

Aprendizaje No Supervisado

Machine Learning



Agenda


1. ¿Qué es el Aprendizaje No Supervisado?
2. K-Means
 1. Idea General
 2. Algoritmo de K-Means
 3. Inicialización de K-Means
 4. ¿Cómo elegir K?
3. K-Means++



¿Qué es el
Aprendizaje No
Supervisado?


Aprendizaje No Supervisado

¡Debemos encontrar patrones en los datos!



Aprendizaje Supervisado

$$\{(x^{(1)}, y^{(1)}), \dots, (x^{(n)}, y^{(n)})\}$$



Aprendizaje No Supervisado


$$\{x^{(1)}, x^{(2)}, \dots, x^{(n)}\}$$

Aprendizaje No Supervisado

- En el aprendizaje no supervisado no se dan las clases o valores correctos de los datos.
- ¿Por qué? No siempre es posible determinar el número de clases de antemano, o es caro o difícil determinarlas.
- Aquí la tarea es encontrar estructuras o patrones en los datos.

Aprendizaje No Supervisado

- En el aprendizaje no supervisado no se dan las clases o valores correctos de los datos.
- ¿Por qué? No siempre es posible determinar el número de clases de antemano, o es caro o difícil determinarlas.
- Aquí la tarea es encontrar estructuras o patrones en los datos.
- Se busca detectar clústeres en los datos.




¿Qué es un clúster?



Esta foto de Autor desconocido está bajo licencia [CC BY-NC-ND](https://creativecommons.org/licenses/by-nc-nd/4.0/)

Año	(Década del 2010)
Género	(Alternativo)
Lugar	(Estados Unidos)
Ambiente	
Social	(Empoderamiento)



Aprendizaje No Supervisado

Una tarea común es en la clasificación de noticias:


- No sabemos en cuantas clases separar cada noticias. E.g., deportes, sociales, nacional, internacional, etc.
- Una forma es determinar clústeres por medio de similitud en cuanto a temas y palabras.




The image shows a Google News search results page for the query "Falcon Heene". The search bar at the top contains the text "Falcon Heene" and has buttons for "Buscar en Noticias" and "Buscar en la Web". Below the search bar, the page displays several news results. The first result is from "La Gaceta Tucumán" with the headline "Lo creían atrapado en un globo y estaba en el garaje de su casa". The second result is from "True/Slant" with the headline "Balloon Boy Falcon Heene Farts on Larry King". The third result is from "AP News in Brief" with the headline "They found themselves at the center of yet another strange saga Thursday when 6-year-old Falcon Heene vanished around the time that a homemade helium...". The fourth result is from "BBC" with the headline "Boy in the Balloon Falcon Heene found". The page also includes a sidebar with filters for content type and sorting options.

Aprendizaje No Supervisado

SAMPLE MARKET SEGMENTATION:
FAMILY LIFE STAGE



Esta foto de Autor desconocido está bajo licencia [CC BY](#)




Esta foto de Autor desconocido está bajo licencia [CC BY-SA](#)



K-Means


K-Means



Tenemos nuestros datos, que por cuestiones de explicación, **solo cuentan con dos dimensiones** x_1 y x_2 .

Además, deseamos **dividir los datos en 2 grupos distintos**, es decir, 2 clústeres.


K-Means



Iniciamos el algoritmo **proponiendo dos centroides**, uno por cada clúster que se quiere encontrar. Usualmente es al azar.


Estos puntos se conocen como **los centroides del clúster**.

K-Means



El primer paso consiste en **asignar cada punto a uno de los centroides** según su distancia. Es decir, **se asigna al más cercano.**


K-Means



El primer paso consiste en **asignar cada punto a uno de los centroides** según su distancia. Es decir, **se asigna al más cercano**.


Este paso se le conoce como **asignación del clúster**.

K-Means




El segundo paso consiste en **mover los centroides**. Lo que sucede aquí es mover la ubicación de los centroides **al promedio o media de los puntos del mismo color**.

K-Means




El segundo paso consiste en **mover los centroides**. Lo que sucede aquí es mover la ubicación de los centroides **al promedio o media de los puntos del mismo color**.

K-Means




Se **repite el paso de asignación** de clúster con las nuevas ubicaciones.

K-Means




Se **repite el paso de movimiento de los centroides** del clúster con los nuevos puntos.

