Por eso, la comunicación es una dimensión estratégica dentro del trabajo con datos.

A continuación, abordaremos cuatro aspectos que permiten mejorar la transmisión de hallazgos en entornos organizacionales. En primer lugar, cómo adaptar el mensaje según el perfil de la audiencia y estructurar una narrativa clara. En segundo lugar, qué visualizaciones elegir para acompañar la lectura e interpretar patrones. Finalmente, cómo utilizar un lenguaje accesible y situar los datos en su contexto.

#### 1. NARRATIVA DE DATOS

#### 2. VISUALIZACIÓN ADECUADA SEGÚN EL TIPO DE DATOS

#### 3. LENGUAJE COMPENSIBLE Y DATOS EN CONTEXTO

Al momento de compartir hallazgos analíticos dentro de una organización, uno de los factores que más influye en su recepción es la capacidad de estructurar una historia comprensible, ajustada al perfil de quienes van a recibirla. La narrativa basada en datos —conocida como *data storytelling*— permite traducir análisis complejos en mensajes claros, apoyados en visualizaciones y guiados por una estructura que favorezca la toma de decisiones. Esta práctica se vuelve especialmente valiosa cuando se busca comunicar hallazgos a públicos no técnicos, o cuando los datos necesitan ser interpretados en contextos dinámicos donde el tiempo de lectura y análisis es limitado.

Una historia de datos combina tres elementos principales: el **análisis**, que representa el contenido técnico; la **visualización**, que actúa como puente entre los datos y el público; y la **narrativa**, que da sentido, organiza el mensaje y guía la lectura (Reveal, s.f.):

- **Análisis de datos**

El primer paso para construir una narrativa efectiva es tener un buen dominio del análisis. Esto implica trabajar con datos actualizados, confiables y relevantes para el objetivo que se busca. La selección de variables, la limpieza de registros y el tipo de tratamiento aplicado inciden directamente en los resultados que se van a comunicar. Por ejemplo, si un equipo de planificación educativa quiere mostrar la evolución del abandono escolar, necesita definir claramente el indicador, los períodos comparables, y cómo se tratarán los datos faltantes o inconsistentes.

Este análisis no se presenta directamente en detalle, pero sí determina qué aspectos se destacan en la historia. Es importante que quienes construyen la narrativa conozcan el origen y las características del análisis, ya que sobre esa base se construirán las visualizaciones y el mensaje.

- **Visualización de datos**

El segundo componente es la visualización, que cumple un rol clave en la forma en que el mensaje llega a la audiencia. Un gráfico bien elegido puede resaltar patrones, hacer visible una tendencia o mostrar diferencias relevantes entre grupos. En cambio, un gráfico mal construido puede generar confusión, distraer la atención o incluso inducir a interpretaciones erróneas.

Por ejemplo, si se quiere mostrar una caída progresiva en la participación de estudiantes en actividades extracurriculares, un gráfico de líneas es más adecuado que una tabla de números o un gráfico de torta. Si se desea comparar el rendimiento de varias sedes de una organización, puede optarse por un gráfico de barras ordenado de mayor a menor. La visualización, además, debe adaptarse al nivel de familiaridad que la audiencia tenga con el tipo de información presentada.

