



Universidad
Tecmilenio®



Aprendizaje Automático No Supervisado

Introducción al
aprendizaje automático
supervisado



Los términos de inteligencia artificial y aprendizaje automático a menudo se relacionan con las ciencias de la computación, pero la raíz de estas palabras se encuentra en la convergencia de múltiples disciplinas, como las matemáticas puras, la ingeniería eléctrica, la estadística, el procesamiento de señales, los sistemas de comunicaciones y la computación en sí misma. Por lo tanto, sus aplicaciones actualmente se encuentran prácticamente en cualquier lugar.

A finales de la década de 1970, la industria del aprendizaje automático, que incluía una gran cantidad de investigadores y técnicos, se reorganizó y su enfoque general cambió a los métodos y tácticas utilizados en la teoría de la probabilidad y la estadística, pero durante este tiempo mantuvo de forma paralela su investigación en las redes neuronales y luego floreció en la década de 1990. La mayor parte de este éxito fue el resultado del crecimiento del Internet, beneficiándose de la disponibilidad cada vez mayor de los datos digitales y la capacidad de compartir sus servicios a través de esta red.





Los algoritmos de aprendizaje automático, de acuerdo con el enfoque que utilizan, se clasifican en cuatro grupos principales:

- **Aprendizaje supervisado:** un sistema de aprendizaje automático se conforma de una función principal (modelo) que es capaz de generar un conjunto de salidas para unas entradas dadas.
- **Aprendizaje no supervisado:** los datos no están etiquetados en este tipo de paradigma de aprendizaje. Un ejemplo clásico de este grupo es la clusterización.
- **Aprendizaje por refuerzo:** este tipo de aprendizaje es un método especial que no clasifica como ninguno de los grupos anteriores, ya que aunque no incluye muestras etiquetadas para el entrenamiento, involucra algún tipo de retroalimentación del entorno.
- **Aprendizaje profundo:** este enfoque incorpora el uso de las redes neuronales agrupadas en capas sucesivas para realizar el proceso de aprendizaje de los datos de manera iterativa.





Los sistemas que procesan datos etiquetados estáticos se denominan **métodos de aprendizaje estáticos**, mientras que los sistemas que tratan con datos que cambian continuamente con el tiempo se denominan **métodos dinámicos**.

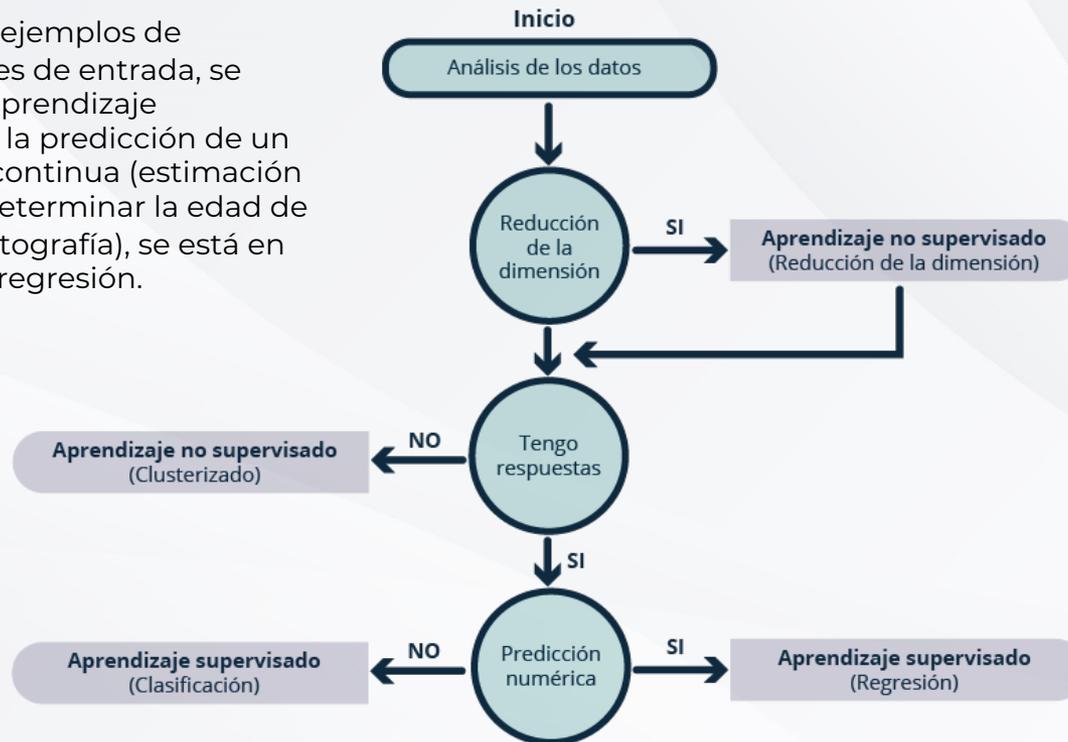
- Métodos estáticos: el aprendizaje estático se refiere al aprendizaje de los datos que se toman como muestras instantáneas y cuyas propiedades permanecen constantes a lo largo del tiempo.
- Métodos dinámicos: este método también se denomina aprendizaje basado en series de tiempo. Los datos que se utilizan en este tipo de problemas son sensibles al tiempo y cambian con el transcurso de este.





