

Módulo 3. Analítica predictiva y *machine learning*

Unidad 1. Construyendo una metodología de analítica predictiva

Introducción

Hasta ahora, hemos aprendido a analizar datos reales sobre las acciones que los usuarios han realizado en el pasado dentro de nuestros productos digitales. Es decir, ocurre una acción, esta se registra en nuestra herramienta de analítica, la analizamos y, en función del análisis, planteamos soluciones de optimización.

Esto constituye un enfoque reactivo orientado a aplicar mejoras futuras. Pero imaginemos que necesitamos actuar de forma proactiva, que contamos con poco margen de reacción para tomar decisiones o que debemos proponer medidas preventivas ante una situación concreta.

Para ello, es necesario aplicar lo que denominamos análisis predictivo. Pero ¿a qué nos referimos cuando hablamos de análisis predictivo?

Existen muchas definiciones. En concreto, *HubSpot* define el análisis predictivo como el examen de un conjunto de datos —a través de técnicas estadísticas y algoritmos— con el fin de interpretarlos, detectar patrones y generar predicciones sobre un proceso. En otras palabras, se trata de utilizar los datos para identificar la probabilidad de resultados futuros a partir de datos históricos. Esto nos permite tomar decisiones informadas y proactivas.

La técnica estadística más conocida en la explotación de datos para análisis predictivo es el *machine learning*, una rama de la inteligencia artificial (*IA*) que permite a las máquinas aprender de los datos y mejorar su rendimiento sin necesidad de una programación explícita.

A continuación, profundizaremos en este concepto.

Tema 1. ¿Para qué sirve el análisis predictivo en una organización?

En un mundo cada vez más impulsado por los datos, la analítica predictiva se ha convertido —como señalábamos en la introducción— en una herramienta esencial para

anticipar tendencias, optimizar procesos y mejorar la toma de decisiones con un alto grado de precisión.

Desde los primeros modelos estadísticos hasta los enfoques más avanzados de *machine learning* y redes neuronales profundas, el desarrollo de la analítica predictiva ha evolucionado gracias a múltiples contribuciones de matemáticos, científicos de datos e ingenieros en inteligencia artificial. Actualmente, sus aplicaciones abarcan numerosos sectores: salud, finanzas, marketing, ciberseguridad, y, por supuesto, el ámbito deportivo.

Pero ¿por qué es importante este análisis en una organización? Muchas podrían ser las respuestas, pero principalmente porque permite obtener información profunda sobre tendencias o patrones de comportamiento de los usuarios, así como implementar estrategias que maximizan resultados y minimizan errores (siempre y cuando el dato sea de calidad, lo cual es fundamental en esta disciplina).

Si tuviéramos que resumir los principales beneficios de la analítica predictiva en el contexto organizacional, podríamos presentarlos de la siguiente manera:

Tabla 1. Beneficios de la analítica predictiva en las organizaciones

Beneficios	Observaciones
Reducir el impacto de riesgos	Si afirmamos que, gracias al análisis predictivo, podemos anticipar impactos futuros, entonces esto nos permite identificar con antelación posibles riesgos que puedan amenazar al negocio. Esta capacidad de anticipación nos da la oportunidad de invertir en acciones que minimicen ese posible impacto.
Optimizar las operaciones de la empresa	Si sabemos qué van a querer nuestros clientes, podemos predecir con mayor precisión las cantidades de inventario necesarias o identificar futuras demandas. Esto permite a las empresas invertir en recursos de forma más inteligente y eficiente.
Definir estrategias de <i>marketing</i> eficiente	Si logramos identificar las necesidades de nuestros clientes, podemos incluso influir en su toma de

	<p>decisiones, mostrando en cada momento el contenido o producto más indicado.</p> <p>Un ejemplo clásico en este sentido son los carritos abandonados, las recomendaciones personalizadas en un <i>e-commerce</i> o la detección de los canales que mejor convierten y aportan mayor retorno de inversión (ROI).</p>
Ampliar los territorios de impacto	Es posible identificar nuevas oportunidades para posicionar nuestros productos en mercados potencialmente rentables.
Más oportunidades de negocio	Nuevamente, si comprendemos las necesidades de nuestros clientes, las oportunidades de <i>cross-sell</i> y <i>up-sell</i> se multiplican.

Fuente: elaboración propia.

Modelos de análisis predictivo

Para empezar a aplicar el análisis predictivo en nuestros negocios, es necesario implementar modelos. Existen varios tipos, todos desarrollados gracias al esfuerzo colectivo de expertos a lo largo del tiempo. El modelo nos ayudará a describir *cómo* se realiza el análisis predictivo. Más adelante veremos las técnicas, que corresponden a las *acciones* necesarias para llevarlo a cabo.

Comprender estos modelos es fundamental para seleccionar e implementar correctamente las tareas de análisis predictivo dentro de la organización y para asegurar que las predicciones obtenidas sean confiables y útiles en la toma de decisiones estratégicas.

Normalmente, es el especialista en *data science* quien diseña estos modelos. Para hacerlo, define un conjunto de datos de entrada sobre el cual se desarrollará el análisis, y los resultados variarán en función del objetivo planteado.

Antes de pasar a revisar los modelos más utilizados en el mercado, debemos preguntarnos: ¿sabemos cuáles son los elementos que necesitamos combinar para crearlos? La creación de modelos predictivos requiere la participación de varios componentes clave:

- Datos históricos relevantes para el objetivo del análisis.
- Procesamiento de los datos: limpieza y preparación para su análisis.
- Creación de nuevas variables que ayuden al modelo a interpretar mejor los datos.
- Elección del algoritmo de *machine learning* más adecuado para la tarea.
- Selección de los datos que se utilizarán para entrenar el modelo.
- Criterios y selección de métricas que permitan evaluar el rendimiento del modelo.
- Experiencia en el campo específico para orientar adecuadamente el desarrollo del modelo.

Bien, ahora que sabemos qué elementos intervienen en la creación de un modelo, vamos a ver en detalle cuáles son los más utilizados en el mercado.