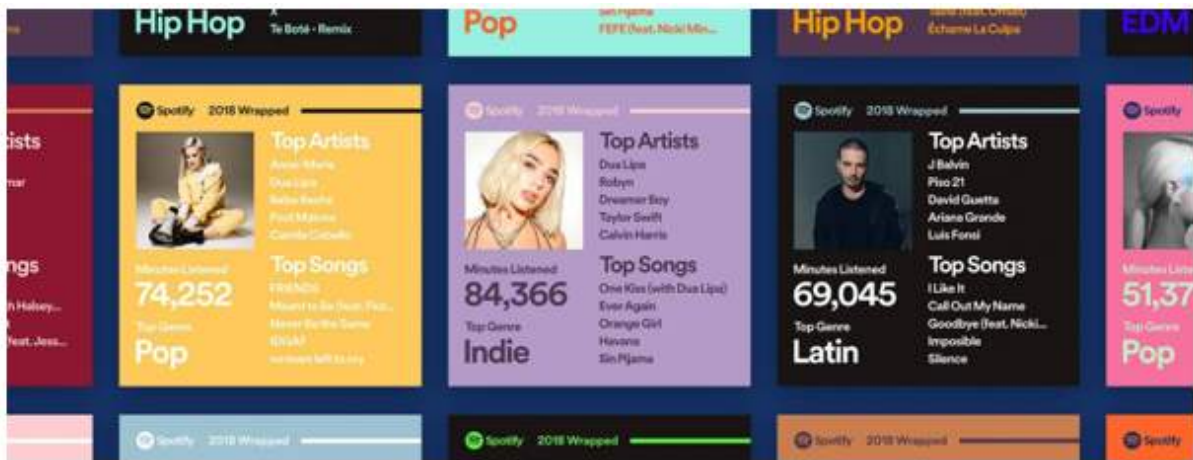
- **Narrativa**

Finalmente, la narrativa organiza el recorrido. Utiliza lenguaje sencillo, frases breves y estructuras claras para guiar la interpretación. En lugar de limitarse a mostrar qué dicen los datos, plantea una lectura posible, destacando lo relevante: variaciones, tendencias, valores atípicos o cambios significativos.

Una de las referencias más conocidas de narración basada en datos es la campaña *Spotify Wrapped*. Cada fin de año, la plataforma genera un resumen visual para cada usuario, con datos sobre sus artistas más escuchados, minutos de reproducción, géneros preferidos y canciones destacadas. Estos informes no solo presentan información en crudo, sino que están organizados como una historia personalizada, con lenguaje accesible, recursos gráficos atractivos y un tono que apela a lo emocional y lo compartible.

Este caso muestra claramente cómo los tres componentes trabajan en conjunto: el análisis de los datos de escucha permite generar *rankings* e indicadores personalizados; las visualizaciones están diseñadas para captar la atención y facilitar la lectura rápida; y la narrativa convierte esos datos en una experiencia cercana y memorable. El resultado no es solo informativo, sino que **logra involucrar activamente a los usuarios**, al punto de convertirse en una campaña viral cada año.

### **Figura 7. Ejemplo de narrativa de datos**



Fuente: Reveal, s.f., <https://goo.su/45IR4z5>

### 1. NARRATIVA DE DATOS

### 2. VISUALIZACIÓN ADECUADA SEGÚN EL TIPO DE DATOS

### 3. LENGUAJE COMPRESIBLE Y DATOS EN CONTEXTO

Hoy en día, herramientas como Power BI, Tableau o Looker Studio sugieren visualizaciones automáticamente según el tipo de datos y el objetivo general del análisis. Estas recomendaciones pueden ser útiles como punto de partida, pero no reemplazan el criterio necesario para decidir qué gráfico utilizar. Comprender el propósito del análisis, el tipo de variables involucradas y el perfil de la audiencia sigue siendo indispensable para representar los datos de manera clara y efectiva. Una visualización no solo debe ser técnicamente correcta, también debe ser comprensible para quien la interpreta y pertinente para las decisiones que se buscan facilitar.

Entre las funciones más comunes de las visualizaciones se encuentran:

- mostrar el cambio a lo largo del tiempo;
- representar la composición parte-todo;
- analizar distribuciones;