K-Means



Se **repite el paso de asignación** de clúster con las nuevas ubicaciones.

K-Means



Se **repite el paso de movimiento de los centroides** del clúster con los nuevos puntos.

Es posible **repetir el proceso de asignación y movimiento**, pero de aquí en adelante daría los mismos resultados.

Algoritmo de K-Means

Entrada:

- K (número de clústeres)
- Conjunto de entrenamiento $\{x^{(1)}, x^{(2)}, \dots, x^{(n)}\}$
- $x^{(i)} \in \mathbb{R}^m$

Nosotros debemos proponer el valor de K .

El conjunto de datos sin etiquetas.

Es un vector de m características.

Algoritmo de K-Means

1. Inicializar aleatoriamente los K centroides de los clústeres $\mu_1, \mu_2, \dots, \mu_K \in \mathbb{R}^m$.
2. Repetir:
 - a) Para $i = 1$ hasta n :
 $c^{(i)} :=$ índice del centroide del clúster más cercano a $x^{(i)}$
 - b) Para $k = 1$ hasta K :
 $\mu_k :=$ media o promedio de los puntos asignados al clúster k .

Algoritmo de K-Means

1. Inicializar aleatoriamente los K centroides de los clústeres $\mu_1, \mu_2, \dots, \mu_K \in \mathbb{R}^m$.

2. Repetir:

a) Para $i = 1$ hasta n :

$c^{(i)} :=$ índice del centroide del clúster más cercano a $x^{(i)}$

$$c^{(i)} = \min_k \|x^{(i)} - \mu_k\|^2$$

b) Para $k = 1$ hasta K :

$\mu_k :=$ media o promedio de los puntos asignados al clúster k .

Asignación

Algoritmo de K-Means

1. Inicializar aleatoriamente los K centroides de los clústeres $\mu_1, \mu_2, \dots, \mu_K \in \mathbb{R}^m$.

2. Repetir:

a) Para $i = 1$ hasta n :

$$c^{(i)} = \min_k \|x^{(i)} - \mu_k\|^2$$

$c^{(i)} :=$ índice del centroide del clúster más cercano a $x^{(i)}$

b) Para $k = 1$ hasta K :

$\mu_k :=$ media o promedio de los puntos asignados al clúster k .

$$\mu_2 = \frac{1}{4} [x^{(1)} + x^{(5)} + x^{(7)} + x^{(12)}] \in \mathbb{R}^m$$

$$\begin{array}{c} x^{(1)}, x^{(5)}, x^{(7)}, x^{(12)} \\ \downarrow \\ c^{(1)} = 2, c^{(5)} = 2, c^{(7)} = 2, c^{(12)} = 2 \end{array}$$

Asignación

Movimiento

Algoritmo de K-Means

$c^{(i)}$ = índice del clúster $(1, \dots, K)$ que se asigna al vector de datos $x^{(i)}$ en la actual iteración

μ_k = centroide del clúster k , $\mu_k \in \mathbb{R}^m$

$\mu_c^{(i)}$ = centroide del clúster que se asigna al vector $x^{(i)}$

$$x^{(i)} \rightarrow 5, c^{(i)} \rightarrow 5, \mu_c^{(i)} \rightarrow \mu_5$$

Función Objetivo (*Distortion Cost Function*):

$$J(c^{(1)}, \dots, c^{(n)}; \mu_1, \dots, \mu_K) = \frac{1}{n} \sum_{i=1}^n \left\| x^{(i)} - \mu_{c^{(i)}} \right\|^2$$

$$\min_{c^{(1)}, \dots, c^{(n)}, \mu_1, \dots, \mu_K} J(c^{(1)}, \dots, c^{(n)}; \mu_1, \dots, \mu_K)$$

Algoritmo de K-Means

1. Inicializar aleatoriamente los K centroides de los clústeres $\mu_1, \mu_2, \dots, \mu_K \in \mathbb{R}^m$.

2. Repetir:

a) Para $i = 1$ hasta n :
$$\min_{c^{(1)}, \dots, c^{(n)}} J(c^{(1)}, \dots, c^{(n)}; \mu_1, \dots, \mu_K)$$

$c^{(i)} :=$ índice del centroide del clúster más cercano a $x^{(i)}$

b) Para $k = 1$ hasta K :

$\mu_k :=$ media o promedio de los puntos asignados al clúster k .

$$\min_{\mu_1, \dots, \mu_K} J(c^{(1)}, \dots, c^{(n)}; \mu_1, \dots, \mu_K)$$

Algoritmo de K-Means

Supongamos que ejecutamos el algoritmo de K-Means y al finalizar obtenemos que:

$$c^{(1)} = 3, c^{(2)} = 5, c^{(3)} = 3, \dots$$

¿Cuáles de los siguientes enunciados son correctos?

