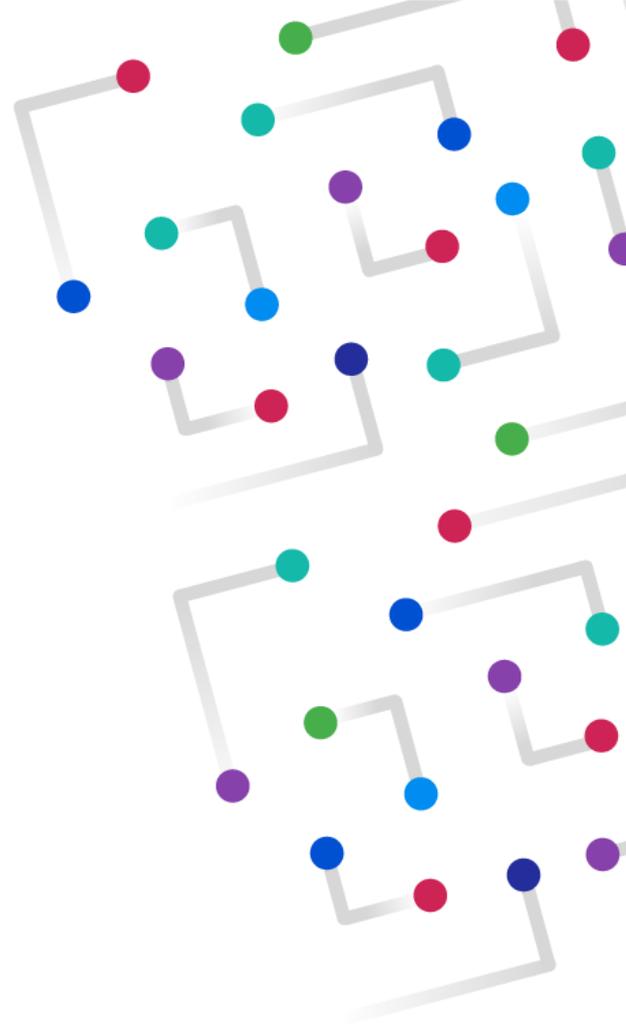


Raspberry Pi
Foundation

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 (ML) que se utilizan en las [Lecciones de Experience AI](#) y en otros materiales.

[Ir al glosario](#)

Estas explicaciones están dirigidas a profesores y docentes, y orientadas a un público joven. Mediante este glosario, queremos ayudarte a reforzar tus competencias sobre estos términos clave, así como a mejorar tus conocimientos técnicos.

El vocabulario es una parte importante de la enseñanza y el aprendizaje. El uso correcto del vocabulario puede ayudar a los alumnos a desarrollar sus conocimientos, mientras que un uso incoherente puede dar lugar a nociones erróneas (confusiones) que pueden dificultar el aprendizaje de los estudiantes. Consulta [nuestra Guía rápida sobre pedagogía para obtener más información sobre el concepto de nociones erróneas](#). Como profesor, el uso frecuente y coherente de vocabulario técnico y preciso puede ayudar a fomentar la comprensión de conceptos por parte de los estudiantes.

Hemos utilizado la teoría de las "olas semánticas" como ayuda a la hora de redactar las explicaciones. De este modo, cada explicación sigue la misma estructura de tres partes: la primera parte es una explicación más abstracta del término, la segunda parte desglosa el significado del término utilizando un ejemplo común y la tercera parte vuelve a hacer referencia a lo explicado en el ejemplo, pero con términos más abstractos para volver a conectar con el vocabulario. 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 agregará, revisará y actualizará junto con la evolución de las lecciones de Experience AI.

Tabla de contenido

[Alfabetización en IA](#)
[Aprendizaje automático](#)
[Aprendizaje no supervisado](#)
[Aprendizaje por refuerzo](#)
[Aprendizaje supervisado](#)
[Árbol de decisión 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 decisión 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 relevante con las aplicaciones de **inteligencia artificial (IA)**, así como con las situaciones en las que se utilizan las aplicaciones de IA. Entre estas competencias se incluyen la comprensión de la IA, la participación en el desarrollo de sistemas de IA y los conocimientos informados sobre las formas en que se utilizan los sistemas de IA en el mundo. Por ejemplo, supongamos que una persona utiliza la alfabetización en IA al evaluar la precisión de la

información que proporciona una aplicación de chatbot de IA. Además de las diferentes formas de interactuar con las aplicaciones de IA, la alfabetización en IA también incluye el potencial de las personas para participar activamente en la decisión de cómo se podrían utilizar los sistemas de IA en su entorno.