Modelo	Descripción
Clasificación	<p>Estos modelos se basan en clasificaciones generadas a partir del aprendizaje extraído de datos históricos, y ofrecen respuestas generalmente binarias (sí/no) a las preguntas planteadas.</p> <p>Ejemplo: imaginemos que queremos identificar usuarios propensos a hacer <i>churn</i> (abandonar) en un producto de suscripción. Con este tipo de modelo obtendremos una clasificación que nos indica si un usuario es susceptible o no de irse. Gracias a estas clasificaciones, podemos dirigir de forma eficiente mensajes personalizados para evitar que el usuario abandone la marca antes de que eso ocurra.</p>
Regresión	<p>Se trata de uno de los modelos más utilizados. Sirve para modelar la relación entre una variable dependiente (lo que queremos predecir) y una o más variables independientes (los factores que influyen en la predicción). En este caso, el modelo aprende de los datos históricos para realizar estimaciones, generalmente utilizando valores numéricos.</p> <p>Existen tres tipologías principales de análisis de regresión:</p> <ul style="list-style-type: none"> <p>● Regresión lineal: desarrollado en el siglo XIX por Carl Friedrich Gauss y Adrien-Marie Legendre —quienes introdujeron el método de mínimos cuadrados—, es el modelo más básico y ampliamente utilizado para predecir valores continuos.</p> <p>Ejemplo: predecir el precio de una entrada a un estadio en función de la ubicación del asiento y el tipo de rival.</p> <p>● Regresión múltiple: una extensión de la regresión lineal en la que se incorporan múltiples variables independientes. Cuantas más variables se consideren, mayor será la complejidad del modelo.</p> <p>Ejemplo: además de la ubicación del asiento y el tipo de rival, se añaden variables como el aforo, el tiempo</p>

	<p>atmosférico o el día de la semana.</p> <ul style="list-style-type: none"> ● Regresión logística: introducida por David Cox en 1958 como modelo probabilístico para clasificación binaria. Se utiliza cuando la variable dependiente es categórica, es decir, cuando queremos clasificar en categorías como sí/no. Ejemplo: predecir si un cliente comprará un producto o no, en función de sus características. ● Regresión polinómica: derivada del trabajo de Gauss y Legendre sobre mínimos cuadrados, es una variante de la regresión lineal que permite modelar relaciones no lineales, incluyendo términos elevados a una potencia. Ejemplo: predecir el rendimiento de un vehículo de Fórmula 1 en función de su velocidad.
Agrupación	<p>Estos modelos son especialmente útiles porque permiten identificar características y comportamientos comunes entre determinados grupos de clientes o prospectos, para luego reconocer y segmentar nuevos usuarios que comparten esos mismos rasgos. Esto nos da la posibilidad de diseñar campañas, mensajes y contenidos de marketing mucho más enfocados y personalizados.</p> <p>Ejemplo: imaginemos que gestionamos un <i>e-commerce</i> de calzado deportivo. Con un modelo de agrupación podríamos segmentar a los clientes en grupos con características similares — como tipo de calzado comprado, frecuencia de compra o rango de edad— y diseñar estrategias de marketing más eficientes para cada segmento, a mayor escala.</p>
Previsión	<p>Este tipo de modelo se enfoca en la predicción de un valor, estimando el resultado numérico de nuevos datos a partir del aprendizaje obtenido de datos históricos.</p> <p>Ejemplo: gestionamos un <i>e-commerce</i> deportivo y queremos estimar el volumen de trabajo de nuestro servicio de <i>customer support</i> en función de la cantidad de llamadas que recibiremos en</p>

	determinados periodos de tiempo.
Valores atípicos	<p>Este modelo permite identificar valores anómalos tanto de forma individual como en relación con otros del mismo grupo, y categorizarlos en consecuencia. Está orientado a la detección de datos atípicos, ya sea porque son inusuales por sí mismos o porque difieren significativamente respecto al comportamiento general del conjunto.</p> <p>Es especialmente útil en el análisis predictivo aplicado al sector minorista y al ámbito financiero.</p> <p>Ejemplo: resulta muy eficaz para detectar fraudes o fallos en productos.</p>
Series temporales	<p>Este modelo utiliza los datos del último año para desarrollar una métrica numérica y predecir las próximas tres a seis semanas a partir de esa métrica. El análisis de series temporales permite comprender la evolución de una métrica a lo largo del tiempo con un nivel de precisión superior al que ofrecen los promedios simples. Además, tiene en cuenta factores estacionales o eventos que puedan influir en dicha métrica.</p> <p>Ejemplo: imaginemos que gestionamos un club deportivo. El análisis de series temporales podría resultar útil para el equipo de venta de entradas, ya que permitiría prever la asistencia al estadio en los días de partido y, en función de esa previsión, optimizar los precios de cada zona.</p>

Fuente: elaboración propia.

Ahora bien, ¿cómo determinar qué modelo de análisis predictivo se adapta mejor a nuestras necesidades? Para ello, debemos comenzar por identificar qué preguntas predictivas queremos responder y, sobre todo, qué haremos con esa información una vez la tengamos.

Técnicas de análisis predictivo

Para poder aplicar estos modelos, existen diferentes técnicas basadas en algoritmos de análisis, que no dejan de ser métodos informáticos utilizados para analizar datos históricos y hacer predicciones sobre acontecimientos futuros.

Estos algoritmos, como la regresión lineal, los árboles de decisión y las redes neuronales, identifican patrones y relaciones en los datos para predecir resultados, lo que permite tomar decisiones y planificar estrategias con conocimiento de causa.

Estas técnicas de análisis predictivo intentan lograr el menor error posible, y lo hacen, o bien utilizando lo que llamamos *boosting* (una técnica que ajusta el peso de una observación en función de la última clasificación), o bien con el *bagging* (que crea subconjuntos de datos a partir de muestras de entrenamiento elegidas aleatoriamente con reemplazo).

Generalmente, los algoritmos de análisis predictivo pueden dividirse en dos grupos:

- **Aprendizaje automático.** Implica datos estructurales que vemos en una tabla. Para ello existen algoritmos lineales y no lineales. Los algoritmos lineales se entrenan más rápidamente, mientras que los no lineales están mejor optimizados para los problemas a los que probablemente se enfrenten (que suelen ser no lineales).
- **Aprendizaje profundo:** es un subconjunto del aprendizaje automático más popular para tratar audio, vídeo, texto e imágenes.

Tabla 2. Técnicas de análisis predictivo

Técnica	Descripción
Árbol de decisión	Los árboles de decisión son modelos predictivos que representan una serie de reglas en forma de estructura arbórea. Cada nodo interno del árbol plantea una pregunta sobre los datos, cada rama representa una respuesta posible, y cada hoja (nodo final) contiene una predicción. Son modelos muy utilizados por su interpretabilidad, rapidez de entrenamiento y capacidad para manejar datos tanto numéricos como categóricos.

	<p>Ejemplo: supongamos que queremos predecir si una persona adquirirá un plan de suscripción a una OTT.</p> <p>¿La persona gana más de \$ 50 000?</p> <ul style="list-style-type: none"> ● Sí → ¿Tiene menos de 30 años? ● No → probabilidad de compra alta ● Sí → probabilidad de compra media ● No → probabilidad de compra baja <p>Este proceso se representa en forma de árbol, donde cada pregunta divide los datos en partes más manejables.</p>
Bosque aleatorio	<p>Se aplica tanto en modelos de clasificación como de regresión. Esta técnica combina múltiples árboles de decisión, cada uno construido sobre diferentes subconjuntos de datos.</p> <p>Es especialmente eficaz en grandes bases de datos, resistente al sobreajuste y capaz de manejar miles de variables de entrada sin necesidad de supresión. Además, permite identificar la importancia relativa de cada variable y mantiene su precisión incluso con una proporción significativa de datos faltantes.</p>
Redes neuronales	<p>Esta técnica imita el funcionamiento del cerebro humano para identificar patrones y hacer predicciones en relaciones de variables complejas. Es especialmente útil en contextos donde las interacciones entre variables no son lineales ni evidentes.</p>
<i>Data mining</i>	<p>Conocida también como minería de datos, se refiere a la explotación de grandes bases de datos para descubrir patrones ocultos. Los resultados obtenidos mediante <i>data mining</i> no pueden extraerse mediante <i>queries</i> convencionales, ya sea por el volumen de datos o por la complejidad de las relaciones entre ellos.</p>

Fuente: elaboración propia.