Para resolver un problema con aprendizaje automático es necesario conocer con claridad la situación que se quiere analizar y la naturaleza de los datos que la describen.

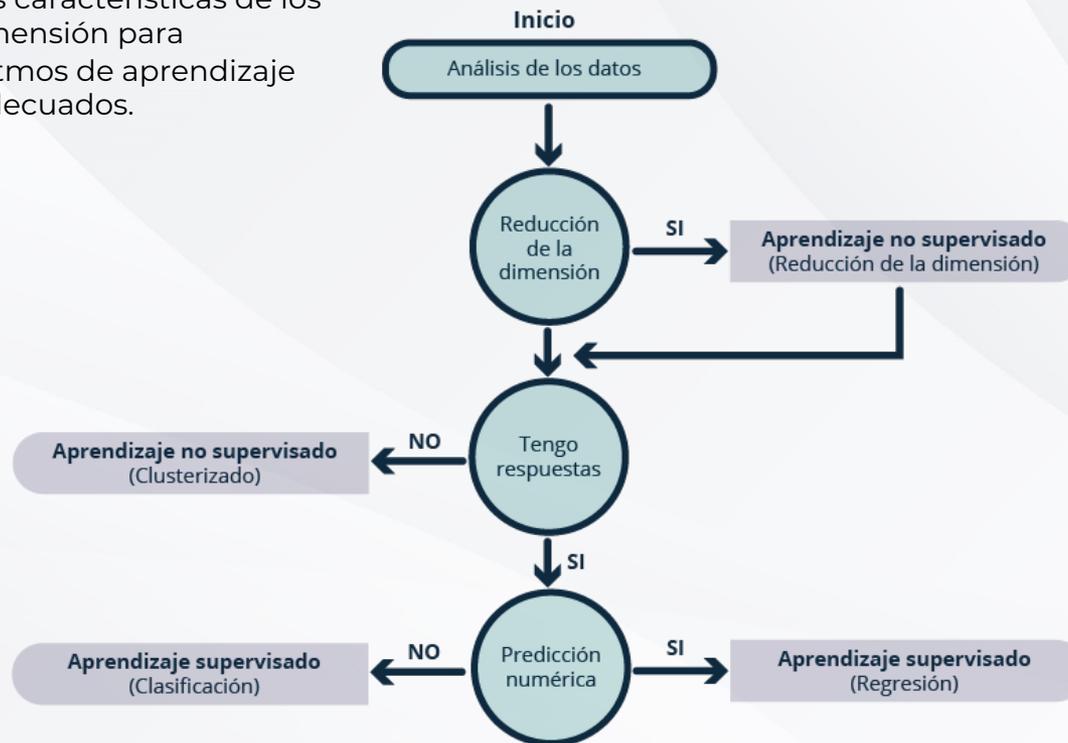
Si la información base incluye ejemplos de respuestas para algunos valores de entrada, se puede utilizar el enfoque del aprendizaje supervisado. Si la respuesta es la predicción de un valor numérico en una salida continua (estimación de precio de una propiedad, determinar la edad de una persona a partir de una fotografía), se está en presencia de un problema de regresión.





En el caso de que la respuesta consista en encontrar una categoría específica (puede ser una o varias), estamos ante un problema de clasificación.

