

Fomentando la Inteligencia Artificial en las Escuelas

Directrices para profesores de educación formal



Tabla de contenidos

Introducción	4
¿Por qué necesitamos enseñar sobre inteligencia artificial?	4
Cómo usar este documento	5
Conocimientos previos	6
¿Qué es la IA?	6
¿Qué son los datos?	9
¿Qué es el sesgo y el sesgo algorítmico?	9
¿Qué es un algoritmo?	11
¿Cuáles son los diferentes subcampos de la IA?	11
Representación del conocimiento y razonamiento (sistemas expertos)	11
Planificación automatizada	12
Aprendizaje automático	12
Aprendizaje por refuerzo	12
Percepción de la máquina	13
Procesamiento natural del lenguaje	13
Robótica	13
Aprendizaje automático	14
Aprendizaje supervisado	15
Aprendizaje no supervisado	16
Aprendizaje por refuerzo	16
Clasificación	17
Preparar datos	17
Entrenamiento	18
Probar el modelo	18
Desplegar el modelo	18
Nota importante sobre la elección de los datos de entrenamiento	19
Introducción a la herramienta LearningML	20
Demo de la herramienta LearningML	20
Introducción al aprendizaje automático supervisado	23
Lecciones relacionadas con el sesgo algorítmico	32
Actividad uno: Clase genérica sobre sesgo algorítmico	32
Actividad dos: Ciencias sociales	39
Lecciones específicas para las materias del aula	43
Lecciones específicas de LearningML	43
Matemáticas	43
Edificios religiosos	52
Herramientas adicionales	55
Música	55
Glosario	56
Bibliografía relacionada	58

Impresión

2023: El proyecto FAIaS

Redacción: Universidade Rey Juan Carlos (ES), Vrije Universiteit Brussel (BE), CollectiveUP (BE), Teatro Circo Braga (PT).

Autores: Gregorio Robles, Meritxell Díaz, Antonio J. Romero (Universidad Rey Juan Carlos), Marjon Blondeel (Vrije Universiteit Brussel), Liliana Carrillo, Chrysanthi Katrini, Loredana Bucseneanu (CollectiveUP), Joana Miranda y Sara Borges (Teatro Circo Braga). Revisado por Brian Chen (Massachusetts Institute of Technology).

Maquetación: Jurate Laugalyte (CollectiveUP), Carlos Nivia Otero (CollectiveUP).

Sugerimos citar este informe de la siguiente manera: Robles, Díaz, Romero, Blondel, et al. (2023). Fomentando la Inteligencia Artificial en las Escuelas: Directrices para profesores de educación formal. <http://www.fosteringai.net>

Esta publicación ha sido creada por el proyecto Erasmus+ Fostering AI at Schools, cuyo objetivo es ayudar a los educadores a integrar y utilizar conceptos de Inteligencia Artificial (IA) en sus lecciones mediante la creación y el intercambio de recursos sobre IA que se pueden utilizar en el aula.

CollectiveUP agradece al Digital Belgium Skills Fund (DBSF) por cofinanciar el proyecto AI4InclusiveEducation (www.ai4inclusiveeducation.be) con un número de subvención DBSF2023-14. DBSF cofinanció y apoyó parcialmente la realización del proyecto Erasmus+ FAIAS creando un impacto en Bélgica.

Esta publicación (en inglés, español, holandés y portugués) y otras publicaciones y herramientas producidas en el proyecto se pueden descargar de forma gratuita en: www.fosteringai.net

Este trabajo está bajo una licencia internacional Creative Commons Attribution-ShareAlike 4.0. Para ver una copia de esta licencia, visite <http://creativecommons.org/licenses/by-sa/4.0/>




Descargo de responsabilidad

Fostering AI at Schools es un proyecto de asociación cofinanciado a través de la Comisión Europea. Esta publicación refleja únicamente las opiniones de los autores, y la Comisión Europea no se hace responsable del uso que pueda hacerse de la información contenida en el mismo.

Fostering Artificial Intelligence at School – Proyecto Erasmus+, tipo de acción “Asociaciones de cooperación en Educación escolar”, Número de subvención: 2020-1-ES01-KA201-083047.

Créditos de imágenes

Portada y contraportada – Diseño propio, utilizando imagen creadas [por Freepik](#) y [por kjpargeter](#)
Paginas 4, 6, 20, 43 – Imagen de cabecera creada [por kjpargeter](#)



Introducción

¿Por qué necesitamos enseñar sobre inteligencia artificial?

A menudo pensamos en la Inteligencia Artificial (IA) como una misteriosa caja negra. Sin embargo, se encuentra a nuestro alrededor y la usamos todos los días: filtros de spam, chatbots en línea, motores de búsqueda, videojuegos que anticipan nuestros próximos movimientos, aplicaciones de navegación, aplicaciones de viajes compartidos, solo por nombrar algunos. Los procesos y conceptos subyacentes rara vez se exponen a la mayoría de las personas, lo que dificulta comprender qué es la IA y cómo se debe abordar. Sin embargo, entender los conceptos fundamentales se está volviendo muy importante para las personas de todas las edades, incluidos los niños que crecen en un entorno que integra más productos de IA que nunca. Además, los niños y estudiantes de hoy ingresarán en un entorno laboral más impulsado por IA. Ignorar la IA se puede comparar con ignorar Internet en la década de los 90. Al llevar la IA al aula, los estudiantes pueden comprender el impacto potencial de la IA en su vida diaria. También les permite comprender el papel de la IA y las consideraciones éticas.

Conocer los aspectos e impacto de la IA es de gran importancia para los docentes. En primer lugar, porque es una realidad a la que los alumnos tienen que acostumbrarse. Esto debe verse como una oportunidad, ya que pueden incluir técnicas de IA en sus clases, tal como se utilizan en entornos profesionales y académicos. En segundo lugar, porque deben ser conscientes del uso potencial y del pernicioso de la IA. Como responsables de desarrollar las habilidades de sus alumnos, necesitan saber cómo se puede utilizar la IA para ese propósito. Deben ser ellos los que consigan que los alumnos adquieran capacidades que son innatas al ser humano y que no pueden ser sustituidas con el uso de la IA. Entre estas habilidades se encuentran, por ejemplo, el pensamiento crítico o la identificación de sesgos.

Cómo usar este documento

Este documento se plantea como un punto de partida básico para comprender qué es la IA (y, en particular, el aprendizaje automático) y cómo aplicarlo a sus lecciones, ofreciendo planes de lecciones genéricos y específicos.

En particular, el esquema de este documento es el siguiente:

En la sección de introducción se realiza una aproximación de los siguientes conceptos:

- Una introducción a la IA, datos, algoritmos y sesgo (algorítmico).
- Una visión general de los diferentes subcampos de IA.
- Una introducción al aprendizaje automático, con ejemplos e ilustraciones.
- Una introducción más profunda a la clasificación y cómo se entrenan los modelos de IA para realizar la clasificación.

En la siguiente sección presentamos cómo utilizar en el aula la herramienta del proyecto LearningML. A continuación, en la tercera sección damos una visión general de planes de lecciones genéricos y específicos. Los planes de lecciones genéricos se pueden adaptar a diferentes temáticas, pudiendo ajustarse a diferentes lecciones. En la siguiente sección se presentan los planes de lecciones específicas que se centran en un contenido concreto, generalmente vinculado a un tema en particular, como una asignatura concreta. Los planes didácticos específicos siguen la misma estructura, y han sido pensados para adaptarse a tus necesidades (duración, edad, etc.). En particular, se proponen un conjunto de actividades sobre el concepto de sesgo. Hemos apartado estas actividades de las lecciones porque pensamos que permiten desarrollar el pensamiento crítico de los estudiantes, que más allá de comprender qué es la IA y cómo funciona o se puede aplicar, es de gran importancia. También encontrará algunas herramientas adicionales que se pueden utilizar en el aula.

Finalmente, la última sección recoge un glosario con los conceptos más relevantes de IA y aprendizaje automático explicados a lo largo de esta memoria.

Conocimientos previos

Este capítulo introduce y detalla algunos conceptos necesarios para poder entender la terminología utilizada a lo largo de las actividades indicadas en este documento. La estructura es la siguiente:

Primero,

se explicarán algunos conceptos clave, como comprender qué es la IA, qué son los algoritmos y qué es el sesgo (algorítmico). También se proporciona una descripción general de los subcampos de la IA.

En segundo lugar,

se proporciona una explicación detallada de una de las subramas más importantes de la IA, el aprendizaje automático (ML, en inglés).

Finalmente,

analizamos la clasificación y la usamos para explicar los pasos básicos necesarios para crear un modelo de ML: selección de datos, capacitación y prueba.

¿Qué es la IA?

La inteligencia artificial (IA) es una disciplina de la informática que trata de replicar y desarrollar la inteligencia humana y sus procesos implícitos a través de las computadoras. El término fue acuñado en 1956 en la Conferencia de Dartmouth por el renombrado informático John McCarthy, aunque algunas primeras menciones se remontan a poco después de la Segunda Guerra Mundial.

Aunque no hay acuerdo sobre una definición única de IA, sí hay consenso sobre cuatro enfoques principales: dos de ellos se basan en humanos (sistemas que piensan como ellos y sistemas que actúan como ellos) y dos en aspectos racionales (sistemas que piensan racionalmente y sistemas que actúan racionalmente).

La IA sintetiza y automatiza tareas que inicialmente son intelectuales y, por lo tanto, pueden considerarse potencialmente relevantes para cualquier campo de la actividad intelectual humana. Estamos hablando de un campo genuinamente universal.

Por lo tanto, la IA es la combinación de algoritmos diseñados para crear máquinas que tengan las mismas capacidades que los seres humanos. Los informáticos Stuart Russell y Peter Norvig distinguen entre cuatro tipos principales de IA:

1. Sistemas que piensan como humanos

Automatizan actividades como la toma de decisiones, la resolución de problemas y el aprendizaje. Un ejemplo son las redes neuronales artificiales ilustradas en la Figura 1.

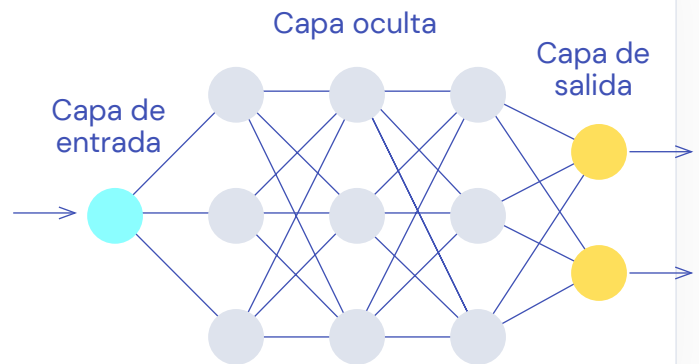


Figura 1. Diagrama de flujo de trabajo de una Red Neuronal.

2. Sistemas que actúan como humanos

Estos son ordenadores que realizan tareas de manera similar a las personas. Es el caso de los robots.

3. Sistemas que piensan racionalmente

Tratan de emular el pensamiento lógico racional de humanos, es decir, se investiga cómo hacer que las máquinas perciban, razonen y actúen en consecuencia. Los sistemas expertos pertenecen a este grupo, la Figura 2 muestra un esquema de sus componentes.

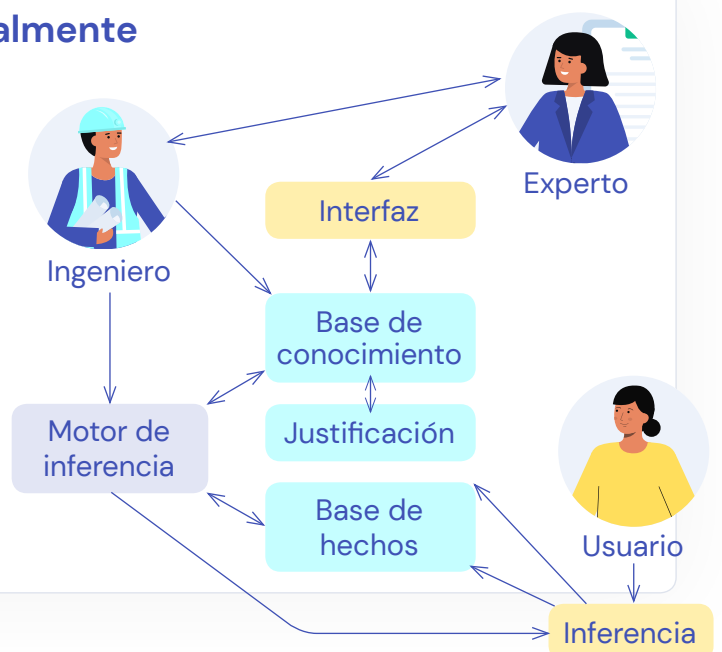
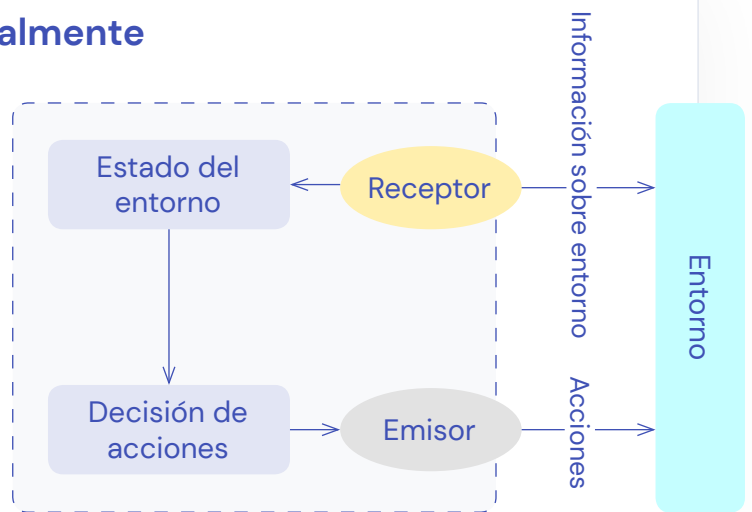


Figura 2. Diagrama de flujo de trabajo de sistemas expertos.

4. Sistemas que actúan racionalmente

Idealmente, estos son sistemas que tratan de imitar racionalmente el comportamiento humano produciendo algún tipo de cambio en el medio ambiente. La Figura 3 muestra un esquema de los componentes de un agente inteligente.

Figura 3. Diagrama de los componentes de un agente inteligente.