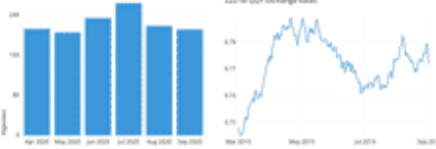
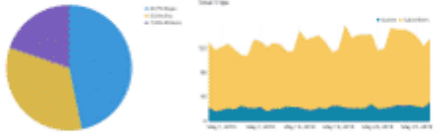
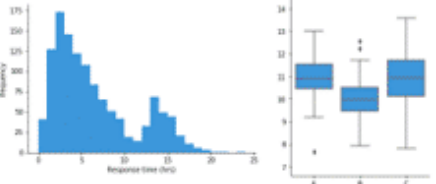
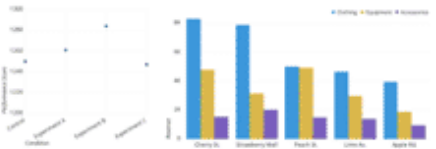
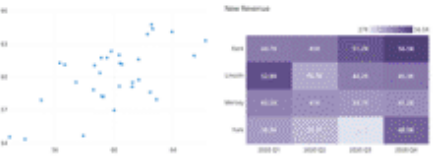
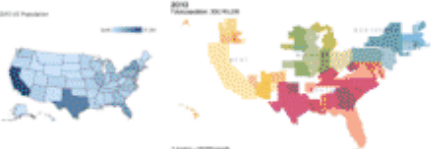
- comparar valores entre grupos;
- observar relaciones entre variables;
- representar datos geográficos.

Cada una de estas funciones responde a una necesidad distinta de análisis, por lo que no hay una visualización única que sirva para todo. A continuación, se presentan algunos de los gráficos más utilizados, agrupados según el tipo de tarea que permiten realizar, con una breve descripción de su aplicación.

### **Tabla 3. Tipos de gráficos según la función de análisis**

Fuente: adaptación propia con base en Yi y Restori, 2024, <https://goo.su/VXxnU>

Como vemos, cada gráfico tiene una función específica dentro del análisis de datos. La elección correcta permite que la información sea más clara, facilite la comparación entre variables y contribuya a una mejor interpretación por parte de quienes toman decisiones. Tener presente estas diferencias ayuda a diseñar visualizaciones que no solo sean atractivas, sino también útiles y pertinentes según el contexto organizativo.

Función de análisis	Tipo de gráfico	Descripción
Mostrar cambio a lo largo del tiempo	<p>Gráfico de barras o líneas</p> 	Ideal para observar la evolución de una variable en el tiempo (por ejemplo, ventas mensuales).
Representar la composición parte-todo	<p>Gráfico de barras apiladas o gráfico circular</p> 	Permite ver cómo se divide un total en sus componentes (por ejemplo, reparto de presupuesto por área).
Analizar la distribución de los datos	<p>Diagrama de caja (<i>box-plot</i>)</p> 	Muestra mediana, cuartiles y valores atípicos; útil para comparar variabilidad entre grupos.
Comparar valores entre grupos	<p>Gráfico de barras agrupadas o diagrama de puntos</p> 	Facilita la comparación entre categorías o segmentos (por ejemplo, rendimiento por sede).
Observar relaciones entre variables	<p>Diagrama de dispersión (<i>scatter plot</i>)</p> 	Representa dos (o más) variables para visualizar su correlación o patrón conjunto.
Visualizar datos geográficos	<p>Mapa coroplético o mapa con puntos</p> 	Permite ver datos sobre localización (por ejemplo, tasa de servicio por región).

## 1. NARRATIVA DE DATOS

## 2. VISUALIZACIÓN ADECUADA SEGÚN EL TIPO DE DATOS

## 3. LENGUAJE COMPRENSIBLE Y DATOS EN CONTEXTO

En entornos organizacionales, la forma en que se comunica un hallazgo analítico influye directamente en su impacto. No se trata solo de mostrar resultados, sino de construir mensajes claros, comprensibles y relevantes para quienes deben actuar en función de esa información. Para lograrlo, es necesario prestar atención al lenguaje que se utiliza y al contexto en el que se presentan los datos.