Aprendizaje automático

El aprendizaje automático (ML, o “Machine Learning” en inglés) es un enfoque que se utiliza para diseñar y desarrollar sistemas de **inteligencia artificial (IA)**. El aprendizaje automático utiliza ejemplos en forma de **datos** en lugar de ejecutar instrucciones paso a paso para su aprendizaje. En otras palabras, las aplicaciones de ML están **basadas en datos**. Supongamos que tenemos una aplicación de ML que se utiliza para reconocer el habla. La aplicación se basa en ejemplos de habla de muchas personas que hablan con diferentes acentos y tonos de voz. Otras aplicaciones de ML son, por ejemplo, la identificación de objetos en imágenes o los juegos complejos. Cada aplicación de ML 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 (ML)**. Los desarrolladores de ML entrenan modelos de aprendizaje no supervisado para organizar **datos** en función de similitudes. Este proceso permite encontrar patrones ocultos en los datos. La agrupación es un tipo de aprendizaje no supervisado. Un ejemplo de problema de agrupación sería cómo **predecir** la forma en que se pueden agrupar los datos sanitarios para ayudar a diagnosticar enfermedades. Estos conjuntos se denominan grupos y no se conocen de antemano. El modelo de ML se puede utilizar para predecir si los nuevos datos sanitarios pertenecen a uno de los grupos. Los enfoques de aprendizaje no supervisado pueden resultar útiles para resolver problemas en los que las personas no saben qué deben buscar.

Aprendizaje por refuerzo

El aprendizaje por refuerzo es un enfoque que se utiliza para **entrenar modelos de aprendizaje automático (ML)**. Este enfoque se utiliza para resolver problemas con un objetivo claro y se usan recompensas y penalizaciones para alcanzar dicho objetivo. El aprendizaje por refuerzo se utiliza en el diseño de vehículos autónomos o para jugar a juegos complicados. Por ejemplo, puede utilizarse un modelo de aprendizaje por refuerzo para diseñar una aplicación para jugar al ajedrez. El modelo se entrenaría para **predecir** los movimientos que maximicen las recompensas y minimicen las penalizaciones de cara a ganar el juego. Los enfoques de aprendizaje por refuerzo utilizan recompensas y penalizaciones para identificar estrategias para alcanzar un objetivo establecido.

Aprendizaje supervisado

El aprendizaje supervisado es un enfoque que se utiliza para **entrenar modelos de aprendizaje automático (ML)**. En el aprendizaje supervisado se utilizan grandes cantidades de **datos etiquetados** con información relevante por personas. La **clasificación** es un tipo de aprendizaje

supervisado. La identificación de tigres en estado salvaje es un ejemplo de problema de clasificación. Los datos están formados por numerosas imágenes, y las que contienen tigres están etiquetadas como tales.

El modelo de ML se entrena con las imágenes etiquetadas y **predice** si hay un tigre en dichas imágenes. Disponer de imágenes etiquetadas correctamente permite al desarrollador saber hasta qué punto las predicciones del modelo son **precisas** y, de este modo, adaptar el entrenamiento del modelo. A continuación, el modelo de ML se puede utilizar para predecir si hay un tigre en imágenes completamente nuevas. Los enfoques de aprendizaje supervisado dependen de si hay suficientes datos etiquetados correctamente disponibles como para producir predicciones precisas.