Para mostrar la importancia de la IA, La Figura 4 muestra algunas de las aplicaciones de la IA y los ingresos estimados que se producirán en un periodo de tiempo de 9 años.

Como vemos, la IA es un elemento clave en la actualidad y es necesario conocer el concepto y sus posibles aplicaciones.

Figura 4. Aplicaciones de la Inteligencia Artificial (Fuente: Tractica).

Ingresos globales estimados de la IA de 2016 a 2025 (en millones de €)




¿Qué son los datos?

AI, y en particular ML, hace un uso intensivo de datos. Usando la analogía atómica, la unidad más pequeña de los datos es el dato. Un dato es una representación simbólica de un atributo o variable cuantitativa o cualitativa. Los datos describen hechos empíricos, eventos y entidades. La naturaleza de un dato puede ser numérica, alfabética, algorítmica (hablaremos de ella más adelante), o espacial, entre otras.

Aunque hoy en día escuchamos muy a menudo sobre el valor de los datos, por sí mismos pueden no contener información humanamente relevante. Solo cuando esos datos se examinan de forma conjunta a la luz de un enfoque, hipótesis o teoría, se puede apreciar la información contenida en los datos. Es por ello que los datos debidamente agrupados, estructurados e interpretados se consideran la base de información humanamente relevante que se puede utilizar para tomar decisiones, reducir la incertidumbre o realizar cálculos. Esta es la razón por la que muchos consideran los datos como el petróleo de las máquinas más relevantes de este siglo, las computadoras.

En la Figura 5 podemos ver, de forma simplificada, la necesidad de procesar los datos, siendo el objetivo final obtener información para extraer el conocimiento subyacente en los datos.

Figura 5. Diagrama de la forma de adquirir conocimiento.



Consideraremos los datos como la entrada en nuestras actividades de IA. Las computadoras aprenderán de los datos y reflexionarán en base a ellos. Si no utilizamos los mejores datos o nuestros datos están sesgados, es posible que tengamos sesgos, lo que podría influir en gran medida en nuestros resultados, especialmente si los humanos se ven afectados. Hablaremos más sobre el sesgo en este documento y, dada su relevancia, ofrecemos varias actividades para trabajar este concepto con sus alumnos.

¿Qué es el sesgo y el sesgo algorítmico?

Toda persona tiene sesgos: son tendencias, inclinaciones o prejuicios hacia o en contra de alguien o algo. Algunos de ellos son positivos y útiles. Por ejemplo, suponga que se le acerca un extraño que tiene un cuchillo en la mano. En este escenario es bueno ser aprensivo. Otro ejemplo es cuando elige comer solo alimentos que se consideran saludables.

Sin embargo, la mayoría de las veces, los sesgos dan como resultado prejuicios que conducen a la discriminación y decisiones precipitadas. Un ejemplo típico es cuando un gerente entrevista a personas para un puesto vacante. Al gerente le gusta inmediatamente la primera persona cuando la conoce por primera vez. Durante la entrevista, sin embargo, el candidato parece nervioso y el gerente le dice que se calme y que comience de nuevo. Después de eso, la entrevista fue genial. Un par de horas más tarde, el gerente entrevista a otra persona, pero inmediatamente se desanima por una primera impresión. En este caso la persona también está nerviosa pero no recibe ninguna palabra de aliento o consuelo. La entrevista salió muy mal. Las primeras impresiones marcan una gran diferencia.

Los sistemas automatizados no son inherentemente neutrales. Los ordenadores deben ser codificados por personas y, como consecuencia, reflejan prejuicios y preferencias de quienes crean esos algoritmos de IA detrás de estos sistemas. A continuación, enumeramos algunos ejemplos de posibles causas de sesgo en la IA.

Una forma muy común en que se introduzca el sesgo en los sistemas de IA es debido a datos sesgados. Por ejemplo, suponga que desea automatizar el proceso de decisión de si un solicitante es aceptado en su universidad o facultad. Suponga que en el pasado ha admitido principalmente a hombres. Si utiliza estos datos históricos para entrenar el nuevo sistema, es probable que se replique este sesgo de género.

Cuando se utilizan datos del mundo real, como artículos de noticias o publicaciones en redes sociales, es probable que los sistemas de IA refuercen los prejuicios existentes. Las aplicaciones de sistemas de traducción automática, por ejemplo, tienden a estar sesgadas en contra de las mujeres cuando se traducen de idiomas que usan pronombres neutros en cuanto al género. Ejemplos típicos son “ella cuida de los niños” y “él invierte”.

Por ello, es especialmente importante la forma en que se recopilan los datos. Tanto el submuestreo como el sobremuestreo pueden generar sesgos. Un ejemplo de submuestreo es cuando los sistemas de detección de rostros se entrenan principalmente en rostros masculinos blancos y, como consecuencia, no reconocen los rostros femeninos más oscuros tan bien como los rostros masculinos más claros. El sobremuestreo, por otro lado, puede conducir a una sobrerrepresentación de ciertos grupos. Por ejemplo, los delitos cometidos en áreas frecuentadas por la policía estarán más presentes en el conjunto de datos y el modelo de IA entrenado en los datos probablemente reflejará esta desproporción y estas áreas se etiquetarán como más peligrosas.

Las personas también pueden reforzar el sesgo en los modelos de IA ya implementados. Por ejemplo, es posible que un sistema de IA esté mostrando anuncios de una tarjeta de crédito de alto interés a personas con un nivel educativo más bajo. Es posible que hagan clic en este anuncio sin darse cuenta de que esto reforzará el sesgo ya existente y seguirán recibiendo tales sugerencias.

¿Qué es un algoritmo?

Un algoritmo es un conjunto de instrucciones o reglas definidas y no ambiguas, ordenadas y finitas que permiten resolver un problema. En nuestro caso, los ordenadores usan algoritmos para procesar datos y realizar otras tareas como la clasificación. No solo las computadoras usan algoritmos; por ejemplo, en la cocina los humanos también los usan pero en forma de recetas. En el caso de las computadoras, los ingredientes son los datos y la receta es el algoritmo.

¿Cuáles son los diferentes subcampos de la IA?

La IA ha evolucionado enormemente desde 1956, cuando un pequeño grupo de científicos se reunió para el Proyecto de Investigación de Verano de Dartmouth sobre Inteligencia Artificial, que ahora se considera el nacimiento de este campo de investigación. Hoy en día, cuando escuchas sobre la IA en los medios, principalmente hacen referencia a algoritmos que aprenden de muchos datos o incluso de experiencias. Sin embargo, la IA es mucho más que eso e incluye varios subcampos. En esta sección intentaremos dar una visión general de los diferentes subcampos. Esta es una tarea muy difícil; La IA se superpone con otros campos de investigación, como la informática, las matemáticas, la psicología, la biología y muchos más. Algunas de las líneas de investigación también se han convertido en campos propios, como el procesamiento del lenguaje natural. Además, la mayoría de los diferentes subcampos se superponen. Finalmente, en la práctica, la mayoría de las aplicaciones siguen un enfoque híbrido y usan ideas y técnicas de varios subcampos.

Representación del conocimiento y razonamiento (sistemas expertos)

Este subcampo ha existido desde los primeros días de la IA. Se ocupa de representar información de manera que una computadora pueda razonar sobre ella usando reglas, por ejemplo, la lógica, sin necesidad de escribir código que resuelva el problema. Las aplicaciones incluyen tareas complejas como programar o resolver sudokus. Como entrada, estos sistemas toman una descripción del problema, y la maquinaria interna le dará sentido al problema y generará posibles soluciones. Una característica importante de estos algoritmos es su fácil entendimiento: siempre hay un razonamiento detrás de ellos. Por supuesto, el mundo es muy complejo y no se puede describir completamente en reglas. Estos algoritmos son en su mayoría adecuados en dominios muy cerrados. Nunca se podrá construir un buen automóvil autónomo solo con este tipo de algoritmos.

Planificación automatizada

La planificación automatizada es otro subcampo de la IA que está estrechamente relacionada con la representación y el razonamiento del conocimiento. Una aplicación típica es la planificación de rutas (óptimas) para robots en un almacén. Estos algoritmos calculan rutas utilizando una representación del almacén como entrada. Nuevamente, estos algoritmos son transparentes, pero pueden volverse muy ineficientes en situaciones en las que tenemos varios robots en un almacén relativamente pequeño. Una ventaja es que estos algoritmos seguirán funcionando cuando modifique el diseño del almacén, no tendrá que cambiar nada.

Aprendizaje automático

Como se mencionó antes, el mundo es demasiado complejo para describirlo con reglas. La idea del ML no es programar estas reglas nosotros mismos, sino dejar que la computadora aprenda (algunas de) estas reglas. En ML, una computadora, o algoritmo, aprenderá de datos, como por ejemplo numéricos o imágenes. En esencia, estos algoritmos intentan encontrar patrones en los datos: al ver muchas imágenes que contienen gatos, aprenderá a decidir si una imagen nueva contiene un gato o no. Los ordenadores son realmente buenos para encontrar patrones de esta manera, pero al contrario de la planificación y la presentación del conocimiento, estas técnicas no son transparentes: se está aprendiendo una regla, pero esta regla no tiene ningún significado.

El aprendizaje automático a menudo se combina con otras técnicas. Un ejemplo es cuando es necesario responder preguntas sobre imágenes. Suponga que desea saber cuántos gatos hay en una imagen. ML podrá reconocer gatos en las imágenes, pero es muy difícil saber cuántos gatos hay. Por lo tanto, es mucho más fácil usar ML para detectar gatos y luego usar la lógica y las reglas para contarlos.

En los medios de comunicación, a menudo se habla sobre el aprendizaje profundo. Este es un subcampo del ML. La principal diferencia es que necesita menor intervención humana, puede trabajar con datos sin procesar (p. ej., píxeles en una imagen) y puede aprender de sus propios errores. La desventaja es que se necesita una gran cantidad de datos, lleva mucho tiempo aprender algo significativo y se necesita una infraestructura especializada.

Aprendizaje por refuerzo

El aprendizaje por refuerzo puede verse como una rama del ML, pero ha crecido tanto que se ha convertido en un campo propio. La principal diferencia con ML es que estos algoritmos aprenden de la interacción y no de los datos. Por ejemplo, nuestro automóvil autónomo de antes no funcionaría bien usando solo ML. Para ello, sería necesario adquirir datos de situaciones pasadas para que nuestro coche pudiera aprender a actuar. Esta es una tarea inviable: es imposible destilar una lista representativa de situaciones. Aquí es donde entra en juego el aprendizaje por refuerzo. Estos algoritmos aprenden qué acciones tomar al interactuar con el mundo. Se basa en la idea del aprendizaje por ensayo y error y está estrechamente relacionado con el campo de la psicología.

Durante la fase de aprendizaje, los algoritmos exploran o explotan lo que ya saben y reciben retroalimentación constante. Este es un marco muy fácil de entender que se puede transferir a muchas aplicaciones: los algoritmos reciben una observación del mundo, toman una acción y reciben retroalimentación basada en lo que el algoritmo debe aprender. Por ejemplo, si no desea colisionar con otros objetos, se debe enviar una señal de recompensa negativa cuando el automóvil se acerca a otros objetos. Estos algoritmos han demostrado ser muy exitosos en entornos que pueden cambiar rápidamente: aprenden a adaptarse rápidamente a nuevas situaciones. Una ventaja es que no necesitan datos, solo necesitan un entorno para interactuar. Una desventaja es que el aprendizaje lleva tiempo, y estos algoritmos carecen de explicabilidad, ya que son muy complejos en su funcionamiento interno.

Percepción de la máquina

Nuestro automóvil autónomo no podrá aprender nada útil si no puede percibir el mundo: necesita formas de mirar a su alrededor, escuchar, sentir y ver lo que está sucediendo. La percepción de la máquina es un término general para las técnicas que perciben el mundo y tratan de darle sentido. Algunos ejemplos son la visión por ordenador, el reconocimiento de voz y el tacto por ordenador. La mayoría de las técnicas utilizan física, matemáticas, ingeniería, ML,...

Procesamiento natural del lenguaje

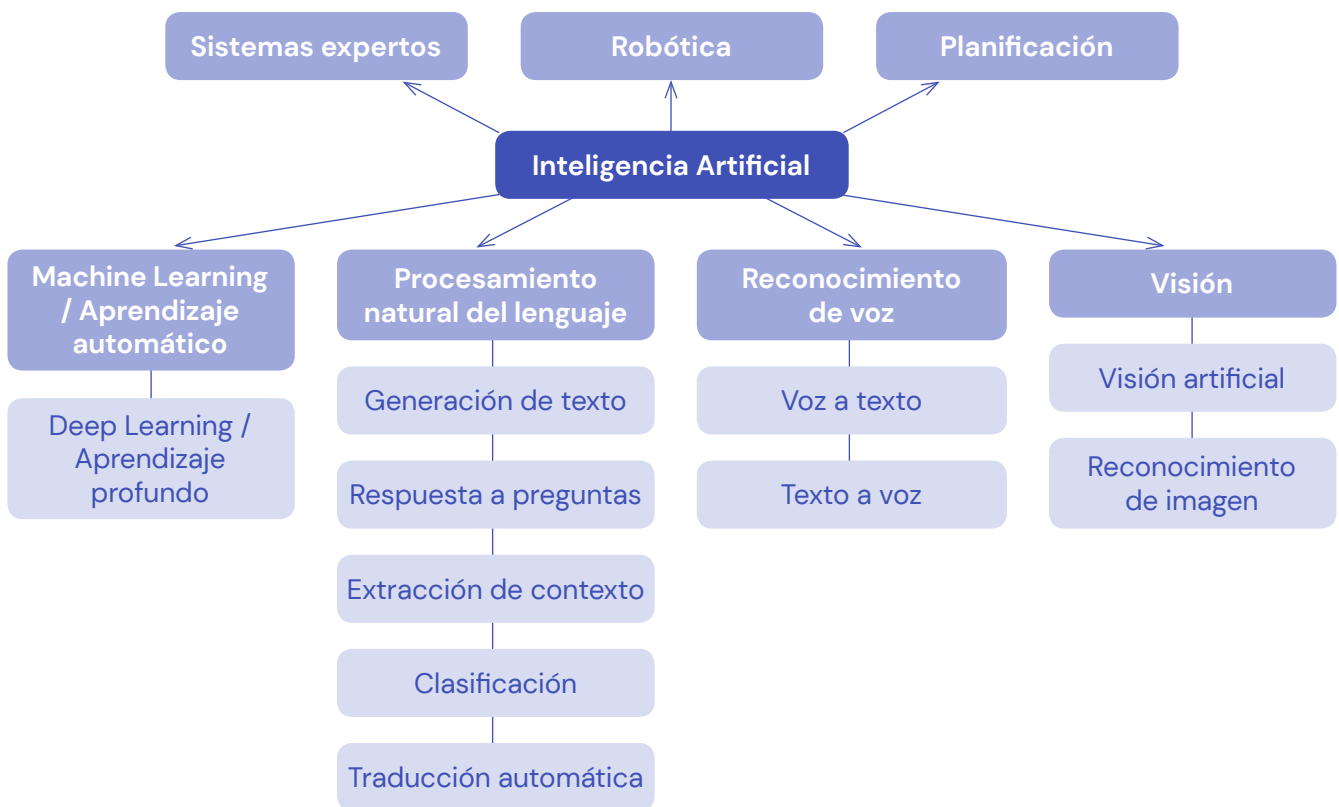
El procesamiento del lenguaje natural es el campo en el que los investigadores exploran cómo se pueden usar los ordenadores para comprender y manipular el lenguaje natural. Este subcampo tiene mucha influencia de otros campos como la lingüística, la ingeniería, la psicología, el aprendizaje automático, etc. Las aplicaciones son la traducción automática, el resumen de textos, el reconocimiento de voz, la generación de textos, la respuesta a preguntas y muchas más.