Tema 2. Ciclo de vida de un proyecto de analítica predictiva

Las técnicas que podemos aplicar dependerán del objetivo que persigamos; por eso, es el momento de revisar cuál es el ciclo de vida —o las etapas— que deberemos afrontar en el desarrollo de un proyecto de analítica predictiva. Podemos resumirlo en los siguientes siete puntos.

1. **Definición del proyecto:** lo primero que debemos hacer es determinar los objetivos que queremos alcanzar y definir las fuentes de datos que nos ayudarán en esta tarea. Por ejemplo, si buscamos vender más entradas para un estadio de fútbol, deberemos plantearnos una serie de preguntas clave: ¿desde cuándo se han estancado las ventas?, ¿quiénes son nuestros principales compradores?, ¿qué factores intervienen en la caída o estancamiento?
2. **Recopilación de datos:** el siguiente paso será identificar las fuentes de información y recolectar los datos relevantes. Es probable que tengamos que recurrir a diversas fuentes para nutrir adecuadamente el proceso. Debemos considerar tanto datos provenientes de medios de comunicación u organismos oficiales como aquellos registrados por nuestros sistemas internos de ventas, registros web, centros de soporte al cliente, entre otros.
3. **Preparación de datos:** esta etapa implica la limpieza, transformación y selección de variables. Es fundamental contar con un sistema que nos ayude a depurar la información, conservando solo los datos realmente relevantes, a fin de evitar que conclusiones erróneas contaminen el análisis. El conocimiento del negocio será clave por parte de quienes realicen esta tarea. Además, existen herramientas especializadas que permiten optimizar estos procesos.
4. **Análisis exploratorio/estadístico:** una vez que tenemos los datos listos, es momento de trabajar en la visualización, con el fin de comprender patrones y tendencias. La herramienta que utilicemos para esta tarea nos ayudará a identificar comportamientos y relaciones dentro de los datos.
5. **Modelado predictivo:** ahora sí, llega el momento de seleccionar qué modelos predictivos aplicaremos para cumplir con los objetivos definidos. Tal como mencionamos anteriormente, según el objetivo establecido, elegiremos el modelo que mejor se ajuste a nuestras necesidades.

6. **Validación:** es fundamental hacer un seguimiento y supervisión del modelo (o modelos) para asegurar su fiabilidad. La evaluación del desempeño se realiza mediante métricas como precisión, *recall* y área bajo la curva ROC (AUC).
7. **Despliegue:** finalmente, una vez validado que el modelo funciona correctamente y no presenta errores, se procede a su implementación en un entorno productivo.

Algunas herramientas

En el análisis predictivo se utilizan diversas herramientas y plataformas para recopilar, limpiar, modelar y visualizar datos. Estas herramientas pueden clasificarse según su propósito y nivel de complejidad. Los dos lenguajes más comunes que se emplean son los siguientes:

- **Python:** es uno de los lenguajes más utilizados en *machine learning* y análisis predictivo, gracias a su simplicidad y a una comunidad muy activa. Algunas de las herramientas más utilizadas en este entorno incluyen: las siguientes:
 - Scikit-learn: modelos de regresión, clasificación y *clustering*.
 - Pandas: manipulación y análisis de datos.
 - NumPy: cálculo numérico y álgebra lineal.
 - Matplotlib y Seaborn: visualización de datos.
 - TensorFlow y PyTorch: modelos avanzados de *deep learning*.
- **R:** lenguaje más especializado en análisis estadístico y modelado de datos. Entre los recursos más habituales se encuentran los siguientes:
 - Caret: modelos de *machine learning*.
 - ggplot2: visualización avanzada de datos.
 - forecast: modelado de series temporales.

A continuación, presentamos algunas de las herramientas más empleadas en análisis predictivo, organizadas según su función principal:

Tabla 3. Herramientas más comunes para el análisis predictivo

Tipología	Herramienta	Descripción
<p>Plataformas y herramientas de machine learning</p> <p>Son entornos que facilitan la construcción, el entrenamiento y el despliegue de modelos de <i>machine learning</i> sin necesidad de escribir grandes volúmenes de código.</p>	Google AutoML (Google Cloud)	<ul style="list-style-type: none"> • Automatiza la selección y ajuste de modelos. • Útil para visión por computadora y procesamiento de texto.
	Azure Machine Learning (Microsoft)	<ul style="list-style-type: none"> • Plataforma de desarrollo y despliegue de modelos en la nube. • Integración con Power BI para visualización.
	Amazon SageMaker	<ul style="list-style-type: none"> • Permite entrenar y desplegar modelos de Machine Learning en AWS. • Compatible con TensorFlow, PyTorch y Scikit-learn.
	IBM Watson Studio	<ul style="list-style-type: none"> • Análisis predictivo con inteligencia artificial. • Aplica el procesamiento de lenguaje natural y diagnóstico médico.
<p>Herramientas de análisis de datos y BI (business intelligence)</p> <p>Se centran en la visualización de datos y</p>	Power BI (Microsoft)	<ul style="list-style-type: none"> • Permite crear <i>dashboards</i> interactivos con modelos predictivos. • Integración con Azure Machine Learning.

<p>en la extracción de <i>insights</i> relevantes para apoyar la toma de decisiones.</p>	Tableau	<ul style="list-style-type: none"> • Visualización de datos con capacidades predictivas básicas. • Uso de regresión y <i>clustering</i> para detectar patrones.
	Google Data Studio	<ul style="list-style-type: none"> • Plataforma gratuita para reportes interactivos. • Conexión con Google Analytics y BigQuery para análisis de datos.
<p>Herramientas para <i>big data</i> y almacenamiento</p> <p>Se utilizan cuando se trabaja con grandes volúmenes de datos que requieren procesamiento y gestión eficientes.</p>	Apache Spark	<ul style="list-style-type: none"> • Procesamiento distribuido de datos en tiempo real. • Integración con Python (PySpark) y R (SparkR).
	Hadoop	<ul style="list-style-type: none"> • Almacena y procesa grandes volúmenes de datos de manera eficiente. • Usado en aplicaciones de análisis predictivo en la industria financiera.
	Google BigQuery	<ul style="list-style-type: none"> • Base de datos analítica para consultas rápidas sobre grandes conjuntos de datos. • Ideal para modelos de predicción basados en SQL.
Herramientas específicas para modelado predictivo	RapidMiner	<ul style="list-style-type: none"> • Plataforma de análisis sin necesidad de programación. • Modelos de regresión, clasificación y <i>clustering</i>.

