


Raspberry Pi  
Foundation

# Experience AI

Glosario de  
términos de IA



# Experience AI: glosario de términos

Este glosario explica los términos clave de inteligencia artificial (IA) y aprendizaje automático (AA, Machine Learning o ML en inglés) que se utilizan en las [Lecciones de Experience AI](#) y en otros materiales.

[Ir al glosario](#)

Estas explicaciones están dirigidas a docentes, y orientadas a un público joven. Con este glosario, queremos ayudar a reforzar tus competencias sobre estos términos clave, así como a mejorar tu conocimiento técnico.

El vocabulario es una parte importante del proceso de enseñanza-aprendizaje. Su uso correcto puede ayudar al alumnado a desarrollar su conocimiento, mientras que un uso incorrecto puede generar ideas erróneas que dificulten el aprendizaje. Consulta [nuestra Guía rápida sobre pedagogía para obtener más información sobre el concepto de ideas erróneas](#). Como docente, un uso frecuente y coherente de vocabulario técnico y preciso puede ayudar a que tu alumnado comprenda mejor los conceptos.

Hemos utilizado la teoría de las "olas semánticas" como referencia para redactar las explicaciones. De este modo, cada definición sigue una misma estructura, dividida en tres partes: la primera es una explicación más abstracta del término, la segunda desglosa el significado del término utilizando un ejemplo común y la tercera vuelve a abordar el término con un lenguaje más abstracto para conectar nuevamente con el vocabulario técnico. Consulta [nuestra Guía rápida sobre pedagogía para obtener información sobre el concepto de olas semánticas](#).

Esta es la versión 1 del glosario. Este glosario se completará, revisará y actualizará conforme evolucionen las lecciones de Experience AI.

## Tabla de contenido

[Alfabetización en IA](#)  
[Aprendizaje automático](#)  
[Aprendizaje no supervisado](#)  
[Aprendizaje por refuerzo](#)  
[Aprendizaje supervisado](#)  
[Árbol de decisiones de aprendizaje automático](#)  
[Característica de aprendizaje automático](#)  
[Ciclo de vida del proyecto de IA](#)  
[Clase de aprendizaje automático](#)  
[Clasificación de aprendizaje automático](#)  
[Datos de entrenamiento de aprendizaje automático](#)  
[Datos de prueba de aprendizaje automático](#)  
[Datos](#)  
[Depuración de los datos](#)  
[Entrenamiento de aprendizaje automático](#)  
[Etiqueta de aprendizaje automático](#)  
[Explicabilidad del aprendizaje automático](#)  
[Fiabilidad del aprendizaje automático](#)  
[IA generativa](#)  
[Inteligencia artificial](#)  
[Modelo de aprendizaje automático](#)  
[Nodo de árbol de decisiones de aprendizaje automático](#)  
[Precisión del aprendizaje automático](#)  
[Predicción del aprendizaje automático](#)  
[Sesgo de datos](#)  
[Sesgo social](#)  
[Sesgo](#)  
[Tarjeta de modelo de aprendizaje automático](#)  
[Tecnología basada en datos](#)  
[Tecnología basada en reglas](#)  
[Umbral de fiabilidad del aprendizaje automático](#)  
[Visión artificial](#)

## Alfabetización en IA

La alfabetización en IA es un conjunto de competencias y formas de pensar que permite a las personas interactuar de manera adecuada con las aplicaciones de IA, y comprender los contextos en que se utilizan. Estas competencias incluyen la comprensión de la IA, la participación en el desarrollo de sistemas de IA y los conocimientos informados sobre sus aplicaciones en el mundo. Por ejemplo, una persona alfabetizada en IA podría evaluar el nivel de precisión de la información que ofrece un chatbot. Además de interactuar con estas aplicaciones, la alfabetización en IA

también implica la capacidad de participar activamente en el proceso de decisión sobre cómo se deberían utilizar los sistemas de IA en su entorno.

## Aprendizaje automático

El aprendizaje automático (AA, conocido como “Machine Learning” o ML en inglés) es un enfoque que se utiliza para diseñar y desarrollar sistemas de **IA**. A diferencia de los sistemas que siguen instrucciones paso a paso, el AA se basa en ejemplos o **datos** para aprender y mejorar. En otras palabras, las aplicaciones de AA están **basadas en datos**. Por ejemplo, una aplicación de AA diseñada para reconocer el habla, se entrena con grabaciones de personas que hablan con distintos acentos y tonos. Otras aplicaciones de AA son, por ejemplo, la identificación de objetos en imágenes o los juegos complejos. Cada aplicación de AA está diseñada para resolver un problema específico.