Robótica

Una última rama interdisciplinaria de la IA involucra el diseño, implementación, fabricación y operación de robots. Cada vez más nos encontramos con robots en nuestro día a día. Donde parecían usarse solo en entornos militares y unidades de fabricación, ahora vemos regularmente vehículos autónomos, robots para limpiar pisos, exoesqueletos que ayudan a los trabajadores con el levantamiento pesado, brazos robóticos que asumen algunas funcionalidades básicas para amputados y robots que muestran el camino en aeropuertos, hoteles, etc. Son muy utilizados en cirugías asistidas, almacenes autónomos y se utilizan para explorar otros planetas como Marte. Para funcionar bien, se deben combinar muchas técnicas de IA, pero también ingeniería. Necesitan observar el mundo, necesitan interpretar las observaciones y necesitan saber qué acciones tomar en qué situaciones.

En la siguiente página, la Figura 6 muestra un esquema de las diferentes ramas de la IA.

Figura 6. Árbol jerárquico de los tipos de IA.



Aprendizaje automático

En lo que resta de sección nos centraremos en el subcampo del ML y más en particular en la clasificación de tareas, ya que estos conceptos son omnipresentes en las aplicaciones de IA.

De manera similar a cómo los humanos necesitan un cerebro que funcione incluso para sobrevivir, las computadoras necesitan instrucciones para hacer incluso las cosas más simples. Sin código o instrucciones, una computadora es básicamente inútil. Para describir lo que deben hacer las computadoras, los humanos escriben algoritmos. A continuación, estos algoritmos se traducen a código que puede ser ejecutado por la computadora. En ML, los investigadores investigan cómo las computadoras o los algoritmos pueden aprender de datos sin ser programados explícitamente. La idea básica es comenzar con un algoritmo base y dejar que este algoritmo mejore hasta que pueda realizar una tarea determinada de una manera que los humanos decidan cuándo es lo suficientemente bueno. Nuevamente, esta idea se puede comparar con la forma en que aprenden los humanos. Al nacer sólo puedes realizar funciones vitales, durante los primeros años de tu vida aprendes mucho de los ejemplos, de la interacción, etc. Habitualmente, el ML se clasifica en tres tipos de algoritmos:

- **Aprendizaje supervisado**
- **Aprendizaje no supervisado**
- **Aprendizaje por refuerzo**

En el aprendizaje supervisado y no supervisado, los algoritmos aprenden de datos. En el aprendizaje por refuerzo, los algoritmos aprenden de la interacción con un entorno. En las siguientes secciones se dará una breve descripción de los tres tipos de algoritmos de aprendizaje.

Aprendizaje supervisado

En el aprendizaje supervisado, se presenta un algoritmo con datos etiquetados. Los datos etiquetados son un conjunto de muestras con etiquetas informativas. Un ejemplo de un problema de clasificación es cuando se desea predecir “enfermo” o “no enfermo” en un paciente. Otro ejemplo típico de tales datos son los correos electrónicos que están etiquetados como spam o no spam, representados en la Figura 7.

Luego, el algoritmo aprende a predecir el spam (o no spam) para correos electrónicos que no ha visto antes. Éste es un ejemplo de clasificación de un problema, en el que la variable de salida es una categoría como “spam” y “no spam”, como se muestra en la Figura 8.

La variable de salida también puede ser un valor numérico, como “euros”, donde el algoritmo aprende a predecir los precios de una vivienda en función de otros parámetros como la superficie, los metros cuadrados totales, etc., como se muestra en la Figura 9.

Después de la fase de aprendizaje, predecirá el precio de un nuevo tipo de casa. Este tipo de problema en el que desea predecir un número en lugar de una categoría se denomina regresión, como se muestra en la Figura 10.

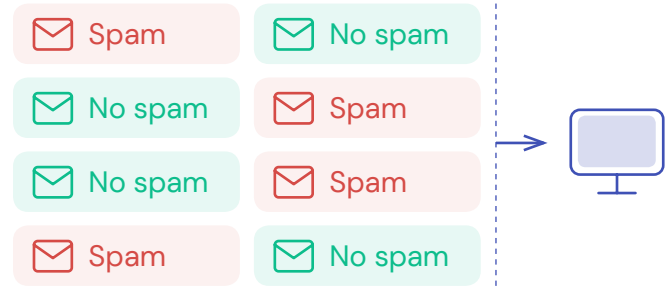


Figura 7. Posibilidades de clasificación de correos electrónicos spam (Verdadero Positivo, Falso Positivo, Verdadero Negativo, Falso Negativo).




Figura 8. Flujo de decisión del algoritmo de clasificación de spam.



Figura 9. Proceso de aprendizaje para predecir los precios de la vivienda a partir de datos de entrenamiento.





Figura 10. Estimación del precio de una casa por el algoritmo.

Aprendizaje no supervisado

En el aprendizaje no supervisado, se presenta un algoritmo con datos no etiquetados. Por ejemplo, para los correos electrónicos no deseados, el ordenador recibiría correos electrónicos pero sin ninguna información adicional sobre si se trata de correo no deseado o no. La figura 11 muestra cómo la computadora recibe los correos electrónicos y debe categorizarlos según su tipo.

El ordenador entonces intentará descubrir grupos en los datos. Sin embargo, no los etiquetará. Este tipo de aprendizaje automático se llama agrupación (clustering en inglés). Se utiliza, por ejemplo, para la segmentación de clientes en la que una empresa divide su base de clientes en grupos que son similares. De esta manera, los clientes similares pueden dirigirse de manera similar. Otra aplicación del aprendizaje no supervisado es cuando una empresa quiere descubrir asociaciones entre productos. Por ejemplo: un cliente que compra el producto A probablemente también compre el producto B.

Figura 11. Proceso de clasificación de correos electrónicos.



Aprendizaje por refuerzo

Finalmente, en un problema de aprendizaje por refuerzo, un algoritmo aprende no de los datos sino de la interacción. Utiliza una técnica de aprendizaje basada en objetivos en la que un algoritmo aprende por ensayo y error qué acciones debe realizar en diferentes situaciones o estados para optimizar una recompensa. Es la tecnología principal detrás de los vehículos autónomos y se utiliza para numerosas tareas, como las ofertas en tiempo real y el control de temperatura automatizado en los centros de datos.

Muchos de los algoritmos centrales en el aprendizaje por refuerzo se inspiraron originalmente en sistemas de aprendizaje biológico como el condicionamiento operante, una técnica conductista en psicología, donde el comportamiento se refuerza con estímulos positivos o negativos. El condicionamiento operante fue ampliamente estudiado por Edward L. Thorndike (1874-1949), quien observó el comportamiento de un grupo de gatos hambrientos que intentaban escapar de algunas cajas que contenían rompecabezas. Los gatos podían escapar de la caja y alcanzar la comida mediante acciones sencillas como tirar de una cuerda. Al principio, los gatos tardaron mucho en salir de la caja, pero en intentos sucesivos se hizo más fácil hasta el punto en que los gatos podían escapar sin dificultad.

Los humanos son muy buenos aprendiendo por ensayo y error. Un ejemplo típico es cómo los humanos aprenden a andar en bicicleta: no pueden aprenderlo de un libro, no pueden aprenderlo observando a otros, la única manera es haciéndolo. Al principio cometerán errores y probablemente se caerán (recompensa negativa), pero eventualmente, después de varios intentos fallidos, descubrirán cómo hacerlo. Un segundo ejemplo son los padres que obsequian a sus hijos con chocolate cuando terminan su tarea: el niño aprende que recibirá un regalo o una recompensa cuando termine su tarea, pero el problema de esta aproximación es que el niño no aprenderá a realizar esa tarea sin errores. De hecho, cuando se programa un algoritmo de aprendizaje por refuerzo, es muy importante establecer una recompensa correcta.


Clasificación

En esta subsección profundizaremos en los problemas de clasificación. La clasificación básicamente significa categorizar un conjunto de datos en clases. Ejemplos típicos son la detección de spam, la clasificación de dígitos escritos a mano, la clasificación de especies de plantas, la detección de fraudes..., solo por mencionar algunos.

En IA, la clasificación es una técnica de aprendizaje automático supervisado que ya fue analizada brevemente en la sección anterior. La forma en que se entrena un algoritmo para clasificar datos es similar a cómo los padres enseñan a sus bebés o niños pequeños a reconocer animales: señalan una imagen y dicen "oso" o "vaca". Las palabras "oso" y "vaca" son las etiquetas.

En términos generales, la clasificación implica los pasos ilustrados en la Figura 12.

Figura 12. Pasos de preparación del modelo de clasificación.



Preparar datos	Entrenamiento	Probar el modelo	Desplegar el modelo
<p>De manera similar a cómo los padres enseñan a sus niños pequeños a reconocer animales, un algoritmo de aprendizaje automático supervisado necesita datos etiquetados para ser entrenado, se trata del primer paso. Estos datos se denominan datos de entrenamiento. Algunos ejemplos:</p> <ul style="list-style-type: none"> → Detección de spam: un conjunto de correos electrónicos y, para cada correo electrónico, una etiqueta como spam o no spam. → Clasificación de dígitos escritos a mano: un conjunto de imágenes que contienen dígitos escritos a mano y para cada imagen el número correcto del 0 al 9. <p>En la clasificación, los datos de entrenamiento deben etiquetarse. El etiquetado de datos generalmente comienza pidiendo a los humanos que etiqueten manualmente los datos. Este proceso suele ser costoso y requiere mucho tiempo.</p>			

Preparar datos
Entrenamiento
Probar el modelo
Desplegar el modelo

El siguiente paso es el entrenamiento. Al final de esta fase, tendremos lo que llamamos un modelo entrenado. Un modelo es una palabra elegante (una abstracción) para denotar un mapeo entre entrada y salida. En el ejemplo de detección de spam, el modelo toma como entrada un correo electrónico (sin etiqueta) y muestra si es spam o no. En clasificación, este modelo también se llama clasificador y sus entradas y salidas se muestran en la Figura 13.

Lo que sucede esencialmente es que comenzamos con un modelo “en blanco”. Para la detección de spam, esto podría generar de forma aleatoria spam o no spam. Luego alimentamos al modelo con datos de entrenamiento y el modelo se adaptará a medida que vea más datos. El modelo Intentará cambiar la forma en que funciona internamente de manera que la mayor parte posible de los datos de entrenamiento se clasifiquen correctamente. Es por eso que esta fase se llama la fase de aprendizaje.

Figura 13. Filtro clasificador de correo electrónico.

Preparar datos
Entrenamiento
Probar el modelo
Desplegar el modelo

Después de entrenar el modelo, sabemos que el modelo funcionará con los datos de entrenamiento. Sin embargo, esto no significa que el modelo funciona bien con nuevos datos no vistos anteriormente. Esto es similar a cómo evalúa un profesor a sus estudiantes. Puede resolver algunos ejercicios de ejemplo en clase, pero en una prueba les pedirá que resuelvan problemas similares pero diferentes. Esto es para asegurarse de que no aprendan las respuestas de memoria sino que comprendan los conceptos e ideas subyacentes. Esto es exactamente lo que sucede en el aprendizaje automático supervisado. Si solo prueba su modelo en ejemplos que se usaron para entrenarlo, el modelo podría haber aprendido sus etiquetas de memoria.

Preparar datos
Entrenamiento
Probar el modelo
Desplegar el modelo

Una vez entrenado y probado el modelo, es posible utilizarlo para realizar la tarea para la cual fue pensado. Este es el último paso.

Nota importante sobre la elección de los datos de entrenamiento

Además de reservar los datos de prueba solo para probar el modelo, la elección de los datos de entrenamiento también es muy importante. Deben evitarse errores claros, datos mal etiquetados y datos contradictorios. Así como las personas se confunden, entrenar un modelo usando esos datos podría crear anomalías. Tener datos insuficientes también son una razón por la cual un modelo predice con un bajo nivel de precisión; no habrá visto suficientes datos para comprender las características de lo que hace que un correo electrónico sea spam y lo que no.

El modelo puede volverse realmente peligroso cuando los datos de entrenamiento están sesgados. Puede encontrar más información y ejemplos en la sección de sesgo algorítmico.

Introducción a la herramienta LearningML

La sección anterior proporcionó una breve introducción a los conceptos que se utilizarán a lo largo de esta guía. En las actividades que se presentarán en la siguiente sección usaremos la herramienta **LearningML**, que ha sido desarrollada por **Juan David Rodríguez**, docente y experto en desarrollo de software.

Esta herramienta nos permite interactuar y experimentar con modelos de IA: se puede usar para entrenar modelos, para investigar cómo se pueden introducir sesgos en los sistemas de IA, etc.


En este capítulo presentaremos la herramienta y brindaremos una pequeña demostración en la que se muestra la funcionalidad básica de LearningML. También revisaremos los pasos necesarios para crear un modelo de IA: preparar datos, entrenar modelo y probar modelo. Finalmente, mostraremos algunos ejemplos sobre el sesgo algorítmico.

Demo de la herramienta LearningML

Ir a la herramienta: [LearningML](#).