	KNIME	<ul style="list-style-type: none"> • Entorno gráfico para análisis de datos y <i>machine learning</i>. • Compatible con Python, R y SQL.
	DataRobot	<ul style="list-style-type: none"> • Plataforma AutoML para automatizar el análisis predictivo. • Aplicado en el sector financiero y de salud.

Fuente: elaboración propia.

La elección de la herramienta adecuada dependerá del nivel de experiencia del usuario, del volumen de datos y de la complejidad del problema. Por eso, te recomendamos:

- Para principiantes se recomienda *Power BI*, *RapidMiner* o *Google AutoML*.
- Para quienes trabajan con grandes volúmenes de datos, lo más conveniente es usar *Apache Spark* o *BigQuery*.
- Por último, para maximizar la personalización se sugiere *Python* o *R* en combinación con herramientas como *Scikit-learn* y *TensorFlow*.

Unidad 2. Fundamentos de *machine learning*

Introducción

El *machine learning* (*ML*) es una herramienta que ha revolucionado diversas industrias. Comprender sus fundamentos, tipos y componentes clave permite desarrollar soluciones innovadoras basadas en datos.

¿Pero qué es *ML*? Es una rama de la inteligencia artificial (*IA*) que permite a los sistemas aprender patrones a partir de los datos y realizar predicciones o tomar decisiones sin necesidad de ser programados explícitamente. Se basa en algoritmos que mejoran su rendimiento con la experiencia, lo que lo convierte en una herramienta eficaz para resolver problemas en sectores como la salud, las finanzas, el *e-commerce*, la tecnología y, por supuesto, el deporte.

El crecimiento del *ML* se debe al aumento del volumen de datos disponibles, a la mejora en las capacidades computacionales y a los avances en los algoritmos. Esta disciplina ha evolucionado desde técnicas estadísticas hasta modelos avanzados de redes neuronales capaces de abordar problemas complejos.

Tema 1. Descubriendo el *machine learning*

La idea central del *machine learning* es que existe una relación matemática entre cualquier combinación de datos de entrada y salida. El modelo de *machine learning* no conoce esta relación de antemano, pero puede inferirla si se le proporcionan suficientes conjuntos de datos. En esencia, se trata de permitir que los algoritmos descubran patrones recurrentes en esos datos.

Aunque se trata de conceptos básicos, el *machine learning* parte del principio de que los sistemas computacionales pueden establecer relaciones matemáticas entre puntos de datos complejos, siempre que cuenten con una cantidad suficiente de información y potencia de procesamiento. Por lo tanto, la precisión de los resultados estará directamente relacionada con la cantidad y calidad de los datos proporcionados.

¿Pero por qué es importante el *ML* para una empresa? Básicamente, podríamos resumirlo en los siguientes puntos:

1. Automatización de tareas repetitivas y laboriosas: el aprendizaje automático libera tiempo y recursos, permitiendo que los esfuerzos se orienten a actividades de mayor valor añadido, lo que mejora la eficiencia en los procesos productivos.
2. Reducción de errores humanos.
3. Generación de *insights* basados en los datos recopilados: permite ofrecer recomendaciones, pronósticos o escenarios construidos a partir de modelos y análisis profundos.
4. Optimización de las estrategias de marketing o ventas.
5. Personalización de las interacciones con el usuario según sus hábitos individuales, con el objetivo de mejorar el compromiso, la satisfacción y la lealtad del cliente.
6. Detección de fraudes.

7. Optimización de los procesos operativos: identifica ineficiencias, cuellos de botella y oportunidades de mejora.

Ahora bien, la aplicación del *machine learning* implica una serie de requerimientos que las empresas deben tener en cuenta al integrarlo en sus estrategias de negocio:

- **Datos de alta calidad:** como mencionamos en el primer tema, el *machine learning* requiere conjuntos de datos grandes, completos y de alta calidad para ofrecer resultados precisos y fiables. Esto supone, en muchos casos, un esfuerzo considerable en la recolección, limpieza y preparación de los datos. Los datos no pueden estar sesgados, incompletos ni ser poco representativos; de lo contrario, los resultados podrían distorsionarse y conducir a conclusiones erróneas. Un punto clave en este aspecto es la privacidad y la seguridad que implica trabajar con grandes volúmenes de datos. El tratamiento de información sensible requiere medidas de seguridad adicionales, como protocolos de protección, métodos de anonimización y cumplimiento de normativas de protección de datos, como el *RGPD*, lo que implica mayores recursos.
- **Sobreaprendizaje/Subaprendizaje:** hablamos de sobreaprendizaje cuando un modelo es excesivamente complejo y se ajusta demasiado a los datos, perdiendo capacidad de generalización. Por el contrario, el subaprendizaje ocurre cuando el modelo es demasiado simple y no logra capturar las relaciones entre las variables. Para evitar estos escenarios, es necesario aplicar técnicas como la validación cruzada, la regularización y el ajuste de parámetros.
- **Validación cruzada:** consiste en dividir el conjunto de datos en partes o *folds*. En cada iteración, uno de ellos se usa como conjunto de prueba, y los restantes, para entrenar el modelo. El proceso se repite varias veces y se promedian los resultados para obtener una estimación más confiable del rendimiento.
 - **Regularización:** técnica que incorpora una penalización en la función de pérdida del modelo para evitar que los coeficientes de los parámetros crezcan desproporcionadamente.
 - **Ajuste de parámetros:** se refiere a la búsqueda de los valores óptimos para los hiperparámetros del modelo (aquellos que no se modifican durante el entrenamiento, como la tasa de aprendizaje o el número de capas en una red neuronal).

- **Interpretación del dato:** la toma de decisiones requiere conclusiones claras. Por eso, es un problema cuando los resultados que ofrece el *machine learning* son ambiguos o difíciles de interpretar.
- **Buena selección de variables y atributos:** la elección adecuada de variables es esencial para construir un modelo de alta calidad. Esto permite reducir la dimensionalidad, eliminar redundancias y favorecer la interpretación de los datos.

Tipologías de *machine learning*

El *machine learning* se clasifica en tres categorías principales, según la forma en que los algoritmos aprenden a partir de los datos.