Árbol de decisión de aprendizaje automático

El árbol de decisión de **aprendizaje automático (ML)** es un tipo de **modelo** de ML. Los desarrolladores de ML utilizan árboles de decisión para estructurar los conjuntos de condiciones en función de los que se puede hacer una **predicción**. Las condiciones se derivan de **características** de los **datos**. Por ejemplo, se podría utilizar un árbol de decisiones para desarrollar un sistema de recomendación de películas. El modelo de árbol de decisión está **entrenado** a partir de las preferencias cinematográficas de muchas personas. Durante el entrenamiento, las condiciones se generan en función de características como el tipo de película, la duración o el actor principal. El modelo de ML genera una predicción de las películas que le gustaría ver a alguien en función del modo en que sus preferencias siguen las condiciones del modelo. La estructura de los árboles de decisión de ML 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 (ML)**, las características representan rasgos asociados con los **datos**. Por ejemplo, un conjunto de datos musicales puede tener características como, por ejemplo, el ritmo, el tono, la energía o el género. Algunos **modelos** de ML se **entrenan** con características para encontrar similitudes en los datos. Otros **predicen** nuevas características en los datos que la gente no puede observar fácilmente. Elegir qué características usar al entrenar un modelo de ML puede marcar la diferencia en el funcionamiento del modelo.

Ciclo de vida del proyecto de IA

El ciclo de vida del proyecto de **inteligencia artificial (IA)** hace referencia a los distintos pasos que pueden requerir el diseño y el desarrollo de modelo de **aprendizaje automático (ML)**. Entre estos pasos se incluyen la definición del problema, la preparación de los **datos**, el **entrenamiento** del modelo, así como las pruebas, la evaluación y la explicación del modelo. Supongamos, por ejemplo, que un modelo de ML está diseñado para generar nuevas listas de reproducción de canciones. Un desarrollador de ML podría considerar primero el tipo de lista de reproducción que se va a crear. A continuación, podría recopilar y preparar datos de canciones. El modelo de ML se entrena y prueba con los datos de canciones. A continuación, se evalúa el modelo de ML para ver si funciona como se esperaba. Finalmente, se explica el modelo de ML para que otros puedan utilizarlo. Por lo general, los pasos del ciclo de vida del proyecto de IA se utilizan de forma iterativa en lugar de uno

tras otro. El ciclo de vida del proyecto de IA es una serie de pasos iterativos que se utilizan para desarrollar y mejorar modelos de ML.

Clase de aprendizaje automático

Con el fin de **entrenar** a los **modelos de clasificación**, los **desarrolladores de aprendizaje automático (ML)** organizan los **datos** en grupos predefinidos que se conocen como clases. Las clases están predefinidas en función de lo que las personas consideran de utilidad como criterio de agrupación. Imaginemos una aplicación de aprendizaje automático diseñada para identificar frutas en un supermercado. Los datos podrían organizarse en clases de manzanas, plátanos, naranjas, arándanos, etc. Una clase es un grupo de cosas que los modelos de clasificación utilizan para identificar similitudes en los datos.

Clasificación de aprendizaje automático

La clasificación hace referencia a la tarea de asignar cosas a los grupos predefinidos, también conocidos como **clases**. Las clases están predefinidas en función de lo que las personas consideran de utilidad como criterio de agrupación. Un ejemplo de problema de clasificación es el análisis de opiniones de reseñas de canciones. Supongamos que un **modelo** de clasificación de **aprendizaje automático (ML)** se **entrena** con revisiones que los usuarios **etiquetan** como “positivas” o “negativas”. Tras el entrenamiento, el modelo de ML se puede utilizar para **predecir** si una nueva revisión debe clasificarse como “positiva” o “negativa”. De este modo, el modelo de clasificación es capaz de predecir una o varias etiquetas de clase. El enfoque de clasificación es útil para resolver problemas en los que las respuestas se pueden atribuir a los grupos predefinidos.

Datos de entrenamiento de aprendizaje automático

En **aprendizaje automático (ML)**, los datos de entrenamiento hacen referencia a los ejemplos en forma de **datos** que se utilizaron para **entrenar** a los **modelos de ML**. Los desarrolladores de ML crean modelos para determinar patrones en los datos de entrenamiento que pueden usarse para generar **predicciones** sobre nuevos datos. Supongamos que un desarrollador de ML crea una aplicación de reconocimiento de voz. Los datos de entrenamiento pueden incluir ejemplos de habla de muchas personas con diferentes acentos o tonos de voz. Cuanto mejor representen la realidad los datos de entrenamiento, mejor será el rendimiento del modelo.