En esta demostración vamos a trabajar con imágenes: seleccione **“reconocer imágenes”**, tal y como se muestra en la Figura 14. Para seguir las instrucciones que se indican a continuación, serán necesarias las imágenes de un perro y dos imágenes de un gato. También puede utilizar las imágenes utilizadas en la demostración, que se encuentran en [este enlace](#).

Figura 14. LML V.1.2. opciones de clasificación.



En la Figura 15 se representan los pasos que la herramienta muestra para crear y utilizar un modelo de ML.

Figura 15. Los tres pasos para usar la herramienta LML.



El proceso consta de tres pasos:



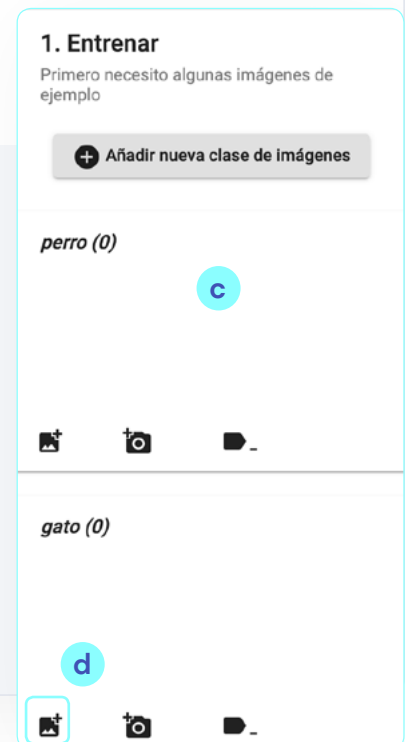
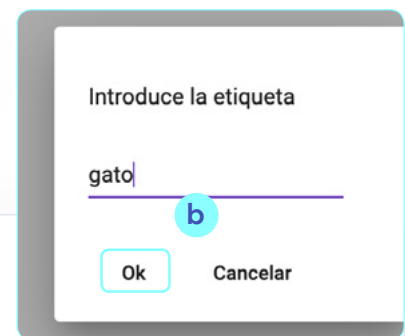
Paso 1: Entrenar

En este paso le proporcionamos al ordenador una serie de imágenes de perros y gatos. Para ello, se proveen los datos con etiquetas, ya que LearningML utiliza aprendizaje supervisado.

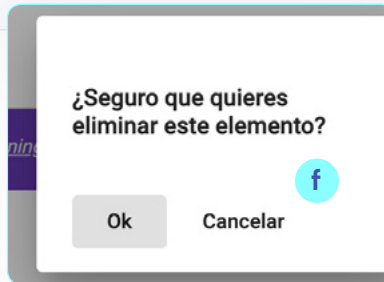
- a** Seleccione **"Agregar nueva clase de imágenes"** para agregar una nueva etiqueta.
- b** Agregue una clase "gato" y haga clic en **"Aceptar"**
- c** Repita este paso pero ahora agregue una clase "perro". En la Figura c se muestran ambas etiquetas.

Tenga en cuenta que el modelo de ML no está restringido a sólo dos clases, puede agregar más. En esta demostración solo usaremos perros y gatos.

- d** Ahora puede agregar imágenes haciendo clic en el botón **"agregar imagen"** para ambas clases, como se muestra en la Figura d.




- e Después de agregar una imagen de un gato y una de un perro, verá algo similar a lo que se muestra en la Figura e.
- f Las imágenes subidas junto con su etiqueta se denominan datos de entrenamiento. Si cometió un error y desea eliminar una imagen, puede hacerlo haciendo clic en esa imagen en particular y confirmando que desea eliminarla.



1. Entrenar
Primero necesito algunas imágenes de ejemplo


+ Añadir nueva clase de imágenes

perro (1) e



+ + -

gato (1)



+ + -

Paso 2: Aprender

Ahora haga clic en “**Aprender a reconocer imágenes**”, como se muestra en la Figura g. El modelo pasa por un fase de aprendizaje en el que aprende de los datos de entrenamiento proporcionados en la fase anterior.

2. Aprender
Llegó el momento de aprender a clasificar imágenes

g Aprender a reconocer imágenes

Paso 3: Probar

Finalmente probamos nuestro clasificador. Hacemos esto cargando imágenes, que son nuestros datos de prueba.

- h Haga clic en “**cargar una imagen de prueba**”, como se muestra en la Figura h, y elija una imagen para usar en la prueba. Elija una imagen que no haya usado como datos de entrenamiento.
- i La computadora ahora predecirá una etiqueta para su imagen cargada. Verá algo como la imagen que se muestra en la Figura i.

En este caso, la predicción es “gato”, ya que la puntuación de la computadora para la predicción es un poco más alta para el gato (59.10%) que para el perro (40.90%).

Estos porcentajes cuantifican la probabilidad de que la imagen proporcionada pertenezca a una clase u otra.

3. Probar
Introduce términos nuevos y comprueba si se clasifican correctamente


h








Subir imagen de prueba

3. Probar
Introduce términos nuevos y comprueba si se clasifican correctamente



gato

Creo que pertenece a la clase gato, aunque no estoy muy segura

i

- gato (59.10 %)
- perro (40.90 %)

Introducción al aprendizaje automático supervisado

Temática

Esta clase es genérica, no relacionada con ninguna asignatura en particular.

Edad

Aunque se puede adaptar a cualquier edad, se recomienda su uso en grupos de 10-12 años.

Duración

1 hora

Descripción y objetivos de aprendizaje

En esta actividad se propone introducir a los estudiantes los conceptos de IA y aprendizaje supervisado a través de la herramienta LearningML. De esta forma los alumnos podrán manejar los datos de entrada para comprobar cómo afecta al desempeño del modelo. En la próxima sección se muestra un ejemplo sobre el sesgo algorítmico.

Situación previa

Esta clase no requiere ningún conocimiento particular además de saber trabajar con un ordenador.

Objetivos educativos

Esta clase es genérica, no relacionada con ningún tema particular. El objetivo de esta actividad es proporcionar un ejemplo breve y sencillo para presentar la IA a los estudiantes.

Tipo de instrucción

Instrucción indirecta donde los estudiantes trabajan en grupos y discuten y resuelven problemas.

Materiales, recursos y equipos

- Cada grupo de estudiantes necesitará un ordenador que tenga acceso a Internet.
- El enlace a la herramienta que se usa en la lección es: <https://learningml.org/editor/>
- Se proporciona una hoja de actividades para los estudiantes al final de esta lección.
- Las imágenes¹ usadas se pueden encontrar en [esta carpeta](#).

Referencias y fuentes

Aprendizaje automático, clasificación

Guía del profesor

Comience con una discusión en clase.

Pregunte a los estudiantes sobre ejemplos de clasificación que usan en su vida o que han visto en la escuela. Algunos ejemplos son: detección de spam, clasificación de animales, las diferentes secciones en una biblioteca, detección de escritura a mano utilizada por los servicios postales, géneros de películas, ...

Explique lo que haremos en esta clase.

En esta clase construiremos nuestro propio clasificador. Enseñaremos a un ordenador a clasificar perros y gatos. Haremos esto dando muchos ejemplos: mostraremos imágenes de perros y gatos y también le diremos al ordenador cuáles son perros y cuáles son gatos. Recuerde a los estudiantes cómo los padres enseñan a sus hijos pequeños a reconocer a los animales. Señalarán imágenes de animales en un libro y dirán "vaca" u "oso".

Demostración en LearningML.

Consultar la **sección previa** para una demostración que se puede utilizar en clase sobre la herramienta. Asegúrese de introducir los conceptos de datos de entrenamiento y datos de prueba.

Deje que los estudiantes trabajen con la herramienta.

Se proporciona una **hoja de actividades** junto con enlaces a las carpetas que contienen las imágenes. A los estudiantes se les harán algunas preguntas.

Algunas indicaciones que te pueden ayudar a orientar la actividad y discutir estas cuestiones en clase:

1. ¿Qué sucede si prueba su clasificador usando los datos de entrenamiento?

La predicción es correcta y la puntuación de probabilidad de la predicción es alta. Esto se debe a que el clasificador pudo aprender de memoria la etiqueta de esta imagen. Usar datos de entrenamiento como datos de prueba no es una buena idea, le dará la impresión de que el clasificador funciona bien, pero no le dice cómo de bien funcionará en ejemplos no vistos.

2. ¿Qué sucede si prueba el clasificador de perros/gatos con la imagen de un león?

Dará como resultado perro o gato. En cierto modo, estos algoritmos son realmente tontos. Averiguan si su imagen se parece más a los perros o gatos en sus datos de entrenamiento. No es lo suficientemente inteligente como para decirte que no es ninguno de los dos.

3. ¿Qué sucede cuando entrena al clasificador usando más datos de entrenamiento?

En términos generales, las predicciones serán mejores y las probabilidades serán más altas. Cuantos más ejemplos pueda usar el clasificador para entrenar, mejor comprenderá las diferencias entre las clases.

Sin embargo, debe tener cuidado con los datos que agrega. Al agregar más imágenes, también puede agregar (más) sesgo en los datos. Por ejemplo, si agrega solo imágenes de gatos blancos, el clasificador podría entender que un pelaje blanco implica que es un gato. El sesgo se discutirá en la próxima sección.

4. ¿Qué sucede si sólo tiene un número limitado de imágenes de perros y muchas más de gatos?

La mayoría de las etiquetas previstas serán gatos. Esto se debe a que no había muchos perros en los datos de entrenamiento y el clasificador no pudo aprender muy bien cómo diferenciar un perro de un gato. La mayoría de los datos de prueba tendrán más en común con los datos de entrenamiento de gatos que con los datos de entrenamiento de perros.

5. ¿Está bien si algunos gatos/perros están mal clasificados?

Esto no es un gran problema. Como se mencionó anteriormente, es posible que no haya suficientes datos de entrenamiento, lo que dificulta que el clasificador los distinga. Sólo hay un problema si sistemáticamente clasificó erróneamente a todos los gatos o a todos los perros.

Se proporciona en la siguiente sección una versión de esta hoja de actividades con los resultados, junto con algunos consejos y reflexiones adicionales.

1. Vaya a <https://learningml.org/> y elija “reconocer imágenes”.

2. En esta lección usamos las imágenes dadas en [esta carpeta](#) que tiene varias subcarpetas:

Conjunto de entrenamiento

Conjunto de prueba

leones

extra

3. Identifique las tres partes de un sistema de aprendizaje automático supervisado: datos de entrenamiento, fase de aprendizaje y datos de prueba.

Figura 16. Introducción: pasos de LML para entrenar un modelo de clasificación.



4. Entrene el ordenador para clasificar perros y gatos.

- Agregue una nueva clase de imágenes: **perro**.
- Añada una nueva clase de imágenes: **gato**.
- Ahora, de la carpeta indicada anteriormente, suba las imágenes de perros y gatos a las clases correspondientes.
- Haga clic en “**Aprender a reconocer imágenes**”.
- Ahora pruebe el clasificador usando las imágenes contenidas en la carpeta conjunto de prueba y rellene la **Tabla 1**.
- Responda a las siguientes preguntas:**
 - ¿Todas las predicciones son correctas? De no ser así, ¿qué crees que ha pasado?

Tabla 1. Introducción – Paso 1: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato11			gato
gato12			gato
gato13			gato
gato14			gato
gato15			gato
perro11			perro
perro12			perro
perro13			perro
perro14			perro
perro15			perro

5. Para los próximos apartados mantendremos los mismos datos de entrenamiento pero agregaremos más ejemplos.
- Vaya a la carpeta extra y sube las imágenes de perros y gatos a las clases correspondientes.
 - Haga clic en “**Aprender a reconocer imágenes**”.
 - Vuelva a probar usando las imágenes provistas en el conjunto de prueba y anotar en la **Tabla 2** la clase pronosticada, puntaje de probabilidad y clase real.
 - Responda a las siguientes preguntas:**
 - Compare estos resultados con sus resultados anteriores. ¿Han mejorado las predicciones? ¿Por qué?

Tabla 2. Introducción – Paso 2: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato11			gato
gato12			gato
gato13			gato
gato14			gato
gato15			gato
perro11			perro
perro12			perro
perro13			perro
perro14			perro
perro15			perro

6. Mantengamos los mismos datos de entrenamiento.
- Pruebe el clasificador con las siguientes imágenes del conjunto de entrenamiento y escriba en la **Tabla 3** la clase pronosticada, puntaje de probabilidad y clase real.
 - Responda las siguientes preguntas:**
 - ¿Por qué cree que las predicciones son tan buenas?
 - ¿Es una buena idea usar datos de entrenamiento para probar el clasificador?

Tabla 3. Introducción – Paso 3: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato1			gato
gato2			gato
perro2			perro
perro3			perro

7. Mantenga los mismos datos de entrenamiento.

- a. Pruebe el clasificador con la imagen lion1 en la carpeta leones y escriba la clase prevista y la puntuación en **Tabla 4**.
- b. **Responda las siguientes preguntas:**
 - ¿Cómo clasificó el modelo al león?
 - ¿Puede explicar lo que ha pasado?

Tabla 4. Introducción - Paso 4: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
lion1			lion

8. Cambie los datos de entrenamiento.

- a. Retire todos los perros. Puede hacerlo haciendo clic en la imagen que desea eliminar y confirmar que desea eliminarla.
- b. Vaya a la carpeta **datos de entrenamiento** y agregue los 4 ejemplos de perros a la clase de perros.
- c. Ahora debería tener 4 ejemplos de entrenamiento para perros y 9 para gatos.
- d. Haz clic en "**Aprender a reconocer imágenes**".
- e. Vuelva a probar usando las imágenes proporcionadas en la carpeta del conjunto de prueba y anote en la **Tabla 5** la clase pronosticada, puntaje de probabilidad y clase real.
- f. **Responda las siguientes preguntas:**
 - ¿Por qué los resultados son tan malos?

Tabla 5. Introducción - Paso 5: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
perro11			perro
perro12			perro
perro13			perro
perro14			perro
perro15			perro

Respuestas a la hoja de actividades

Introducción a aprendizaje automático supervisado

1

Los valores proporcionados en esta sección se obtuvieron con la versión de la herramienta disponible el 7 de abril de 2022. Los valores obtenidos por los estudiantes pueden ser ligeramente diferentes, pero la tendencia general debería ser la misma.