Tabla 4. Categorías del *machine learning*

Categoría	Descripción
Aprendizaje supervisado	<p>Este tipo de aprendizaje se basa en datos etiquetados*, donde el algoritmo recibe entradas y sus salidas correspondientes para aprender una función de mapeo. Se utiliza en tareas como clasificación y regresión.</p> <p>Este enfoque requiere menos datos de entrenamiento que otros y facilita el proceso, ya que los resultados del modelo pueden compararse con los datos ya etiquetados. Sin embargo, el proceso de etiquetar los datos puede resultar costoso.</p> <p>Ejemplo: predicción del precio de una entrada de fútbol en función de su ubicación y del rival.</p> <p>Modelos comunes: regresión lineal, árboles de decisión, <i>random forest</i>, <i>support vector machines (SVM)</i> y redes neuronales.</p> <p>*Etiquetar un dato equivale a categorizarlo con su correspondiente valor de salida.</p>
Aprendizaje no supervisado	<p>En este caso, el modelo aprende patrones sin recibir etiquetas de salida. Se utiliza para descubrir estructuras ocultas en los datos, como agrupamientos o relaciones. Procesa grandes volúmenes de datos y aplica algoritmos para extraer las características</p>

	<p>relevantes necesarias para etiquetar, ordenar y clasificar en tiempo real, sin intervención humana.</p> <p>En lugar de automatizar decisiones y predicciones, este enfoque permite identificar patrones y relaciones que podrían pasar desapercibidos para los humanos. Aunque no es la técnica más sencilla de aplicar, está ganando popularidad, especialmente en el ámbito de la ciberseguridad.</p> <p>Ejemplo: segmentación de clientes en un <i>e-commerce</i> según su comportamiento de compra.</p> <p>Modelos comunes: <i>K-Means</i>, <i>DBSCAN</i>, algoritmos de <i>clustering</i> jerárquico y <i>autoencoders</i>.</p>
Aprendizaje por refuerzo	<p>Este enfoque se basa en agentes que interactúan con un entorno y aprenden a través de recompensas o penalizaciones. Consiste en permitir que un algoritmo «aprenda» de sus errores para alcanzar un objetivo. El modelo prueba múltiples estrategias y ajusta su comportamiento en función de los resultados obtenidos.</p> <p>Es ampliamente utilizado en campos como la robótica y los videojuegos.</p> <p>Ejemplo: un programa que aprende a jugar al ajedrez optimizando sus movimientos.</p> <p>Modelos comunes: Q-Learning, Deep Q Networks (DQN) y algoritmos de aprendizaje profundo aplicados al refuerzo.</p>

Fuente: elaboración propia.

***Machine learning*: ¿enfoque determinista o probabilístico?**

La mayoría de las aplicaciones de software responden de forma predecible a la acción del usuario, por lo que se puede afirmar: «si el usuario hace esto, obtiene aquello». Sin embargo, los algoritmos de *machine learning* aprenden mediante la observación y la experiencia. Por lo tanto, su naturaleza es probabilística.

En el *machine learning*, el determinismo es una estrategia que puede aplicarse a los métodos de aprendizaje mencionados anteriormente. Cualquiera de los enfoques

supervisados, no supervisados u otros, puede adaptarse de forma determinista, en función de los resultados que la empresa desee obtener.

El enfoque determinista se centra en la precisión y la cantidad de datos recopilados, priorizando la eficiencia por encima de la incertidumbre.

Por su parte, el proceso no determinista (o probabilístico) está diseñado para gestionar el factor azar. Los algoritmos de *machine learning* incorporan herramientas que permiten cuantificar, identificar y medir la incertidumbre durante el proceso de aprendizaje y observación.

Tema 2. Aplicaciones avanzadas y desafíos del *machine learning*

Modelos avanzados en *machine learning*

El *machine learning* ha evolucionado significativamente en los últimos años, dando lugar a modelos avanzados capaces de abordar problemas cada vez más complejos. Estos modelos han mejorado en precisión, eficiencia y capacidad de generalización, lo que los convierte en herramientas ideales para aplicaciones en inteligencia artificial, análisis predictivo y automatización de decisiones.

Para su implementación adecuada, es necesario encontrar un equilibrio entre la capacidad computacional, la cantidad de datos disponibles y la complejidad del problema. A medida que la tecnología avanza, estos modelos continúan evolucionando, abriendo nuevas posibilidades en el ámbito de la inteligencia artificial y la automatización de procesos.

El *deep learning*

Llegados a este punto, no podemos dejar de hablar de lo que denominamos *deep learning* (aprendizaje profundo), una subcategoría —o versión más avanzada— del *machine learning*. Inventado en 1986 por Geoffrey Hinton, utiliza una técnica que le otorga mayor capacidad para detectar patrones, incluso los más sutiles.

El *deep learning* se inspira en la estructura del cerebro humano y es capaz de aprender representaciones a partir de datos sin necesidad de una programación explícita.

Las redes neuronales profundas (*deep neural networks*) permiten que los modelos extraigan automáticamente características de los datos, lo que las hace especialmente útiles en tareas complejas como el reconocimiento de imágenes, el procesamiento del lenguaje natural y la toma de decisiones en entornos dinámicos.

Podemos resumir sus características principales en cuatro puntos:

- **Uso de redes neuronales profundas:** compuestas por múltiples capas ocultas que permiten extraer características abstractas.
- **Entrenamiento con grandes volúmenes de datos:** requiere grandes cantidades de información para alcanzar altos niveles de precisión.
- **Necesidad de alta capacidad computacional:** se apoya en unidades de procesamiento gráfico (*GPU*) o de procesamiento tensorial (*TPU*) para acelerar los cálculos.
- **Menor necesidad de preprocesamiento manual:** a diferencia del *machine learning* tradicional, el *deep learning* puede aprender directamente de los datos, sin requerir una ingeniería de características extensa.

Diferencias entre *deep learning* y *machine learning*

Bien, acabamos de ver qué es el deep learning, pero ¿cuáles son, concretamente, las diferencias que lo distinguen del machine learning? A continuación, veamos las principales:

Tabla 5. Diferencias entre *deep learning* y *machine learning*

Característica	<i>Machine learning</i>	<i>Deep learning</i>
Definición	Algoritmos que aprenden patrones a partir de los datos para hacer predicciones.	Usa redes neuronales profundas para extraer características automáticamente de los datos.
Procesamiento	Requiere de ingeniería de características manual (selección y extracción de variables relevantes).	Extrae automáticamente las características relevantes sin intervención humana.
Cantidad de datos	Puede funcionar con conjuntos de datos más pequeños.	Requiere grandes volúmenes de datos para un entrenamiento efectivo.
Algoritmos comunes	Regresión, árboles de decisión, SVM, k-NN.	Redes neuronales convolucionales (CNN), redes neuronales recurrentes (RNN),

		<i>transformers.</i>
Tiempo de entretenimiento	Más rápido debido a su menor complejidad.	Puede tardar horas o días debido a la cantidad de cálculos necesarios.
Uso de <i>hardware</i>	Puede ejecutarse en CPU sin problemas.	Requiere GPUs o TPUs para manejar grandes volúmenes de datos y cálculos.

Fuente: elaboración propia.

Pongamos un ejemplo práctico. Imaginemos que queremos desarrollar un sistema de reconocimiento de imágenes para identificar si una foto contiene el logo del patrocinador A o del patrocinador B.

Con *machine learning*:

- Extraemos manualmente características de las imágenes (forma del logo, tamaño, elementos, colores).
- Utilizamos un modelo como *SVM* o *random forest* para clasificar la imagen como «patrocinador A» o «patrocinador B».

Con *deep learning*:

- Usamos una red neuronal convolucional (CNN), que analiza automáticamente la imagen y detecta patrones visuales.
- La red aprende por sí sola qué características (textura, elementos, formas) son relevantes para distinguir entre el logo del patrocinador A y el del patrocinador B.