Datos de prueba de aprendizaje automático

En el **aprendizaje automático (ML)**, los datos de prueba hacen referencia a los **datos** que se utilizan para probar y evaluar **modelos** de ML **entrenados**. Tomemos por ejemplo un modelo de ML entrenado para **predecir** el diagnóstico de una afección médica. Antes de utilizarlo en situaciones de la vida real, el modelo se prueba y evalúa con datos de prueba. Los datos de prueba están separados de los **datos de entrenamiento** con los que se entrenó el modelo de ML. Los datos de

prueba se utilizan para medir el rendimiento de un modelo de ML con ejemplos más allá de los datos de entrenamiento.

Datos

Los datos hacen referencia a valores, mediciones, hechos u observaciones disponibles en formatos que los programas informáticos son capaces de procesar. Existen numerosos tipos de datos, como, por ejemplo, el texto, las imágenes o el sonido. Un ejemplo de datos de texto son los mensajes que las personas intercambian con sus amigos con sus dispositivos digitales. En **aprendizaje automático (ML)**, los datos representan los ejemplos con los que se **entrenan** los **modelos** de ML. La recopilación, **depuración** y estructuración de grandes cantidades de datos son actividades esenciales en el diseño de modelos de ML.

Depuración de los datos

La depuración de los datos es un paso de preparación de **datos** que se utiliza para **entrenar un modelo de aprendizaje automático (ML)**. La depuración de datos implica identificar y corregir errores en los datos. Por ejemplo, corregir errores tipográficos o eliminar duplicados en datos de texto son dos tareas sencillas de depuración de datos. En la mayoría de los casos, los datos son confusos y requieren una depuración más compleja antes de que se puedan usar para entrenar modelos de ML. Existen muchas formas de depurar los datos en función del problema y el tipo de datos. El uso de datos depurados es de vital importancia para crear modelos de aprendizaje automático **precisos**.

Entrenamiento de aprendizaje automático

Los **modelos de aprendizaje automático (ML)** se entrenan con ejemplos en forma de **datos** para encontrar patrones y crear **predicciones**. Durante el entrenamiento, los patrones se ajustan para mejorar las predicciones. Supongamos que un desarrollador de ML crea un modelo para recomendar canciones. El modelo de ML se entrenará en las elecciones de canciones de muchas personas para encontrar similitudes de preferencias de reproducción de diferentes personas. Cuanto mayor sea la diversidad de opciones de canciones con las que se entrene el modelo, mejor será la predicción de la canción recomendada. Hay muchas formas diferentes de entrenar modelos de ML con diferentes tipos de datos. 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 (ML)** se **entrenan** con **datos** etiquetados. Cada dato tiene una o más etiquetas anotadas que proporcionan información sobre los datos. Supongamos que tenemos un modelo de ML diseñado para identificar sonidos de pájaros. Cada sonido está etiquetado con el nombre del pájaro que emitió el sonido. Al entrenar el modelo de ML con los sonidos etiquetados, este será capaz de **predecir** la etiqueta (nombre del

pájaro) de los nuevos sonidos. La mayoría de las veces, las personas etiquetan los datos para proporcionar ejemplos precisos con los que entrenar los modelos de ML.

Explicabilidad del aprendizaje automático

La explicabilidad hace referencia a la capacidad de algo para que se pueda comprender. En **aprendizaje automático (ML)**, la explicabilidad ayuda a las personas a comprender cómo se produjo una **predicción**. Por ejemplo, los **modelos de árbol de decisiones** son explicables porque los **nodos** se pueden analizar de una manera que las personas pueden comprender. La mayoría de los modelos de ML no son completamente explicables y algunos son más explicables que otros. Aumentar la explicabilidad de un modelo puede ayudar a solucionar problemas y combatir el **sesgo**.

Fiabilidad del aprendizaje automático

La fiabilidad se refiere a la seguridad que ofrece algo. En el **aprendizaje automático (ML)**, la fiabilidad es una forma de medir la certeza de una **predicción**. Tomemos, por ejemplo, un **modelo de clasificación** que está diseñado para predecir si lloverá mañana. El modelo es capaz de predecir con un 90 % de fiabilidad que mañana lloverá. En otras palabras, hay un 90 % de certeza de que mañana lloverá. Usar la fiabilidad para medir la certeza de las predicciones ayuda a evaluar la calidad de un modelo de ML.