El primer paso es **elegir un lenguaje accesible**. Esto implica evitar tecnicismos innecesarios, siglas no explicadas o expresiones demasiado específicas del campo analítico. El objetivo no es simplificar en exceso, sino facilitar la comprensión sin perder precisión. Por ejemplo, en lugar de decir que «la variable presenta alta varianza intercuartílica», puede expresarse como «los valores están muy dispersos entre los casos analizados». Esta forma de comunicar respeta el contenido técnico, pero se adapta al vocabulario de equipos que no necesariamente trabajan con métricas estadísticas.

Además del lenguaje, es fundamental **situar los datos en un marco que permita interpretarlos**. Ningún valor dice mucho por sí solo: necesita referencias, comparaciones o antecedentes. Presentar un porcentaje, por ejemplo, solo es útil si se indica a qué se refiere, cómo cambió respecto de un periodo anterior o cómo se ubica en relación con un objetivo. Si se comunica que «el 68% de los formularios fueron completados correctamente», esa cifra adquiere sentido si se aclara que el mes pasado fue 52%, o que el objetivo del área es superar el 75%.

También es importante señalar el origen de los datos, la fecha de actualización y, si es necesario, los límites de interpretación. Cuando se contextualizan los resultados, se reduce la posibilidad de malas lecturas o

decisiones basadas en supuestos incorrectos. Incluso en documentos breves o presentaciones orales, ofrecer estos elementos básicos de contexto permite que quien recibe la información la integre de forma más precisa a sus propios marcos de decisión.

Por último, adaptar el mensaje al destinatario mejora la efectividad de la comunicación. A un equipo operativo se le puede presentar un resumen de lo que afecta directamente a su trabajo cotidiano, mientras que a una dirección estratégica le resultará más útil una síntesis general del impacto en el conjunto del área. En ambos casos, los datos son los mismos, pero la forma de narrarlos cambia para que tengan sentido en función del rol de quien los recibe.

Para finalizar, es importante señalar que, en contextos donde se produce y se analiza una gran cantidad de información, contar con estrategias para comunicar los hallazgos facilita que esos datos circulen entre equipos y áreas. Cada instancia de comunicación —ya sea un informe, una reunión o un tablero compartido— es una oportunidad para transformar resultados analíticos en insumos útiles. Por eso, pensar en la audiencia, el lenguaje, el formato y el contexto es una parte más del proceso de trabajo con datos.

**CONTINUAR**

## Referencias

---

**Aragón, P.** (2025). ¿Qué es un Data Scientist? Funciones, habilidades y formación. *The Valley*. <https://thevalley.es/blog/que-es-un-data-scientist>

**Belcic, I., & Stryker, C.** (2024). Análisis de autoservicio. IBM Think. <https://www.ibm.com/es-es/think/topics/self-service-analytics>

**DataScientest.** (2024). *Data Science: definición, problemática y casos de uso*. <https://datascientest.com/es/data-science-definicion-problematika-y-casos-de-uso>

**De Arregui, M.** (2025). El rol del Data Product Manager: puente entre negocio, datos y tecnología. OBS Business School. <https://www.obsbusiness.school/blog/el-rol-del-data-product-manager-puente-entre-negocio-datos-y-tecnologia>

**Goodwin, M.** (2024). *¿Qué es una API (interfaz de programación de aplicaciones)?* IBM Think. <https://www.ibm.com/es-es/think/topics/api>

**Khan, U. H.** (2024, July 4). *What are database APIs? Why and how are they used?* Astera Blog. <https://www.astera.com/type/blog/database-api/>

**Martorello, A.** (2022). *5 ejemplos de dashboards en Power BI 2023. Más El Data.* <https://www.maseldata.com/post/5-dashboards-de-power-bi-para-obtener-mejores-insights>

**Reveal.** (s.f.). *Narración basada en datos (Data-driven storytelling).* <https://www.revealbi.io/es/glossary/data-driven-storytelling>

**Yi, M., & Restori, M.** (2024). *Cómo elegir la visualización de datos adecuada.* Atlassian. <https://www.atlassian.com/data/charts/how-to-choose-data-visualization>

CONTINUAR