

1.3 Cómo aprender de los datos, Machine Learning

1.3 Cómo aprender de los datos

Machine Learning (ML): enseñar a las máquinas con ejemplos

En el capítulo anterior hemos visto que las máquinas no aprenden de una única manera. Distinguimos **aprendizaje supervisado, no supervisado, semisupervisado y por refuerzo**, categorías que, curiosamente, tienen un paralelismo muy claro con la educación humana. El **Machine Learning (ML)** no es algo distinto a esos tipos de aprendizaje, sino el **marco general** que los hace posibles en la práctica cuando trabajamos con datos reales.

Por tanto, cuando ahora hablamos de *cómo aprender de los datos*, no estamos empezando desde cero, sino **profundizando en cómo esos tipos de aprendizaje se implementan en sistemas reales**. El Machine Learning es el puente entre los datos y el comportamiento “inteligente” de la máquina, del mismo modo que la enseñanza es el puente entre la experiencia y el aprendizaje del alumnado.

Aprender no es entender: una comparación necesaria

Uno de los errores más habituales al hablar de Machine Learning es asumir que aprender equivale a comprender. No es así, ni en las máquinas ni, en muchos casos, en las personas.

Existe un ejemplo muy conocido en neurociencia que ayuda mucho a entender esta diferencia. Personas que han nacido ciegas y recuperan la visión en la edad adulta, gracias a avances médicos, **no son capaces de interpretar lo que ven**. Sus ojos funcionan, pero su cerebro nunca aprendió durante la infancia a reconocer formas, distancias, rostros o profundidad. Perciben luz, colores y movimiento, pero no significado. Necesitan un largo proceso de aprendizaje visual, y aun así su percepción nunca llega a ser equivalente a la de alguien que aprendió a ver desde pequeño.

Este caso humano es un paralelismo casi perfecto del Machine Learning.

Una máquina puede recibir imágenes, textos o sonidos perfectamente convertidos en datos numéricos, pero **si no ha sido entrenada con suficientes ejemplos, no “ve”, no “lee” y no “escucha” nada**. Igual que en las personas, es el aprendizaje previo el que da sentido a la

percepción. Sin datos y sin experiencia, solo hay estímulos sin significado.

¿Qué significa realmente aprender de los datos?

Aprender de los datos no consiste en almacenar información como en un archivo. Consiste en **extraer patrones**. Un sistema de Machine Learning analiza grandes volúmenes de ejemplos y ajusta sus parámetros internos para que ciertas respuestas sean más probables que otras en el futuro.

Desde el punto de vista de los tipos de aprendizaje vistos en el capítulo anterior, esto puede hacerse de varias maneras. En el aprendizaje supervisado, el sistema aprende comparando sus predicciones con respuestas correctas. En el no supervisado, descubre estructuras internas sin que nadie le diga qué buscar. En el aprendizaje por refuerzo, ajusta su comportamiento en función de las consecuencias de sus acciones. En todos los casos, el mecanismo es el mismo: **datos → números → patrones → decisiones**.

No hay comprensión conceptual, pero sí una capacidad muy potente de **generalización**, que es lo que hace útil al Machine Learning en contextos complejos como la educación.

El ciclo del Machine Learning explicado para docentes

Aunque por dentro los modelos puedan parecer opacos, el proceso del Machine Learning sigue un ciclo que resulta muy familiar para cualquier docente.

1. Todo comienza con la **recopilación de datos**. Se trata de **recoger ejemplos (los datos)**: igual que cuando enseñamos a un niño o niña qué es un triángulo mostrándole muchos dibujos, un sistema de *Machine Learning* necesita muchos ejemplos para aprender. En educación, estos ejemplos pueden ser datos como tiempos de respuesta, registros de asistencia, uso de plataformas digitales o resultados de actividades competenciales.

Desde el punto de vista educativo y legal, es recomendable utilizar conjuntos de datos sintéticos, anonimizados, **evitando el uso directo de producciones** reales del alumnado en **sistemas de terceros**

Recordemos que, según la normativa de protección de datos como el **RGPD y la LOPDGDD**, el profesorado debe evitar introducir datos personales identificables en herramientas externas de IA y utilizar, siempre que sea posible, **datos anonimizados** o ejemplos ficticios. Es importante asegurarse también de que los datos utilizados respetan la privacidad del alumnado y se emplean únicamente con fines educativos legítimos

2. **Preparar los ejemplos:** Las máquinas necesitan que los datos estén organizados y en un formato que puedan analizar: antes de poder aprender, esos datos deben limpiarse, organizarse y transformarse en números, ya que la máquina no trabaja con significados, sino con valores numéricos. Es parecido a cuando un docente revisa ejercicios y los clasifica: correctos, incorrectos, incompletos...


3. **Aprender a partir de los ejemplos.** A continuación tiene lugar el **entrenamiento**. El sistema analiza los datos y ajusta su comportamiento interno aplicando alguno de los tipos de aprendizaje estudiados: supervisado, no supervisado o por refuerzo. En esta fase el sistema intenta encontrar patrones, por ejemplo, puede detectar que el alumnado que entrega pocas tareas y participa poco suele tener más dificultades. La máquina no “entiende” como una persona, pero identifica combinaciones de datos que suelen repetirse.