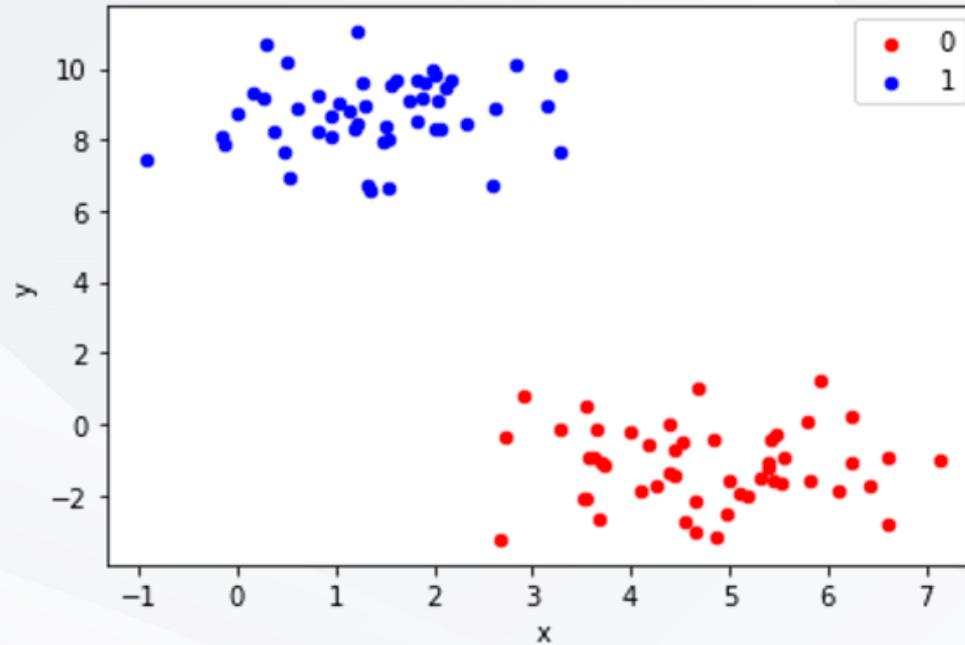
Si no tenemos respuestas o las características de los datos requieren reducir su dimensión para analizarse, entonces los algoritmos de aprendizaje no supervisado son los más adecuados.





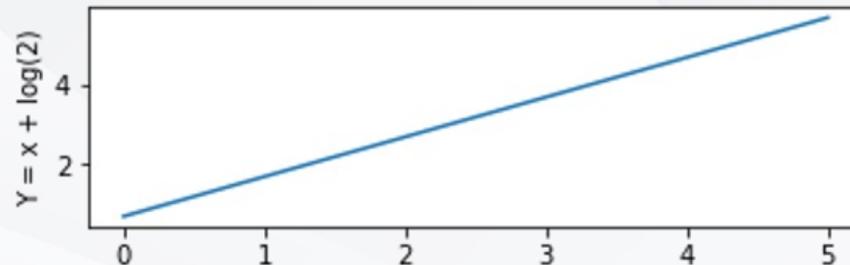
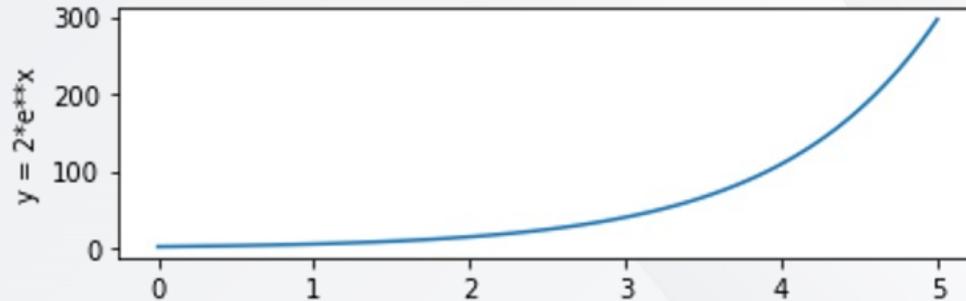
Linealidad en los datos: los datos se denominan lineales si la relación entre la entrada y la salida es lineal. Esto quiere decir que, cuando el valor de la entrada aumenta, el valor de la salida también aumenta y viceversa.

La relación inversa entre estos valores también se considera lineal y seguirá la regla de proporcionalidad con la inversión del signo para la entrada y la salida. La figura muestra gráficamente una posible relación lineal entre entradas y salidas.



