

2022-2023

Aprendizaje Automático

1. Introducción al Aprendizaje Automático



Enrique Vidal Ruiz
(evidal@dsic.upv.es)

Francisco Casacuberta Nolla
(fcn@dsic.upv.es)

Departament de Sistemes Informàtics i Computació (DSIC)

Universitat Politècnica de València (UPV)

Septiembre, 2022

Aprendizaje Automático. 2022-2023

[Introducción al Aprendizaje Automático: 1.1](#)

Index

- 1 *Aprendizaje Predicción y Generalización* ▷ 1
- 2 Modos de Aprendizaje Automático (AA) ▷ 4
- 3 Conceptos básicos ▷ 10
- 4 Aproximaciones al AA ▷ 13
- 5 Evolución histórica ▷ 21
- 6 Áreas y aplicaciones ▷ 24
- 7 Notación ▷ 26

Introducción

Aprendizaje automático (AA), aprendizaje computacional o “machine learning” (ML):

- Tecnologías desarrollados en el marco de varias disciplinas relacionadas con los *sistemas inteligentes*: *reconocimiento de formas, cibernética, inteligencia artificial, estadística aplicada*, entre otras.
- Modernamente se suele considerar como un planteamiento *integrador* de todas estas disciplinas.
- *No solo se interesa en el “aprendizaje de modelos” propiamente dicho, sino en todo el proceso de resolución de problemas, basado más o menos explícitamente en una aplicación rigurosa de la teoría de la decisión estadística.*

Aprendizaje automático: predicción y generalización

Aprendizaje:

- Se asume la existencia de *datos de aprendizaje o entrenamiento*; típicamente datos de *entrada* $x \in \mathcal{X}$ y *salida* $y \in \mathcal{Y}$ de un sistema o proceso.
- El objetivo es obtener un modelo (o función $f : \mathcal{X} \rightarrow \mathcal{Y}$) que *generalice* estos datos adecuadamente.
- “Generalizar” frecuentemente consiste en *predecir* la salida a partir de nuevos datos de entrada diferentes de los de entrenamiento.

Index

- 1 Aprendizaje Predicción y Generalización ▷ 1
- 2 *Modos de Aprendizaje Automático (AA)* ▷ 4
- 3 Conceptos básicos ▷ 10
- 4 Aproximaciones al AA ▷ 13
- 5 Evolución histórica ▷ 21
- 6 Áreas y aplicaciones ▷ 24
- 7 Notación ▷ 26

Aprendizaje deductivo e inductivo

- *Aprendizaje Deductivo* (o “por instrucción”):
Se asume que existe un agente (humano) que posee el conocimiento necesario, el cual se transfiere de alguna forma al sistema.

En el contexto de AA, no se considera que esto sea propiamente “aprendizaje”, sino más bien se trataría de un modo de “enseñanza” en el que el sistema es “programado” para resolver cierta tarea.

- *Aprendizaje Inductivo* (o “a partir de ejemplos”):
Es el planteamiento propio de AA.

El sistema posee escaso conocimiento a-priori sobre la tarea a resolver y debe construir su(s) modelo(s) principalmente mediante la observación de *ejemplos* o *muestras de aprendizaje* de *entrada/salida* de dicha tarea.


Aprendizaje supervisado y no supervisado

Aprendizaje supervisado: Información (completa) de *entrada* y *salida* en los datos de entrenamiento.

Aprendizaje no supervisado:

- Los datos de entrenamiento solo contienen información de la *entrada* $x \in \mathcal{X}$.
- El objetivo es obtener información sobre la estructura del dominio de *salida*, $\mathcal{Y}$.
- En problemas de *clasificación*, esta información se refiere a la (posible) estructura en clases de los datos $x \in \mathcal{X}$. En este caso, el problema se conoce como *agrupamiento* o “*clustering*”.

Ejemplo: Datos de entrenamiento en $\mathcal{X} = \mathbb{R}^2$:



Aprendizaje supervisado y no supervisado

Aprendizaje supervisado: Información (completa) de *entrada* y *salida* en los datos de entrenamiento.

Aprendizaje no supervisado:

- Los datos de entrenamiento solo contienen información de la *entrada* $x \in \mathcal{X}$.
- El objetivo es obtener información sobre la estructura del dominio de *salida*, $\mathcal{Y}$.
- En problemas de *clasificación*, esta información se refiere a la (posible) estructura en clases de los datos $x \in \mathcal{X}$. En este caso, el problema se conoce como *agrupamiento* o “*clustering*”.