4. Comprobar si ha aprendido: **evaluación con datos nuevos.** Es parecido a cuando enseñamos algo en clase y luego ponemos un ejercicio diferente para ver si el alumnado ha entendido la idea o solo ha memorizado un ejemplo. En Machine Learning es fundamental comprobar si el modelo generaliza o si simplemente ha memorizado. Este paso conecta directamente con la evaluación educativa **y también recuerda la necesidad de revisar críticamente los resultados de la IA, ya que las decisiones pedagógicas deben seguir siendo responsabilidad del docente.**

Finalmente, el modelo se utiliza en situaciones reales, siempre bajo **supervisión humana**, especialmente cuando se trata de decisiones que afectan a personas.

https://cdn.prod.website-files.com/64a7eed956ba9b9a3c62401d/64e3840f756417834cea5270_Feat

Esquema de aprendizaje en ML, se entrena al modelo con datos y luego se testea con datos nuevos para valorar su eficacia



Otra versión del esquema anterior. Al final siempre buscamos la obtención de un modelo

Un ejemplo educativo completo: aprender a anticipar dificultades

Imaginemos un centro educativo que quiere detectar de forma temprana dificultades de aprendizaje. En lugar de esperar al suspenso final, decide analizar datos históricos de cursos

anteriores: asistencia, entregas, resultados parciales, participación y uso de recursos digitales.

Siempre teniendo en cuenta que el tratamiento de estos datos debe cumplir con la normativa de protección de datos y **realizarse dentro de los sistemas autorizados** del propio centro o de la administración educativa, **evitando compartir información personal con herramientas externas.**

Aplicando **aprendizaje supervisado**, se entrenan modelos con ejemplos reales de alumnado que tuvo dificultades y alumnado que no las tuvo. El sistema aprende combinaciones de factores que suelen anticipar problemas académicos.

El resultado no es una decisión automática, sino una **señal de alerta**. El Machine Learning no sustituye al tutor ni al orientador, pero proporciona información objetiva que ayuda a intervenir antes y mejor. El aprendizaje de la máquina se convierte así en un apoyo al aprendizaje humano.

Modelos sencillos frente a modelos complejos

Otro aspecto importante, especialmente en educación, es que **no siempre necesitamos modelos complejos**. Aunque el aprendizaje profundo ha impulsado grandes avances, muchos problemas educativos se resuelven mejor con modelos simples, más transparentes y más fáciles de explicar.

Esto conecta con lo aprendido en el capítulo anterior: el tipo de aprendizaje elegido debe responder al problema educativo, no al atractivo tecnológico. En muchos casos, entender por qué el modelo toma una decisión es más importante que ganar unas décimas de precisión.

Aprender haciendo: herramientas educativas de Machine Learning

Una de las mejores formas de comprender el Machine Learning es **vivir el proceso de entrenamiento**. En este sentido, existen herramientas educativas que permiten trabajar con ML de forma accesible en el aula. Una de las más conocidas es **Machine Learning for Kids**, que permite entrenar modelos sencillos a partir de ejemplos aportados por el alumnado, sin necesidad de programar.

Además de ML for Kids, en el ámbito educativo y formativo se utilizan también otras herramientas y entornos como:

- [Teachable Machine de google](#)
- [Scratch + extensiones de IA del MIT](#)
- [Orange Data Mining](#)

- [Google Colab para programadores](#)
- [AutoML de Google](#)

El valor pedagógico de estas herramientas no está en el resultado final, sino en el proceso: el alumnado comprende que **si los datos son pobres, el modelo aprende mal**, y que mejorar el aprendizaje implica mejorar los ejemplos.

El error como motor del aprendizaje

Igual que ocurre en los tipos de aprendizaje estudiados en el capítulo anterior, el error desempeña un papel central en el Machine Learning. Cuando un modelo falla, no se corrige escribiendo una regla, sino **añadiendo mejores ejemplos** o ajustando los datos de entrenamiento.

Este enfoque conecta directamente con la evaluación formativa. Tanto las máquinas como las personas **aprenden cuando el error se convierte en información**, no en castigo.

Límites, ética y responsabilidad educativa

Trabajar con Machine Learning en educación implica una responsabilidad especial. Los modelos aprenden de datos pasados, no del potencial futuro del alumnado. Pueden reproducir sesgos, simplificar realidades complejas o generar etiquetas que condicionen expectativas.

Por eso, el Machine Learning debe entenderse siempre como **una herramienta de apoyo al profesorado**, nunca como un sustituto del criterio pedagógico. La máquina detecta patrones; el docente entiende personas, contextos y trayectorias.

Conclusión

El Machine Learning nos recuerda que aprender es un proceso acumulativo. Sin ejemplos, no hay aprendizaje. Sin experiencia, no hay interpretación. Esto es cierto para las máquinas... y también para las personas.

El caso de quienes recuperan la visión en la edad adulta nos enseña que **ver no es solo recibir estímulos, sino haber aprendido a interpretarlos**. La IA puede aprender rápido, pero no comprende. Las personas aprenden más despacio, pero dan sentido a lo aprendido.

“ Las máquinas aprenden de los datos; la educación enseña a comprender el mundo. ”

Revision #10

Created 2025-12-17 18:09:36 CET by Maria

Updated 2026-03-16 17:18:20 CET by Luis Hueso