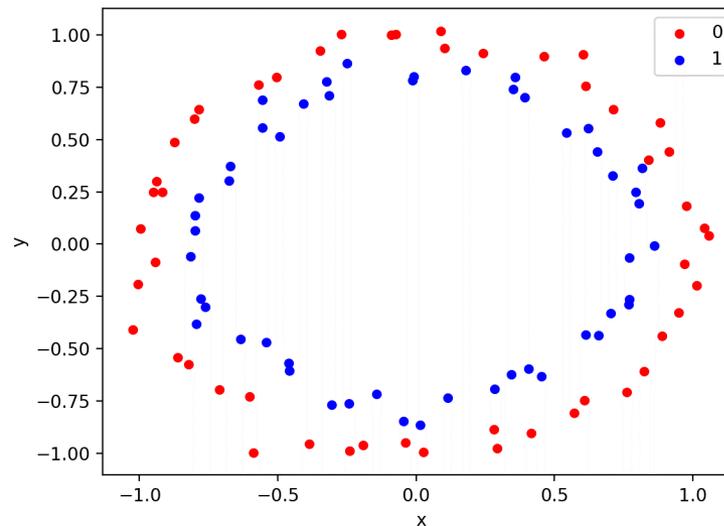


Linealidad en los modelos: los modelos lineales tienen una definición un poco más complicada que la de linealidad en los datos. En este caso, todos los modelos que utilizan ecuaciones lineales para representar la relación entre la entrada y la salida se denominan modelos lineales. Sin embargo, en ocasiones es necesario precondicionar la entrada o la salida (que pueden tener una relación no lineal) a una relación lineal, para luego aplicar el modelo lineal. Por ejemplo, si la entrada y la salida están relacionadas con una relación exponencial como, en este caso, los datos son claramente no lineales.





En algunos casos, la relación entre entradas y salidas es puramente no lineal, por lo que se necesita un modelo no lineal adecuado para mapearla. La figura muestra un ejemplo de relación entre datos no lineales.



Los modelos no lineales utilizan otro tipo de funciones para aproximarse a las características no lineales de los datos. Ejemplos de este tipo de modelos son las redes neuronales, los árboles de decisión, los modelos probabilísticos, entre otros.





La comprensión de los datos se puede dividir en tres partes:

- **Entender las entidades:** las entidades representan grupos de datos separados en función de los temas conceptuales que identifican o por los métodos por los cuales se adquirieron. En la figura se muestra la representación de una entidad que contiene la información de varias de las mediciones realizadas de forma experimental a los sépalos y pétalos de tres variedades de la flor de iris

	sepal length	sepal width	petal length	petal width	target
0	5.1	3.5	1.4	0.2	Iris-setosa
1	4.9	3.0	1.4	0.2	Iris-setosa
2	4.7	3.2	1.3	0.2	Iris-setosa
3	4.6	3.1	1.5	0.2	Iris-setosa
4	5.0	3.6	1.4	0.2	Iris-setosa
...
145	6.7	3.0	5.2	2.3	Iris-virginica
146	6.3	2.5	5.0	1.9	Iris-virginica
147	6.5	3.0	5.2	2.0	Iris-virginica
148	6.2	3.4	5.4	2.3	Iris-virginica
149	5.9	3.0	5.1	1.8	Iris-virginica





- **Comprensión de los atributos:** cada atributo se puede considerar como una columna en el archivo o la tabla. En el caso de los datos de las flores de iris, los atributos de cada entidad única son la longitud del sépalo en centímetros, el ancho del sépalo en centímetros, la longitud del pétalo en centímetros y el ancho del pétalo en centímetros. Si se hubieran agregado entidades adicionales como olor, color o longevidad, cada una de esas entidades tendría sus propios atributos.

	sepal length	sepal width	petal length	petal width	target
0	5.1	3.5	1.4	0.2	Iris-setosa
1	4.9	3.0	1.4	0.2	Iris-setosa
2	4.7	3.2	1.3	0.2	Iris-setosa
3	4.6	3.1	1.5	0.2	Iris-setosa
4	5.0	3.6	1.4	0.2	Iris-setosa
...
145	6.7	3.0	5.2	2.3	Iris-virginica
146	6.3	2.5	5.0	1.9	Iris-virginica
147	6.5	3.0	5.2	2.0	Iris-virginica
148	6.2	3.4	5.4	2.3	Iris-virginica
149	5.9	3.0	5.1	1.8	Iris-virginica