Ejemplo: Datos de entrenamiento en $\mathcal{X} = \mathbb{R}^2$, agrupados en tres clases:



Otros modos de aprendizaje automático

- **Aprendizaje “semi-supervisado” (ASS):** se refiere a planteamientos de AA situados entre el aprendizaje totalmente supervisado y totalmente no-supervisado.
- **Aprendizaje adaptativo (AAD):** se parte de un modelo previo, cuyos parámetros se modifican (“adaptan”) usando los (nuevos) datos de entrenamiento.
- **Aprendizaje “on-line” (AOL):** no hay distinción explícita entre las fases de “entrenamiento” y “test”; el sistema aprende (posiblemente partiendo de cero) mediante el propio proceso de predicción, con supervisión humana.

Para cada *entrada* $x \in \mathcal{X}$, la supervisión consiste en la validación o corrección de la salida $y = f(x) \in \mathcal{Y}$ predicha por el sistema.

- **Aprendizaje activo (AAC):** no se dispone de la salida, y , de cada dato (x) de entrenamiento y el sistema escoge las muestras x más adecuadas para que un agente externo (humano) las etiquete con su y correcta.
- **Aprendizaje por refuerzo (AR):** Puede considerarse como un caso de AOL y ASS en el que la supervisión es “incompleta”; típicamente una información (booleana) de *premio* o *castigo* con respecto a la salida predicha por el sistema.

Una taxonomía de técnicas de AA


Asignaturas:

APR

PER

SIN

SIN, PER, APR



Index

- 1 Aprendizaje Predicción y Generalización ▷ 1
- 2 Modos de Aprendizaje Automático (AA) ▷ 4
- 3 *Conceptos básicos* ▷ 10
- 4 Aproximaciones al AA ▷ 13
- 5 Evolución histórica ▷ 21
- 6 Áreas y aplicaciones ▷ 24
- 7 Notación ▷ 26

Planteamiento formal de aprendizaje inductivo

En *aprendizaje inductivo* el sistema posee escaso conocimiento a-priori sobre la tarea a resolver y obtiene su(s) modelo(s) principalmente mediante *ejemplos* o muestras de *entrada/salida* de dicha tarea.

En un planteamiento formal intervienen los siguientes elementos:

- *Método o algoritmo de aprendizaje, $\mathcal{A}$.*
- *Clase $\mathcal{G}$ de funciones a aproximar o “aprender”.* Toda $g \in \mathcal{G}$ es de la forma $g: \mathcal{X} \rightarrow \mathcal{Y}$. Para cada tarea, se asume que existe alguna $g \in \mathcal{G}$ que la representa exactamente¹.
- *Clase $\mathcal{F}$ funciones con las que se representan los “modelos” resultado del aprendizaje.* Toda $f \in \mathcal{F}$ es de la forma: $f: \mathcal{X} \rightarrow \mathcal{Y}$.
- *Muestra finita de aprendizaje $S \subset \mathcal{X} \times g(\mathcal{X})$.*
- *Modo de presentación de la muestra.* Indica cómo se extraen las muestras S de $\mathcal{X} \times g(\mathcal{X})$.
- *Criterio de éxito.* Indica qué se espera de $\mathcal{A}$ al final del aprendizaje.

1. Esta definición obvia la existencia de una *función de representación* que asigna a cada objeto real un elemento del *espacio de representación*, $\mathcal{X}$. Cuando esto se tiene en cuenta, en general $\mathcal{G}$ no puede ser un espacio de *funciones*, sino de *relaciones* de la forma: $g \subset \mathcal{X} \times \mathcal{Y}$.

Regresión y clasificación

- **Regresión:** Tanto los datos de entrada como los de salida pertenecen a dominios $(\mathcal{X}, \mathcal{Y})$ arbitrarios.

Ejemplos:

- $\mathcal{X} \subset \mathbb{R}^d$ (vectores de d componentes reales), $\mathcal{Y} \subset \Sigma^*$ (cadenas de símbolos).
- Un caso simple: $\mathcal{X} = \mathcal{Y} = \mathbb{R}$ y el modelo predictor es una función $f : \mathbb{R} \rightarrow \mathbb{R}$.

