



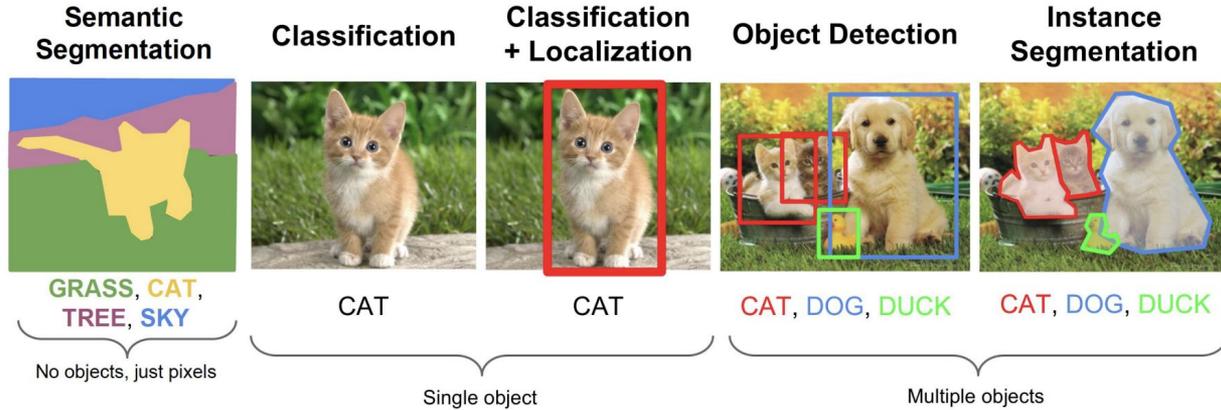
UNIVERSIDAD
DE LA REPUBLICA
URUGUAY

Clustering

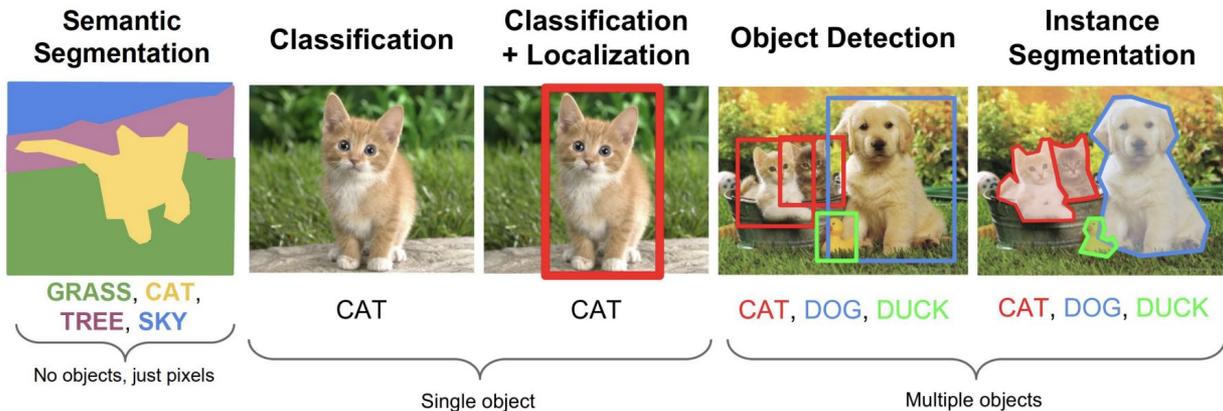
Introducción a la Ciencia de Datos 2025

(slides prestadas del curso “Laboratorio de Datos” de la UBA y del curso CICADA 2023)

Repaso: Aprendizaje supervisado



Repaso: Aprendizaje supervisado



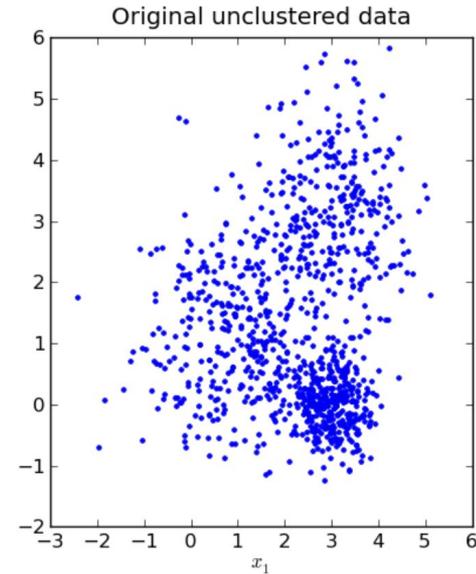
- Datos etiquetados: (\mathbf{x}, y)
- Objetivo: aprender una función $f(\mathbf{x}) \approx y$
- Probabilísticamente: aprender $p(y | \mathbf{x})$

Aprendizaje NO supervisado

- Datos **no etiquetados**: $\mathbf{x}_1, \dots, \mathbf{x}_n$
- **Objetivo**: aprender estructura de datos

Ejemplos:

- Clustering

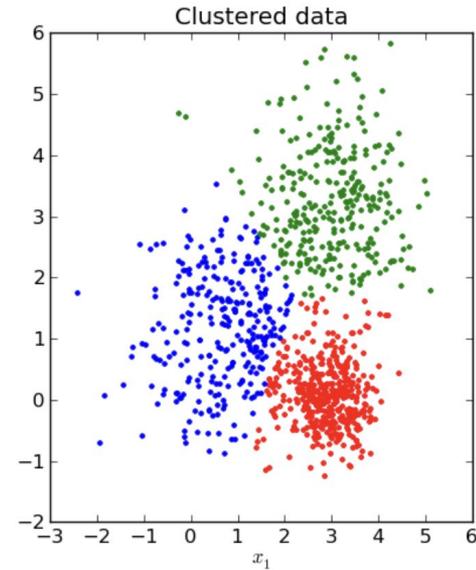


Aprendizaje NO supervisado

- Datos **no etiquetados**: $\mathbf{x}_1, \dots, \mathbf{x}_n$
- **Objetivo**: aprender estructura de datos

Ejemplos:

- Clustering

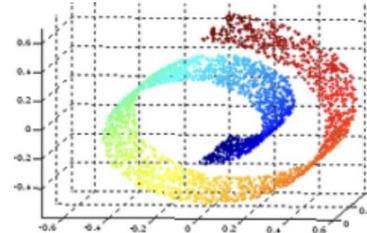


Aprendizaje NO supervisado

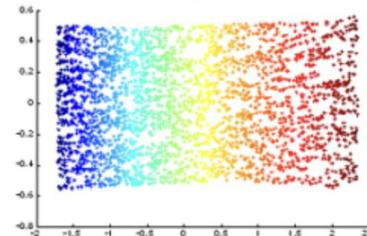
- Datos **no etiquetados**: $\mathbf{x}_1, \dots, \mathbf{x}_n$
- **Objetivo**: aprender estructura de datos

Ejemplos:

- Clustering
- Reducción de dimensión



(a)



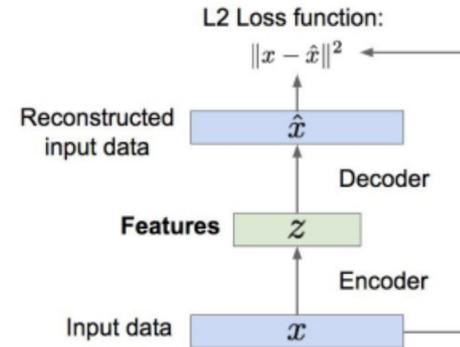
(c)

Aprendizaje NO supervisado

- Datos **no etiquetados**: $\mathbf{x}_1, \dots, \mathbf{x}_n$
- **Objetivo**: aprender estructura de datos

Ejemplos:

- Clustering
- Reducción de dimensión
- *Feature representation*



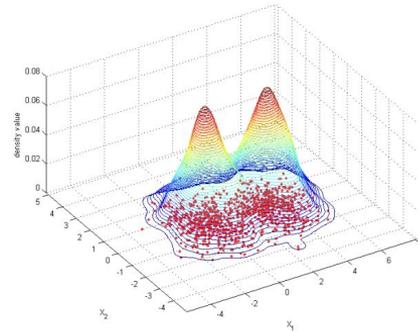
Wikipedia

Aprendizaje NO supervisado

- Datos **no etiquetados**: $\mathbf{x}_1, \dots, \mathbf{x}_n$
- **Objetivo**: aprender estructura de datos

Ejemplos:

- Clustering
- Reducción de dimensión
- *Feature representation*
- Estimación de densidad subyacente
 $p_{\theta}(\mathbf{x})$



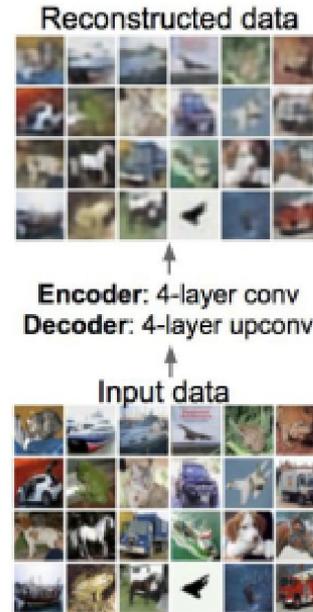
cs231n (Stanford)

Aprendizaje NO supervisado

- Datos **no etiquetados**: $\mathbf{x}_1, \dots, \mathbf{x}_n$
- **Objetivo**: aprender estructura de datos

Ejemplos:

- Clustering
- Reducción de dimensión
- *Feature representation*
- Estimación de densidad subyacente $p_\theta(\mathbf{x})$
- Síntesis de datos (muestras de la densidad subyacente)



cs231n (Stanford)

Aprendizaje NO supervisado

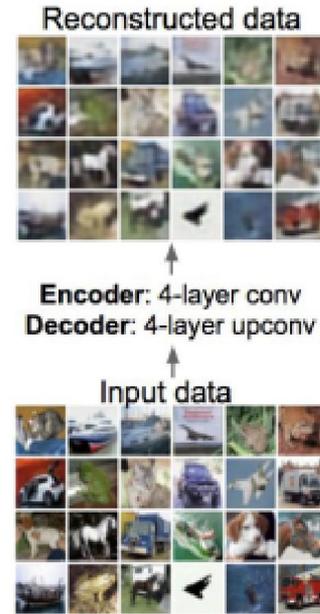
- Datos **no etiquetados**: $\mathbf{x}_1, \dots, \mathbf{x}_n$
- **Objetivo**: aprender estructura de datos

Ejemplos:

- Clustering
- Reducción de dimensión
- *Feature representation*
- Estimación de densidad subyacente $p_{\theta}(\mathbf{x})$

Gran ventaja del aprendizaje no supervisado:

- No necesito etiquetas:
datos abundan (en general)



Motivación: ¿Por qué estudiamos el aprendizaje no supervisado?

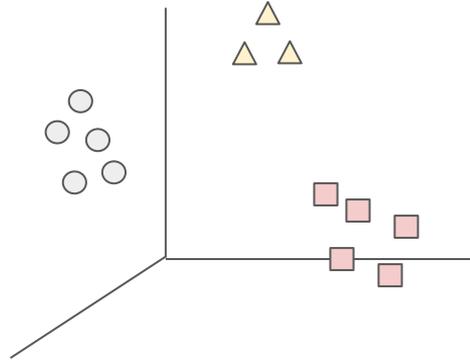
-  Mayoría de los datos no están etiquetados: es caro y a menudo inviable.
-  Descubrir estructuras subyacentes: revelar patrones y agrupaciones en datos.
-  Base para el aprendizaje autosupervisado.
-  Escala mejor: Eficaz para conjuntos de datos a gran escala sin curar.

