

Ideas clave

Inteligencia Artificial y Aprendizaje Automático

La **Inteligencia Artificial (IA)** comprende cualquier técnica que permita a las computadoras imitar el comportamiento humano y reproducir o incluso superar la capacidad de decisión humana para resolver tareas complejas de manera autónoma o con mínima intervención humana.

El **aprendizaje automático (AA)**, por sus siglas en español; machine learning en inglés) es una rama fundamental de la inteligencia artificial moderna, aunque no la única. Se centra en el aprendizaje a partir de datos mediante algoritmos capaces de identificar relaciones y patrones dentro de ellos. Su desarrollo ha sido impulsado por el aumento en la velocidad de cómputo y la disponibilidad de grandes volúmenes de almacenamiento de datos.


Ideas clave

Redes Neuronales y Aprendizaje Profundo

Las **Redes Neuronales (RN)** son un tipo de modelo dentro del aprendizaje automático que se inspiran en el cerebro humano. Están compuestas por unidades llamadas neuronas artificiales, que procesan información a través de conexiones con pesos que se ajustan a medida que el modelo aprende. Este proceso permite que las redes neuronales reconozcan patrones y clasifiquen datos de forma eficiente.

El **Aprendizaje Profundo (AP)**, también conocido como Deep Learning, es una extensión avanzada de las redes neuronales. Se caracteriza por tener múltiples capas ocultas, lo que permite que el modelo aprenda representaciones más complejas y abstractas de los datos.


$$IA \supset AA \supset RN \supset AP$$



Relación de inclusión entre los campos: el aprendizaje profundo (AP) es un subconjunto de las redes neuronales (RN), que a su vez forman parte del aprendizaje automático (AA), dentro del campo más amplio de la inteligencia artificial (IA).

Aprendizaje Automático vs. Programación Tradicional

Para entender qué es el AA, resulta útil compararlo con el paradigma de la programación clásica, el cual ha dominado la informática desde sus orígenes.



Programación Tradicional: reglas explícitas

En la programación tradicional, el desarrollador define explícitamente las reglas que el programa debe seguir. Estas reglas, junto con los datos de entrada, son procesadas por el programa para generar una salida.

Ejemplo:

Si queremos que un programa sume 2 a cualquier número, debemos proporcionar:

Regla: "Sumar 2"

Dato de entrada: 3

El resultado será 5.

Relación básica: **Datos + Reglas = Respuesta**

En este enfoque, **el conocimiento (las reglas) es introducido manualmente por el programador**. Esta dependencia limita la capacidad del sistema para adaptarse o aprender de nuevas experiencias.

Aprendizaje Automático: aprender reglas desde los datos

En la programación tradicional, el desarrollador debe definir explícitamente las reglas que el sistema seguirá. Sin embargo, el Aprendizaje Automático invierte este enfoque. En lugar de proporcionar las reglas, se le entregan al sistema datos junto con las respuestas conocidas (también denominadas etiquetas), y es el propio sistema el que infiere las reglas por sí mismo.

Ejemplo:

Se le da al sistema que el número 3 corresponde al resultado 5.
A partir de esto, el sistema aprende que la regla probable es "sumar 2".

Relación básica: **Datos + Respuestas = Reglas**

Este enfoque permite que las máquinas aprendan de la experiencia, identifiquen patrones complejos y se adapten a nuevas situaciones sin intervención humana directa. A diferencia de la programación tradicional, en la que cada nuevo caso requiere una regla específica, **en el Aprendizaje Automático el sistema generaliza a partir de ejemplos previos, liberando al ser humano de la tarea de explicar y formalizar todas las reglas.**

AA permite trabajar con datos de alta dimensión, realizando tareas de clasificación, regresión y agrupamiento (clustering).

ASOCIACIÓN

DESCUBRE CORRELACIÓN ENTRE LAS VARIABLES DE INTERÉS

REGRESIÓN

DESCRIBE CÓMO INFLUYE LA MODIFICACIÓN DEL VALOR DE LAS VARIABLES PREDICTORAS EN EL VALOR DE LA VARIABLE RESPUESTA

CLASIFICACIÓN

IDENTIFICA LA CATEGORÍA DE PERTENENCIA DE UNA NUEVA OBSERVACIÓN ASIGNÁNDOLE UNA ETIQUETA

RECONOCIMIENTO DE PATRONES

DESCUBRE CORRELACIÓN ENTRE LAS VARIABLES DE INTERÉS

EXTRACCIÓN DE CONOCIMIENTOS

DESCUBRE CORRELACIÓN ENTRE LAS VARIABLES DE INTERÉS

AA puede clasificarse en 3 categorías:

Aprendizaje supervisado

Requiere un conjunto de datos de entrenamiento que contenga tanto las entradas como las salidas etiquetadas (valores objetivos o variables “y”). El modelo se entrena ajustando sus parámetros abiertos con estos pares entrada-salida. Luego puede predecir la “y” (output) para nuevos datos “x” (input). Se subdivide en problemas de regresión (resultado numérico) y clasificación (resultado categórico).