1. Vaya a <https://learningml.org/> y elija “reconocer imágenes”.
2. En esta lección usamos las imágenes dadas en [esta carpeta](#), que tiene varias subcarpetas:

Conjunto de entrenamiento

Conjunto de prueba

leones

extra

3. Identifique las tres partes de un sistema de aprendizaje automático supervisado: datos de entrenamiento, fase de aprendizaje y datos de prueba.

Figura 16. Introducción: pasos de LML para entrenar un modelo de clasificación.



4. Entrene el ordenador para clasificar perros y gatos.
 - a. Agregue una nueva clase de imágenes: **perro**.
 - b. Añada una nueva clase de imágenes: **gato**.
 - c. Ahora, de la carpeta indicada anteriormente, suba las imágenes de perros y gatos a las clases correspondientes.
 - d. Haga clic en “Aprender a reconocer imágenes”.
 - e. Ahora pruebe el clasificador usando las imágenes contenidas en la carpeta conjunto de prueba y rellene la **Tabla 1**.
 - f. **Responda a las siguientes preguntas:**
 - ¿Todas las predicciones son correctas? De no ser así, ¿qué crees que ha pasado?

Tabla 1. Introducción - Paso 1: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato11	gato	87.04%	gato
gato12	gato	66.98%	gato
gato13	gato	94.90%	gato
gato14	gato	61.28%	gato
gato15	gato	78.72%	gato
perro11	perro	90.31%	perro
perro12	perro	58.75%	perro
perro13	perro	70.17%	perro
perro14	perro	71.13%	perro
perro15	gato	68.82%	perro

En este ejemplo tenemos un perro que fue clasificado incorrectamente. La razón por la que este perro fue clasificado como gato es porque el perro tiene más en común (color del pelaje, ubicación de las patas) con los gatos en el conjunto de datos de entrenamiento que con los perros.

5. Mantenga los mismos datos de entrenamiento, pero agreguemos más ejemplos.
- Vaya a la carpeta extra y sube las imágenes de perros y gatos a las clases correspondientes.
 - Haga clic en “**Aprender a reconocer imágenes**”.
 - Vuelva a probar usando las imágenes provistas en el conjunto de prueba y anotar en la **Tabla 2** la clase pronosticada, puntaje de probabilidad y clase real.
 - Responda a las siguientes preguntas:**
 - Compare estos resultados con sus resultados anteriores.
 - ¿Han mejorado las predicciones? ¿Por qué?

Tabla 2. Introducción – Paso 2: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato11	gato	90.35%	gato
gato12	gato	60.63%	gato
gato13	gato	88.17%	gato
gato14	gato	74.53%	gato
gato15	gato	69.78%	gato
perro11	perro	94.46%	perro
perro12	perro	85.31%	perro
perro13	perro	90.93%	perro
perro14	perro	90.01%	perro
perro15	perro	89.16%	perro

No todas las puntuaciones predichas son más altas que en el caso anterior, pero en general las predicciones para perros han mejorado. El clasificador está mejorando para distinguir gatos de perros.

6. Mantengamos los mismos datos de entrenamiento.
- Pruebe el clasificador con las siguientes imágenes del conjunto de entrenamiento y escriba en la **Tabla 3** la clase pronosticada, puntaje de probabilidad y clase real.
 - Responda las siguientes preguntas:**
 - ¿Por qué cree que las predicciones son tan buenas?
 - ¿Es una buena idea usar datos de entrenamiento para probar el clasificador?

Tabla 3. Introducción – Paso 3: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato1	gato	98.53%	gato
gato2	gato	97.39%	gato
perro2	perro	99.31%	perro
perro3	perro	98.82%	perro

El clasificador funciona muy bien en todos los ejemplos de los datos de entrenamiento. Los puntajes de probabilidad para las predicciones son altos. Esto se debe a que el clasificador pudo aprender de memoria la etiqueta de esta imagen. Usar datos de entrenamiento como datos de prueba no es una buena idea, le dará la impresión de que el clasificador funciona bien, pero no le dice qué tan bien funcionará en ejemplos no vistos.

7. Mantenga los mismos datos de entrenamiento.

- Pruebe el clasificador con la imagen lion1 en la carpeta leones y escriba la clase prevista y la puntuación en **Tabla 4**.
- Responda las siguientes preguntas:**
 - ¿Cómo clasificó el modelo al león?
 - ¿Puede explicar lo que ha pasado?

Tabla 4. Introducción - Paso 4: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
lion1	perro	80.10%	lion

El clasificador clasifica al león como un perro. El clasificador siempre generará un gato o un perro. Según los datos de entrenamiento, el león se parece a un perro.

8. Cambie los datos de entrenamiento.

- Retire todos los perros. Puede hacerlo haciendo clic en la imagen que desea eliminar y confirmar que desea eliminarla.
- Vaya a la carpeta **datos de entrenamiento** y agregue los 4 ejemplos de perros a la clase de perros.
- Ahora debería tener 4 ejemplos de entrenamiento para perros y 9 para gatos.
- Haz clic en "**Aprender a reconocer imágenes**",
- Vuelva a probar usando las imágenes proporcionadas en la carpeta del conjunto de prueba y anote en la **Tabla 5** la clase pronosticada, puntaje de probabilidad y clase real.
- Responda las siguientes preguntas:**
 - ¿Por qué los resultados son tan malos?

Tabela 5. Introdução - Paso 5: Tabela de resultados da classificação.

Imagen	Clase predicha	Puntaje	Clase real
perro11	perro	63.64%	perro
perro12	gato	51.06%	perro
perro13	gato	64.04%	perro
perro14	gato	69.29%	perro
perro15	gato	68.90%	perro

Casi todos los perros se clasifican como gatos. Esto se debe a que no había muchos perros en los datos de entrenamiento y el clasificador no pudo aprender correctamente cómo diferenciar un perro de un gato.

Lecciones relacionadas con el sesgo algorítmico

Actividad uno: Clase genérica sobre sesgo algorítmico

Temática

Esta clase es genérica y no está relacionada con ninguna asignatura específica.

Edad

Esta clase no está restringida a un rango de edades concreto, por lo que se puede adaptar según la necesidad

Duración

1 hora

Descripción y objetivos de aprendizaje

En esta lección, los estudiantes usarán un conjunto de datos sesgado. Aprenderán qué es el sesgo algorítmico y cómo se produce. Reflexionarán sobre cómo prevenirlo y tratarlo.

Situación previa

Esta clase no requiere ningún conocimiento concreto, más allá de saber trabajar con un ordenador.

Objetivos educativos

Esta clase es genérica, y no está relacionada con una asignatura específica. Sin embargo, esta actividad introduce el pensamiento crítico y el sesgo en los estudiantes, permitiéndoles distinguir cuándo existe y, sobre todo, cómo evitarlo.

Tipo de instrucción

Instrucción indirecta donde los estudiantes trabajan en grupos, discuten y resuelven problemas.

Materiales, recursos y equipos

- Cada grupo de estudiantes necesitará un ordenador que tenga acceso a Internet.
- El enlace a la herramienta que se usa en la lección es: <https://learningml.org/editor/>
- Se proporciona una hoja de actividades para los estudiantes al final de esta lección.
- Las imágenes² usadas se pueden encontrar en [esta carpeta](#).

Referencias y fuentes

Aprendizaje automático, clasificación, sesgo algorítmico.

Guía del profesor

Comience con una discusión en clase

Pregunte a los estudiantes si se han encontrado con situaciones en las que la tecnología fue injusta con ellos o con alguien que conocen. Si es necesario, pregúnteles cómo se podría sesgar la tecnología.

Algunos ejemplos:

- Algunos sistemas de reconocimiento facial no reconocen rostros femeninos más oscuros como rostros masculinos más claros.
- Un dispensador de jabón que no sirve para personas de raza negra: https://www.youtube.com/watch?v=YJjv_OeiHmo
- El sistema del banco que no aprueba un préstamo si vives en cierta zona subdesarrollada.
- Una plataforma en línea que muestra anuncios de trabajo en enfermería o secretariado principalmente para mujeres.

Cuando los algoritmos tienen resultados que son injustos de manera sistemática, lo llamamos sesgo algorítmico.

Recuerde de la última lección si se usa como una clase de seguimiento

Pregúnteles a sus alumnos qué sucedió en las últimas lecciones cuando entrenamos al clasificador usando un grupo pequeño de perros y un grupo grande de gatos en los datos de entrenamiento.

La mayoría de las etiquetas predichas eran gatos. Esto se debe a que no había muchos perros en los datos de entrenamiento y el clasificador no pudo aprender muy bien cómo diferenciar un perro de un gato. La mayoría de los datos de prueba tendrán más en común con los datos de entrenamiento de gatos que con los datos de entrenamiento de perros.

Decimos que nuestro algoritmo está sesgado hacia los gatos, ya que funciona muy bien con ellos, y contra los perros, ya que no funciona tan bien con ellos.

Si no se utiliza como clase de seguimiento, ofrezca una demostración de la herramienta.

Véase la sección anterior para realizar una demostración de la herramienta en clase. Asegúrese de introducir los conceptos de datos de entrenamiento y datos de prueba.

Permita que los estudiantes trabajen con la herramienta.

Se proporciona una ficha de actividad al final de esta sección.

Las imágenes con las que trabajarán los estudiantes se pueden encontrar en esta carpeta. En la ficha de actividades a los estudiantes se les harán algunas preguntas. La versión completa de la ficha de actividades con sus soluciones, algunos consejos adicionales y reflexiones se agrega después de la ficha de actividades.

Reflexionar

El clasificador del ejemplo anterior clasificó a todos los perros pelirrojos como gatos y, excepto el gato pelirrojo, todos los gatos fueron clasificados erróneamente como perros. El clasificador tenía el siguiente sesgo: suponía que para ser un gato, el pelaje debía ser pelirrojo. Este sesgo proviene directamente de los datos de entrenamiento: todos los gatos en los datos de entrenamiento son pelirrojos

Pregunte a los alumnos si pueden pensar en una situación del mundo real en la que los datos de entrenamiento estén sesgados.

Un ejemplo típico es aquel en el que los sistemas de detección facial funcionan bien en los varones más claros, pero mal en las mujeres oscuras. Esto se debe a que las bases de datos de capacitación estándar son predominantemente varones blancos.

¿Por qué es esto potencialmente dañino?

Por ejemplo, el reconocimiento facial que se usa en la calle puede conducir a arrestos falsos porque las personas fueron identificadas incorrectamente.

Esto es algo con lo que debemos tener cuidado al usar datos para entrenar un modelo de ML, ya que no debe excluir a nadie.

1. Vaya a <https://learningml.org/> elija “reconocer imágenes”.

2. En esta lección usamos las imágenes provistas en [esta carpeta](#) que tiene varias subcarpetas:



3. Identifique en la herramienta los tres pasos de los que se compone: datos de entrenamiento, fase de aprendizaje y fase de pruebas.

Figura 17. Sesgo algorítmico: pasos LML para entrenar un modelo de clasificación.



4. Entrene el modelo para clasificar perros y gatos.

- a. Agregue una nueva clase de imágenes: perro.
- b. Añada una nueva clase de imágenes: gato.
- c. A continuación, suba las imágenes de perros y gatos contenidas en la carpeta conjunto de entrenamiento.
- d. Para el conjunto de datos de entrenamiento de perros:
 - ¿Cuántas imágenes se incluyen?
 - ¿Son similares las imágenes?
 - ¿Las imágenes son diferentes?
- e. Para el conjunto de datos de entrenamiento de gatos:
 - ¿Cuántas imágenes se incluyen?
 - ¿Son similares las imágenes?
 - ¿Las imágenes son diferentes?
- f. Haga clic en “Aprender a reconocer imágenes”.
- g. Ahora pruebe el clasificador usando las imágenes dadas en la carpeta conjunto de pruebas y anote la clase pronosticada, la puntuación de probabilidad y la clase real en la **Tabla 11**.
- h. ¿Para qué clase ha mostrado mejor rendimiento el modelo? ¿Por qué?

Tabla 11. Sesgo algorítmico – Paso 1: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato01			gato
gato02			gato
gato03			gato
gato 14			gato
gato 15			gato
perro01			perro
perro02			perro
perro03			perro
perro04			perro
perro05			perro

5. Intente arreglar el conjunto de datos de entrenamiento. Vaya a la carpeta extra y aumente su conjunto de datos eligiendo imágenes de gatos y perros y agregándolas a las clases correspondientes. Si lo desea, también puede navegar por Internet y cargar nuevas imágenes.

- a. Para el conjunto de datos de entrenamiento de perros:
 - ¿Cuántas imágenes se incluyen?
 - ¿Son similares las imágenes?
 - ¿Las imágenes son diferentes?
- b. Para el conjunto de datos de entrenamiento de datos:
 - ¿Cuántas imágenes se incluyen?
 - ¿Son similares las imágenes?
 - ¿Las imágenes son diferentes?
- c. Haga clic en "Aprender a reconocer imágenes".
- d. Pruebe el clasificador con el conjunto de datos de prueba y anote la clase predicha, el puntaje de probabilidad y la clase real en la **Tabla 12**.
- e. ¿Para qué clase se desempeñó mejor su clasificador? ¿Funcionó igual para ambas clases? ¿Cómo influyeron los cambios que realizó? ¿Por qué?

Tabla 12. Sesgo algorítmico – Paso 2: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato11			gato
gato12			gato
gato13			gato
gato 14			gato
gato 15			gato
perro11			perro
perro12			perro
perro13			perro
perro14			perro
perro15			perro

Los valores proporcionados en esta sección se obtuvieron con la versión de la herramienta disponible el 7 de abril de 2022. Los valores obtenidos por los estudiantes pueden ser ligeramente diferentes, pero la tendencia general debería ser la misma.

1. Vaya a <https://learningml.org/> elija “reconocer imágenes”.

2. En esta lección usamos las imágenes provistas en [esta carpeta](#) que tiene varias subcarpetas:

Conjunto de entrenamiento

Conjunto de prueba

extra

3. Identifique en la herramienta los tres pasos de los que se compone: datos de entrenamiento, fase de aprendizaje y fase de pruebas.

Figura 17. Sesgo algorítmico: pasos LML para entrenar un modelo de clasificación.



4. Entrene el modelo para clasificar perros y gatos.

- a. Añada una nueva clase de imágenes: perro.
- b. Añada una nueva clase de imágenes: gato.
- c. A continuación, suba las imágenes de perros y gatos contenidas en la carpeta conjunto de entrenamiento.
- d. Para el conjunto de datos de entrenamiento de perros:
 - ¿Cuántas imágenes se incluyen?
 - ¿Son similares las imágenes?
 - ¿Las imágenes son diferentes?