Ejemplos de aplicaciones:

- Reconocimiento de imágenes a gran escala (por ejemplo, Facebook/Google)
- Agrupamiento del comportamiento de los clientes en comercio electrónico
- Clasificación del uso del suelo a partir de imágenes satelitales

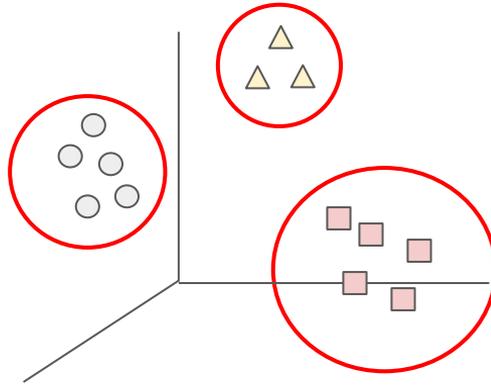
Clustering

Encontrar **subgrupos** (*clústers*) en los datos



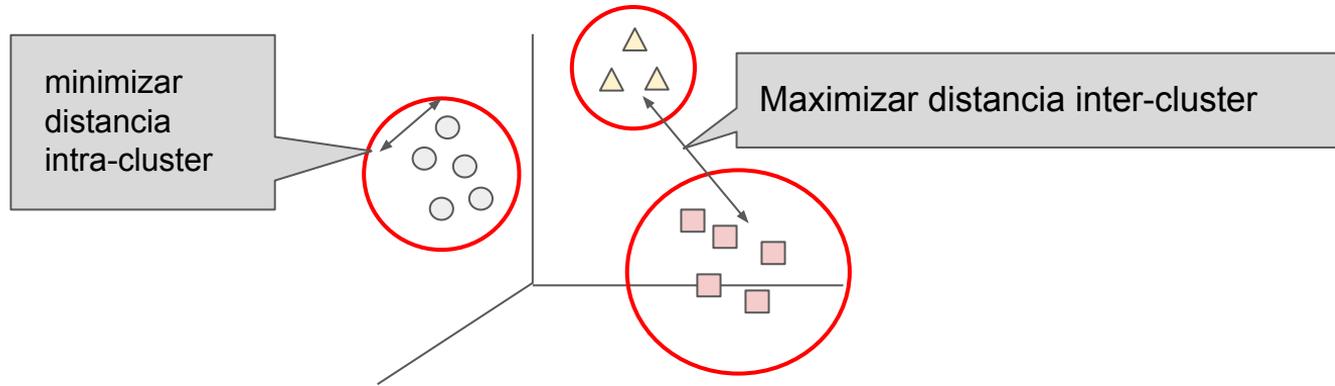
Clustering

Encontrar **subgrupos** (*clústers*) en los datos



Clustering

Encontrar **subgrupos** (*clústers*) en los datos



Observaciones dentro de un cluster **similares**

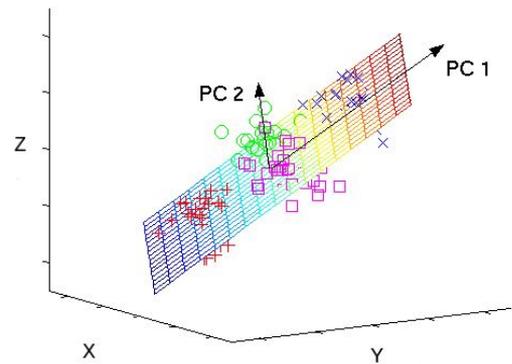
Observaciones entre clusters **no similares**

Clustering

- Objetivo: descubrir estructura dentro de un conjunto de datos, dividiéndolo en subgrupos que muestran una cierta coherencia.
 - *Coherencia*: muestras dentro de un mismo grupo o *cluster* son más parecidas entre sí que a las muestras de otros clusters.
 - *Muestras parecidas*: noción de similitud o de distancia entre muestras.
- La mayor parte de los métodos de clustering son de dos tipos:
 - *Particionales*: producen una única partición que optimiza una función criterio
 - *Jerárquicos*: jerarquía de particiones anidadas; cada nivel de la jerarquía es en sí mismo una partición, obtenida por unión de *clusters* de la jerarquía inferior.
- **Importante:**
Un método de clustering siempre produce clusters, aunque éstos no existan realmente \Rightarrow todo método de clustering debe ser seguido de una etapa de validación de los clusters obtenidos.

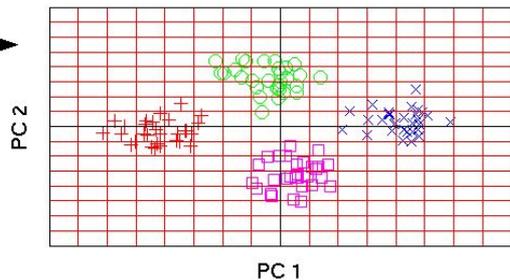
Clustering

original data space



PCA

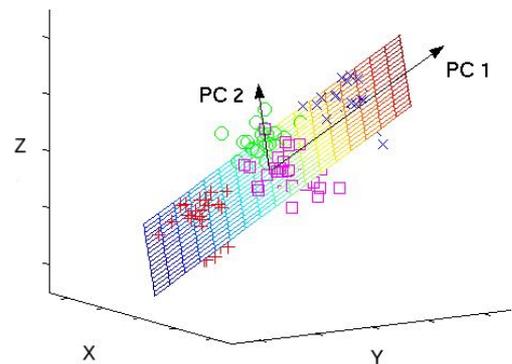
component space



Reducir dimensión maximizando la varianza

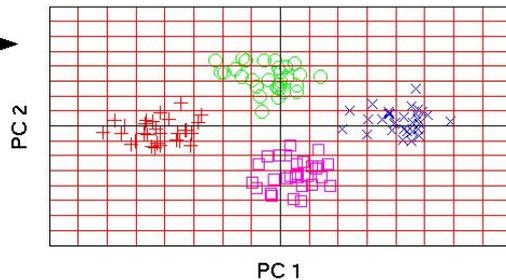
Clustering

original data space



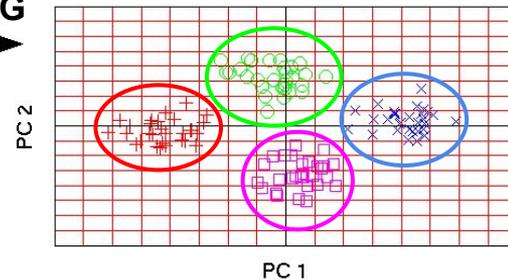
PCA

component space



CLUSTERING

component space

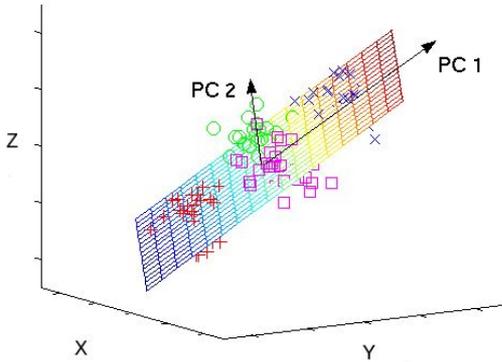


Reducir dimensión maximizando la varianza

Encontrar grupos homogéneos

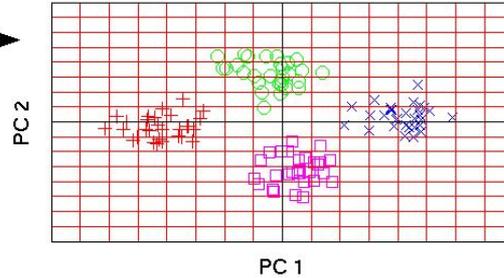
Clustering

original data space



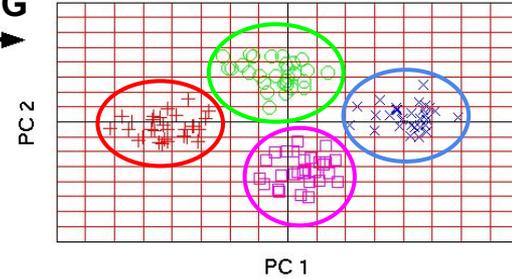
PCA

component space



CLUSTERING

component space



Reducir dimensión maximizando la varianza

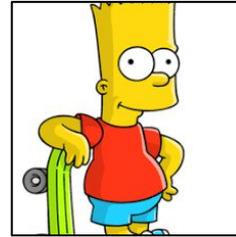
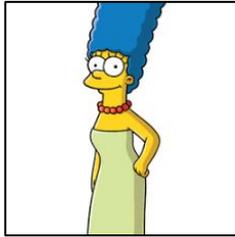
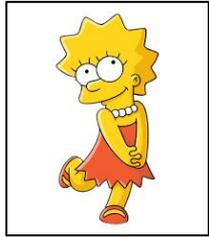
Encontrar grupos homogéneos

Se puede encontrar grupos en el espacio de features original

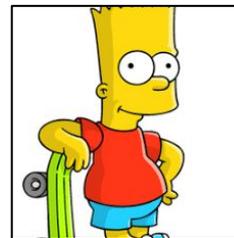
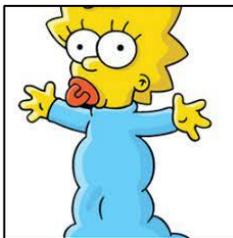
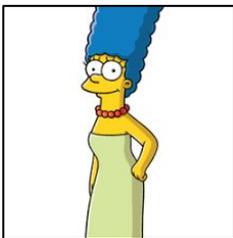
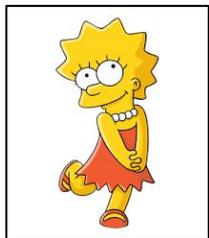
Si son muchos -> podría ser costoso computacionalmente

-> podrían esconderse las características que mejor agrupan los datos

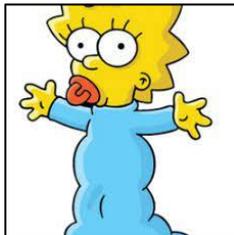
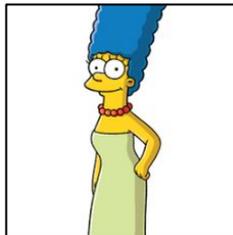
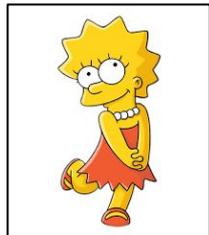
Clustering - forma natural de agrupar los datos



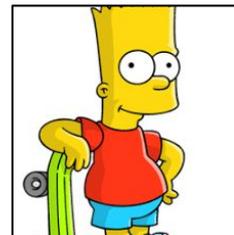
Clustering - forma natural de agrupar los datos



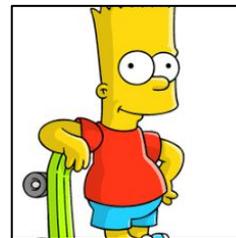
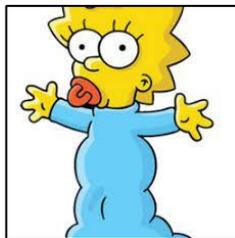
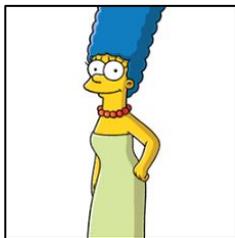
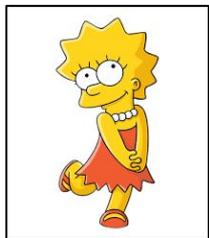
Mujeres



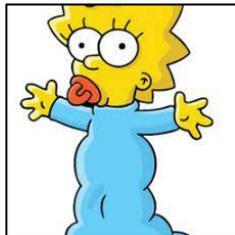

Hombres



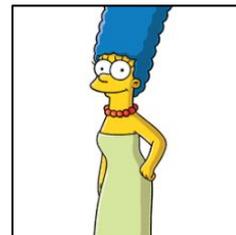
Clustering - forma natural de agrupar los datos



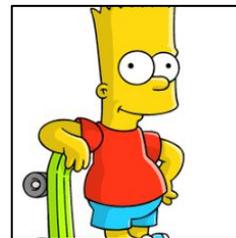

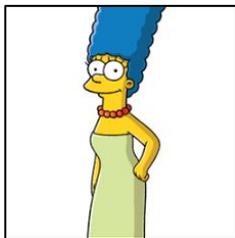
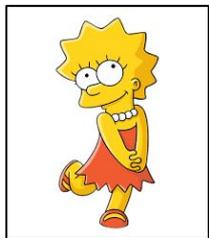
Niños



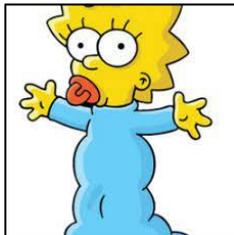
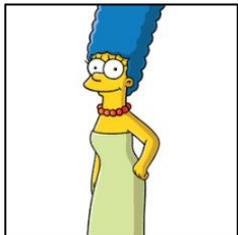
Adultos



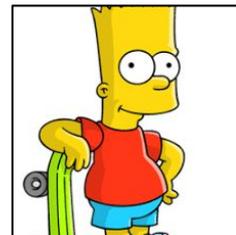
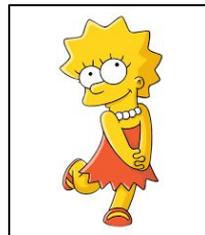
Clustering - forma natural de agrupar los datos



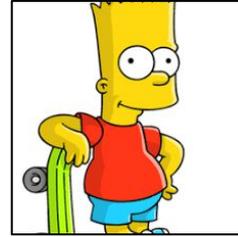
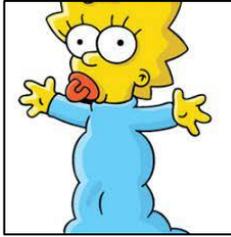
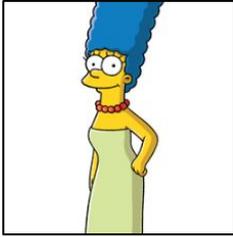
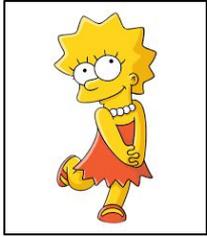
No van a la primaria



Van a la primaria



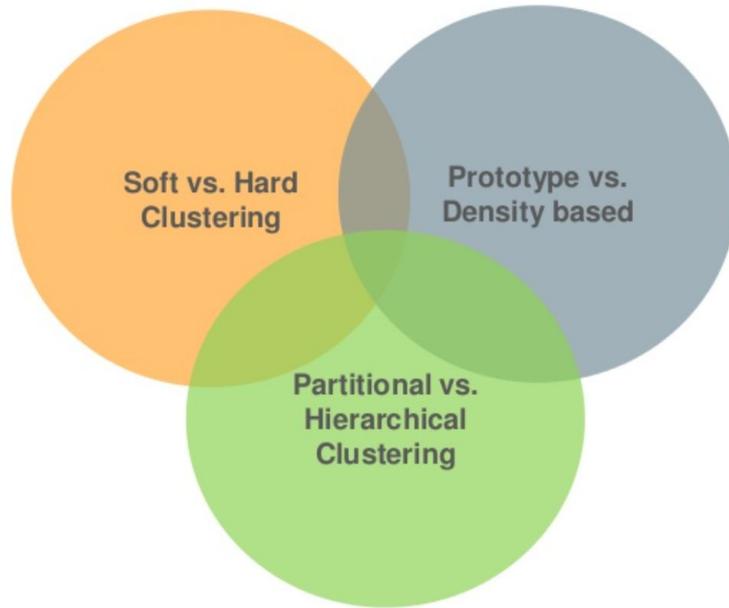
Clustering - forma natural de agrupar los datos