Las redes neuronales artificiales (ANN)

Tal como su nombre indica, las redes neuronales artificiales son un método de cálculo que busca imitar la estructura del cerebro humano mediante la interconexión de nodos o «neuronas» artificiales. Constituyen la base del deep learning y permiten resolver problemas de clasificación, regresión y reconocimiento de patrones.

Las redes neuronales en inteligencia artificial no hacen más que trasladar el funcionamiento biológico al ámbito matemático. Así como nuestro cerebro identifica patrones en los sabores al comer un alimento, un ordenador procesa datos concretos y, mediante un proceso de «entrenamiento», descubre los patrones más adecuados para analizarlos.

Las redes neuronales están compuestas por diferentes capas:

- **Capa de entrada:** recibe los datos en su forma original y los transmite a las capas ocultas.
- **Capas ocultas:** son responsables de transformar la información mediante funciones de activación y conexiones ponderadas.
- **Capa de salida:** genera la predicción o clasificación en función de los cálculos realizados por las capas anteriores.

Ahora bien, ¿cómo funcionan las redes neuronales? Como comentamos anteriormente, su estructura busca emular el funcionamiento del cerebro humano. Una red neuronal está compuesta por neuronas —también llamadas perceptrones—, cada una de las cuales recibe un conjunto específico de valores o datos de entrada.

Al recibir los datos de entrada, los perceptrones los transforman según la influencia que estos tendrán en la conclusión que se desea obtener. Luego, los valores se transmiten a las siguientes neuronas de la red, modificándose progresivamente hasta alcanzar una salida final o conclusión concreta.

Un ejemplo gráfico de este funcionamiento podría encontrarse en la sección de vídeos recomendados de una plataforma *OTT* de suscripción. La plataforma recopila una gran cantidad de datos de los cuales puede aprender: el tiempo que permanecemos viendo un vídeo, los vídeos que seleccionamos, los que añadimos a nuestra lista de reproducción, aquellos que marcamos con «Me gusta», entre otros. A partir de esos parámetros, la misión del sistema es aprender nuestros gustos.

Podemos resumir en cuatro puntos los usos más recurrentes de las redes neuronales:

- **Visión artificial:** es la capacidad de los sistemas computacionales para extraer información y conocimiento de imágenes y vídeos. Gracias a las redes neuronales, estos sistemas pueden distinguir y reconocer imágenes de forma similar a los humanos. Se aplica, por ejemplo, en la moderación de contenido, el reconocimiento facial o el etiquetado automático para identificar logotipos u otros elementos visuales.

- **Reconocimiento de voz:** las redes neuronales pueden analizar el habla humana. Asistentes virtuales como Alexa utilizan esta tecnología para asistir a agentes de centros de llamadas, transcribir conversaciones o subtítular con precisión vídeos y grabaciones.
- **Procesamiento del lenguaje natural (PLN):** es la capacidad de comprender y procesar texto creado por humanos. Está presente en *chatbots*, agentes virtuales, sistemas de clasificación automática de documentos, resúmenes automáticos o generación de contenido textual.
- **Motores de recomendaciones:** al seguir el comportamiento del usuario, las redes neuronales pueden elaborar recomendaciones personalizadas. Analizando los patrones de navegación y preferencias, predicen qué productos o servicios podrían interesar a cada usuario.

Tipos de redes neuronales

Las redes neuronales pueden clasificarse según la forma en que los datos fluyen desde el nodo de entrada hasta el nodo de salida. Podemos resumirlas en tres tipologías principales:

Tabla 6. Tipos de redes neuronales

Tipología	Descripción
Prealimentadas	Se caracterizan por procesar los datos en una única dirección: del nodo de entrada al de salida. Todos los nodos de una capa están conectados con los nodos de la capa siguiente. Utilizan un proceso de retroalimentación para mejorar las predicciones con el tiempo.
Algoritmo de retropropagación	Aprenden de forma continua mediante bucles de retroalimentación correctivos que permiten mejorar su análisis predictivo. Los datos fluyen desde el nodo de entrada hasta el de salida a través de múltiples caminos dentro de la red neuronal.
Convolucionales	En esta tipología, las capas ocultas realizan funciones matemáticas específicas denominadas convoluciones. Esta operación se lleva a cabo entre dos funciones: una entrada

	<p>(por ejemplo, una imagen) y un filtro o <i>kernel</i>. El objetivo es extraer características relevantes —como bordes, texturas o patrones— de la entrada.</p> <p>Son especialmente útiles para la clasificación de imágenes, ya que permiten identificar y extraer automáticamente las características necesarias para su reconocimiento y posterior clasificación.</p>
--	---

Fuente: elaboración propia.

Diferencias entre las redes neuronales y el *machine learning*

Como hemos visto, el *machine learning* y las redes neuronales artificiales están estrechamente relacionados, pero no son lo mismo. Las redes neuronales son un subconjunto del *machine learning*, aunque existen diferencias clave entre ambos enfoques.

Tabla 7. Diferencias entre las redes neuronales y el *machine learning*

Característica	<i>Machine learning</i>	Redes neuronales
Definición	Es un campo más amplio que abarca múltiples algoritmos de aprendizaje automático.	Es una técnica específica dentro del <i>machine learning</i> , basada en la simulación de redes de neuronas artificiales.
Tipos de modelos	Regresión, árboles de decisión, SVM, KNN, <i>Naïve Bayes</i> , etc.	Perceptrón, MLP, CNN, RNN, LSTM, GAN, etc.
Procesamiento de datos	Depende en gran medida de la ingeniería de características.	Extrae automáticamente las características de los datos, especialmente en <i>deep learning</i> .

Cantidad de datos	Funciona bien con conjuntos de datos pequeños o medianos.	Generalmente, necesita grandes volúmenes de datos para obtener buenos resultados.
Interpretabilidad	Los modelos como árboles de decisión o regresión son interpretables.	Las redes neuronales profundas pueden funcionar como una «caja negra» difícil de interpretar.
Requerimientos computacionales	Puede ejecutarse en CPU, generalmente con menor demanda computacional.	Requiere hardware potente como GPU o TPU, especialmente en redes profundas.
Casos de uso	Análisis de datos estructurados, predicción de tendencias, clasificación básica.	Procesamiento de imágenes, reconocimiento de voz, procesamiento de lenguaje natural.

Fuente: elaboración propia.

Usaremos, pues, el *machine learning* tradicional cuando:

- tengamos datos estructurados y bien organizados (tablas de Excel, bases de datos relacionales);
- busquemos interpretabilidad y explicabilidad en los resultados;
- no dispongamos de grandes volúmenes de datos.

Y recurriremos a las redes neuronales cuando:

- trabajemos con datos no estructurados (imágenes, texto, audio, vídeo);
- necesitemos automatizar la extracción de características sin intervención humana.
- contemos con una gran cantidad de datos y recursos computacionales para el entrenamiento.

¿Qué es la reducción de dimensionalidad?

Por todo lo que acabamos de ver, queda claro que los algoritmos empleados en *machine learning* son capaces de extraer información relevante a partir de conjuntos de datos con múltiples características. Gracias al avance tecnológico, es posible ejecutar modelos de aprendizaje automático cada vez más grandes y con mayor potencia.