## Aprendizaje no supervisado

El aprendizaje no supervisado es un enfoque que se utiliza para **entrenar modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) sin etiquetas previas en los datos. En este tipo de aprendizaje, los desarrolladores entrenan modelos para organizar los **datos** según sus similitudes, lo que permite descubrir patrones ocultos. Un ejemplo de problema de aprendizaje no supervisado es la clasificación, donde los datos se organizan en “**grupos**” que no se conocen de antemano. Por ejemplo, con respecto a la información de salud, el modelo podría agrupar datos de pacientes para ayudar en el diagnóstico de enfermedades. Este tipo de aprendizaje es útil en problemas en los que no se sabe de antemano qué patrones se buscan.

## Aprendizaje por refuerzo

El aprendizaje por refuerzo es un enfoque que se utiliza para **entrenar modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés). En situaciones con un objetivo claro, donde se emplean recompensas y penalizaciones para alcanzarlo. Este método es útil en el diseño de vehículos autónomos y en juegos complejos. Por ejemplo, al crear una aplicación de ajedrez, un modelo se entrenaría para **predecir** los movimientos que maximicen las recompensas y minimicen las penalizaciones, con el fin de ganar el juego. Este tipo de aprendizaje permite que el modelo descubra estrategias efectivas al recibir recompensas y penalizaciones a medida que intenta alcanzar el objetivo.

## Aprendizaje supervisado

El aprendizaje supervisado es un enfoque que se utiliza para **entrenar modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) a partir de **datos etiquetados** por personas con información relevante. La **clasificación** es un tipo de aprendizaje supervisado. Por ejemplo, la identificación de tigres en estado salvaje es un problema de clasificación: el conjunto de datos incluye numerosas imágenes, y las que contienen tigres están etiquetadas como tales.

El modelo de AA se entrena con estas imágenes etiquetadas y aprende a **predecir** si hay un tigre en nuevas imágenes. Disponer de etiquetas precisas permite al desarrollador evaluar la **precisión** de las predicciones del modelo y ajustar su entrenamiento. Así, el modelo de AA podrá predecir con fiabilidad la presencia de tigres en imágenes completamente nuevas. La efectividad del aprendizaje supervisado depende de contar con suficientes datos etiquetados de manera precisa.

## Árbol de decisiones de aprendizaje automático

El árbol de decisiones de **aprendizaje automático** (AA, conocido como “Machine Learning” o ML) es un tipo de **modelo** de AA. Los desarrolladores de AA utilizan árboles de decisiones para estructurar los conjuntos de condiciones en función de las cuales se puede hacer una **predicción**. Estas se derivan de **características** de los **datos**. Por ejemplo, se podría utilizar un árbol de decisión para desarrollar un sistema de recomendación de películas. El modelo de árbol de decisiones está **se entrena** a partir de las preferencias cinematográficas de muchas personas. Durante el entrenamiento, las condiciones se generan en función de características como el género de la película, la duración o el actor o la actriz principal. El modelo de AA genera una predicción sobre las películas que podrían gustar a alguien en función de cómo sus preferencias coinciden con las condiciones del modelo. La estructura de los árboles de decisión de AA se genera a partir de grandes volúmenes de datos y puede cambiar si se vuelve a entrenar con diferentes datos.

## Característica de aprendizaje automático

En **aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés), las características representan rasgos asociados a los **datos**. Por ejemplo, un conjunto de datos musicales puede tener características como el ritmo, el tono, la energía o el género. Algunos **modelos** de AA se **entrenan** con estas características para encontrar similitudes en los datos, mientras que otros, **predicen** nuevas características en los datos que no son fácilmente observables por las personas. Elegir qué características usar al entrenar un modelo de AA puede marcar la diferencia en el rendimiento del modelo.

## Ciclo de vida del proyecto de IA

El ciclo de vida del proyecto de **IA** hace referencia a las distintas etapas necesarias para diseñar y desarrollar un modelo de **aprendizaje automático (AA, conocido como “Machine Learning” o ML en inglés)**. Entre estas etapas se incluyen:- La definición del problema- La preparación de los **datos**- El **entrenamiento** del modelo- Las pruebas- La evaluación- La explicación del modelo Por ejemplo, en un proyecto para crear listas de reproducción de canciones, un desarrollador podría comenzar definiendo el tipo de lista que se busca generar. A continuación, recopilaría y prepararía datos de canciones, entrenaría el modelo con esta información y lo pondría a prueba. Finalmente, evaluaría si el modelo funciona como se espera y explicaría cómo utilizarlo. El ciclo de vida de un proyecto de IA suele ser constante, es decir, estas etapas se repiten para perfeccionar el modelo de forma continua.