No hay una forma natural de agrupar los datos, el clustering es **subjetivo**, la mejor elección de grupos depende de qué le queremos preguntar a los datos

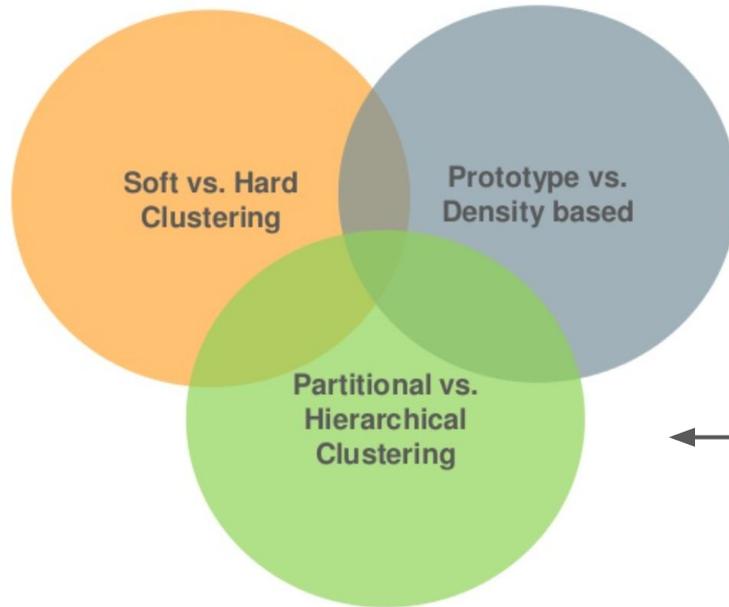
Clustering - estrategias

Hay muuuuchos métodos de clusterización y distintos criterios de división

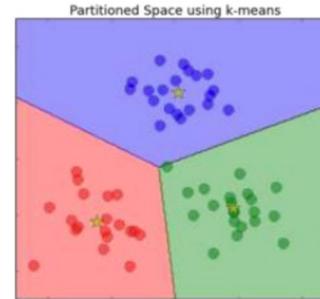


Clustering - estrategias

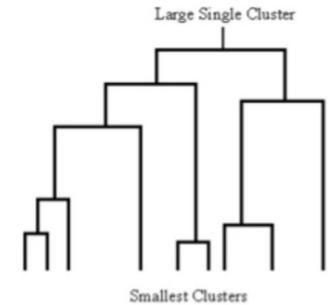
Hay muuuuchos métodos de clusterización y distintos criterios de división.



Partición



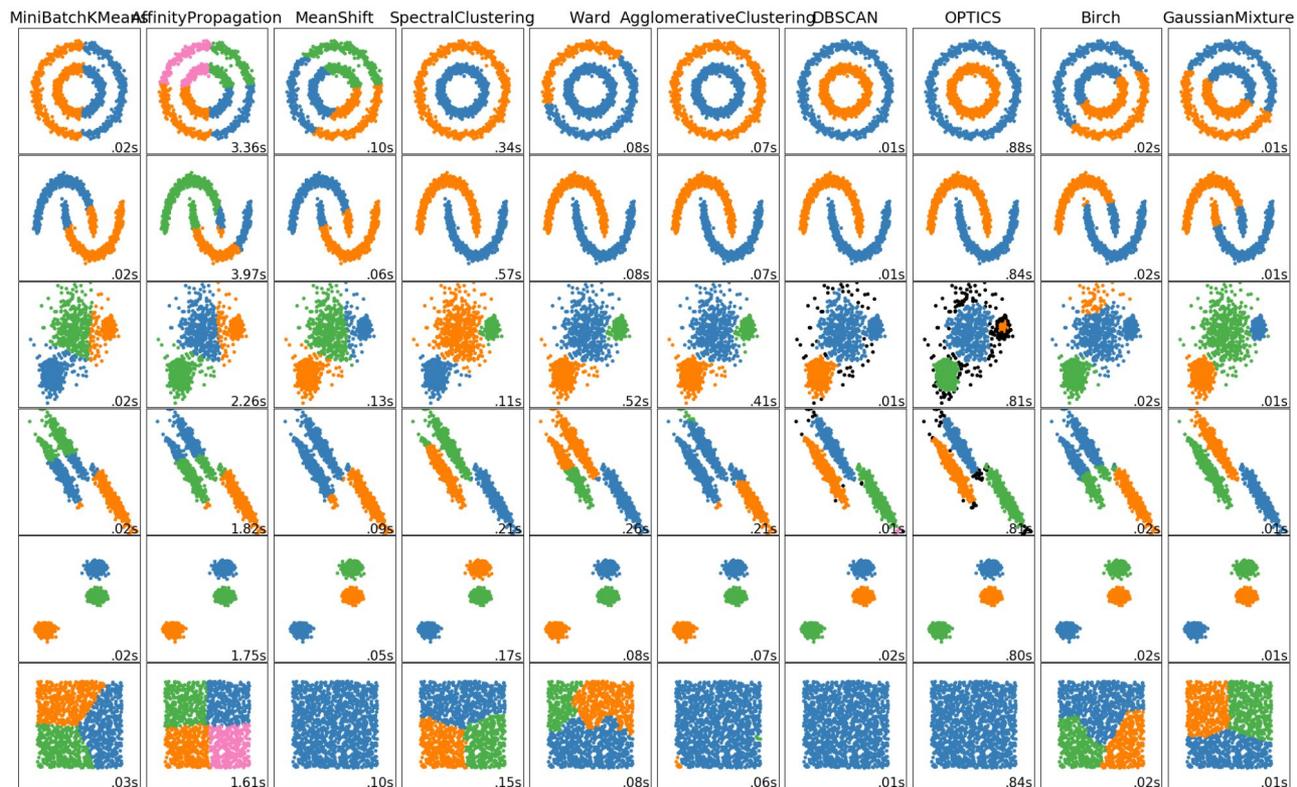
Jerárquico



←
-particiona el espacio
-encuentra todos los clusters simultáneamente

-genera una jerarquía de clusters anidados

Clustering - ejemplos y desafíos



K-means: Esquema

Damos el número de clusters k que queremos obtener



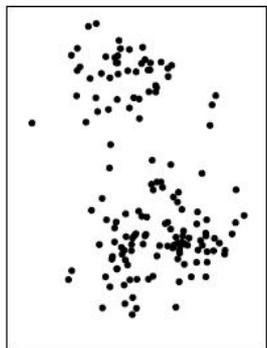
K-means: Esquema

Damos el número de clusters k que queremos obtener

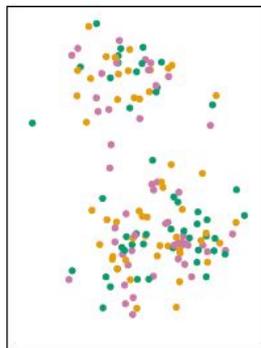
Inicialización random



Data



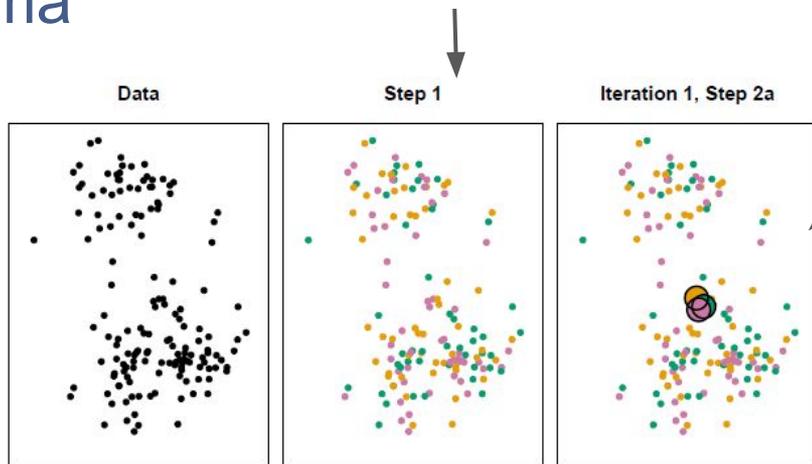
Step 1



K-means: Esquema

Damos el número de clusters k que queremos obtener

Inicialización random



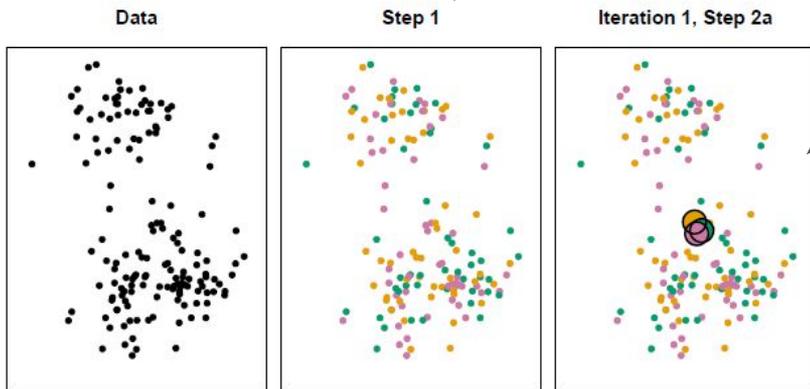
Computa los **centroides** (centros) de cada cluster como el promedio de las features de sus samples

K-means: Esquema

Inicialización random

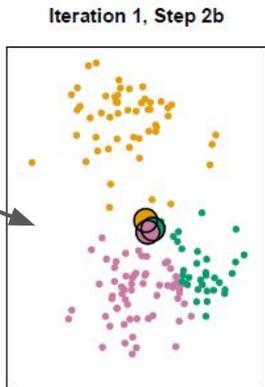


Damos el número de clusters k que queremos obtener



Computa los **centroides** (centros) de cada cluster como el promedio de las features de sus samples

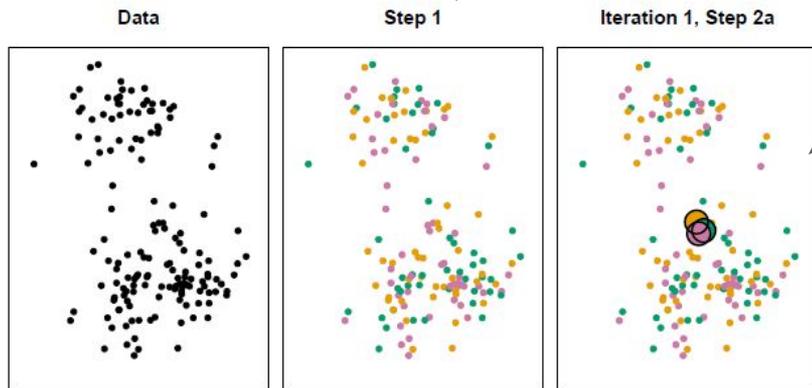
le asigna a cada sample la etiqueta del cluster cuyo centroide es más cercano (distancia euclídea al cuadrado)



K-means: Esquema

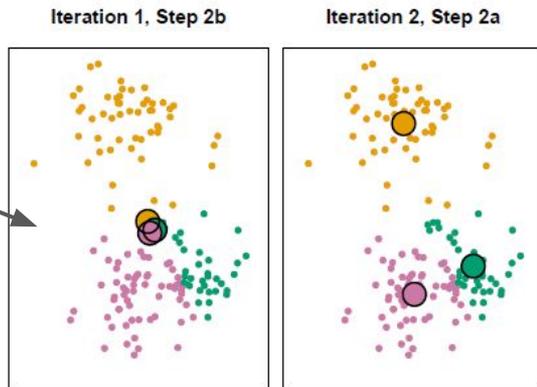
Inicialización random

Damos el número de clusters k que queremos obtener



Computa los **centroides** (centros) de cada cluster como el promedio de las features de sus samples

le asigna a cada sample la etiqueta del cluster cuyo centroide es más cercano (distancia euclídea al cuadrado)