- **Comprensión de los tipos de datos:** los atributos en cada entidad pueden contener varios tipos de datos diferentes desde la perspectiva del almacenamiento y procesamiento (cadena de caracteres, entero, fecha y hora, booleano, entre otros). Los atributos pueden tener su origen en dominios completamente diferentes, como una imagen o un archivo de sonido. Cada tipo debe manejarse por separado para generar un vector de características que será consumido por el algoritmo de aprendizaje automático.

	sepal length	sepal width	petal length	petal width	target
0	5.1	3.5	1.4	0.2	Iris-setosa
1	4.9	3.0	1.4	0.2	Iris-setosa
2	4.7	3.2	1.3	0.2	Iris-setosa
3	4.6	3.1	1.5	0.2	Iris-setosa
4	5.0	3.6	1.4	0.2	Iris-setosa
...
145	6.7	3.0	5.2	2.3	Iris-virginica
146	6.3	2.5	5.0	1.9	Iris-virginica
147	6.5	3.0	5.2	2.0	Iris-virginica
148	6.2	3.4	5.4	2.3	Iris-virginica
149	5.9	3.0	5.1	1.8	Iris-virginica





Los datos que conforman el ejemplo de las flores de iris tienen cuatro dimensiones. En casos como este, no hay forma de graficar la información completa de cada muestra en un solo gráfico. Para estas situaciones se pueden considerar dos opciones diferentes:

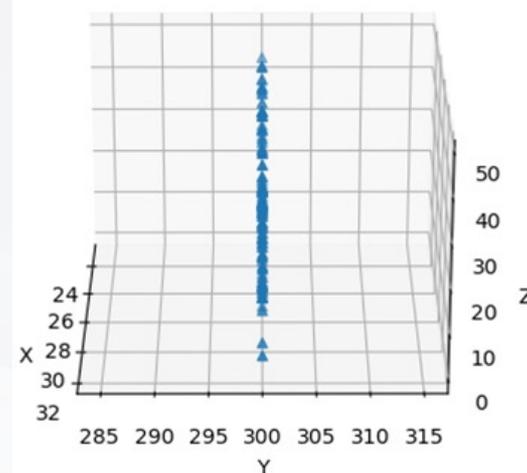
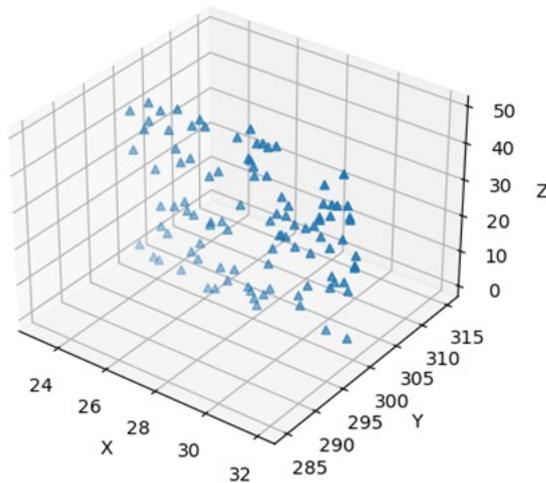
- Dibujar varios gráficos tomando dos o tres dimensiones a la vez.
- Reducir la dimensionalidad de los datos y graficarlos en tres dimensiones.

	sepal length	sepal width	petal length	petal width	target
0	5.1	3.5	1.4	0.2	Iris-setosa
1	4.9	3.0	1.4	0.2	Iris-setosa
2	4.7	3.2	1.3	0.2	Iris-setosa
3	4.6	3.1	1.5	0.2	Iris-setosa
4	5.0	3.6	1.4	0.2	Iris-setosa
...
145	6.7	3.0	5.2	2.3	Iris-virginica
146	6.3	2.5	5.0	1.9	Iris-virginica
147	6.5	3.0	5.2	2.0	Iris-virginica
148	6.2	3.4	5.4	2.3	Iris-virginica
149	5.9	3.0	5.1	1.8	Iris-virginica