IA generativa

La IA generativa es un tipo de inteligencia **artificial (IA)** diseñada para generar contenido, como, por ejemplo, texto, imágenes o sonido. Hay muchas aplicaciones que utilizan IA generativa, como la producción de arte o música, o la generación de texto para chatbots. Por ejemplo, las aplicaciones de arte de IA generativa pueden crear una imagen a partir de mensajes, como, por ejemplo, "crea una imagen de un dragón leyendo un libro". El arte de IA generativa se crea utilizando **modelos de aprendizaje automático entrenados** con millones de imágenes de obras de arte existentes. Las imágenes resultantes pueden reproducir el estilo de un artista, sin que el artista original lo sepa o lo apruebe. Las aplicaciones de IA generativa son cada vez más comunes y, a menudo, es imposible saber si se ha utilizado IA generativa para crear el contenido.

Inteligencia artificial

La inteligencia artificial (IA) es el diseño y estudio de sistemas que imitan comportamientos inteligentes. Algunas aplicaciones de IA se basan en reglas. Actualmente, las aplicaciones de IA se crean cada vez más mediante **aprendizaje automático**, es decir, que "aprende" de ejemplos que se proporcionan en forma de **datos**. Por ejemplo, algunas aplicaciones de IA están diseñadas para responder preguntas o ayudar a diagnosticar enfermedades. Otras aplicaciones de IA pueden crearse con fines dañinos, como la difusión de noticias falsas. Las aplicaciones de IA no piensan. Las aplicaciones de IA están diseñadas para realizar tareas de una manera que parece inteligente.

Modelo de aprendizaje automático

Las aplicaciones de ML utilizan los modelos de **aprendizaje automático (ML)** para completar tareas o resolver problemas. El modelo de ML es una representación del problema que se va a resolver. Los desarrolladores de ML utilizan grandes cantidades de **datos** representativos de problemas específicos para **entrenar** los modelos para detectar patrones. El resultado del entrenamiento es un modelo, que se utiliza para hacer **predicciones** sobre nuevos datos con el mismo contexto. Por ejemplo, los vehículos autónomos se desarrollan utilizando modelos ML capaces de predecir cuándo detenerse. Los modelos se entrenan con millones de ejemplos de situaciones en las que los automóviles deben detenerse. Existen numerosos tipos de modelos distintos que utilizan diferentes tipos de datos y distintas formas de entrenar los modelos. 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 decisión de aprendizaje automático

Los **árboles de decisión de aprendizaje automático (ML)** se componen de nodos. A su vez, los nodos están vinculados para formar una estructura según la cual se puede generar una **predicción**. Hay dos tipos de nodos: los nodos de decisión y los nodos de hoja. Supongamos que tenemos un árbol de decisión diseñado para predecir los tipos de estrellas que existen 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 representan los tipos de estrellas en forma de **etiquetas** de predicción, como, por ejemplo, "Enana roja", "Enana blanca" o "Enana marrón". Los nodos del árbol de decisión forman la estructura necesaria para que un **modelo** de ML genere una predicción.

Precisión del aprendizaje automático

El concepto de precisión hace referencia a la exactitud de las cosas. En **aprendizaje automático (ML)**, la precisión permite medir la frecuencia con la que un **modelo** de ML realiza una **predicción** correcta. Supongamos que tenemos un modelo de **clasificación** diseñado para clasificar manzanas. El modelo clasifica correctamente 90 de cada 100 imágenes de manzanas. En este caso, la precisión de clasificación del modelo es del 90 %. La precisión es una forma de evaluar los modelos de ML. La precisión se utiliza a menudo con otras medidas para evaluar la calidad de un modelo.

Predicción del aprendizaje automático

Los **modelos de aprendizaje automático (ML)** están **entrenados** para hacer predicciones. La predicción que produce un modelo de ML recomienda lo que representan los **datos** o lo que puede resultar útil para una tarea. Por ejemplo, un desarrollador de ML podría entrenar un modelo para predecir qué película puede querer ver a continuación un usuario en función de sus hábitos de visualización. De este modo, el modelo generará una predicción después de haberse entrenado con las elecciones de películas de muchas personas. La función principal de los modelos de ML es hacer predicciones. Todos los modelos de ML hacen predicciones, incluso si en algunos casos estas predicciones no son obvias para el usuario.