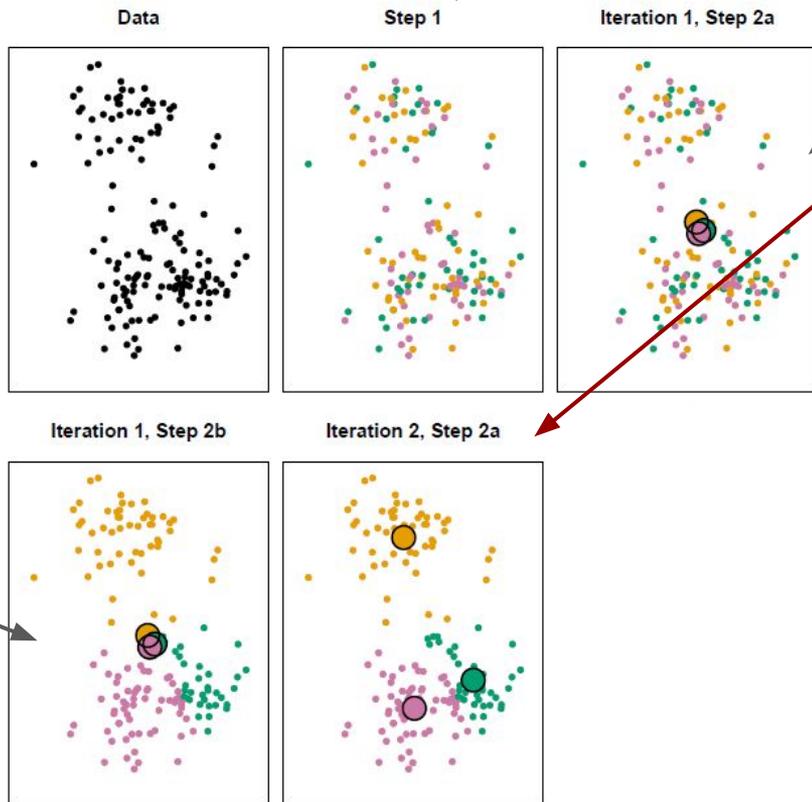
K-means: Esquema

Inicialización random

Damos el número de clusters k que queremos obtener

le asigna a cada sample la etiqueta del cluster cuyo centroide es más cercano (distancia euclídea al cuadrado)

Computa los **centroides** (centros) de cada cluster como el promedio de las features de sus samples



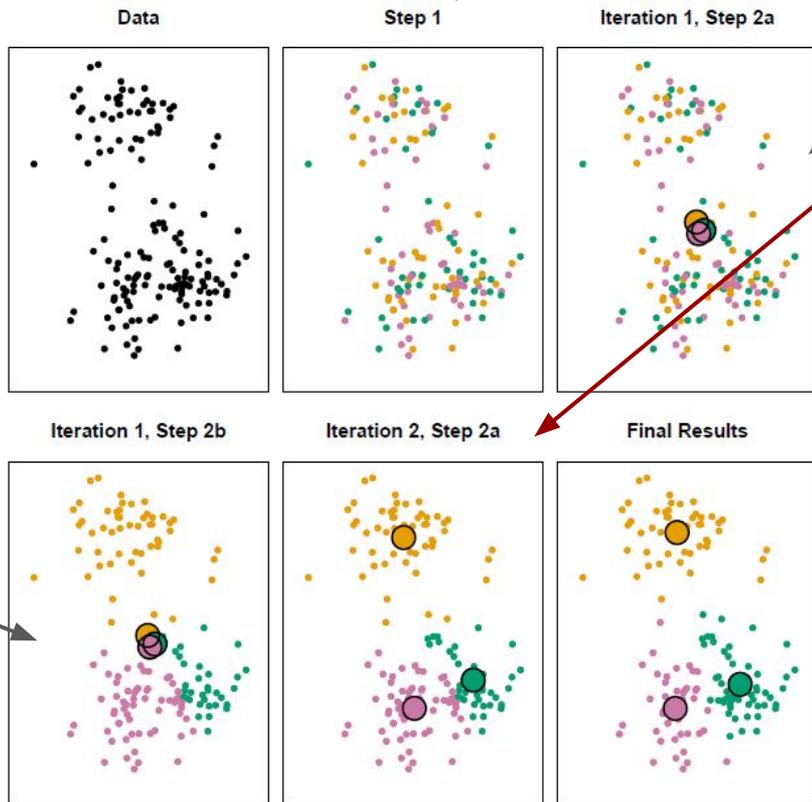
K-means: Esquema

Inicialización random

Damos el número de clusters k que queremos obtener

le asigna a cada sample la etiqueta del cluster cuyo centroide es más cercano (distancia euclídea al cuadrado)

Computa los **centroides** (centros) de cada cluster como el promedio de las features de sus samples



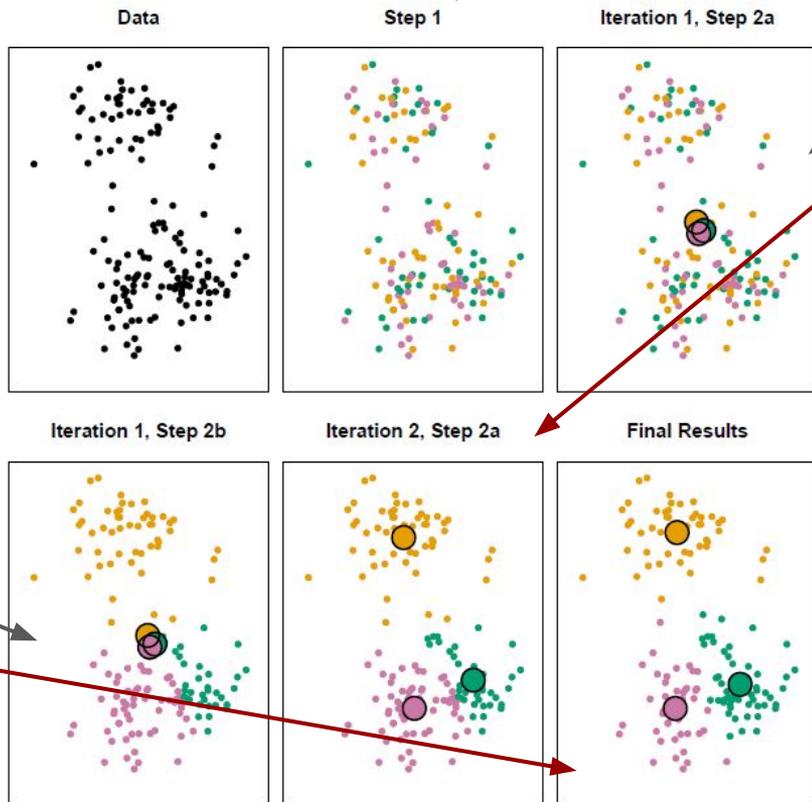
K-means: Esquema

Inicialización random

Damos el número de clusters k que queremos obtener

le asigna a cada sample la etiqueta del cluster cuyo centroide es más cercano (distancia euclídea al cuadrado)

Computa los **centroides** (centros) de cada cluster como el promedio de las features de sus samples



K-means: Esquema

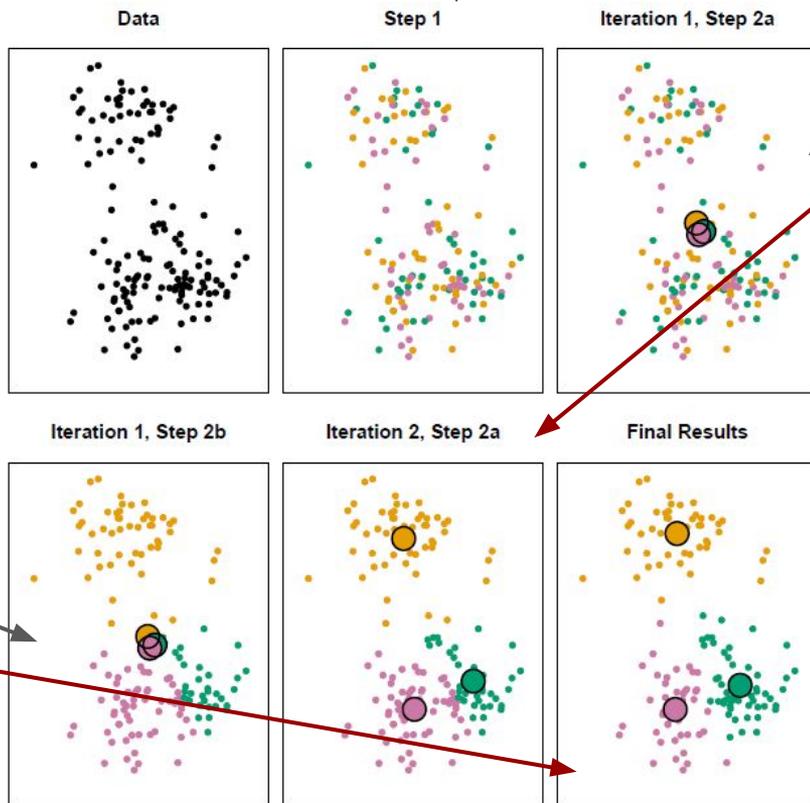
Inicialización random

Damos el número de clusters k que queremos obtener

le asigna a cada sample la etiqueta del cluster cuyo centroide es más cercano (distancia euclídea al cuadrado)

Computa los **centroides** (centros) de cada cluster como el promedio de las features de sus samples

Termina cuando en una iteración no hay cambio de etiqueta o se llega a un máximo de iteraciones 'max_iter'



K-means: Esquema


Inicialización random

Damos el número de clusters k que queremos obtener

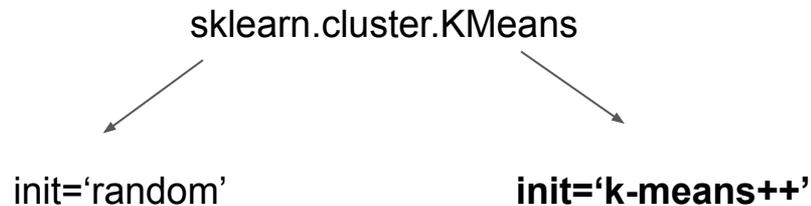


K-means: Esquema

Damos el número de clusters k que queremos obtener



Inicialización random



K-means: Esquema

Damos el número de clusters k que queremos obtener



Inicialización random

`sklearn.cluster.KMeans`

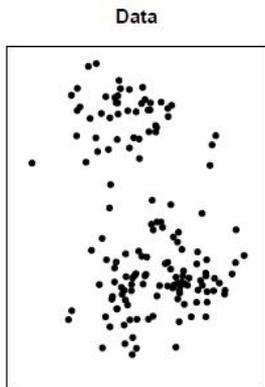
`init='random'`

`init='k-means++'`

elige aleatoriamente k samples como centroides

K-means: Esquema

Damos el número de clusters k que queremos obtener



Inicialización random

`sklearn.cluster.KMeans`

`init='random'`

elige aleatoriamente k samples como centroides

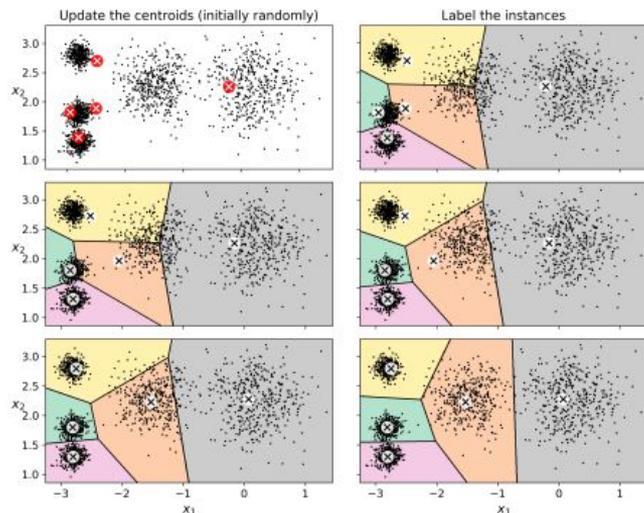
`init='k-means++'`

mayor velocidad de convergencia

1. Selecciona aleatoriamente un dato y lo asigna como centroide
2. Para los otros datos x , calcula $D(x)$, distancia entre x y el centro más cercano que ya ha sido seleccionado.
3. Escoge un nuevo punto al azar como nuevo centroide, utilizando una distribución de probabilidad ponderada donde un punto x es escogido con la probabilidad proporcional a $D(x)^2$.
4. Repite paso 2 y 3 hasta que se hayan seleccionado k centroides.

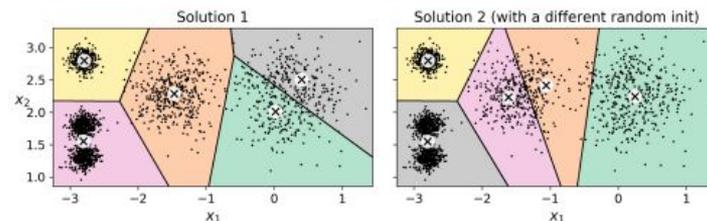
K-means: inicialización

Evolución con un buena inicialización.



En este caso converge en tres iteraciones.

Otras inicializaciones pueden conducir a soluciones sub-óptimas.



Cómo resolvemos esto:

- Métodos de inicialización.
- Métricas de calidad de la partición.