- **Clasificación:** $\mathcal{X}$ es arbitrario, pero $\mathcal{Y}$ es un conjunto finito (y generalmente pequeño) de C elementos llamados *clases*. Sin pérdida de generalidad, se puede asumir que $\mathcal{Y} = \{1, 2, \dots, C\} \subset \mathbb{N}$.

Ejemplos:

- Reconocimiento de imágenes de dígitos: $\mathcal{X} \subset \mathbb{R}^d$, $\mathcal{Y} = \{1, 2, \dots, 10\}$.
- Detección de “spam”: $\mathcal{X} \subset \Sigma^*$, $\mathcal{Y} = \{1, 2\}$, donde Σ es el alfabeto ASCII (o UTF) y las etiquetas $\{1, 2\}$ corresponden a *spam* y *no-spam*.

Index

- 1 Aprendizaje Predicción y Generalización ▷ 1
- 2 Modos de Aprendizaje Automático (AA) ▷ 4
- 3 Conceptos básicos ▷ 10
- 4 *Aproximaciones al AA* ▷ 13
- 5 Evolución histórica ▷ 21
- 6 Áreas y aplicaciones ▷ 24
- 7 Notación ▷ 26

Marcos formales para AA

Identificación en el límite: comportamiento de un método de AA para tallas crecientes de los conjuntos de aprendizaje. Este criterio de éxito ha sido ampliamente utilizado en el campo de la *Inferencia Gramatical* (IG). Conclusiones computacionales pesimistas. En general, AA considera este criterio poco útil en la práctica.

Aprendizaje probablemente aproximadamente correcto (PAC): el algoritmo AA debe seleccionar con alta probabilidad un modelo cuyo error de generalización sea pequeño.

Teoría de la decisión estadística: marco más realista para la mayor parte de los problemas prácticos.

Otros marcos.

Aproximaciones al AA

- Aprendizaje de modelos probabilísticos, tales como los modelos de Markov, modelos de n -gramas o *modelos gráficos* en general.
- Aprendizaje de funciones discriminantes en máquinas de vectores soporte, redes neuronales, etc.
- Aprendizaje por *proximidad* y *memorización* (almacenamiento de prototipos), basado en medidas de *disimilitud o distancia*.
- Aprendizaje *evolutivo* basado en *algoritmos genéticos* y otras técnicas de computación inspiradas en ideas de selección natural en biología.

AA basado en proximidad

- Se asume que $\mathcal{X}$ es un espacio *métrico* o al menos *pseudométrico* (aunque no necesariamente vectorial).
- Se define una medida de *disimilitud o distancia* adecuada, $d : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$, de manera que si dos objetos x, x' son “*similares*”, $d(x, x')$ es pequeña.
- El aprendizaje es básicamente por *memorización*: los *prototipos* son directamente los propios datos de entrenamiento, S , o subconjuntos adecuadamente seleccionados de S .
- En problemas de clasificación, las *clases* se representan mediante (conjuntos de) *prototipos*; es decir, elementos (adecuadamente escogidos) de $\mathcal{X}$ cuya etiqueta de clase es conocida. La función de clasificación f , se basa en las distancias entre un dato de *test* y los prototipos de las distintas clases.
- Existen extensiones adecuadas para problemas de *regresión*.
- Este planteamiento de AA se encuadra propiamente en el marco estadístico considerando que la probabilidad a posteriori $P(c \mid x)$ se estima mediante las distancias de x a prototipos de c .

Planteamiento conexionista o basado en funciones discriminantes

- Puede considerarse que corresponde a la aproximación al RF, tradicionalmente llamada “*no paramétrica*” (o “*no estadística*”).
- No se requiere ninguna asunción probabilística sobre el dominio de las funciones a aprender, $\mathcal{X} \times \mathcal{Y}$.
- El *criterio de éxito* se establece directamente en términos de minimización del error de decisión sobre un *conjunto de test*.
- La clase de modelos $\mathcal{F}$ se suele definir mediante *funciones discriminantes* (FD); típicamente funciones *lineales* o *generalizaciones* (en algunos casos llamadas “*núcleos*”).
- Las funciones de decisión del marco estadístico del AA pueden verse como un caso particular de FDs y, a la inversa, las FDs entrenadas bajo ciertos criterios son aproximaciones a las probabilidades a posteriori.