# Clase de aprendizaje automático

Con el fin de **entrenar** a los **modelos de clasificación**, los **desarrolladores de aprendizaje automático (AA, conocido como "Machine Learning" o ML en inglés)** organizan los **datos** en grupos predefinidos que se conocen como "clases". Las clases están definidas según los criterios de agrupación que las personas consideran más útiles. Imaginemos una aplicación de AA diseñada para identificar frutas en un supermercado. Los datos podrían organizarse en clases de manzanas, plátanos, naranjas, arándanos, entre otros. Cada clase agrupa elementos que el modelo de clasificación utiliza para identificar similitudes en los datos.

## Clasificación de aprendizaje automático

La clasificación es el proceso de asignar elementos a los grupos predefinidos, también llamados **clases**. Estas clases se establecen según criterios de agrupación que se consideran útiles. Un ejemplo de problema de clasificación es el análisis de opiniones de reseñas de canciones. Imaginemos que un **modelo de aprendizaje automático (AA, conocido como "Machine Learning" o ML en inglés) entrenado** con reseñas **etiquetadas** como "positivas" o "negativas" por los usuarios. Después del entrenamiento, el modelo puede **predecir** si una nueva reseña debería clasificarse como "positiva" o "negativa". De este modo, el modelo de clasificación es capaz de asignar una o más etiquetas a los datos. Este enfoque de clasificación es útil para resolver problemas en los que las respuestas pueden organizarse en grupos predefinidos.

## Datos de entrenamiento de aprendizaje automático

En **aprendizaje automático (AA, conocido como "Machine Learning" o ML en inglés)**, los **datos de entrenamiento** son los ejemplos utilizados para enseñar a los **modelos** a identificar patrones. Los desarrolladores de AA construyen estos modelos para extraer patrones útiles de los ejemplos de entrenamiento, permitiendo así generar **predicciones** sobre nueva información. Por ejemplo, en una aplicación de reconocimiento de voz, los datos de entrenamiento pueden incluir muestras de habla de personas con diferentes tonos y acentos. Cuanto más representativos de la realidad sean estos ejemplos, mejor funcionará el modelo.

## Datos de prueba de aprendizaje automático

En **aprendizaje automático (AA, conocido como "Machine Learning" o ML en inglés)**, los **datos de prueba** son ejemplos que se usan para evaluar el rendimiento de un **modelo ya entrenado**. Por ejemplo, si un modelo ha sido entrenado para **predecir** diagnósticos médicos, antes de aplicarlo en situaciones de la vida real, se prueba y evalúa con datos de prueba, que están separados de los **datos de entrenamiento** originales. Estos datos de prueba permiten medir cómo responde el modelo ante casos nuevos y determinar su precisión en situaciones reales.

# Datos

Los datos son valores, mediciones, hechos u observaciones que los programas informáticos son capaces de procesar. Existen muchos tipos de datos, como el texto, las imágenes o el sonido. Por ejemplo, los mensajes que las personas intercambian con sus amigos y amigas en sus dispositivos digitales, son datos de texto. En **aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés), los datos representan los ejemplos con los que se **entrenan** los **modelos**. La recopilación, **depuración** y a estructuración de grandes cantidades de datos son pasos esenciales en el diseño de modelos de AA.

## Depuración de los datos

La depuración de los datos es un paso esencial en la preparación de **información** para **entrenar** un **modelo de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés). Este proceso consiste en identificar y corregir errores en los datos, como eliminar duplicados o corregir errores tipográficos en datos de texto. En muchos casos, los datos pueden ser confusos y requieren una depuración más exhaustiva antes de ser útiles para el modelo. Existen muchas formas de depuración, que dependen del tipo de datos y del problema a resolver. Contar con datos depurados es fundamental para crear modelos de AA **precisos**.