K-means: Función objetivo

Buena clusterización es la que minimiza la varianza entre datos de un mismo cluster

K-means: Función objetivo

Buena clusterización es la que minimiza la varianza entre datos de un mismo cluster

$$\text{minimize}_{C_1, \dots, C_K} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \right\}$$

K-means: Función objetivo

Buena clusterización es la que minimiza la varianza entre datos de un mismo cluster

$$\text{minimize}_{C_1, \dots, C_K} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \right\}$$

distancia euclídea al
cuadrado - lo más usual

K-means: Función objetivo

Buena clusterización es la que minimiza la varianza entre datos de un mismo cluster

$$\text{minimize}_{C_1, \dots, C_K} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \right\}$$

K-means: Función objetivo

Buena clusterización es la que minimiza la varianza entre datos de un mismo cluster

$$\text{minimize}_{C_1, \dots, C_K} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \right\}$$

Básicamente K-means es un algoritmo de optimización de esta función objetivo

K-means: Función objetivo

Buena clusterización es la que minimiza la varianza entre datos de un mismo cluster

$$\text{minimize}_{C_1, \dots, C_K} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \right\}$$

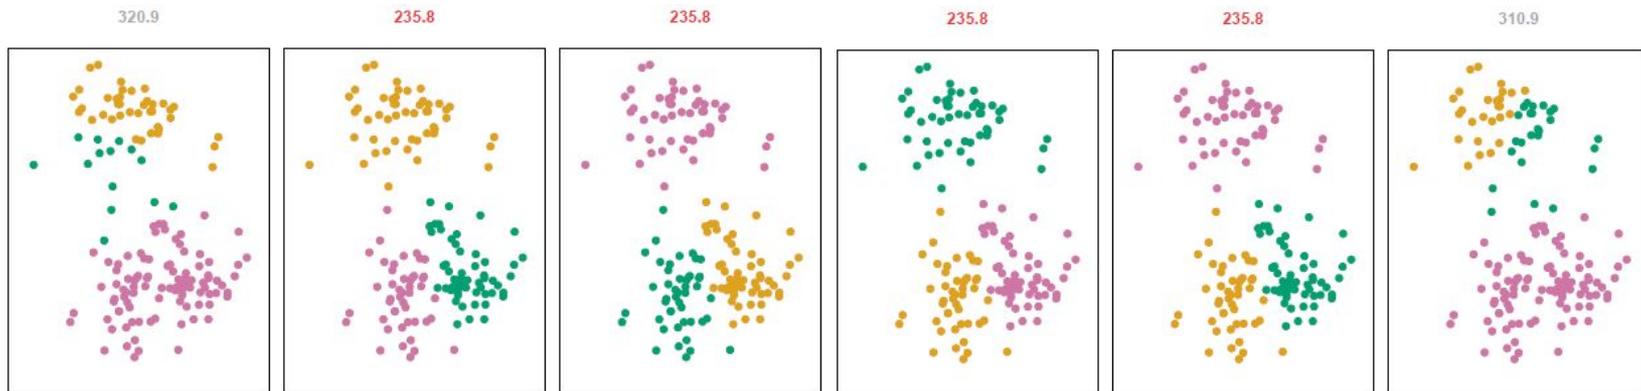
Básicamente K-means es un algoritmo de optimización de esta función objetivo
Depende de la inicialización -> **método no determinista**

K-means: Función objetivo

Buena clusterización es la que minimiza la varianza entre datos de un mismo cluster

$$\text{minimize}_{C_1, \dots, C_K} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^P (x_{ij} - x_{i'j})^2 \right\}$$

Básicamente K-means es un algoritmo de optimización de esta función objetivo
Depende de la inicialización -> **modelo no determinista**



distintas inicializaciones del mismo modelo con los mismos datos

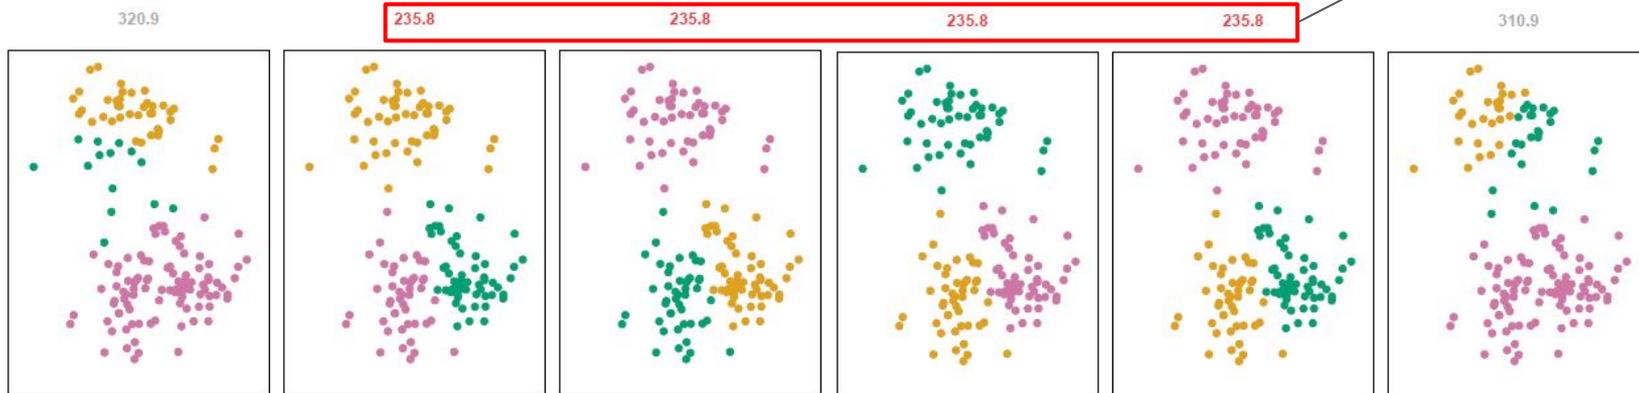
K-means: Función objetivo

Buena clusterización es la que minimiza la varianza entre datos de un mismo cluster

$$\text{SSE} = \underset{C_1, \dots, C_K}{\text{minimize}} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^P (x_{ij} - x_{i'j})^2 \right\}$$

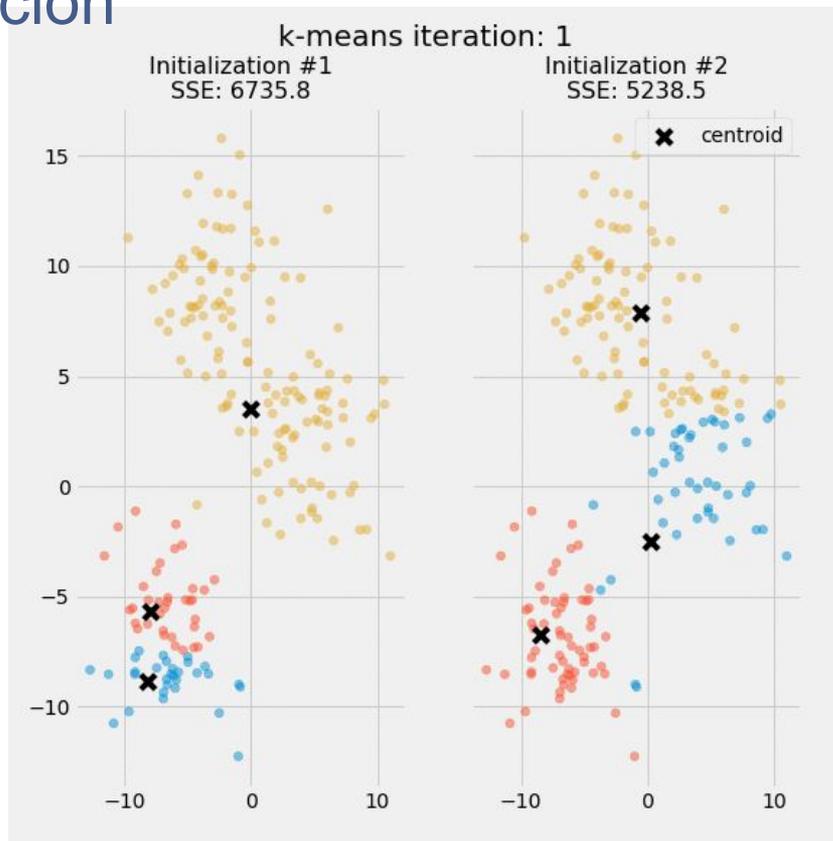
Elige alguna de estas 4 inicializaciones

Básicamente K-means es un algoritmo de optimización de esta función objetivo
Depende de la inicialización -> **modelo no determinista**



distintas inicializaciones del mismo modelo con los mismos datos 'n_init'

K-means en acción



K-means: Función objetivo

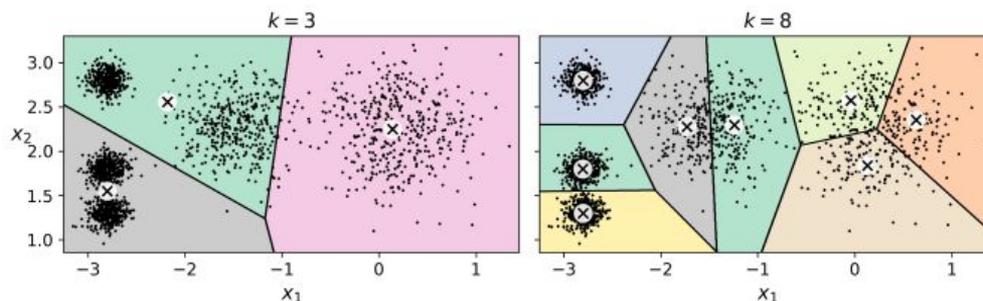
Una solución posible es iterar muchas veces el algoritmo con diferentes inicializaciones conservando el clustering que minimiza el valor de la función objetivo.

K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

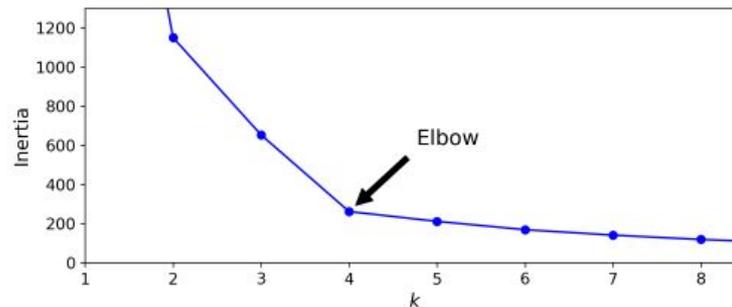
K-means: Elección de k

En general desconocemos cuántos clusters hay. En el ejemplo anterior:



El valor de la inercia no es una medida adecuada: tiende a bajar cuanto más grande es k .

Método gráfico basado en comportamiento de la inercia con K : en general la cantidad de clusters óptima se encuentra cerca del codo (cambio de comportamiento).



K-means: Elección de k

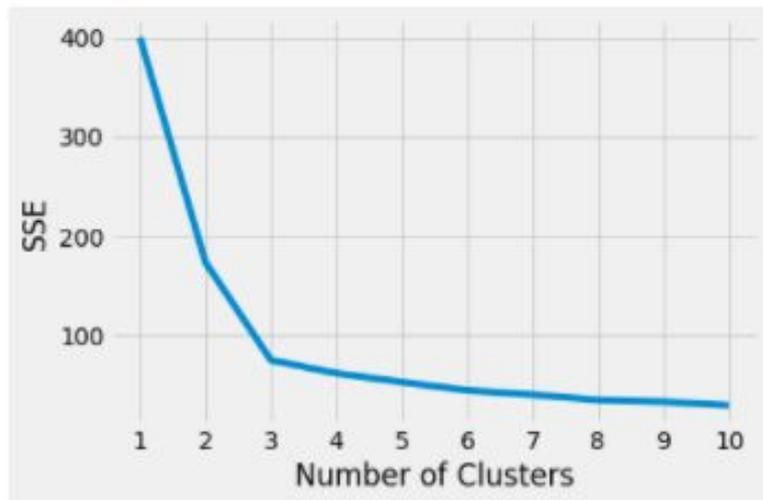
No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”

K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

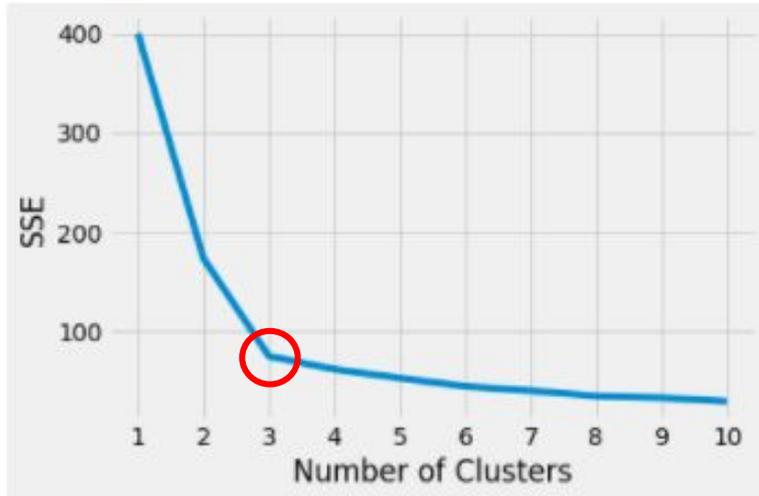
“Método del codo”



K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”

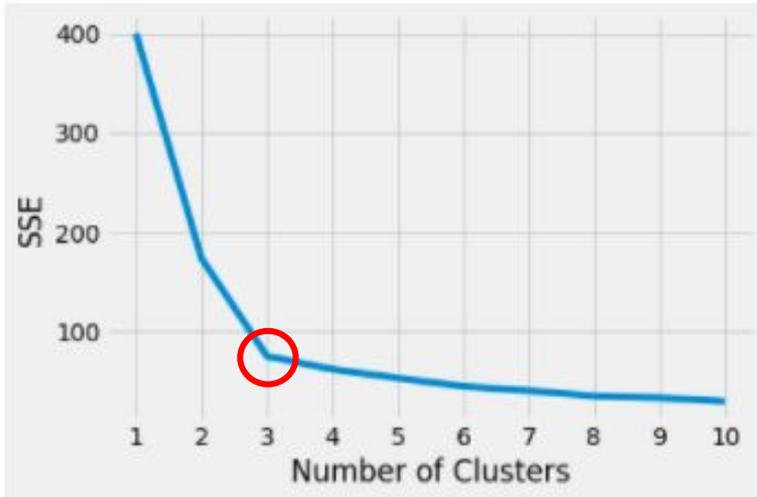


K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”