Sesgo de datos

El sesgo de datos hace referencia al **sesgo** que se observa en los **datos** que se utilizaron para **entrenar los modelos de aprendizaje automático (ML)**. El sesgo de datos puede dar lugar a modelos de aprendizaje automático que generan **predicciones** sesgadas tras el entrenamiento. Por ejemplo, algunos modelos de reconocimiento facial pueden mostrar sesgo con rostros de determinados tonos de piel por el hecho de haber entrenado los modelos de ML con imágenes de rostros de un tono de piel. Existen varias fuentes posibles de sesgo de datos. Entre estas, se incluyen los datos incompletos y los datos que reflejan **sesgo social**. Detectar el sesgo de los datos es importante para evitar que los modelos de ML generen predicciones sesgadas.

Sesgo social

El sesgo social hace referencia al **sesgo** que tiene un gran grupo de personas o la sociedad en general. Existen numerosos tipos de prejuicios sociales, como, por ejemplo, el prejuicio racial, de género o étnico. Un ejemplo de sesgo de género es la idea de que las mujeres están menos preparadas que los hombres para las carreras de ingeniería. Los **datos** recopilados de grandes grupos de personas pueden reflejar sesgos sociales, lo que resultaría en un **sesgo de datos**. Si se utilizan datos que reflejan un sesgo social para **entrenar modelos de aprendizaje automático (ML)**, esto podría dar lugar a modelos que generan **predicciones sesgadas**. En ML, es importante mitigar el sesgo social reflejado en los **datos de entrenamiento** para evitar resultados discriminatorios o injustos.

Sesgo

El sesgo no es otra cosa que una preferencia a favor o en contra de algo. Por ejemplo, un estudiante puede preferir las lecciones de inglés en lugar de las de matemáticas y dedicar más tiempo a sus tareas de inglés. En otras palabras, este estudiante tiene un sesgo hacia la asignatura de inglés. Existen numerosos tipos de sesgo, como, por ejemplo, el **sesgo social** y el **sesgo de datos**. Los desarrolladores de **aprendizaje automático (ML)** deben tener cuidado y evaluar si los **datos** que van a utilizar para **entrenar** a los **modelos** de ML tienen algún tipo de sesgo. El sesgo puede otorgar ventaja a personas, grupos o conjuntos de ideas o creencias en detrimento de otros.

Tarjeta de modelo de aprendizaje automático

Una tarjeta de modelo de **aprendizaje automático (ML)** es una manera de documentar información esencial sobre los **modelos** de ML de forma estructurada. Los desarrolladores de ML escriben las tarjetas de modelo de ML tanto para usuarios expertos como para no expertos. Supongamos por ejemplo que se desarrolla una aplicación de ML para traducir diferentes idiomas, como del árabe al francés y viceversa. La tarjeta de modelo incluye información sobre la **precisión** de la traducción del modelo, así como el rendimiento del modelo con el argot, la jerga y los dialectos. Otra información de la tarjeta de modelo puede incluir el tipo de modelo de ML, diferentes indicadores de rendimiento e incluso el **sesgo** conocido. Las tarjetas de modelo se crean durante la etapa de explicación del **ciclo de vida del proyecto de IA** para exponer información sobre las capacidades y limitaciones del modelo de una manera que resulte fácil de comprender.

Tecnología basada en datos

La tecnología basada en datos es una manera de diseñar sistemas que utilizan **datos** en lugar de instrucciones paso a paso. Por ejemplo, saber cuál es la causa de determinadas enfermedades es difícil; sin embargo, hay muchos datos de ejemplo. Por ello, los diseñadores utilizan los datos médicos de personas afectadas por las distintas enfermedades para diagnosticarlas. Los sistemas basados en datos contrastan con los sistemas **basados en reglas**. Los sistemas basados en datos son adecuados para resolver problemas en los que es difícil producir reglas que cubran todas las situaciones. En su lugar, se pueden recopilar suficientes ejemplos para fundamentar una solución.

Tecnología basada en reglas

La tecnología basada en reglas es una forma de diseñar sistemas mediante un conjunto de reglas predefinidas. Por ejemplo, los programas de tres en raya se diseñan mediante reglas que determinan los movimientos que se deben realizar para intentar ganar el juego. Las reglas las definen humanos que suelen ser expertos en el dominio del problema que se debe resolver. Los **sistemas de inteligencia artificial (IA)** desarrollados con un enfoque basado en reglas también se conocen como "IA tradicional". Los sistemas basados en reglas contrastan con los sistemas **basados en datos**, en los que los **datos** se utilizan como ejemplos de cómo resolver el problema. Los sistemas basados en reglas son útiles para resolver problemas en los que se pueden producir y seguir reglas que cubren la mayoría de las situaciones.