## Entrenamiento de aprendizaje automático

Los **modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) se entrenan con ejemplos en forma de **datos** para identificar patrones y crear **predicciones**. Durante el entrenamiento, estos patrones se ajustan para mejorar la precisión de las predicciones. Por ejemplo, un desarrollador de ML podría crear un modelo para recomendar canciones. Para ello, el modelo se entrenaría en las elecciones de canciones de muchas personas, buscando similitudes en las preferencias de reproducción. Cuanta mayor variedad de canciones se incluya en el entrenamiento, más precisa será la recomendación. Existen diferentes métodos para entrenar los modelos, dependiendo del problema y de los datos disponibles. El desarrollador debe elegir entre los tipos de entrenamiento disponibles en función del problema que se intenta resolver y los datos disponibles para solucionarlo. La calidad del entrenamiento depende en gran medida de la calidad de los datos utilizados.

## Etiqueta de aprendizaje automático

En el **aprendizaje supervisado**, los **modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) se **entrenan** con **datos** etiquetados. Cada dato tiene una o más etiquetas anotadas que describen su contenido. Por ejemplo, si tenemos un modelo diseñado para identificar sonidos de pájaros, cada grabación de sonido estaría etiquetada con el nombre del pájaro correspondiente. Al entrenar el modelo con estos sonidos etiquetados, el modelo podrá **predecir** la etiqueta (nombre del pájaro) en nuevas grabaciones. Generalmente, las personas se encargan de etiquetar los datos para proporcionar ejemplos precisos con los que entrenar los modelos.

# Explicabilidad del aprendizaje automático

La explicabilidad hace referencia a la capacidad de algo para ser entendido. En **aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés), la explicabilidad permite a las personas comprender cómo se produjo una **predicción**. Por ejemplo, los **modelos de árbol de decisiones** son explicables, ya que sus pasos (**nodos**) se pueden analizar de una manera comprensible. No todos los modelos de AA son completamente explicables, y algunos son más explicables que otros. Mejorar la explicabilidad de un modelo ayuda a resolver problemas y a reducir el **sesgo**.

# Fiabilidad del aprendizaje automático

La fiabilidad se refiere a la seguridad que ofrece algo. En **aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés), la fiabilidad mide el grado de certeza de una **predicción**. Por ejemplo, un **modelo de clasificación** diseñado para predecir si lloverá mañana, podría hacerlo con un 90 % de fiabilidad, lo que significa que hay un 90 % de certeza en esa predicción. Evaluar la fiabilidad de las predicciones ayuda a valorar la calidad de un modelo de AA.

# IA generativa

La IA generativa es un tipo de inteligencia **artificial** diseñada para crear contenido, como texto, imágenes o sonido. Tiene múltiples aplicaciones, como la producción de arte o música, o la generación de texto para chatbots. Por ejemplo, las aplicaciones de arte de IA generativa puede crear una imagen a partir de una solicitud, como “crea una imagen de un dragón leyendo un libro”. Este tipo de arte se crea mediante **modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) **entrenados** con millones de imágenes de obras de arte existentes. Las imágenes generadas pueden imitar el estilo de un artista, sin su conocimiento o aprobación. Las aplicaciones de IA generativa son cada vez más comunes y, a menudo, resulta imposible distinguir si se ha utilizado IA generativa para crear un contenido.

# Inteligencia artificial

La inteligencia artificial se refiere al diseño y estudio de sistemas que imitan comportamientos inteligentes. Algunas aplicaciones de IA funcionan a partir de reglas predefinidas, aunque hoy en día se desarrollan cada vez más mediante **aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés), lo que permite que “aprendan” a partir de ejemplos en forma de **datos**. Por ejemplo, algunas aplicaciones de IA están diseñadas para responder preguntas o ayudar a diagnosticar enfermedades, mientras que otras pueden tener fines dañinos, como la difusión de noticias falsas. Sin embargo, las aplicaciones de IA no piensan; están diseñadas para realizar tareas de una forma que aparenta ser inteligente.

# Modelo de aprendizaje automático

Las aplicaciones de **aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) utilizan los modelos para realizar tareas o resolver problemas. Un modelo de AA es una representación del problema que se busca resolver. Los desarrolladores entrenan estos modelos con grandes cantidades de **datos** específicos para que **aprendan** a detectar patrones. El resultado del entrenamiento es un modelo, que se utiliza para hacer **predicciones** sobre nuevos datos en contextos similares. Por ejemplo, los vehículos autónomos se desarrollan utilizando modelos de AA capaces de predecir cuándo detenerse. Los modelos se entrenan con millones de ejemplos de situaciones en las que los automóviles deben parar. Existen numerosos tipos de modelos que emplean diferentes tipos de datos y distintos métodos de entrenamiento. Todos los modelos de ML están entrenados para detectar patrones en los **datos de entrenamiento** y realizar predicciones sobre nuevos datos.