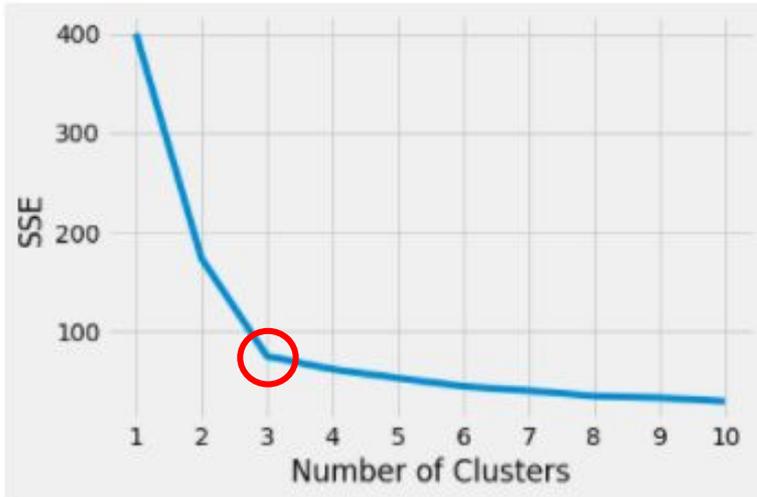
“coeficiente de Silhouette”



K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”



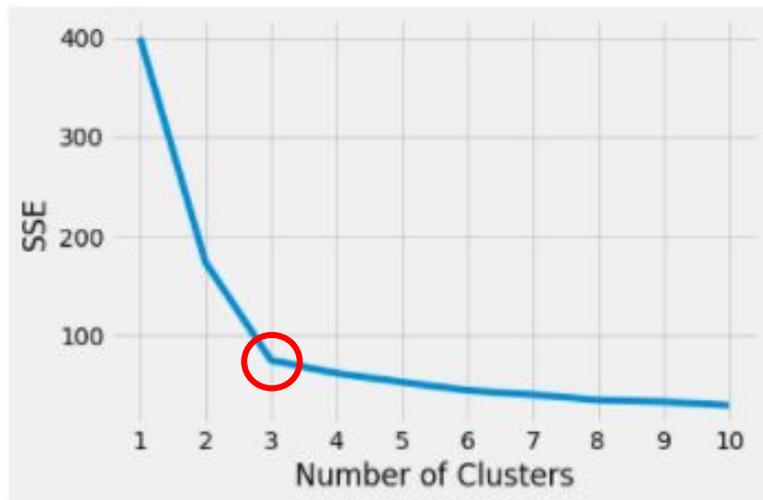
“coeficiente de Silhouette”

medida de cuán similar es un dado dato a los datos de su cluster en comparación a los datos del cluster más cercano

K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”



“coeficiente de Silhouette”

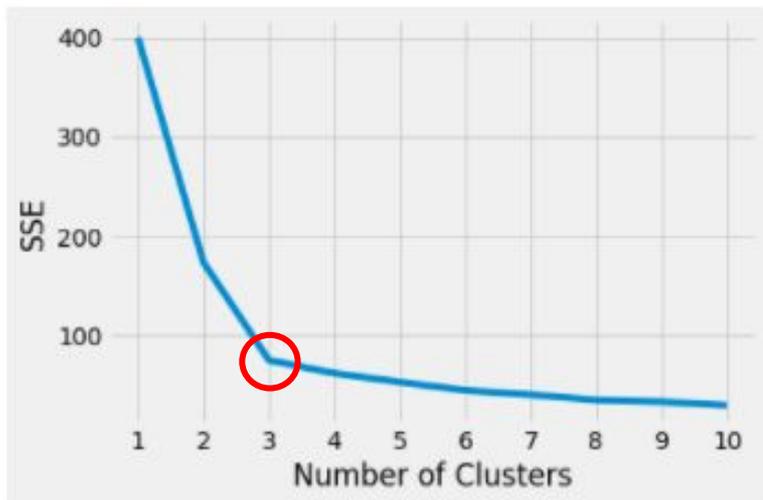
medida de cuán similar es un dado dato a los datos de su cluster en comparación a los datos del cluster más cercano

su valor va $[-1, 1]$

K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”



“coeficiente de Silhouette”

medida de cuán similar es un dado dato a los datos de su cluster en comparación a los datos del cluster más cercano

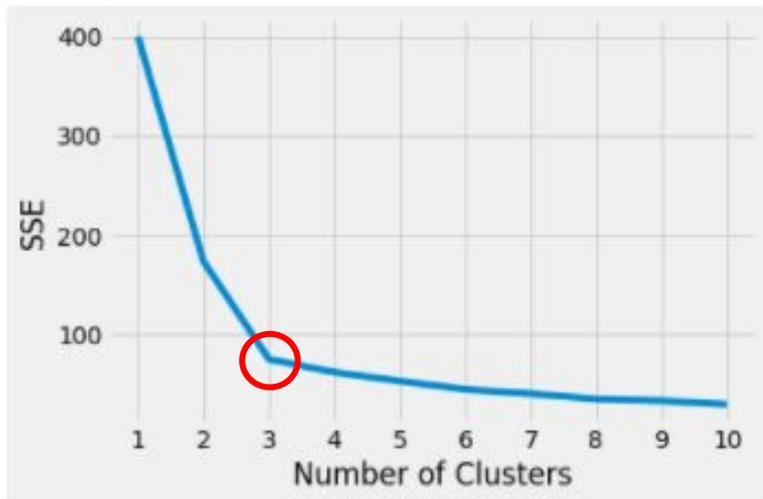
su valor va $[-1, 1]$

1 indica que el dato está bien emparejado en su propio cluster y mal emparejado con los datos de otros clusters

K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”



“coeficiente de Silhouette”

medida de cuán similar es un dado dato a los datos de su cluster en comparación a los datos del cluster más cercano

su valor va $[-1, 1]$

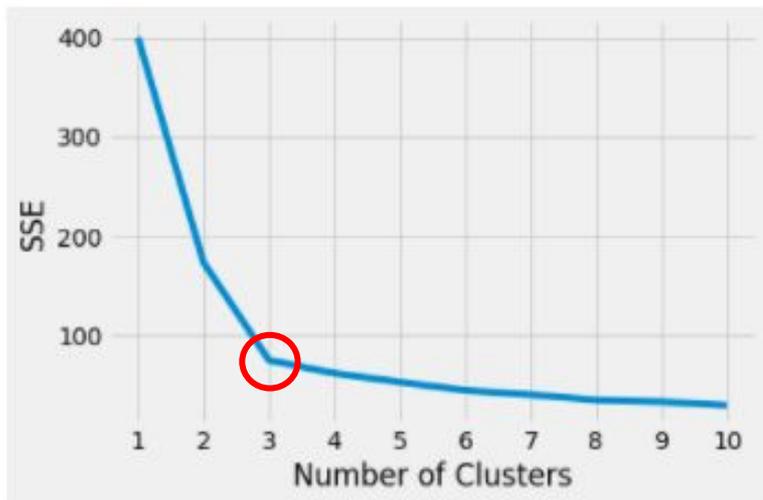
1 indica que el dato está bien emparejado en su propio cluster y mal emparejado con los datos de otros clusters

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}, \text{ if } |C_i| > 1$$
$$a(i) = \frac{1}{|C_i| - 1} \sum_{j \in C_i, i \neq j} d(i, j)$$
$$b(i) = \min_{k \neq i} \frac{1}{|C_k|} \sum_{j \in C_k} d(i, j)$$

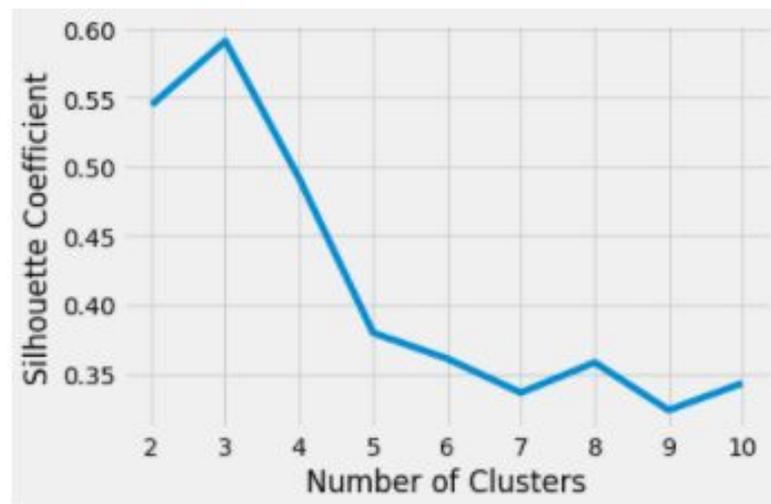
K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”



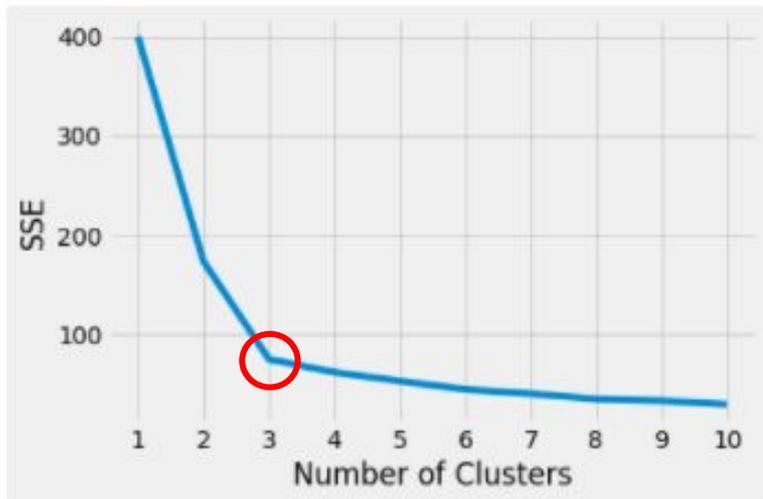
“coeficiente de Silhouette”



K-means: Elección de k

No es trivial elegir k en la mayoría de los dataset reales. No hay algún método que funcione siempre.

“Método del codo”

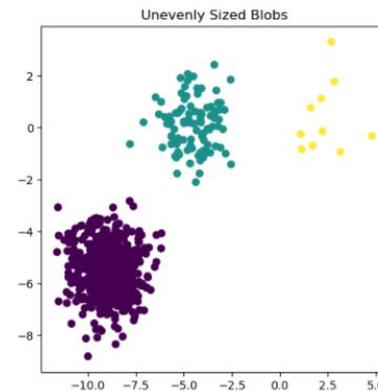
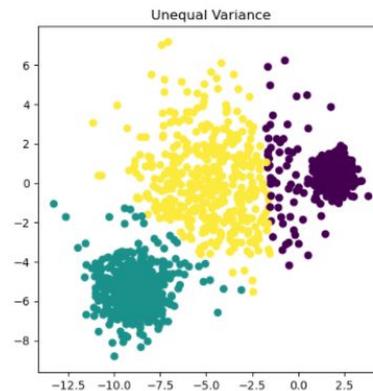
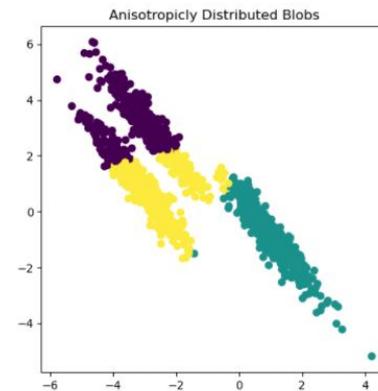
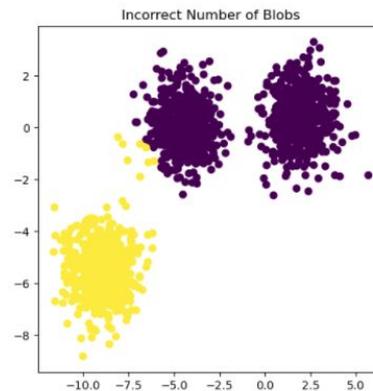
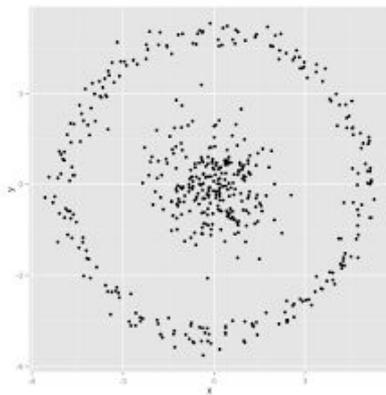


“coeficiente de Silhouette”