Umbral de fiabilidad del aprendizaje automático

El umbral de fiabilidad hace referencia a un valor establecido para la aceptación de las **predicciones de cualquier modelo de aprendizaje automático (ML)**. El desarrollador de ML es quien elige el umbral de fiabilidad durante el diseño del modelo de ML. Por ejemplo, supongamos que un modelo de ML predice con un 50 % **de fiabilidad** de que mañana habrá una tormenta de nieve. Sin embargo, si el umbral de fiabilidad se establece en un 60 %, la predicción se consideraría inexacta. En otras palabras, a menos que la fiabilidad de la predicción sea del 60 % o más, esta no se aceptaría como **precisa**. El valor se establece según la naturaleza del problema que se va a

resolver. De este modo, las predicciones de diagnóstico médico requieren un umbral de fiabilidad más alto que las recomendaciones de canciones. El valor de umbral elegido determina cuál es un nivel aceptable de fiabilidad en la predicción.

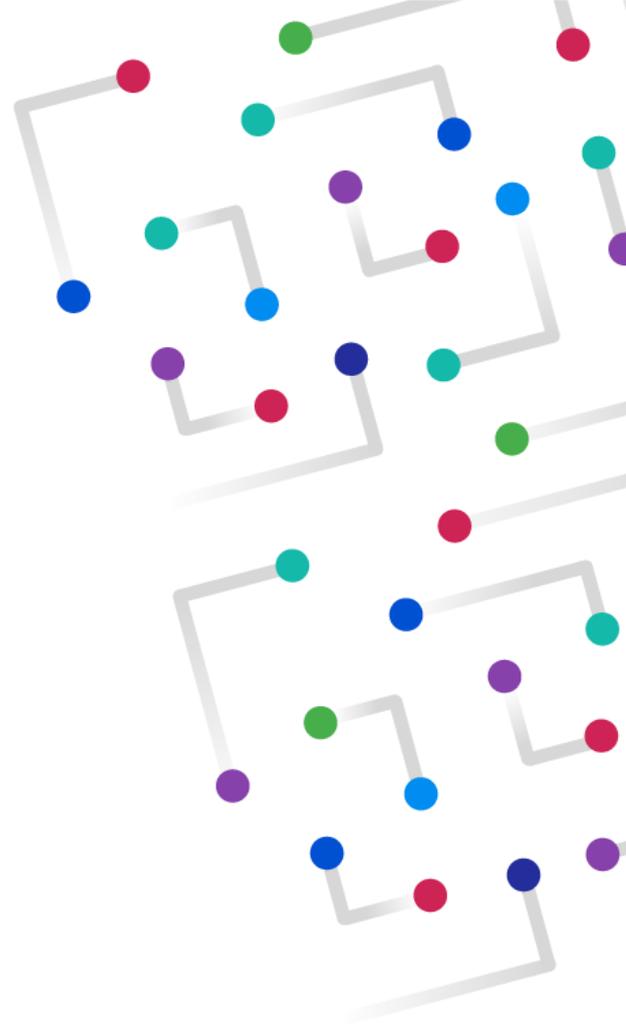
Visión artificial

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. La visión artificial se utiliza, por ejemplo, en el diseño de vehículos autónomos para detectar y evitar colisionar contra otros objetos. Muy a menudo, los sistemas de visión artificial utilizan **modelos de aprendizaje automático** para identificar patrones en los datos de imágenes y vídeos. Los sistemas de visión artificial son útiles cuando la información de las imágenes o vídeos digitales se puede utilizar para resolver un problema.



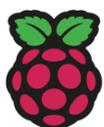
Este recurso dispone de licencia de [Raspberry Pi Foundation](https://www.raspberrypi.org/) otorgada bajo licencia pública internacional de Reconocimiento-NoComercial-SinObraDerivada 4.0 de Creative Commons (CC BY-NC-ND 4.0). Consulta creativecommons.org/licenses/by-nc-nd/4.0 para obtener más información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

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 para obtener más información sobre esta licencia.



Raspberry Pi
Foundation