1. El tercer vector de datos $x^{(3)}$ le fue asignado el clúster 3.
2. El primer y tercer vector de datos $x^{(1)}$ y $x^{(3)}$ fueron asignados al mismo clúster.
3. El segundo y tercer vector de datos $x^{(2)}$ y $x^{(3)}$ fueron asignados al mismo clúster.
4. De todos los posibles valores de $k \in \{1, 2, \dots, K\}$, $k = 3$ minimiza la distancia entre $x^{(2)}$ y μ_k .

Algoritmo de K-Means -- Inicialización

Para $K = 2$

Algunos detalles prácticos:

1. $K < n$


2. Elegir K puntos al azar del conjunto de datos.

3. Asignar a μ_1, \dots, μ_K los puntos elegidos al azar.





$$\mu_1 = x^{(i)}$$

$$\mu_2 = x^{(j)}$$

⋮



Algoritmo de K-Means -- Inicialización



Algoritmo de K-Means -- Inicialización

Primera opción - Repetir K-Means de tal manera que se elija aquel que tenga el menor valor en la función de costo:

Para $i = 1, \dots, 100$:

Inicializar aleatoriamente K-means.

Correr K-Means y obtener $c^{(1)}, \dots, c^{(n)}, \mu_1, \dots, \mu_K$

Calcular la función de costo (distorsión)



$$J(c^{(1)}, \dots, c^{(n)}, \mu_1, \dots, \mu_K)$$

Elegir el clúster que tenga el menor valor de $J(c^{(1)}, \dots, c^{(n)}, \mu_1, \dots, \mu_K)$.

Algoritmo de K-Means



- ¿Qué pasa si un centroide no tiene puntos?
 - Se puede eliminar, de tal manera que queden $K - 1$ clústeres, o se puede reiniciar su ubicación al azar.
 - En práctica es muy difícil que llegue a suceder.

K-Means




Tallas: S,M,L

K-Means



¿Cómo elegir K?



K-Means ++

Propuesto en 2007 por David Arthur y Sergei Vassilvistikii, es una forma de evitar el problema de malos clústeres que se genera durante el algoritmo de K-means tradicional.

Idea principal: elegir **el primer centroide de entre los puntos x_i del conjunto de datos** y **elegir los otros centroides de entre los restantes** con probabilidad proporcional a la distancia entre el punto elegido y el centroide existente más cercano.

K-Means ++

1. Elegir el primer centroide de entre los puntos x_i aleatoriamente con una distribución uniforme.
2. Para cada punto no elegido, calcular la distancia $D(x)$ entre el punto y el centroide más cercano.
3. Elegir un nuevo centroide, donde se elige x_i con probabilidad proporcional a $D(x)^2$.
4. Repetir 2 y 3 hasta que se elijan k centroides.
5. Proceder con el algoritmo de K-Means tradicional.

K-Means ++

Esto genera un *problema*:

K-Means++ es computacionalmente más caro (tardado), pero el tiempo de convergencia mejora drásticamente, ya que los puntos yacen inicialmente en los posibles clústeres.

K-Means ++

The k-means problem is solved using either Lloyd's or Elkan's algorithm.

The average complexity is given by $O(k n T)$, where n is the number of samples and T is the number of iteration.

The worst case complexity is given by $O(n^{(k+2/p)})$ with $n = n_samples$, $p = n_features$. (D. Arthur and S. Vassilvitskii, 'How slow is the k-means method?' SoCG2006)

In practice, the k-means algorithm is very fast (one of the fastest clustering algorithms available), but it falls in local minima. That's why it can be useful to restart it several times.

K-Means

Tarea:

Leer el paper ["How slow is the k-means method?"](#). Hacer un resumen con los resultados principales.

Nota: Para entender qué es complejidad computacional, revisar [esto](#).



Gracias

Luis Zúñiga

luis.zuniga@correo.uia.mx

<https://lzun.github.io>