# Nodo de árbol de decisiones de aprendizaje automático

Los **árboles de decisión de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) están formados por nodos que, a su vez, se conectan para crear una estructura capaz de generar **predicciones**. Existen dos tipos de nodos: los nodos de decisión y los nodos de hoja. Por ejemplo, en un árbol de decisiones diseñado para predecir tipos de estrellas en nuestro sistema solar, los nodos de decisión representan las **características de los datos**, como la temperatura, el radio, el color o el brillo de las estrellas. Los nodos de hoja, en cambio, representan las **categorías** de predicción, como “Enana roja”, “Enana blanca” o “Enana marrón”. Esta estructura de nodos permite que el **modelo** de AA realice predicciones de manera efectiva.

# Precisión del aprendizaje automático

La precisión se refiere a la exactitud de un resultado. En **aprendizaje automático (AA, conocido como “Machine Learning” o ML en inglés)**, la precisión mide cuán a menudo un **modelo** realiza **predicciones** correctas. Por ejemplo, si un modelo de **clasificación** está diseñado para identificar manzanas y clasifica correctamente 90 de cada 100 imágenes, la precisión del modelo es del 90 %. La precisión es una medida útil para evaluar el rendimiento de los modelos de AA, y a menudo se combina con otras métricas para obtener una evaluación completa de su calidad.

# Predicción del aprendizaje automático

Los **modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) están **entrenados** para hacer predicciones. La predicción que produce un modelo de AA sugiere lo que representan los **datos** o lo que podría resultar útil para una tarea específica. Por ejemplo, un

desarrollador de AA podría entrenar un modelo para predecir qué película querrá ver un usuario en función de sus hábitos de visualización. Así, el modelo generará una predicción basada en las elecciones de películas de muchas personas. La función principal de los modelos de ML es hacer predicciones, incluso si en algunos casos estas no son evidentes para el usuario.

## Sesgo de datos

El sesgo de datos hace referencia a los **prejuicios** presentes en los **datos** usados para **entrenar los modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés). Este sesgo puede llevar a que los modelos generen **predicciones** también sesgadas. Por ejemplo, algunos modelos de reconocimiento facial pueden mostrar un sesgo hacia ciertos tonos de piel si se han entrenado principalmente con imágenes de rostros de un solo tono de piel. Las causas del sesgo en los datos incluyen datos incompletos o que reflejan **prejuicios sociales**. Detectar y corregir el sesgo en los datos es fundamental para evitar que los modelos de AA produzcan predicciones sesgadas.

## Sesgo social

El sesgo social se refiere a los **prejuicios** que existen dentro de un gran grupo de personas o en la sociedad en general. Existen muchos tipos de prejuicios sociales, como el prejuicio racial, de género o étnico. Por ejemplo, un sesgo de género sería la creencia de que las mujeres están menos capacitadas que los hombres para las carreras de ingeniería. Los **datos** recopilados de grandes grupos de personas pueden reflejar estos sesgos sociales, lo que puede derivar en un **sesgo de datos**. Si se utilizan datos con sesgo social para **entrenar modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés), esto podría dar lugar a modelos que generan **predicciones sesgadas**. En AA, es fundamental mitigar el sesgo social en los **datos de entrenamiento** para evitar resultados discriminatorios o injustos.

## Sesgo

El sesgo es una preferencia a favor o en contra de algo. Por ejemplo, un estudiante que prefiere la asignatura de inglés a la de matemáticas, podría dedicar más tiempo a sus tareas de inglés, mostrando así un sesgo hacia esa materia. Existen distintos tipos de sesgo, como el **sesgo social** y el **sesgo de datos**. Los desarrolladores de **aprendizaje automático (AA, conocido como “Machine Learning” o ML en inglés)** deben evaluar cuidadosamente si los **datos** que van a utilizar para **entrenar** a los **modelos** de AA presentan algún tipo de sesgo, ya que este puede favorecer a ciertos conjuntos de ideas o creencias en detrimento de otros.