- Hay 6 imágenes.
- Tienen diferentes colores de pelaje y diferentes razas. Solo dos perros tienen el mismo color de pelaje.
- Hay una gran variedad en cuanto a la posición corporal; algunos están caminando y otros están sentados.

- e. Para el conjunto de datos de entrenamiento de gatos:
 - ¿Cuántas imágenes se incluyen?
 - ¿Son similares las imágenes?
 - ¿Las imágenes son diferentes?

- Hay 6 imágenes.
- Todos son gatos pelirrojos y con rayas.
- Hay una variedad de posiciones para sentarse; algunos están caminando.

f. Haga clic en “Aprender a reconocer imágenes”.

- g. Ahora pruebe el clasificador usando las imágenes dadas en la carpeta conjunto de pruebas y anote la clase pronosticada, la puntuación de probabilidad y la clase real.
- h. ¿Para qué clase ha mostrado mejor rendimiento el modelo? ¿Por qué?

Todos los gatos están mal clasificados, excepto el gato pelirrojo. El perro pelirrojo fue clasificado como un gato. El clasificador ha aprendido que si el color del pelaje es rojo, debe ser un gato.

Tabla 11. Sesgo algorítmico - Respuestas de la tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato11	gato	87.02%	gato
gato12	perro	61.87%	gato
gato13	perro	70.33%	gato
gato 14	perro	55.93%	gato
gato 15	perro	55.64%	gato
perro11	perro	84.57%	perro
perro12	perro	93.76%	perro
perro13	perro	70.94%	perro
perro14	gato	52.77%	perro
perro15	perro	91.61%	perro

Nota importante para la pregunta 5. No hay una solución única, esta pregunta debe verse como un experimento. Los alumnos intentan añadir imágenes para mejorar las predicciones. El objetivo es conseguir que se clasifiquen más gatos como gatos y no como perros, asegurándose al mismo tiempo de que los perros siguen siendo clasificados como perros. Si los alumnos no están satisfechos con los resultados, pueden añadir aún más imágenes o eliminar algunas de las que han cargado. Recuérdales que tienen que volver a entrenar al ordenador después de cambiar los datos de entrenamiento.

5. Intente arreglar el conjunto de datos de entrenamiento. Vaya a la carpeta extra y aumente su conjunto de datos eligiendo imágenes de gatos y perros y agregándolas a las clases correspondientes. Si lo desea, también puede navegar por Internet y cargar nuevas imágenes.

- a. Para el conjunto de datos de entrenamiento de perros:
 - ¿Cuántas imágenes se incluyen?
 - ¿Son similares las imágenes?
 - ¿Las imágenes son diferentes?

Como ejemplo se han añadido las siguientes imágenes en la carpeta extra: dog22, dog23 y dog25. De esta manera hemos añadido más variedad, por ejemplo, ahora se dispone de perros blancos.

- b. Para el conjunto de datos de entrenamiento de gatos:
 - ¿Cuántas imágenes se incluyen?
 - ¿Son similares las imágenes?
 - ¿Las imágenes son diferentes?

Como ejemplo se han añadido las siguientes imágenes de gatos en la carpeta extra: cat23, cat24 y cat2. Disponemos de un dataset más balanceado en el que hay mayor variedad en los datos de entrenamiento de gatos: no todos los datos son naranjas y algunos gatos tienen rayas en el pelaje.

- c. Haga clic en "Aprender a reconocer imágenes".
- d. Pruebe el clasificador con el conjunto de datos de prueba y anote la clase predicha, el puntaje de probabilidad y la clase real en la **Tabla 12**.

- e. ¿Para qué clase se desempeñó mejor su clasificador? ¿Funcionó igual para ambas clases? ¿Cómo influyeron los cambios que realizó? ¿Por qué?

La exactitud del clasificador se han incrementado significativamente. Aún hay dos animales que han sido clasificados incorrectamente: cat13 y dog13. Si nos fijamos en los datos de entrenamiento, se puede observar que lo siguiente puede estar sucediendo:

- cat13 se parece a dog1 de los datos de entrenamiento, mucho más de lo que se parece a los gatos de entrenamiento.
- dog13 se parece al nuevo gato añadido, cat25 de los datos de entrenamiento, este parecido es mucho mayor que el que tiene con el resto de perros de los datos de entrenamiento.




Tabla 12. Sesgo algorítmico – Paso 2: Tabla de puntuación de resultados de clasificación.

Imagen	Clase predicha	Puntaje	Clase real
gato11	gato	43%	gato
gato12	gato	84.88%	gato
gato13	perro	70.71%	gato
gato 14	gato	74.66%	gato
gato 15	gato	70.64%	gato
perro11	perro	89.86%	perro
perro12	perro	87.87%	perro
perro13	gato	55.41%	perro
perro14	perro	59.77%	perro
perro15	perro	80.78%	perro

Actividad dos: Ciencias sociales

En esta actividad sobre el sesgo, los estudiantes trabajarán con las consecuencias del sesgo. Hemos creado dos actividades diferentes que se basan en el mismo modelo creado por Thomas Schelling. Se proporcionan enlaces a herramientas que permiten identificar este sesgo de manera interactiva.

Tenga en cuenta que estas actividades no requieren la herramienta LearningML.

 Temática	 Edad	 Duración
Esta lección está relacionada con la materia de ciencias sociales.	Hay dos versiones del experimento. El primero es más adecuado para estudiantes mayores (a partir de 14 años). El segundo también puede ser empleado por niños en escuela primaria.	1 hora

Descripción y objetivos de aprendizaje

En esta sección, los estudiantes aprenderán cómo un pequeño sesgo puede tener grandes consecuencias en los resultados. Específicamente, nos enfocamos en la disciplina de las ciencias sociales donde se identifica mejor el sesgo.

Conocimiento previo

- Los estudiantes deben entender qué es el sesgo algorítmico.
- Los estudiantes entienden que los datos sesgados pueden conducir a un sesgo algorítmico.
- Los estudiantes entienden que los sesgos personales del programador pueden conducir a un sesgo algorítmico.

Recursos

- Ejemplo 1: [juego de sesgo](#)
- Ejemplo 2: [Segregación](#)
- Video en YouTube: [Explicación sobre el modelo de Schelling](#)

Tema relacionado

Sesgo algorítmico

Tipo

Enseñar sobre el impacto de la IA

Antecedentes

Cuando se utilizan herramientas basadas en IA es importante saber que son susceptibles al sesgo. Esto se debe a que los datos pueden estar sesgados y cada programador tiene preferencias personales. Lo que la gente a menudo no se da cuenta son los efectos que puede tener un pequeño sesgo. En esta sección, enumeramos dos experimentos que los estudiantes pueden realizar para comprender cómo un pequeño sesgo puede tener un impacto potencialmente grande.

Estos experimentos se basan en un modelo simple creado por Thomas Schelling en 1960. En este modelo, un grupo mixto de personas es segregado espontáneamente por raza. Esto sucede a pesar de que nadie en la población quiere ese resultado. Inicialmente, las familias blancas y de color se distribuyen aleatoriamente. En cada paso de tiempo fijo, cada familia decide si quiere moverse o no, dependiendo de la composición racial de su vecindario inmediato. Este procedimiento se repite hasta que todos se encuentran en un hogar satisfactorio.

Lo que sucede, por supuesto, depende de las preferencias de las familias. Si todo el mundo es indiferente a la raza, nadie se moverá. Por otro lado, si nadie quiere vivir junto a alguien de otra raza, la segregación total es la única solución. Los casos interesantes son los que se encuentran entre estos dos extremos. Schelling descubrió que la segregación puede surgir cuando las familias no quieren ser minoría. Una preferencia relativamente leve por vecinos de raza similar puede conducir a altos niveles de segregación.

Ejemplo 1: juego de sesgo

Cree 21 cartas, usando 3 colores diferentes: de cada color hay 7 cartas. Cada color representa un tipo de persona, por ejemplo, una raza. Comience colocando tres tarjetas diferentes una al lado de la otra, como se muestra en la Figura 18.

Las cartas restantes se barajan y se colocan en el medio. Los estudiantes van por turnos. Cuando un estudiante toma una tarjeta, debe colocarla sobre la mesa. Sólo se puede colocar la tarjeta junto a una persona del mismo tipo. Por ejemplo, si necesita colocar una persona roja, sólo puede colocarla en las posiciones que se muestran en la Figura 19.

Cuando los estudiantes terminan de agregar todas las tarjetas, ven que han creado un grupo segregado de personas.

Figura 18. Actividad de Ciencias Sociales: Representación simbólica de personas.





Figura 19. Actividad de Ciencias Sociales: Representación de tarjetas de personas.



Ejemplo 2: Segregación

Este experimento se basa directamente en el modelo de Schelling y también se explica en el video. Si quiere, puede incluso usar huevos como en el video. De lo contrario, déjelos trabajar en grupos de 4-5. Para cada grupo:

- Dibuje una cuadrícula de 6 por 6 en una hoja grande de papel.
- Necesitará 30 pedazos de papel de colores que quepan en los mosaicos que dibujaste en el papel. Estos trozos de papel se separarán en dos colores diferentes. El experimento funcionará con diferentes distribuciones, pero debería ser más o menos un 50-50 % de cada color, ya que queremos comenzar en un vecindario mixto.
- Elija dos colores que sean muy distintos, por ejemplo, azul y rojo.
- En lugar de papel, también puede usar piezas de ajedrez o cualquier otro elemento de dos colores diferentes.
- Coloque los trozos de papel en 30 de los mosaicos en la cuadrícula y mézclelos para tener un vecindario mixto.

En lo que sigue de lección llamaremos casa a un trozo de papel; habrá casas de colores rojo y azul. Para cada casa haga lo siguiente:

- Cuente el número de casas de cada color en su barrio local. Todas las x son mosaicos que pueden contener un vecino directo, como se muestra en la Figura 20.
- No olvide contar también su propia casa.
- ¿Debería mover la casa roja en el medio? Ejemplos:

Figura 20. Actividad de Ciencias Sociales – Syep 1: Ejemplo de Casas.

X	X	X
X	🏠	X
X	X	X

🏠	🏠	
	🏠	🏠

Situación uno

Rojo = 2 Azul = 2

Como hay al menos tantas casas rojas como casas azules, no movemos la casa.

Situación dos

Rojo = 3 Azul = 2

Como hay al menos tantas casas rojas como casas azules, no movemos la casa.



Situación tres

Rojo = 2 Azul = 3

Dado que hay más casas azules que casas rojas, la casa debe moverse.



→ Si se debe mover la casa roja, mueva la casa a una celda vacía del mosaico donde los vecinos estén de tal manera que si se mueve la casa, no habrá más casas azules que casas rojas.

Los estudiantes siguen moviendo la casa hasta que cada casa está en un barrio que esté de acuerdo con sus preferencias o hasta que queda claro que el barrio se está segregando con el tiempo.

Durante la actividad se puede ver cómo inconscientemente introducimos sesgos a la hora de crear el barrio. Esto también puede ocurrir cuando elegimos los datos con los que entrenar un modelo de ML, dando lugar a situaciones que podrían evitarse.

Lecciones específicas para las materias del aula

Este capítulo se divide en dos subapartados. El primero contiene lecciones preparadas para asignaturas específicas, utilizando la herramienta LearningML. El segundo proporciona una descripción general de las herramientas que se pueden usar para enseñar IA en determinadas asignaturas.

Nuestro objetivo es proporcionar una descripción general de las herramientas útiles impulsadas por IA que pueden mejorar sus lecciones.

Lecciones específicas de LearningML

Matemáticas

Geometría

 **Sujeto**

Geometría/Matemáticas

 **Edad**

10-12 años

 **Duración**

1 hora

Descripción y objetivos de aprendizaje

Esta lección de ejemplo es una actividad que se puede usar en una clase de geometría para distinguir diferentes polígonos como los paralelogramos, cuadrados, trapecios y rectángulos. En esta actividad, los estudiantes aprenderán a distinguir estas formas en función de sus definiciones y propiedades. La actividad utiliza el ML, concretamente se trata de aprendizaje supervisado, para fortalecer el aprendizaje de los alumnos, así como otras habilidades transversales como el pensamiento crítico, la comunicación y la argumentación.

Temática

Formas geométricas.

Metas educativas

- Distinguir paralelogramos, cuadrados, trapecios y rectángulos en función de sus características.
- Ser capaz de identificar sus principales características.
- Aplicar el pensamiento crítico al usar la IA para la clasificación de estos polígonos.

Situación previa

- Los conocimientos previos requeridos para esta lección son:
- Definiciones de paralelogramos, cuadrados, trapecios y rectángulos
 - Terminología: ángulo, lados, diagonales y triángulos

Tipo de instrucción

Instrucción indirecta donde los estudiantes trabajan en grupos, discuten y resuelven problemas guiados por el maestro.

Materiales, recursos y equipos

- [Herramienta LearningML](#), en particular su funcionalidad de aprendizaje con imágenes:
- Ordenador con buena conexión a Internet
- [Enlace al material](#)

Conceptos previos


Cuadrilátero: polígono de cuatro lados. Un cuadrilátero tiene cuatro lados, cuatro vértices y los ángulos interiores suman 360 grados. Hay algunos tipos especiales de cuadriláteros:

Cuadrilátero

Rectángulo: un cuadrilátero en el que cada ángulo mide 90 grados.

Propiedades:


- Los lados opuestos son iguales y paralelos.
- Un rectángulo tiene dos diagonales de igual longitud que se bisecan entre sí y dividen el rectángulo en dos partes iguales.



Cuadrado: un cuadrilátero en el que cada ángulo mide 90 grados y todos los lados tienen la misma longitud.

Propiedades:


- Todo cuadrado es un rectángulo.
- Los lados opuestos son iguales y paralelos.
- Un cuadrado tiene dos diagonales de igual longitud que se bisecan entre sí y dividen el cuadrado en dos partes iguales.
- Las diagonales se bisecan en 90 grados.
- Las diagonales dividen el cuadrado en dos triángulos rectángulos isósceles.
- Un cuadrado tiene cuatro ejes de simetría.
- Un cuadrado tiene una simetría rotacional de orden 4 alrededor de su centro de rotación.



Paralelogramo: cuadrilátero con lados opuestos paralelos.