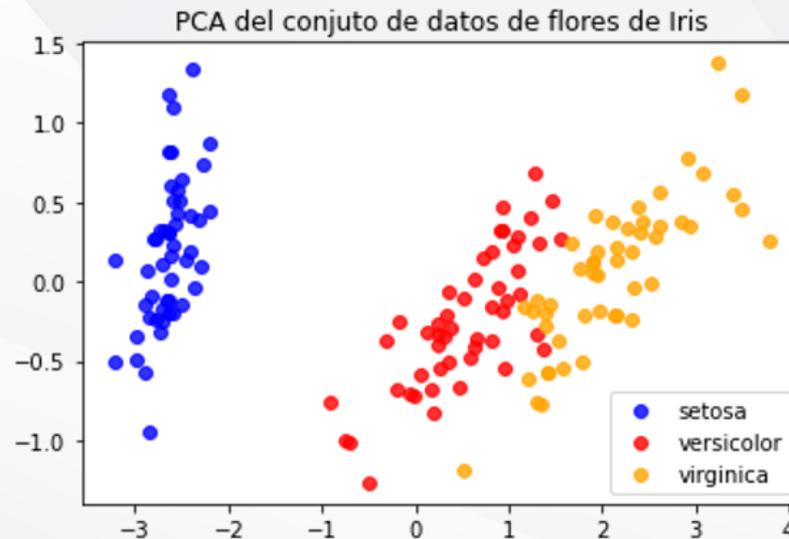


Por ejemplo, los datos tridimensionales graficados en la primera figura son los mismos datos graficados con una perspectiva diferente en la segunda. Como se puede ver en la segunda gráfica, al ajustar las coordenadas de manera adecuada, los datos son en realidad bidimensionales. En otras palabras, si podemos encontrar las coordenadas exactas (X, Y) de la orientación del plano como una combinación lineal de las coordenadas X, Y y Z del espacio tridimensional, podemos reducir la dimensionalidad de los datos de tres a dos.





El proceso matemático para encontrar la información distribuida en todas las dimensiones y luego clasificar las dimensiones en función del contenido de la información se realiza utilizando la teoría del análisis de componentes principales o PCA.

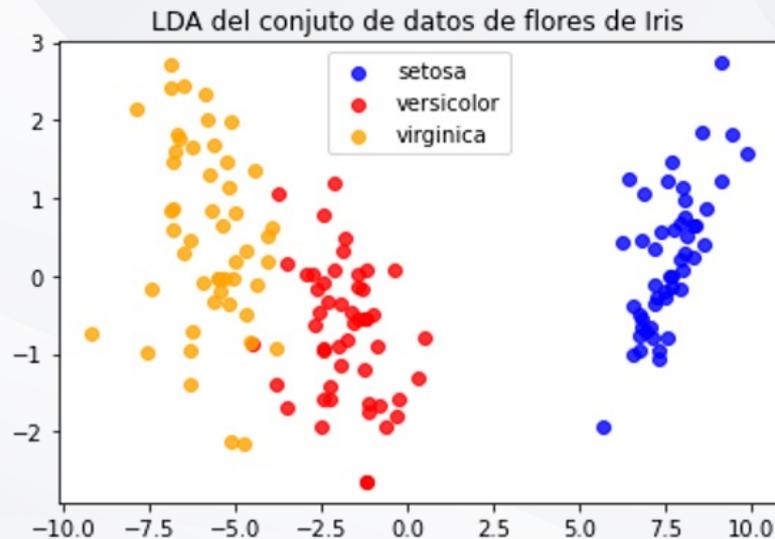


El PCA no se limita solo a reducir las dimensiones, sino a encontrar las dimensiones óptimas que representan los datos. En la figura se puede observar cómo se representan los datos después de realizado el análisis de componentes principales para el ejemplo de la flor de iris.





El PCA intenta encontrar las dimensiones que maximizan la varianza de los datos, mientras que el análisis discriminante lineal o LDA intenta maximizar la separación entre las diferentes clases de estos. El LDA funciona de manera efectiva cuando se trata de un tipo de problema de clasificación, donde los datos contienen intrínsecamente múltiples clases.



En este caso, el elemento k representa el número de clases. Por lo tanto, al hacer esta clasificación, encuentra una representación de los datos en una dimensión menor. La figura muestra la separación de las clases, utilizando el método del análisis de discriminante lineal





Después de haber estudiado el tema puedes abordar las siguientes cuestiones:

- ¿A qué otro tipo de conjunto de datos podrías aplicar las técnicas de PCA o LDA?
- Busca ejemplosa de aplicaciones que trabajen con aprendizaje supervisado y no supervisado, de modo que puedas comparar el propósito de cada una.