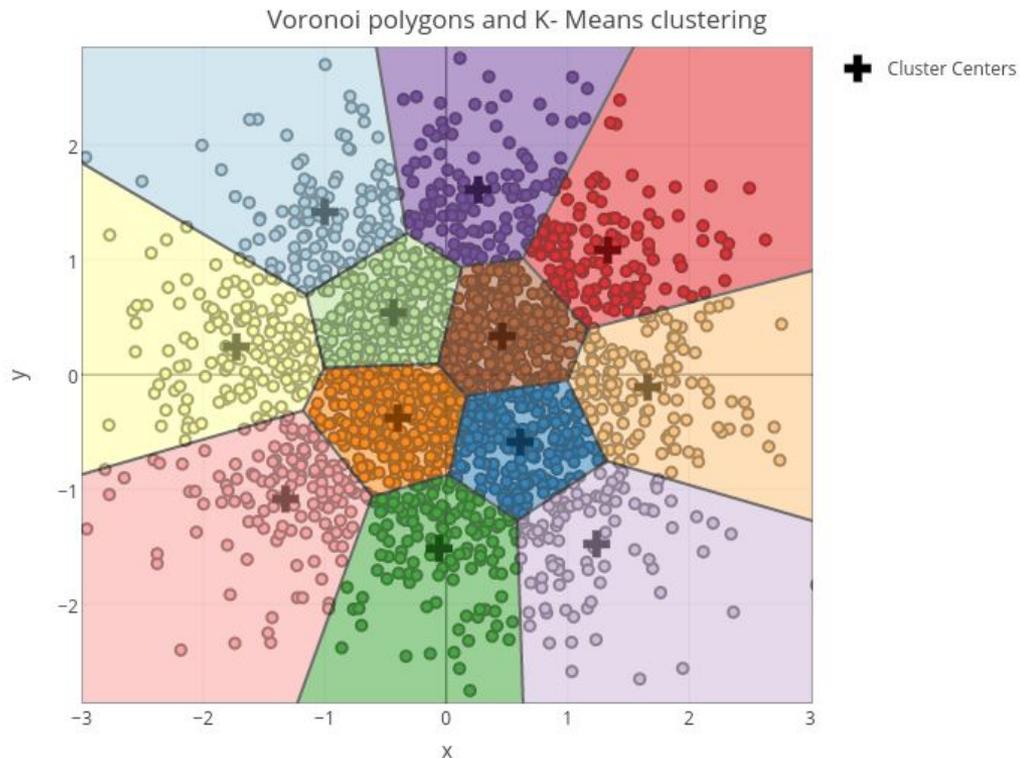
K-means: Pros y Cons

- + Simple y Fácil de implementar
- + Orden del algoritmo es lineal
- Depende de la inicialización
- Tiende a caer en un mínimo local
- Sensible a outliers
- Los clusters tienen que tener forma esférica
- No se puede aplicar a datos categóricos



K-means: Pros y Cons

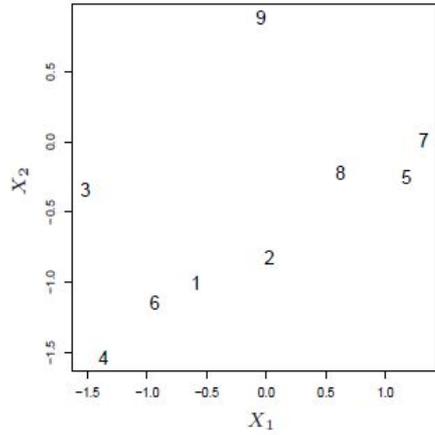
- Da un clustering de los datos aún si los datos no están “clusterizados”



Clustering Jerárquico: Dendrograma

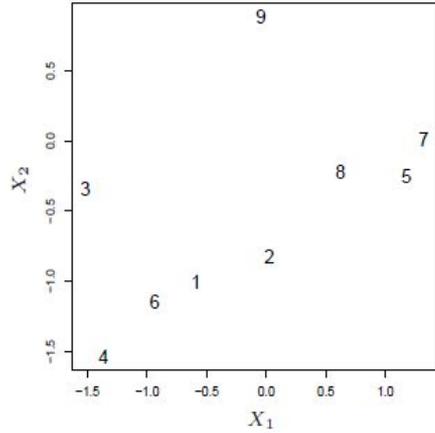
Clustering Jerárquico: Dendrograma

n samples
n clusters



Clustering Jerárquico: Dendrograma

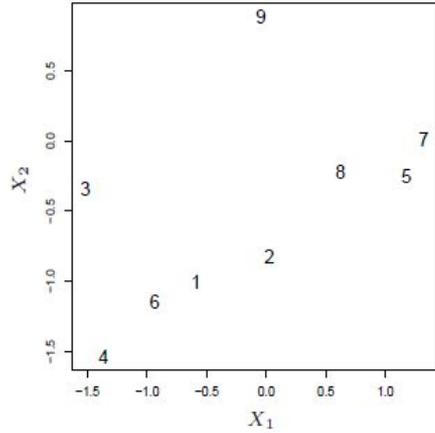
n samples
n clusters



medida de distancia entre
samples ('affinity'),
usualmente la euclídea

Clustering Jerárquico: Dendrograma

n samples
n clusters



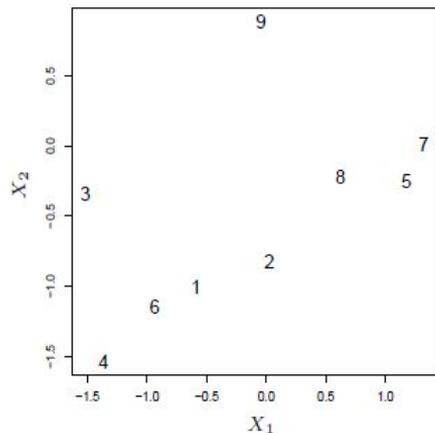
medida de distancia entre
samples ('affinity'),
usualmente la euclídea



junto los dos cluster que
están a menor distancia

Clustering Jerárquico: Dendrograma

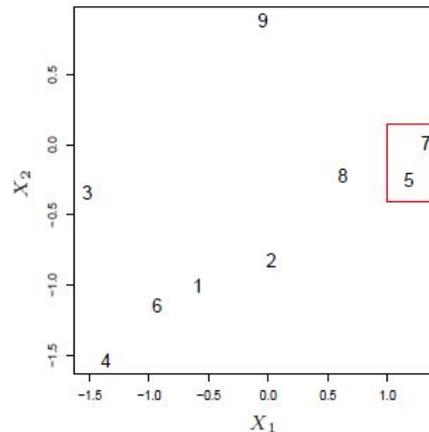
n samples
n clusters



medida de distancia entre
samples ('affinity'),
usualmente la euclídea



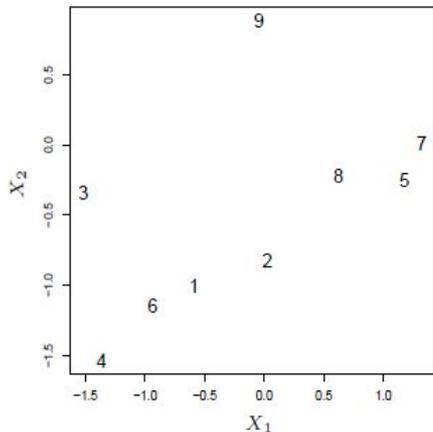
junto los dos cluster
que están a menor distancia



n-1 clusters

Clustering Jerárquico: Dendrograma

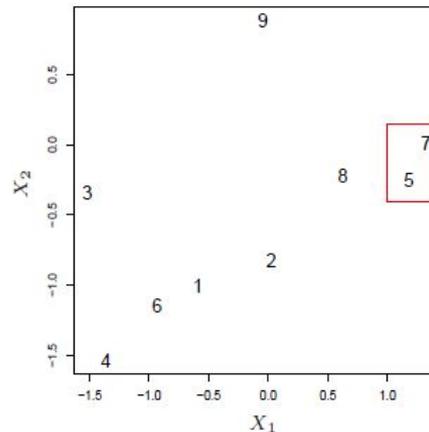
n samples
n clusters



medida de distancia entre samples ('affinity'), usualmente la euclídea



junto los dos cluster que están a menor distancia

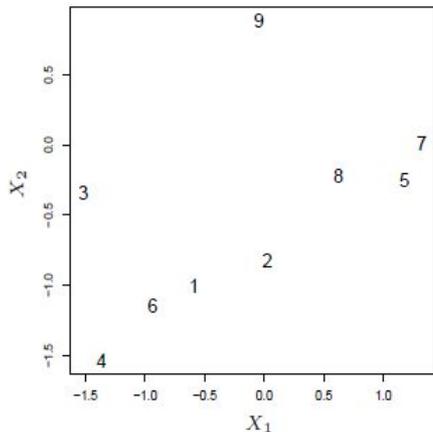


n-1 clusters

distancia entre clusters de ≥ 1 elementos ('linkage')

Clustering Jerárquico: Dendrograma

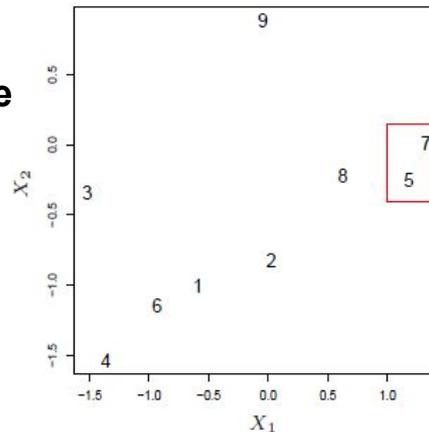
n samples
n clusters



medida de **distancia entre samples** ('affinity'), usualmente la euclídea



junto los dos cluster que están a menor distancia

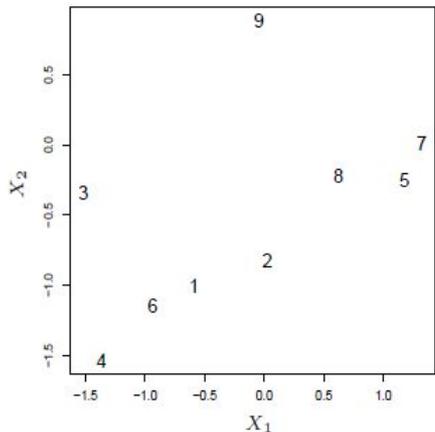


n-1 clusters

distancia entre clusters de ≥ 1 elementos ('linkage')

Clustering Jerárquico: Dendrograma

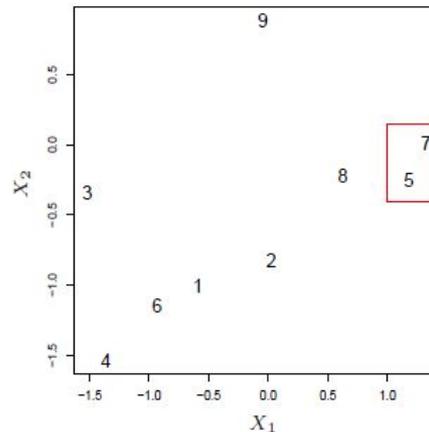
n samples
n clusters



medida de distancia entre samples ('affinity'),
usualmente la euclídea



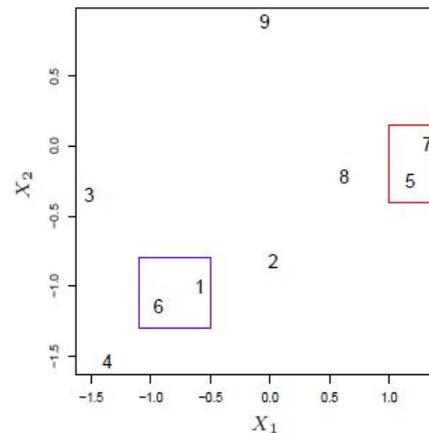
junto los dos cluster que
están a menor distancia



n-1 clusters

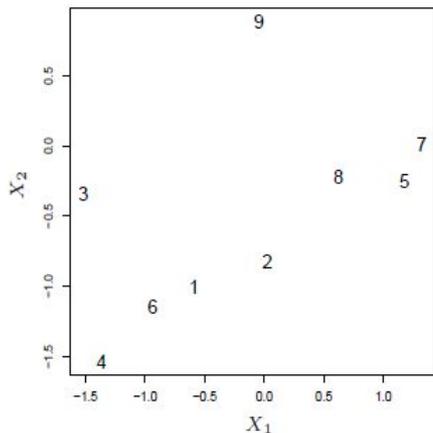


distancia
entre clusters
de ≥ 1
elementos
(‘linkage’)