## Tarjeta de modelo de aprendizaje automático

Una tarjeta de modelo de **aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) es una forma de documentar información clave sobre un **modelo** de AA. Los desarrolladores crean estas tarjetas para que tanto personas expertas como sin experiencia técnica puedan entender el modelo. Por ejemplo, si se desarrolla una aplicación de AA para traducir idiomas, como del árabe al francés, la tarjeta de modelo podría incluir información sobre la

**precisión** de la traducción y su rendimiento con el argot, la jerga y los dialectos. También puede detallar el tipo de modelo, diferentes indicadores de rendimiento e incluso **sesgos** conocidos. Las tarjetas de modelo se crean durante la etapa de explicación del **ciclo de vida del proyecto de IA**, para comunicar de manera accesible las capacidades y limitaciones del modelo.

## Tecnología basada en datos

La tecnología basada en datos permite diseñar sistemas que utilizan **datos** en lugar de instrucciones paso a paso. Por ejemplo, diagnosticar ciertas enfermedades puede ser complicado, pero existen muchos datos médicos de casos previos que pueden ayudar en el proceso. Por esta razón, los diseñadores emplean datos médicos de personas afectadas para ayudar en el diagnóstico de estas enfermedades. A diferencia de los sistemas **basados en reglas**, los sistemas basados en datos son especialmente adecuados para resolver problemas en los que es difícil crear reglas que cubran todas las situaciones posibles. En su lugar, se recopilan suficientes ejemplos que permiten fundamentar una solución.

## Tecnología basada en reglas

La tecnología basada en reglas permite diseñar sistemas mediante un conjunto de reglas predefinidas. Por ejemplo, los programas de tres en raya se crean con reglas que determinan los movimientos necesarios para intentar ganar el juego. Estas reglas las definen personas expertas en el problema que se busca resolver. Los **sistemas de inteligencia artificial** desarrollados con este enfoque también se conocen como "IA tradicional". A diferencia de los sistemas **basados en datos**, que utilizan ejemplos para aprender a resolver problemas, los sistemas basados en reglas son útiles cuando se pueden establecer y seguir reglas que cubren la mayoría de las situaciones posibles.

## Umbral de fiabilidad del aprendizaje automático

El umbral de fiabilidad es un valor que define cuándo se considera aceptable la **predicción** de cualquier **modelo de aprendizaje automático** (AA, conocido como "Machine Learning" o ML en inglés). Este umbral lo establece el desarrollador durante el diseño del modelo. Por ejemplo, si un modelo de AA predice con un 50 % **de fiabilidad** que mañana habrá una tormenta de nieve, pero el umbral de fiabilidad se establece en un 60 %, la predicción se consideraría inexacta. Es decir, solo se aceptan predicciones con una **fiabilidad** del 60 % o más. El umbral se elige en función de la importancia del problema; por ejemplo, los diagnósticos médicos requieren un umbral de fiabilidad más alto que las recomendaciones de canciones. Este valor determina qué nivel de fiabilidad se considera suficiente en cada contexto.

## Visión artificial


La visión artificial es el estudio de sistemas diseñados para procesar información a partir de imágenes o vídeos digitales. El reconocimiento facial, los sistemas de diagnóstico médico por imagen o la videovigilancia son ejemplos de aplicaciones que emplean visión artificial. En el caso de vehículos autónomos, la visión artificial se emplea para detectar y evitar colisiones con otros

objetos. Estos sistemas suelen utilizar **modelos de aprendizaje automático** (AA, conocido como “Machine Learning” o ML en inglés) para identificar patrones en datos visuales. La visión artificial es útil cuando la información de imágenes o vídeos puede ayudar a resolver un problema específico.




Este recurso dispone de licencia de [Raspberry Pi Foundation](https://www.raspberrypi.org/) otorgada bajo licencia pública internacional de Reconocimiento-NoComercial-SinObraDerivada 4.0 de Creative Commons (CC BY-NC-ND 4.0). Consulta [creativecommons.org/licenses/by-nc-nd/4.0](https://creativecommons.org/licenses/by-nc-nd/4.0) para obtener más información sobre esta licencia.

# Experience AI



Raspberry Pi Foundation ha creado este glosario como parte de su programa educativo Experience AI. Más información en [www.experience-ai.org](http://www.experience-ai.org).

Este recurso dispone de licencia de Raspberry Pi Foundation otorgada bajo licencia pública internacional de Reconocimiento-NoComercial-SinObraDerivada 4.0 de Creative Commons (CC BY-NC-ND 4.0). Consulta [creativecommons.org/licenses/by-nc-nd/4.0](http://creativecommons.org/licenses/by-nc-nd/4.0) para obtener más información sobre esta licencia.



**Raspberry Pi**  
Foundation