Ahora bien, cada característica que se agrega incrementa la complejidad del modelo, lo que a su vez dificulta la localización e interpretación de la información. Llegados a este punto, se vuelve necesario reducir la dimensión eliminando características innecesarias. A este proceso se lo denomina **reducción de la dimensionalidad**, y consiste en un conjunto de técnicas utilizadas en *machine learning* y análisis de datos para disminuir el número de variables en un conjunto de datos, preservando al mismo tiempo la mayor cantidad posible de información.

Su objetivo principal es mejorar la eficiencia computacional, reducir el sobreajuste y facilitar la visualización y el análisis de los datos.

Los datos de alta dimensión, el reconocimiento de voz, la visualización de datos, la reducción de ruido y el procesamiento de señales son algunos de los principales campos de aplicación de la reducción de dimensionalidad.

Pero ¿por qué es importante?

- **Evitamos la maldición de la dimensionalidad:** a medida que aumenta el número de características, los datos se vuelven más dispersos y el rendimiento de los modelos de *machine learning* puede degradarse.
- **Reducimos el tiempo de entrenamiento:** menos características implican una menor carga computacional.
- **Minimizamos el sobreajuste:** eliminar características irrelevantes o redundantes permite que el modelo generalice mejor.
- **Facilitamos la visualización:** los datos pueden representarse en 2D o 3D para su análisis gráfico.

Y es que muchas veces recopilamos datos que no son relevantes para responder las preguntas planteadas. La reducción de dimensionalidad puede parecer innecesaria, pero es clave: los modelos no comprenden la causalidad y tienden a asociar cualquier característica presente en el conjunto de datos con la variable objetivo, incluso cuando no existe una relación real. Esto puede llevar a generar modelos erróneos.

Reducir la cantidad de variables permite construir modelos más simples y eficientes.

Técnicas de reducción de dimensionalidad

Existen dos enfoques principales, como se muestra en la siguiente tabla.

Tabla 8. Técnicas de reducción de dimensionalidad

Tipo	Métodos
<p>Selección de características</p> <p>Estas técnicas eliminan variables irrelevantes o redundantes sin modificar las características restantes.</p>	<p>Métodos de filtro: evalúan cada variable de forma independiente y eliminan aquellas con menor relevancia.</p> <p>Ejemplos:</p> <ul style="list-style-type: none">● Correlación: elimina características con alta correlación entre sí.● Chi-cuadrado: mide la relación entre variables categóricas.● ANOVA (análisis de varianza): evalúa la varianza entre grupos.
	<p>Métodos de wrapper: entrenan modelos con diferentes subconjuntos de características y seleccionan las combinaciones que ofrecen el mejor rendimiento.</p> <p>Ejemplos:</p> <ul style="list-style-type: none">● RFE (recursive feature elimination): elimina características de forma recursiva evaluando su impacto en el modelo.● Forward selection y backward elimination: agregan o eliminan características en función del rendimiento del modelo.
	<p>Métodos basados en modelos: utilizan algoritmos que asignan un valor de importancia a cada característica y eliminan aquellas menos relevantes.</p> <p>Ejemplos:</p>

	<ul style="list-style-type: none"> • Lasso regression: penaliza los coeficientes de regresión para reducir o eliminar características irrelevantes. • Random forest feature importance: evalúa la importancia de las características a partir de su influencia en los árboles de decisión.
<p>Extracción de características</p> <p>Transforma las características originales en un nuevo espacio de menor dimensión.</p>	<p>Análisis de componentes principales (PCA)</p> <ul style="list-style-type: none"> • Reduce la dimensionalidad transformando las variables originales en componentes principales. • Identifica las direcciones de mayor variabilidad en los datos y proyecta esa información en un espacio de menor dimensión. • Se utiliza en campos como el análisis de imágenes, biología, procesamiento de señales, entre otros. <p>t-SNE (<i>t-distributed stochastic neighbor embedding</i>)</p> <ul style="list-style-type: none"> • Ideal para la visualización de datos en 2D o 3D. • Preserva las relaciones locales entre los puntos de datos, lo que facilita la identificación de agrupamientos. • Se utiliza principalmente en tareas de <i>clustering</i> y análisis exploratorio. <p>LDA (<i>linear discriminant analysis</i>)</p> <ul style="list-style-type: none"> • Similar al <i>PCA</i>, pero optimizado para problemas de clasificación. • Su objetivo es maximizar la separación entre clases, en lugar de centrarse únicamente en la varianza de los datos. <p>Autoencoders (redes neuronales)</p> <ul style="list-style-type: none"> • Son redes neuronales diseñadas para comprimir los datos en una representación más compacta. • Se utilizan en la reducción de dimensionalidad de imágenes, texto y señales.

Fuente: elaboración propia.

En resumen, contar con un exceso de características puede dar lugar a un modelo de *machine learning* ineficiente. No obstante, la capacidad de reducir variables mediante técnicas de reducción de dimensionalidad es una herramienta clave para desarrollar modelos más optimizados y eficientes.

Tendencias futuras en analítica predictiva y *machine learning*

La analítica predictiva y el *machine learning* han experimentado un crecimiento exponencial en los últimos años, impulsados por la mayor disponibilidad de datos, el avance en la capacidad de cómputo y el desarrollo de algoritmos más sofisticados. Estas disciplinas han transformado industrias como la salud, las finanzas, el marketing y la manufactura, permitiendo a las organizaciones tomar decisiones basadas en datos con un alto nivel de precisión. Además, su expansión se extiende a prácticamente todos los sectores. En el ámbito deportivo, sus aplicaciones van desde el rendimiento y la prevención de lesiones en atletas hasta la optimización del negocio en los estadios y la mejora de los patrocinios.

A medida que la tecnología avanza, surgen nuevas tendencias que están redefiniendo el futuro del análisis de datos y la inteligencia artificial. Estas innovaciones buscan hacer que los modelos predictivos sean más precisos, escalables y accesibles, al tiempo que abordan desafíos clave como la explicabilidad, la privacidad y la eficiencia computacional.

En este contexto, el *machine learning* se está volviendo más automatizado, explicable y descentralizado; mientras que las arquitecturas avanzadas —como los modelos generativos y multimodales— están ampliando el alcance de la inteligencia artificial en múltiples dominios. Además, la integración de estas tecnologías con dispositivos móviles, sensores y sistemas en el borde (*edge AI*) permite tomar decisiones en tiempo real sin depender exclusivamente de la nube.