Aprendizaje NO supervisado

Se aplica cuando no existen etiquetas. El sistema debe detectar patrones o estructuras dentro de los datos. El conjunto de entrenamiento solo contiene variables "x". Se busca encontrar, por ejemplo, grupos similares (clustering) o reducciones de dimensionalidad (pasar de muchos atributos a menos).

Aprendizaje por refuerzo

En lugar de proporcionar pares entrada-salida, **se le da al modelo una descripción del estado del sistema**, un objetivo, un conjunto de acciones posibles y sus restricciones. Luego el modelo explora el entorno por prueba y error para maximizar una recompensa.

AA profundo vs. AA superficial

El **Aprendizaje Automático superficial** se basa en modelos simples que utilizan pocos niveles de procesamiento para aprender de los datos. Ejemplos comunes incluyen máquinas de soporte vectorial, árboles de decisión y redes neuronales poco profundas. Estos modelos **dependen de la ingeniería de características, es decir, el humano debe seleccionar y preprocesar las características importantes de los datos**. Son rápidos, eficientes para tareas simples, pero limitados en su capacidad para manejar datos complejos.

Por otro lado, el Aprendizaje Profundo emplea redes neuronales profundas con múltiples capas ocultas que permiten aprender representaciones jerárquicas y abstractas de los datos. Esto les da la **capacidad de aprender automáticamente características complejas sin intervención humana**. Aunque requieren grandes cantidades de datos y potentes recursos computacionales, el aprendizaje profundo ha demostrado ser fundamental en tareas complejas como reconocimiento de imágenes, procesamiento de lenguaje natural y vehículos autónomos.

Programación explícita (Explicit Programming)

Input: El ser humano provee los datos de entrada.

Extracción de características: No se extraen características automáticamente. **Todo el conocimiento relevante debe ser formalizado manualmente por un experto humano.**

Construcción del modelo: También es manual. El ser humano codifica reglas lógicas o fórmulas específicas que **definen cómo debe comportarse el sistema** (por ejemplo, sistemas expertos).

Evaluación del modelo: El sistema **genera una salida (output), pero no aprende ni ajusta su comportamiento con experiencia.**

Este enfoque es rígido, intensivo en trabajo humano, y no escala bien a problemas complejos o con datos no estructurados.

Aprendizaje automático superficial (Shallow Machine Learning)

Input: Se alimenta al sistema con datos etiquetados o no etiquetados.

Extracción de características: Las características relevantes del conjunto de datos (por ejemplo, longitud del texto, presencia de palabras clave) **deben ser diseñadas manualmente por expertos.** Esto se conoce como feature engineering.

Construcción del modelo: Una vez obtenidas las características, el modelo **se entrena automáticamente.** Se ajustan los parámetros mediante algoritmos como regresión, árboles de decisión, máquinas de soporte vectorial, etc

Evaluación del modelo: Se evalúa la **capacidad del modelo para generalizar a nuevos datos.**

Este enfoque requiere experiencia humana para diseñar buenas características, pero automatiza el aprendizaje de patrones a partir de ellas.

Aprendizaje profundo (Deep Learning)

Input: Se alimenta directamente al sistema con **datos crudos** (por ejemplo, imágenes, texto sin procesar).

Extracción de características y construcción del modelo: Ambas tareas se realizan **de forma automática** mediante redes neuronales profundas. El modelo aprende **representaciones internas** útiles para la tarea directamente desde los datos.

Evaluación del modelo: El sistema produce una salida que puede ser evaluada para afinar la arquitectura o los hiperparámetros.

Este enfoque permite construir sistemas de extremo a extremo (end-to-end) donde no se requiere ingeniería de características manual.

Es ideal para trabajar con datos no estructurados y de alta dimensión.

Bibliografía:

Luger, George F. (2025). Artificial Intelligence: Principles and Practice. Springer Nature Switzerland AG.
Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. Electronic Markets.
<https://doi.org/10.1007/s12525-021-00475-2>