Propiedades:


- Todo paralelogramo es un trapezoide.
- Los ángulos interiores del mismo lado se complementan entre sí.
- Los lados opuestos son iguales.
- Los ángulos opuestos son iguales.
- Las diagonales se bisecan entre sí.
- Las diagonales dividen el paralelogramo en dos triángulos.



Trapezoide: un cuadrilátero con un par de lados paralelos. Los lados paralelos se conocen como bases y los lados no paralelos se conocen como catetos del trapezoide.

Propiedades:

- Los ángulos interiores del mismo lado se complementan entre sí.



Descripción de la lección

Paso 1

5-30
min

Este paso incluye dos opciones (a y b) dependiendo del origen de las imágenes. Estas opciones no son secuenciales, el profesor deberá seleccionar una de ellas. Una vez que el profesor haya elegido, pedirá a los alumnos que realicen la última parte de este paso, el apartado c.

- a. Cargue al menos 10 imágenes de cada una de los polígonos usando el enlace provisto (5 minutos)
- b. Pida a los estudiantes que busquen un mínimo de 10 imágenes de cada polígono en Internet. El buscador de imágenes de Google puede ser de gran ayuda para esta tarea (30 minutos)
- c. Pida a los alumnos que carguen solo 2 imágenes diferentes para cada forma. De esta manera, verá qué tan bien lo está haciendo el modelo ML al reducir los datos de entrenamiento.

Todas las imágenes deben cargarse en LearningML, teniendo al final de este paso cuatro grupos de polígonos (rectángulos, cuadrados, paralelogramos y trapecoides).

Paso 2

15 min

Entrenamiento del modelo. En este paso, LearningML aprende a clasificar imágenes, según los datos proporcionados en el Paso 1. En este punto, es una buena oportunidad para presentar los conceptos más importantes de las diferentes formas. Los alumnos ya deben ser conscientes de las diferencias más significativas.

Paso 3

30-60
min

Pruebas y discusión. Pida a los estudiantes que busquen otras imágenes de polígonos y las suban a la fase de pruebas de LearningML para ver la forma predicha. Como alternativa, el enlace proporcionado se puede utilizar para buscar imágenes. Para cada imagen cargada, los alumnos deben responder las siguientes preguntas:

- ¿Son correctos los resultados? (es decir, ¿la forma más probable es la que crees que es?)
- Si el resultado no es correcto, ¿puede pensar en una razón por la cual el modelo predijo esa forma?
- ¿Qué propiedades usó (el estudiante) para identificar las formas?
- ¿Qué propiedades cree que usa el algoritmo para identificar las formas?

Pida a los alumnos que carguen una imagen de una mesa y que la usen como imagen de prueba.

- ¿Cuál es la predicción?
- ¿Son correctos los resultados?
- ¿Cuál cree que es la propiedad o el detalle más significativo utilizado por el modelo para identificar su tipo?
- Si el resultado no es correcto, ¿puede pensar en una razón por la cual el modelo predijo esa forma?

Ángulos de triángulos

 Sujeto	 Edad	 Duración
Geometría/ Matemáticas	10-12 años	1h o 2h (dependiendo de si usan el conjunto de datos provisto o lo crean por su cuenta)

Descripción y objetivos de aprendizaje

Esta lección puede ser usada en una clase de geometría sobre triángulos. En esta actividad, los estudiantes aprenderán a distinguir triángulos según las propiedades de sus ángulos. La actividad utiliza el ML para fortalecer el aprendizaje de los alumnos, así como otras habilidades transversales como el pensamiento crítico, la comunicación y la argumentación.

Situación previa

Conocimientos previos necesarios:

- Definición de triángulos agudos, rectángulos y obtusos
- Propiedades de los triángulos en función de sus ángulos, como que la suma de todos los ángulos de un triángulo es 180 grados

Metas educativas

- Aprender los tres tipos de triángulos, según sus ángulos.
- Conocer los tipos de triángulos.
- Ser capaz de identificar sus principales características.
- Promover el pensamiento crítico al usar IA en la clasificación de los respectivos triángulos.

Tipo de instrucción

Instrucción indirecta donde los estudiantes trabajan en grupos, discuten y resuelven problemas guiados por el maestro.

Material, recursos y equipos

- La Herramienta [LearningML](#), en particular su funcionalidad de imagen.
- Ordenador con buena conexión a Internet
- [Enlace al material](#)

Conceptos previos

En geometría, un triángulo es un polígono con tres aristas y tres vértices. Según la longitud de los lados y la medida de los ángulos, hay seis tipos de triángulos: triángulo escaleno, triángulo rectángulo, triángulo acutángulo, triángulo obtuso, triángulo isósceles y triángulo equilátero. Sin embargo, en esta actividad sólo veremos los siguientes tres tipos:

- Si uno de los ángulos interiores del triángulo mide más de 90 grados, entonces se llama **triángulo obtuso**.
- Un **triángulo agudo** es un triángulo en el que uno de los tres ángulos interiores mide menos de 90 grados.

Conceptos previos (continuado)

→ Un **triángulo rectángulo** es un triángulo en el que un ángulo mide 90 grados. Un ángulo de 90 grados se llama ángulo recto y, por lo tanto, un triángulo con un ángulo recto se llama triángulo rectángulo. En un triángulo rectángulo se cumple el teorema de Pitágoras.

La suma de todos los ángulos de un triángulo (de todos los tipos) es igual a 180 grados.

Descripción de la lección

Paso 1

5-30 min

Este paso incluye dos opciones (a y b) dependiendo del origen de las imágenes. Estas opciones no son secuenciales, el profesor deberá seleccionar una de ellas. Una vez que el profesor haya seleccionado, pedirá a los alumnos que realicen la última parte de este paso, el apartado c.

- Cargue 10 imágenes para cada tipo utilizando el enlace provisto (5 minutos)
- Pida a los estudiantes que busquen un mínimo de 10 imágenes para cada forma en Internet. El buscador de imágenes de Google puede ser de gran ayuda para esta tarea (30 minutos)
- Pida a los alumnos que carguen solo 2 imágenes diferentes para cada tipo de ángulo. De esta manera, verá qué tan bien lo está haciendo el modelo ML al reducir los datos de entrenamiento.

Todas las imágenes deben cargarse en LearningML, teniendo al final de este paso tres grupos de triángulos (triángulos obtusos, agudos y rectángulos).

Paso 2

15 min

Entrenamiento del modelo. En este paso, LearningML aprende a clasificar imágenes, según los datos proporcionados en el Paso 1. En este punto es una buena oportunidad para presentar los conceptos más importantes de los diferentes triángulos. Los alumnos ya deben ser conscientes de las diferencias más significativas.

Paso 3

30-60 min

Pruebas y discusión. Pida a los alumnos que descarguen imágenes de triángulos de Internet y las suban al apartado de pruebas de learningML para ver los resultados. Como alternativa, el enlace proporcionado se puede utilizar para obtener estas imágenes. Para cada imagen cargada, los alumnos deben responder las siguientes preguntas:

- ¿Son correctos los resultados? (es decir, ¿es correcta la predicción hecha por el modelo de IA?)
- Si el resultado no es correcto, ¿puedes pensar en una razón por la cual el modelo predijo esa forma?
- ¿Qué propiedades usó (el estudiante) para identificar las formas?
- ¿Qué propiedades crees que usa el algoritmo para identificar las formas?

Pida a los alumnos que carguen un cuadrado y lo usen como imagen de prueba.

- ¿Cuál es la predicción hecha por el modelo?
- ¿Por qué el modelo predijo de esa forma?

Lados de triángulos

 Sujeto	 Edad	 Duración
Geometría/ Matemáticas	10-12 años	1h o 2h (dependiendo de si usan el conjunto de datos provisto o lo crean por su cuenta)

Descripción y objetivos de aprendizaje

Esta lección de ejemplo es una actividad que se puede utilizar en una clase de geometría sobre triángulos. En esta actividad, los estudiantes aprenderán a distinguir triángulos según las propiedades de sus lados. La actividad utiliza el ML para fortalecer el aprendizaje de los alumnos, así como otras habilidades transversales como el pensamiento crítico, la comunicación y la argumentación.

Situación previa

Los conocimientos previos necesarios son los siguientes:

- Distinción de triángulos isósceles, escaleno y equilátero
- Propiedades de los triángulos en función de sus ángulos, como que la suma de todos los ángulos de un triángulo es 180 grados

Metas educativas

- Aprender los tres tipos de triángulos, según sus lados.
- Conocer los tipos de triángulos.
- Ser capaz de identificar sus principales características.
- Promover el pensamiento crítico al usar IA en la clasificación de los respectivos triángulos.

Tipo de instrucción

Instrucción indirecta donde los estudiantes trabajan en grupos, discuten y resuelven problemas guiados por el maestro.

Material, recursos y equipos

- La Herramienta [LearningML](#), en particular su funcionalidad de imagen.
- Ordenador con buena conexión a Internet
- [Enlace al material](#)

Conceptos previos

En geometría, un triángulo es un polígono con tres aristas y tres vértices. Según la longitud de los lados, la medida de los ángulos, hay seis tipos de triángulos: triángulo escaleno, triángulo rectángulo, triángulo acutángulo, triángulo obtuso, triángulo isósceles y triángulo equilátero. Sin embargo, en esta actividad solo veremos los siguientes tres tipos:

- Un **triángulo equilátero** es un triángulo en el que los tres lados tienen la misma longitud.
- Un **triángulo isósceles** es un triángulo en el que dos lados miden lo mismo.

Conceptos previos (continuado)

→ Un **triángulo escaleno** es un triángulo en el que ninguno de los miden los mismo.

Propiedades de los triángulos equiláteros:

→ Los ángulos son congruentes y suman 60 grados.

→ La perpendicular trazada desde cualquier vértice a su lado opuesto biseca el lado en longitudes iguales.

Propiedades de los triángulos isósceles:

→ En un triángulo isósceles, los dos lados iguales se llaman catetos y el ángulo entre ellos, el ángulo del vértice. El lado opuesto al ángulo del vértice se llama base.

→ La perpendicular desde el ángulo del vértice biseca la base y el ángulo del vértice.

→ Los ángulos de la base son iguales.

→ La perpendicular trazada desde el ángulo del vértice divide el triángulo en dos triángulos congruentes. Esta es también la línea de simetría del triángulo.

Propiedades de los triángulos escalenos:

→ Los ángulos son de diferente longitud.

→ No tiene lados paralelos o iguales. Por lo tanto, no hay eje de simetría.

→ Un triángulo escaleno puede ser un triángulo obtuso, agudo o rectángulo.

Recuerde que un triángulo obtuso es un triángulo en el que un ángulo mide más de 90 grados. Un triángulo obtuso puede ser un triángulo escaleno o isósceles, pero nunca será equilátero.

Descripción de la lección

Paso 1 Este paso incluye dos opciones (a y b) dependiendo del origen de las imágenes. Estas opciones no son secuenciales, el profesor deberá seleccionar una de ellas. Una vez que el profesor haya seleccionado, pedirá a los alumnos que realicen la última parte de este paso, el apartado c.

5-30 min

- a. Cargue 10 imágenes para cada tipo utilizando el enlace provisto (5 minutos)
- b. Pida a los estudiantes que busquen un mínimo de 10 imágenes para cada forma en Internet. El buscador de imágenes de Google puede ser de gran ayuda para esta tarea (30 minutos)
- c. Pida a los alumnos que carguen solo 2 imágenes diferentes para cada tipo de triángulo. De esta forma verán qué tan bien lo está haciendo el modelo ML al reducir los datos de entrenamiento

Todas las imágenes deben cargarse en LearningML, teniendo al final de este paso tres grupos de formas (isósceles, escaleno y triángulos equiláteros).

Paso 2 **Aprendizaje del modelo.** En este paso, LearningML aprende a clasificar imágenes, según los datos proporcionados en el Paso 1. En este punto es una buena oportunidad para presentar los conceptos más importantes de los diferentes triángulos. Los alumnos ya deben ser conscientes de las diferencias más significativas.

15 min

Paso 3 **Pruebas y discusión.** Pida a los alumnos que descarguen imágenes de triángulos de Internet y las suban a la fase pruebas de LearningML para ver los resultados. Como alternativa, el enlace proporcionado se puede utilizar para obtener estas imágenes de prueba. Para cada imagen cargada, los alumnos deben responder las siguientes preguntas:

30-60 min

- ¿Son correctos los resultados? (es decir, ¿es correcta la predicción hecha por el modelo de IA?)
- Si el resultado no es correcto, ¿puedes pensar en una razón por la cual el modelo predijo esa forma?
- ¿Qué propiedades usó (el estudiante) para identificar las formas?
- ¿Qué propiedades crees que usa el algoritmo para identificar las formas?

Pida a los alumnos que carguen un cuadrado y lo usen como imagen de prueba.

- ¿Cuál es la predicción hecha por el modelo?
- ¿Por qué el modelo predijo ese resultado?

Edificios religiosos

 Sujeto	 Edad	 Duración
Historia	10-12 años	1h o 2h (dependiendo de si usan el conjunto de datos provisto o lo crean por su cuenta)

Descripción y objetivos de aprendizaje

Esta lección es una actividad que se puede utilizar en una clase de historia. En esta actividad, los estudiantes estudiarán las características de los diferentes lugares de culto. Se estima que hay 10.000 religiones distintas en todo el mundo, pero cubriremos las arquitectura de las más populares: Cristianismo, Budismo e Islam. La actividad utiliza el ML para fortalecer el aprendizaje de los alumnos, así como otras habilidades transversales como el pensamiento crítico, la comunicación y la argumentación.

Situación previa

Esta clase es genérica y no requiere ningún conocimiento particular además de poder trabajar con un ordenador.

Metas educativas

- Aprender las diferencias de arquitectura en los diferentes lugares de culto.
- Ser capaz de identificar sus principales características.
- Promover el pensamiento crítico al utilizar la IA en la clasificación de los edificios.

Tipo de instrucción

Instrucción indirecta donde los estudiantes trabajan en grupos, discuten y resuelven problemas guiados por el maestro.