Computación evolutiva y algoritmos genéticos

El aprendizaje “evolutivo” o “genético” puede considerarse una rama de la llamada *computación evolutiva o genética*.

Computación evolutiva (CE):

- Estudia sistemas computacionales inspirados en ideas (darwinianas) de *selección natural*.
- Entre estas ideas, destacan la *mutación* y la *supervivencia del más apto*.
- Las técnicas de CE son aplicables a diversos campos: optimización, diseño, AA, etc.
- Las técnicas de CE no requieren un rico conocimiento del dominio aunque, para que sean efectivas, generalmente es preciso incorporar algo (¡o mucho!) de este conocimiento en el diseño de los algoritmos.

Algoritmos evolutivos y AA

Se han aplicado con cierto éxito a problemas simples de aprendizaje *supervisado* (inductivo), *no-supervisado* y *por refuerzo* en el campo de la *inteligencia artificial*:

- Aprendizaje de sistemas (de clasificación) *basados en reglas*.
- Aprendizaje de *redes neuronales* “evolutivas”.
- Aprendizaje de sistemas de *lógica difusa*.
- Aprendizaje por *co-evolución* (competición).
- etc.

El interés para problemas reales prácticos es limitado.

Aprendizaje por refuerzo (AR)

- En AR, un agente (es decir un sistema) *interactúa* con el entorno para conseguir un *objetivo*. Mediante la propia actividad de interacción, el agente debe *aprender una política de interacción*; es decir, una estrategia de elección de posibles *acciones*.
 - La realización de una acción cambia el *estado* del entorno y las consecuencias de ello son sancionadas por el entorno mediante una señal de *recompensa* (premio o castigo).
 - Cada posible *estado* del entorno tiene un *valor* relacionado con la esperanza de la recompensa acumulada o *ganancia* (“*return*”) que se puede lograr a partir de ese estado, siguiendo la política que se está aprendiendo.
 - En esencia, el aprendizaje en AR consiste en obtener *estimaciones* adecuadas *de los valores* de los estados.
- AR presenta un compromiso entre *explotación* de lo aprendido hasta el momento y *exploración* de acciones no realizadas previamente.
- Ejemplos: Jugar al ajedrez, control de varios ascensores, vehículos autónomos, robots, etc.

Index

- 1 Aprendizaje Predicción y Generalización ▷ 1
- 2 Modos de Aprendizaje Automático (AA) ▷ 4
- 3 Conceptos básicos ▷ 10
- 4 Aproximaciones al AA ▷ 13
- 5 *Evolución histórica* ▷ 21
- 6 Áreas y aplicaciones ▷ 24
- 7 Notación ▷ 26

Orígenes y evolución histórica del AA


Desde los años 40 del pasado siglo, se han venido desarrollando de forma más o menos paralela dos enfoques principales para la disciplina que modernamente se conoce como *sistemas inteligentes* (SI):

- *Inteligencia artificial* (propriadamente dicha, o “clásica” – IA), que se ocupa principalmente de los aspectos mas cognitivos, con claras relaciones con la lógica, el conocimiento y su procesamiento.
- *Reconocimiento de formas* (RF – también “reconocimiento de patrones” o, en inglés, “pattern recognition”), que se ocupa de aspectos más “perceptivos”, relacionados con la visión, el habla, etc.

El *aprendizaje automático* surge en los años 80-90 como planteamiento integrador de los enfoques IA y RF, entre otros.

Grandes avances y espectaculares resultados prácticos en los últimos 20 años.

Evolución de algunas tecnologías importantes de AA



Para cada tecnología, la línea continua indica el periodo de desarrollo teórico-experimental y la de puntos el periodo de vigencia como tecnología consolidada.