En este tema se dio un recorrido por los diferentes tipos de aprendizaje automático: aprendizaje supervisado, no supervisado, con refuerzo y el aprendizaje profundo. Se estudiaron los métodos basados en el tiempo y la importancia de considerar este factor al momento de analizar una problemática o seleccionar un modelo de aprendizaje.

Se destacaron algunos aspectos relacionados con la interpretación inicial de la naturaleza de datos y, a partir del resultado esperado, decidir cuál sería el camino más adecuado para abordar una solución específica.

Se analizaron los elementos que conforman la preparación previa de los datos antes de utilizarlos para entrenar los diversos modelos de aprendizaje automático, ya que cada situación posee un conjunto único de propiedades y peculiaridades.

Al vivir en un mundo tridimensional se nos facilita tener una imagen mental aproximada de la estructura de los datos que tengan estas dimensiones, pero cuando este límite es superado, se vuelve mucho más complicado lograr este resultado. Una forma de alcanzar este objetivo es descomponer los datos y construir varios gráficos separados, esta práctica puede ser útil, pero tiende a causar confusión y a la elaboración de conclusiones erróneas. La reducción de la dimensionalidad es, entonces, el método típicamente preferido. Las formas más comunes que se utilizan para reducir la dimensionalidad son el análisis de componentes principales y el análisis de discriminante lineal.



Aprendizaje Automático No Supervisado

Métodos lineales
básicos



La regresión lineal es uno de los algoritmos de aprendizaje supervisado más sencillos y fáciles de comprender, por lo cual, es un excelente punto de partida para comenzar el aprendizaje en esta temática.

Aunque varios científicos y astrónomos intentaron localizar al famoso asteroide, la única información valiosa que se tenía consistía en los datos sobre las observaciones realizadas durante esos primeros días de avistamiento. El método ideado por Gauss, el de los mínimos cuadrados, fue el único capaz de predecir con exactitud dónde se encontraría dicho asteroide, lo cual fue comprobado cuando se logró visualizar nuevamente a finales de 1801.



En el desarrollo de este tema verás algunos ejemplos de cómo se aplica el famoso método de Gauss para encontrar los parámetros de una función de la regresión lineal. Asimismo, aprenderás cuál es la forma correcta de utilizarla para crear modelos de predicción que demuestren un buen rendimiento en la solución de problemas reales.





Los modelos que operan con datos estrictamente lineales se denominan **modelos lineales**, mientras que los modelos que utilizan alguna transformación no lineal para mapear los datos no lineales originales de un problema a estructuras lineales para luego procesarlas, se denominan **modelos lineales generalizados**.

Para el aprendizaje no supervisado, el concepto de linealidad implica que las distribuciones que se pueden asociar a los datos se definen mediante ecuaciones lineales. Es importante destacar que la noción de linealidad no implica ninguna restricción en las dimensiones. Por lo tanto, podemos tener datos multivariados que sean estrictamente lineales.





El modelo que se está proponiendo (modelo lineal) se conoce como línea de regresión y su ecuación se representa de la siguiente forma:

$$h(x_i) = \beta_0 + \beta_1 x_i$$

Los valores buscados de β_0 y β_1 se obtienen cuando $J(\beta_0$ y $\beta_1)$ es mínimo. Después de realizado el cálculo matemático, se obtiene como resultado:

$$\beta_1 = \frac{SS_{xy}}{SS_{xx}}$$

$$\beta_0 = \bar{y} - \beta_1 \bar{x}$$

Donde SS_{xy} son las desviaciones cruzadas y SS_{xx} se representa por la suma de las desviaciones cuadráticas de x :

$$SS_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n y_i x_i - n\bar{x}\bar{y}$$

$$SS_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n(\bar{x})^2$$





La regresión lineal simple es la forma más básica de la regresión lineal y se usa para predecir una respuesta a partir de características simples. En este caso, asumiremos que existe una relación lineal entre las dos variables x y y , de manera que se quiere obtener una función lineal que pueda predecir el valor de la respuesta (y) con la mayor precisión posible en función de la variable o característica independiente (x).