Si queremos aplicar las últimas tendencias en analítica predictiva y *machine learning*, a continuación se presenta un listado de las innovaciones que marcarán la próxima era de la inteligencia artificial:

Tabla 9. Innovaciones que marcarán la próxima era de la inteligencia artificial

Métodos	Características
<i>Machine learning</i> automatizado (AutoML)	El AutoML (<i>automated machine learning</i>) busca automatizar el diseño, entrenamiento y

	<p>optimización de modelos de <i>machine learning</i> sin necesidad de intervención humana.</p> <p>Impacto:</p> <ul style="list-style-type: none"> ● Facilita la implementación de modelos sin requerir perfiles expertos en datos. ● Reduce el tiempo de desarrollo de modelos predictivos. ● Mejora la escalabilidad en aplicaciones empresariales. <p>Ejemplos:</p> <ul style="list-style-type: none"> ● Google AutoML ● H2O.ai ● TPOT (<i>tree-based pipeline optimization tool</i>)
<p>Inteligencia artificial explicable (XAI - <i>explainable AI</i>)</p>	<p>Se centra en hacer que los modelos de <i>machine learning</i> sean más interpretables y transparentes, especialmente en sectores críticos como la salud y las finanzas.</p> <p>Impacto:</p> <ul style="list-style-type: none"> ● Aumenta la confianza en los modelos predictivos. ● Facilita el cumplimiento de normativas como el <i>GDPR</i>. ● Permite detectar y corregir sesgos en los modelos. <p>Ejemplos de herramientas XAI:</p> <ul style="list-style-type: none"> ● <i>SHAP (SHapley Additive exPlanations)</i> ● <i>LIME (Local Interpretable Model-agnostic Explanations)</i>

	<ul style="list-style-type: none"> ● Modelos de redes neuronales interpretables
Modelos generativos (IA generativa)	<p>Modelos como las redes generativas antagónicas (<i>GANs</i>) y los <i>transformers</i> tienen la capacidad de generar contenido realista, como texto, imágenes y vídeos.</p> <p>Impacto:</p> <ul style="list-style-type: none"> ● Creación de imágenes y vídeos hiperrealistas. ● Generación de datos sintéticos para mejorar modelos predictivos. ● Aplicaciones en diseño, arte, entretenimiento, <i>gaming</i> y más. <p>Ejemplos:</p> <ul style="list-style-type: none"> ● <i>GPT (Generative Pre-trained Transformer)</i> para generación de texto. ● <i>DALL-E</i> y <i>Stable Diffusion</i> para creación de imágenes. ● Tecnología <i>deepfake</i> para edición de vídeo.
Aprendizaje federado (<i>federated learning</i>)	<p>Permite entrenar modelos de <i>machine learning</i> sin necesidad de compartir los datos en la nube, lo que contribuye a preservar la privacidad del usuario.</p> <p>Impacto:</p> <ul style="list-style-type: none"> ● Mejora la privacidad y seguridad de los datos. ● Facilita el desarrollo de modelos en dispositivos móviles y sistemas descentralizados.

	<ul style="list-style-type: none"> ● Reduce la dependencia de grandes centros de datos. <p>Ejemplo: Google utiliza aprendizaje federado en Android para mejorar el teclado <i>Gboard</i> sin necesidad de enviar los datos de los usuarios a sus servidores.</p>
Modelos multimodales	<p>Combinan distintos tipos de datos —como texto, imágenes, audio y vídeo— en un único modelo de <i>machine learning</i>.</p> <p>Impacto:</p> <ul style="list-style-type: none"> ● Mejor interpretación de datos complejos. ● Aplicaciones avanzadas en inteligencia artificial conversacional y asistentes virtuales. ● Mayor capacidad de comprensión por parte de los modelos de IA. <p>Ejemplos:</p> <ul style="list-style-type: none"> ● <i>GPT-4</i> y <i>Gemini</i> de Google, capaces de procesar simultáneamente texto e imágenes. ● Modelos de diagnóstico médico que integran imágenes de rayos X con historiales clínicos.
Edge AI y <i>machine learning</i> en dispositivos locales	<p>Lleva el <i>machine learning</i> a dispositivos locales — como teléfonos, sensores o cámaras— en lugar de depender exclusivamente de la nube.</p> <p>Impacto:</p> <ul style="list-style-type: none"> ● Reducción de la latencia en los modelos predictivos.

	<ul style="list-style-type: none"> ● Menor consumo de energía y reducción de costos en la nube. ● Mayor seguridad y privacidad de los datos. <p>Ejemplos:</p> <ul style="list-style-type: none"> ● Modelos de reconocimiento facial que funcionan en teléfonos sin necesidad de conexión a internet. ● IA en drones y robots autónomos para procesamiento de datos en tiempo real.
<p>Hiperpersonalización en modelos predictivos</p>	<p>La evolución de los modelos predictivos apunta hacia una hiperpersonalización, adaptándose a usuarios específicos en tiempo real.</p> <p>Impacto:</p> <ul style="list-style-type: none"> ● Experiencias personalizadas en sectores como el <i>e-commerce</i>, la salud y la educación. ● Mayor nivel de <i>engagement</i> en plataformas de <i>streaming</i> y redes sociales. ● Publicidad más eficiente basada en datos predictivos. <p>Ejemplos:</p> <ul style="list-style-type: none"> ● Netflix y Spotify optimizando sus recomendaciones según el comportamiento del usuario. ● Modelos de salud personalizados que sugieren tratamientos específicos para cada paciente.

Fuente: elaboración propia.

En resumen, la analítica predictiva y el *machine learning* son herramientas fundamentales para afrontar los desafíos actuales. Su aplicación responsable y ética tiene el potencial de transformar profundamente la manera en que operan las organizaciones, permitiendo tomar decisiones más informadas y efectivas en un entorno cada vez más digitalizado.

Conclusión

El análisis predictivo y el *machine learning* han revolucionado la forma en que las organizaciones deportivas toman decisiones estratégicas. Hemos pasado de un enfoque reactivo, basado en el análisis de datos históricos, a un modelo proactivo que permite anticipar comportamientos, mejorar la eficiencia operativa y personalizar la experiencia de los aficionados y usuarios.

En el contexto del negocio digital en el deporte, estas herramientas se convierten en activos clave para optimizar la retención de usuarios, maximizar el impacto de las estrategias de monetización y mejorar la experiencia del aficionado a través de recomendaciones personalizadas, optimización de precios de entradas, predicción de lesiones en atletas y una mejor gestión de recursos. Todo ello en un ecosistema donde la capacidad de interpretar y aplicar datos de forma ética y eficaz marca la diferencia entre el éxito y la irrelevancia.

Referencias bibliográficas para consulta

- Agarwal, A.** (2018). *Machine learning for beginners: An introduction to artificial intelligence*. Independently Published.
- Bishop, C. M.** (2006). *Pattern recognition and machine learning*. Springer.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep learning*. MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J.** (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2.^a ed.). Springer.
- LeCun, Y., Bengio, Y., & Hinton, G.** (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Mitchell, T.** (1997). *Machine learning*. McGraw-Hill.
- Murphy, K. P.** (2012). *Machine learning: A probabilistic perspective*. MIT Press.
- Ng, A.** (2018). *Machine learning yearning: Technical strategy for AI engineers, in the era of deep learning*. Self-published.

Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4.^a ed.). Pearson.

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>

Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge University Press.

Van der Aalst, W. (2016). *Process mining: Data science in action* (2.^a ed.). Springer.

Zhou, Z. H. (2021). *Machine learning*. Springer.