Index

- 1 Aprendizaje Predicción y Generalización ▷ 1
- 2 Modos de Aprendizaje Automático (AA) ▷ 4
- 3 Conceptos básicos ▷ 10
- 4 Aproximaciones al AA ▷ 13
- 5 Evolución histórica ▷ 21
- 6 *Áreas y aplicaciones* ▷ 24
- 7 Notación ▷ 26

Áreas y aplicaciones

- **Reconocimiento de Imágenes**
Reconocimiento de caracteres, de texto manuscrito, firmas, análisis de documentos, identificación de placas de matrícula y tipos de vehículos, piezas industriales, reconocimiento de texturas y detección de defectos para control de calidad, etc.
- **Visión Artificial y Robótica**
Reconocimiento de rostros y expresiones faciales, visión para navegación de robots, vehículos autónomos y exploración espacial, etc.
- **Teledetección (imágenes aéreas o de satélite)**
Exploración de recursos naturales, predicción de cosechas y explotaciones forestales, localización de posibles yacimientos minerales, etc.
- **Análisis de Señales Sísmicas**
Señales naturales: predicción de terremotos. Señales artificiales: localización de yacimientos minerales y petróleo, etc.
- **Reconocimiento del Habla y Procesado del Lenguaje**
Reconocimiento de palabras aisladas, habla continua, comprensión, traducción automática, etc.
- **Aplicaciones en Biomedicina y Genómica**
Detección de tumores y tejidos cancerosos, análisis de electro cardio/encefalo-gramas, detección de situaciones críticas en UVI, diagnóstico a partir de síntomas, reconocimiento de cromosomas para detección de malformaciones congénitas, análisis de secuencias genómicas, etc.
- **Aplicaciones Biométricas**
Reconocimiento de huellas dactilares, de rostros, iris, análisis de voz para identificación del locutor, etc.
- **Aplicaciones Agrícolas**
Visión artificial para recolección automática, localización de "malas hierbas" para su eliminación selectiva, detección de puntos de injerto para su automatización, detección de defectos y selección de frutos para su envasado, etc.
- **Protección Civil**
Predicción del clima, predicción de terremotos, control incendios forestales, detección de situaciones de alerta en sistemas hidrológicos, etc.
- **Economía**
Segmentación de mercados, predicción de tendencias, detección de patrones de fraude, minería y analítica de datos, etc.
- **Ayudas Discapacitados**
Ayudas para la visión, control del entorno mediante reconocimiento del habla, ayudas al aprendizaje del habla, etc.
- **Análisis de Datos (Analytics)**
Datos masivos (big data analytics), web (web analytics), internet de las cosas (IoT analytics)).

Index

- 1 Aprendizaje Predicción y Generalización ▷ 1
- 2 Modos de Aprendizaje Automático (AA) ▷ 4
- 3 Conceptos básicos ▷ 10
- 4 Aproximaciones al AA ▷ 13
- 5 Evolución histórica ▷ 21
- 6 Áreas y aplicaciones ▷ 24
- 7 *Notación* ▷ 26

Notación

- $\mathbb{R}$, $\mathbb{N}$ y $\mathbb{B}$: espacios de los reales, de los naturales y de los booleanos, respectivamente.
- $\mathbb{R}^d$: espacio vectorial de d dimensiones.
- Σ^* : espacio de cadenas de longitud finita de símbolos.
- $\mathcal{X}, \mathcal{Y}$: espacios de datos de entrada y de salida, respectivamente.
- x, y : un dato de entrada y un dato de salida, respectivamente.
- $f, g : \mathcal{X} \rightarrow \mathcal{Y}$: funciones entre el espacio de entrada y el de salida.
- C : número de clases en un problema de clasificación.

Conceptos básicos de Estadística y Probabilidad

Variable aleatoria, probabilidad $P(X = x) \equiv P(x) : \sum_x P(x) = 1$

Probabilidad, densidad $P(x), p(x) : \sum_x P(x) = 1, \int_x p(x) dx = 1$

Probabilidad conjunta $P(x, y) : \sum_x \sum_y P(x, y) = 1$

Probabilidad condicional $P(x | y) : \sum_x P(x | y) = 1 \quad \forall y$

Marginales $P(x) = \sum_y P(x, y), \quad P(y) = \sum_x P(x, y)$

Regla de la probabilidad conjunta $P(x, y) = P(x) P(y | x)$

Regla de la cadena $P(x_1, x_2, \dots, x_N) = P(x_1) \prod_{i=2}^N P(x_i | x_1, \dots, x_{i-1})$

Regla de Bayes $P(y | x) P(x) = P(y) P(x | y)$

Esperanza $E_P[f(x)] \equiv E_X[f(x)] \equiv \mathbb{E}[f(x)] = \sum_x f(x) P(x)$