Supongamos que tenemos un problema cuyos datos representan la relación entre la cantidad de horas que un jugador invierte en un videojuego (en horas) y el rango (en puntos) que tiene:

Tiempo invertido	20	45	80	100	160	175	190	215	223	257	289	300	358	400	428	460	489
Rango	10	19	27	38	47	56	63	74	87	96	110	126	148	159	170	200	216

Para este caso se puede definir de manera general que:

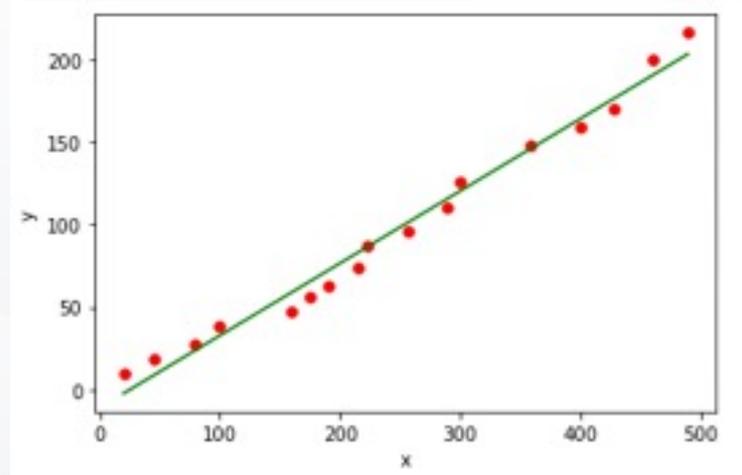
- La entrada x está definida como el vector de características $x = [x_1, x_2, \dots, x_n]$.
- La salida y está definida como el vector de características $y = [y_1, y_2, \dots, y_n]$.





Es posible desarrollar y programar un modelo de aprendizaje automático capaz de predecir el rango del jugador, conociendo la cantidad de horas jugadas, correspondiente a la tabla anterior.

Utilizando SS_{xy} y SS_{xx} , se programó una función de estimación de los parámetros y se obtuvo la siguiente gráfica:



Confirmando que los datos efectivamente representan una relación lineal. Finalmente, se puede emplear el modelo para realizar predicciones.





Busca otro ejemplo al que puedas aplicar regresión lineal.

Revisa los resultados gráficamente y evalúa su desempeño.





En este tema se realizó la introducción a uno de los modelos lineales más sencillos, pero al mismo tiempo más utilizados del aprendizaje automático: la regresión lineal.

En ocasiones, los datos no representan una relación estrictamente lineal, por lo que es necesario acudir a los modelos generalizados que, si bien resultan un poco más complejos de implementar, conservan los principios de este modelo básico en su esencia.

La regresión lineal simple establece las relaciones entre una variable independiente (respuesta) y las características (variables independientes), donde el objetivo principal es encontrar los valores adecuados de los parámetros para ajustar la función lo mejor posible a los datos de entrenamiento.





Tecmilenio no guarda relación alguna con las marcas mencionadas como ejemplo. Las marcas son propiedad de sus titulares conforme a la legislación aplicable, estas se utilizan con fines académicos y didácticos, por lo que no existen fines de lucro, relación publicitaria o de patrocinio.

Todos los derechos reservados @ Universidad Tecmilenio

La obra presentada es propiedad de ENSEÑANZA E INVESTIGACIÓN SUPERIOR A.C. (UNIVERSIDAD TECMILENIO), protegida por la Ley Federal de Derecho de Autor; la alteración o deformación de una obra, así como su reproducción, exhibición o ejecución pública sin el consentimiento de su autor y titular de los derechos correspondientes es constitutivo de un delito tipificado en la Ley Federal de Derechos de Autor, así como en las Leyes Internacionales de Derecho de Autor. El uso de imágenes, fragmentos de videos, fragmentos de eventos culturales, programas y demás material que sea objeto de protección de los derechos de autor, es exclusivamente para fines educativos e informativos, y cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por UNIVERSIDAD TECMILENIO. Queda prohibido copiar, reproducir, distribuir, publicar, transmitir, difundir, o en cualquier modo explotar cualquier parte de esta obra sin la autorización previa por escrito de UNIVERSIDAD TECMILENIO. Sin embargo, usted podrá bajar material a su computadora personal para uso exclusivamente personal o educacional y no comercial limitado a una copia por página. No se podrá remover o alterar de la copia ninguna leyenda de Derechos de Autor o la que manifieste la autoría del material.