Material, recursos y equipos

- La Herramienta [LearningML](#), en particular su funcionalidad de imagen.
- Ordenador con buena conexión a Internet
- [Enlace al material](#)

Conceptos previos

(Adaptado de Wikipedia). La palabra **iglesia** deriva del griego ekklesia, que significa los llamados. Su significado original es para referirse al cuerpo de creyentes, o el cuerpo de Cristo. La palabra iglesia se usa para referirse a un lugar de culto cristiano por algunas denominaciones cristianas, incluidos los anglicanos y los católicos. Otras denominaciones cristianas se oponen al uso de la palabra "iglesia" para referirse a un edificio, ya que argumentan que esta palabra debe reservarse para el cuerpo de creyentes que adoran allí. En cambio, estos grupos usan palabras como "Salón" para identificar sus lugares de culto o cualquier edificio que utilicen con el propósito de reunirse.

Conceptos previos (continuado)

Una **mezquita**, que literalmente significa “lugar de postración”, es un lugar de culto para los seguidores del Islam. Hay requisitos estrictos y detallados en la jurisprudencia sunita para que un lugar de culto sea considerado una mezquita, y los lugares que no cumplen con estos requisitos se consideran musallas. Hay restricciones estrictas sobre los usos del área formalmente demarcada como mezquita (que a menudo es una pequeña parte del complejo más grande) y, en la ley islámica Sharia, después de que un área se designa formalmente como mezquita. Muchas mezquitas tienen cúpulas elaboradas, minaretes y salas de oración, en diferentes estilos de arquitectura. Las mezquitas se originaron en la Península Arábiga, pero ahora se encuentran en todos los continentes habitados. La mezquita sirve como un lugar donde los musulmanes pueden reunirse para el salat (que significa “oración”) así como un centro de información, educación, bienestar social y solución de controversias. El imán dirige a la congregación en oración.

Los **templos en el budismo** representan la tierra pura o el entorno puro de Buda. Los templos budistas están diseñados para inspirar paz interior y exterior. Su estructura y arquitectura varía de una región a otra. Por lo general, el templo consta no sólo de su edificio, sino también del entorno circundante. Los elementos arquitectónicos de un templo budista están destinados a incorporar temas y enseñanzas del budismo.

Descripción de la lección

Paso 1

5-30
min

Este paso incluye dos opciones (a y b) dependiendo del origen de las imágenes. Estas opciones no son secuenciales, el profesor deberá seleccionar una de ellas. Una vez que el profesor haya seleccionado, pedirá a los alumnos que realicen la última parte de este paso, el apartado c.

- a. Cargue 10 imágenes para cada tipo utilizando el enlace provisto (5 minutos)
- b. Pida a los alumnos que busquen al menos 10 imágenes de cada tipo de edificio religioso en Internet. El buscador de imágenes de Google puede ser de gran ayuda para esta tarea (30 minutos)
- c. Pida a los alumnos que carguen sólo 2 imágenes diferentes para cada tipo de edificio. De esta manera, verá qué tan bien lo está haciendo el modelo ML al reducir los datos de entrenamiento.

Todas las imágenes deben cargarse en LearningML, teniendo al final de este paso tres grupos de edificios religiosos (iglesias cristianas, mezquitas y templos budistas).

Paso 2

15 min

Entrenamiento del modelo. En este paso, LearningML aprende a clasificar imágenes basándose en los datos proporcionados en el Paso 1. En este punto es una buena oportunidad para presentar los conceptos más importantes de los diferentes edificios religiosos.

Paso 3

30-60
min

Pruebas y discusión. Pida a los alumnos que descarguen imágenes de edificios religiosos de Internet y que las carguen en la fase de pruebas de LearningML para ver los resultados. Como alternativa, el enlace proporcionado se puede utilizar para buscar imágenes. Para cada imagen cargada, los alumnos deben responder las siguientes preguntas:

- ¿Son correctos los resultados? (es decir, ¿es correcta la predicción hecha por el modelo de IA?)
- Si el resultado no es correcto, ¿puedes pensar en una razón por la cual el modelo predijo ese resultado?
- ¿Qué propiedades usó usted (el estudiante) para identificar los edificios?
- ¿Qué propiedades crees que usa el algoritmo para identificar los edificios?

Pida a los alumnos que suban una imagen de la iglesia de San Basilio en Moscú y que la utilicen como imagen de prueba.

- ¿Cuál es la predicción hecha por el modelo?
- Si el resultado no es correcto, ¿puedes pensar en una razón por la cual el modelo predijo esa forma?
- ¿Qué tipo de edificio es? ¿Qué razonamiento usaste?
- ¿Qué propiedades crees que usa el algoritmo para identificar este edificio?

Herramientas adicionales

En esta sección presentamos algunas herramientas que se pueden utilizar en el aula. Estas no son lecciones en sí mismas.

Música

[Magenta](#) es un proyecto de investigación de código abierto que explora cómo se puede utilizar el aprendizaje automático en el proceso creativo. El objetivo principal es mostrar que el ML se puede utilizar para habilitar y mejorar el potencial creativo de las personas. Proporciona una variedad de demostraciones de código abierto que involucran la interacción con la música.

Usar el ML para generar música y trabajar con música generada por computadora puede abrir un nuevo mundo de oportunidades en la enseñanza de la música. Por ejemplo, cambiar o mejorar la música que se ha compuesto mediante el aprendizaje automático puede representar un desafío emocionante para los estudiantes.

Las herramientas listas para usar se pueden encontrar aquí: <https://magenta.tensorflow.org/demos>. Este proyecto sigue activo y hay más herramientas en desarrollo.

Glosario

Agrupación	Organizar datos en subgrupos con atributos o elementos similares
Algoritmo	Conjunto de instrucciones o reglas definidas y no ambiguas, ordenadas y finitas que permiten resolver un problema. En nuestro caso, las computadoras usan algoritmos para procesar datos y realizar otras tareas como la clasificación.
Aprendizaje automático (ML)	Subcampo de la IA en el que los algoritmos aprenden de los datos
Aprendizaje por refuerzo	Subcampo de la IA en el que los algoritmos aprenden de la interacción con el entorno en base a recompensas.
Aprendizaje no supervisado	Subcampo del aprendizaje automático. Los algoritmos de aprendizaje automático no supervisados se entrenan utilizando datos no etiquetados. Se utiliza en agrupamiento.
Aprendizaje supervisado	Subcampo del aprendizaje automático. Los algoritmos de aprendizaje automático supervisados se entrenan utilizando datos etiquetados. Se utiliza en clasificación y regresión.
Atributo cualitativo o variable	Se refiere a variables que no se pueden medir fácilmente, como olores, sabores, texturas y atractivo
Atributo o variable cuantitativa	Se refiere a variables que pueden describirse mediante números, o un conjunto de ellos, es decir, variables que pueden medirse objetivamente.
Bot conversacional	Programa informático que simula y procesa la conversación humana (ya sea escrita o hablada), lo que permite a los humanos interactuar con dispositivos digitales como si se estuvieran comunicando con una persona real.
Caja negra	En ciencia, computación e ingeniería, una caja negra es un dispositivo, sistema u objeto que produce información sin revelar ninguna información sobre su funcionamiento interno.
Clasificación	Categorizar un conjunto de datos en clases, ejemplos son la detección de correo no deseado, la clasificación de dígitos escritos a mano, la detección de fraude, ...
Datos	Grupo de datos. Los datos describen hechos empíricos, eventos y entidades. Los datos pueden representar ideas abstractas o medidas concretas.

Datos etiquetados	Conjunto de muestras que han sido etiquetadas con una o más etiquetas. Los datos etiquetados se utilizan en el aprendizaje supervisado.
Fase de aprendizaje	Esta es la fase en la que el modelo aprende a asignar la entrada a la salida en función de los datos de entrenamiento. El resultado de esta fase es un modelo de IA que se puede usar para predecir un resultado para una entrada no vista anteriormente.
Fase de entrenamiento	Sinónimo de la fase de aprendizaje
Inteligencia artificial (IA)	Disciplina de la informática que trata de replicar y desarrollar la inteligencia humana y sus procesos implícitos a través de los ordenadores.
LearningML	Herramienta web de código abierto diseñada para enseñar IA a los niños. Simplifica el proceso y proporciona una interfaz fácil de usar para entrenar y probar un modelo de clasificación. Permite utilizar imágenes, texto o conjuntos de datos numéricos.
Modelo	La función que asigna la entrada a la salida. En el aprendizaje automático, esta función se aprende utilizando datos, también llamados datos de entrenamiento. En el aprendizaje automático, el modelo aprendido es una caja negra.
Muestra	Unidad mínima de datos.
Patrón	Una secuencia de objetos, formas o números que se repiten
Reconocimiento de patrones	Proceso de identificación de patrones y regularidades en los datos
Red neuronal	Ver Redes neuronales artificiales
Redes neuronales artificiales (ANN)	También llamadas redes neuronales, son sistemas informáticos inspirados en las redes neuronales biológicas que constituyen los cerebros de los animales. Las ANN consisten en una colección de nodos o neuronas conectados, normalmente organizados en capas. Cada nodo recibe información, la procesa y la envía a los nodos conectados a él. Las conexiones se denominan bordes y, por lo general, tienen un peso que se ajusta a medida que avanza el aprendizaje.
Regresión	Modelar la relación entre variables independientes y una variable dependiente (objetivo) donde la variable objetivo es una variable continua como temperatura, edad, salario, precio
Sesgo	Tendencias, inclinaciones o prejuicios hacia o contra alguien o algo. Los sistemas de IA pueden estar sesgados debido a varias razones, como la calidad de los datos, el submuestreo y el sobremuestreo, etc.

Bibliografía relacionada

Herramienta LearningML

- Rodríguez, Juan & Moreno-León, Jesús & Román-González, Marcos & Robles, Gregorio. (2021). Evaluation of an Online Intervention to Teach Artificial Intelligence With LearningML to 10–16–Year–Old Students.
- LearningML frontpage: <https://web.learningml.org/>

Sesgo en IA

- Rosenfeld, Hannah, Danni Yu, and Abhishek Gupta. 2023. "Ethical AI requires future-ready, inclusive education system | World Economic Forum." The World Economic Forum, June 5, 2023. <https://www.weforum.org/agenda/2023/06/ethical-ai-future-ready-inclusive-education-system/>
- Blackman, Reid. 2020. "A Practical Guide to Building Ethical AI." Harvard Business Review, October 15, 2020. <https://hbr.org/2020/10/a-practical-guide-to-building-ethical-ai>
- Burton, Emanuelle, Judy Goldsmith, Sven Koenig, Benjamin Kuipers, Nicholas Mattei, and Toby Walsh. 2017. "Ethical Considerations in Artificial Intelligence Courses." AI Magazine 38(2) (July): pp22–34. <https://doi.org/10.1609/aimag.v38i2.2731>
- Warikoo, Natasha, Stacey Sinclair, Jessica Fei, and Drew Jacoby-Senghor. n.d. "Examining Racial Bias in Education: A New Approach." Educational Researcher 45 (9). <https://doi.org/10.3102/0013189X16683408>
- Zittleman, Karen, and David Sadker. 2022. "Gender Bias in Teacher Education Texts: New (and Old) Lessons." Journal of Teacher Education 53, no. 2 (March): 168–180. <https://doi.org/10.1177/0022487102053002008>
- Hao, Karen. 2019. "Facebook's ad-serving algorithm discriminates by gender and race." MIT Technology Review. <https://www.technologyreview.com/2019/04/05/1175/facebook-algorithm-discriminates-ai-bias/>

IA en educación no formal

- Norqvist, Lars, and Eva Leffler. 2017. "Learning in non-formal education: Is it "youthful" for youth in action?" Springer link 63 (March): pp235–256. <https://doi.org/10.1007/s11159-017-9631-8>
- "Visa SVP Carolina Barcenás: "Educating the general public on AI is key to ethical use and smart" 2019. Medium. <https://medium.com/authority-magazine/visa-svp-carolina-barcenas-educating-the-general-public-on-ai-is-key-to-ethical-use-and-smart-ea080f37966c>

IA en educación formal

- Willis, Robert J., and Sherwin Rosen. 1979. "Education and Self-Selection." *Journal of Political Economy* 87, no. 5 (October). <https://doi.org/10.1086/260821>
- Glewwe, Paul. 2002. "Schools and Skills in Developing Countries: Education Policies and Socioeconomic Outcomes." *Journal of Economic Literature* 40, no. 2 (June): pp436-482. 10.1257/002205102320161258
- Gururaj, Tejasri. 2023. "10 examples of how artificial intelligence is improving education." *Interesting Engineering*. <https://interestingengineering.com/lists/examples-how-artificial-intelligence-improving-education>
- Morron, Mirriam. 2023. "The Impact of AI on Learning and Creativity: A Critical Look at the Future." LinkedIn. <https://www.linkedin.com/pulse/impact-ai-learning-creativity-critical-look-future-miriam-morron/>
- "Role Models in AI: Stephanie Lampkin | by AI4ALL Team | AI4ALL." 2019. Medium. <https://medium.com/ai4allorg/role-models-in-ai-stephanie-lampkin-f50e6885afa4>
- "Female role models changing the field of Artificial Intelligence in Norway - NORA." n.d. Norwegian Artificial Intelligence Research Consortium. Accessed June 16, 2023. <https://www.nora.ai/news-and-events/news/30-women-in-norway-changing-the-field-of-artificia.html>

Mejores prácticas para IA

- Zowghi, Didar, and Francesca da Rimini. 2023. *Responsible AI: Best Practices for Creating Trustworthy AI Systems*. N.p.: Pearson Addison Wesley. <https://doi.org/10.48550/arXiv.2305.12728>
- Xu, Feiyu, Hans Uszkoreit, Yangzhou Du, Wei Fan, Dongyan Zhao, and Jun Zhu. 2019. "Explainable AI: A Brief Survey on History, Research Areas, Approaches and Challenges." In *Lecture Notes in Computer Science*, pp563-574. Vol. 11839. N.p.: Springer. https://doi.org/10.1007/978-3-030-32236-6_51

Juegos con IA

- "The tag game | Activities." n.d. Scouts. Accessed June 16, 2023. <https://www.scouts.org.uk/activities/the-tag-game/>
- "Describe and draw | Activities." n.d. Scouts. Accessed June 16, 2023. <https://www.scouts.org.uk/activities/draw-the-description/>

Glosarios

- Instituto de Estadística de la UNESCO: [Glosario \[ENG\]](#)
- Facultad de Medio Ambiente, Universidad de Washington: [Glosario de diversidad, equidad e inclusión \[ENG\]](#)
- Recursos Humanos de Harvard: [Glosario de términos de diversidad, inclusión y pertenencia \[ENG\]](#)

Fomentando la Inteligencia Artificial en las Escuelas

Directrices para profesores de educación formal