Clustering Jerárquico: Dendrograma

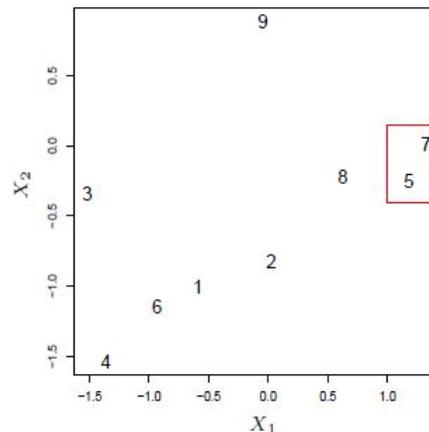
n samples
n clusters



medida de distancia entre samples ('affinity'),
usualmente la euclídea



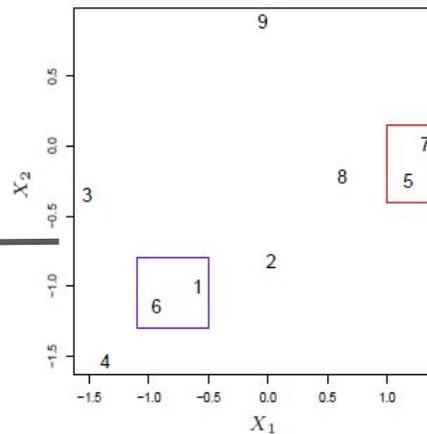
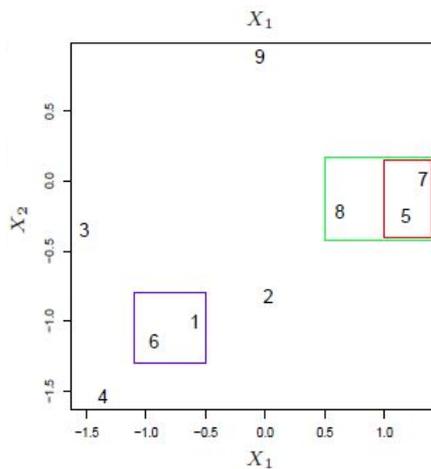
junto los dos cluster que
están a menor distancia



n-1 clusters

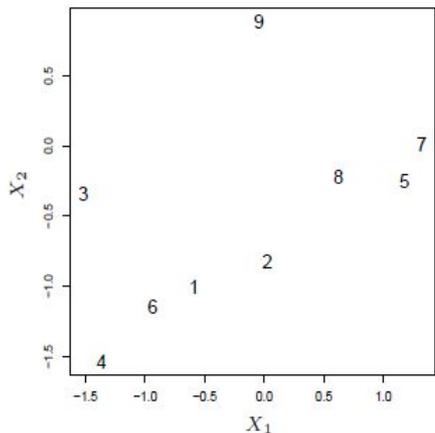


distancia
entre clusters
de ≥ 1
elementos
(*'linkage'*)



Clustering Jerárquico: Dendrograma

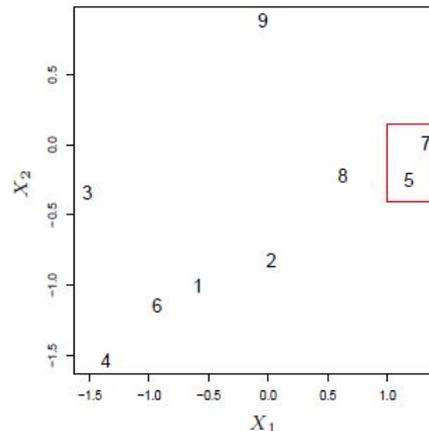
n samples
n clusters



medida de distancia entre samples ('affinity'),
usualmente la euclídea



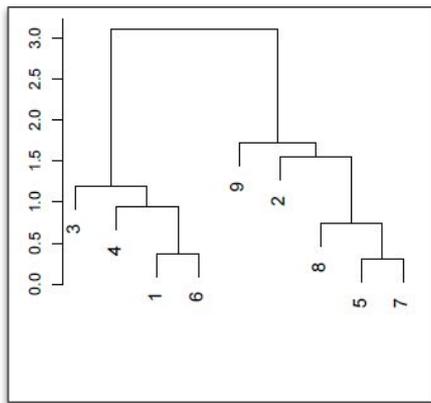
junto los dos cluster que
están a menor distancia



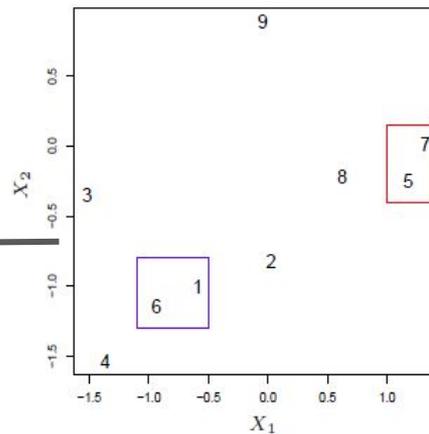
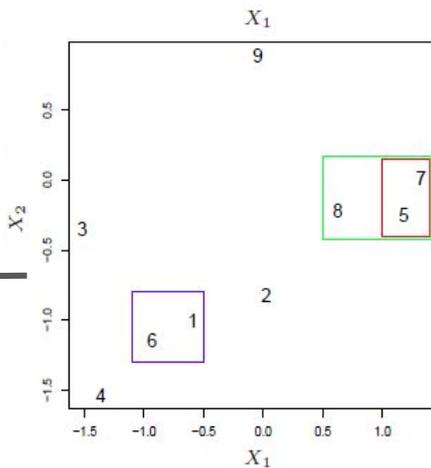
n-1 clusters



distancia
entre clusters
de ≥ 1
elementos
(*'linkage'*)

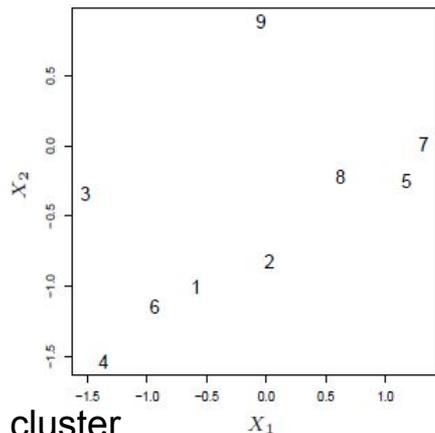


(...)



Clustering Jerárquico: Dendrograma

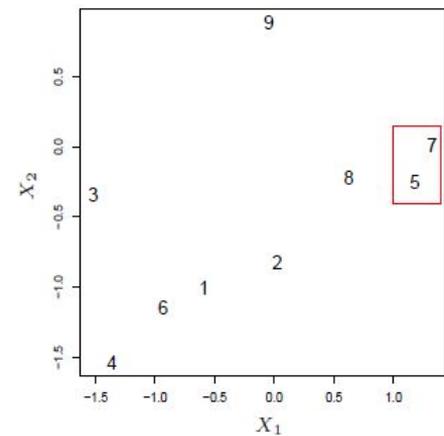
n samples
n clusters



medida de distancia entre samples ('affinity'),
usualmente la euclídea



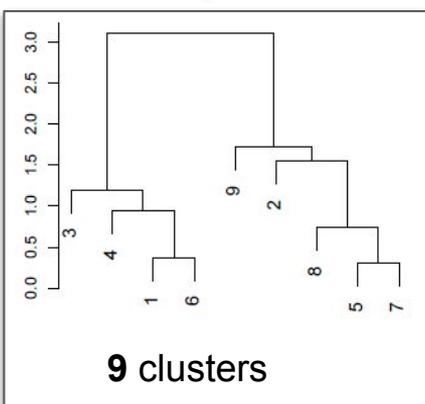
junto los dos cluster que
están a menor distancia



n-1 clusters

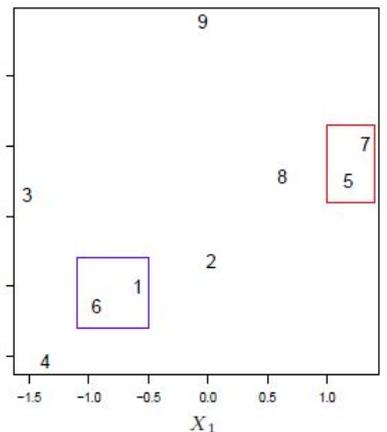
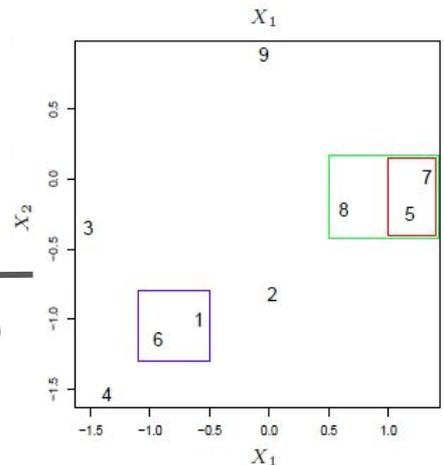
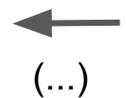


distancia
entre clusters
de ≥ 1
elementos
(*'linkage'*)



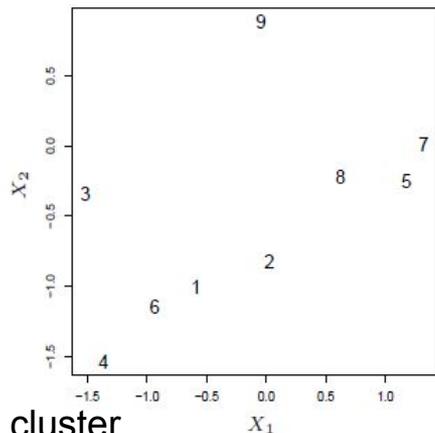
1 cluster

9 clusters



Clustering Jerárquico: Dendrograma

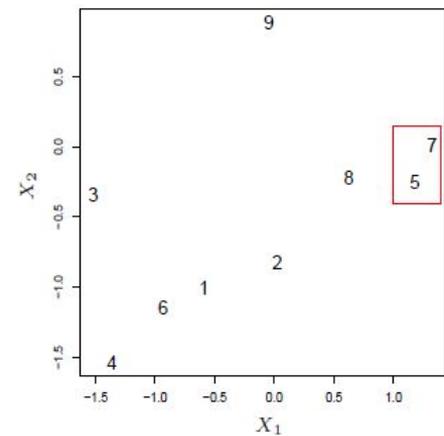
n samples
n clusters



medida de distancia entre samples ('affinity'),
usualmente la euclídea



junto los dos cluster que
están a menor distancia

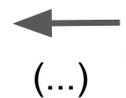
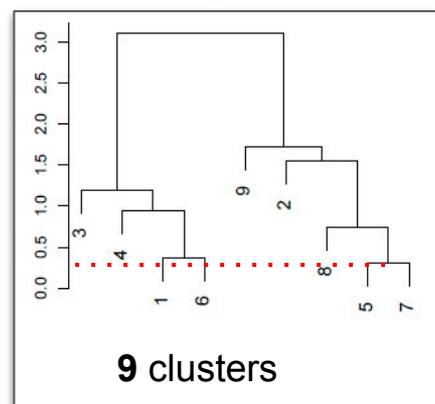


n-1 clusters

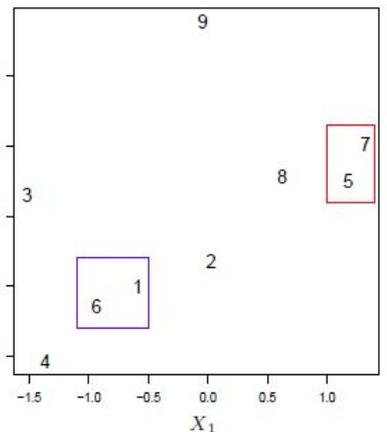
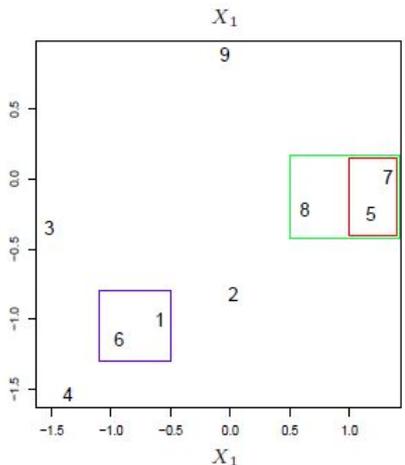


distancia
entre clusters
de ≥ 1
elementos
(*'linkage'*)

1 cluster

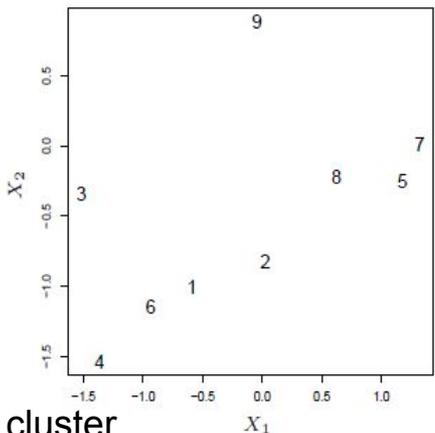


(...)



Clustering Jerárquico: Dendrograma

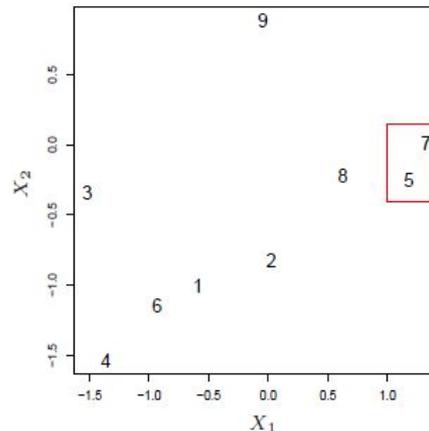
n samples
n clusters



medida de distancia entre samples ('affinity'),
usualmente la euclídea



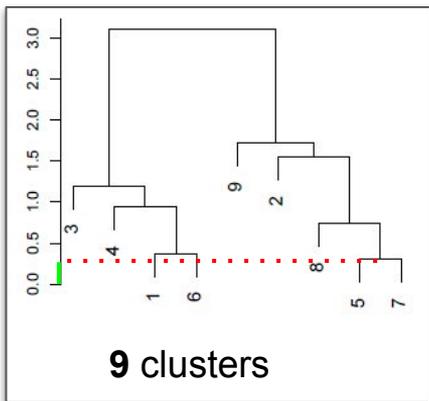
junto los dos cluster que
están a menor distancia



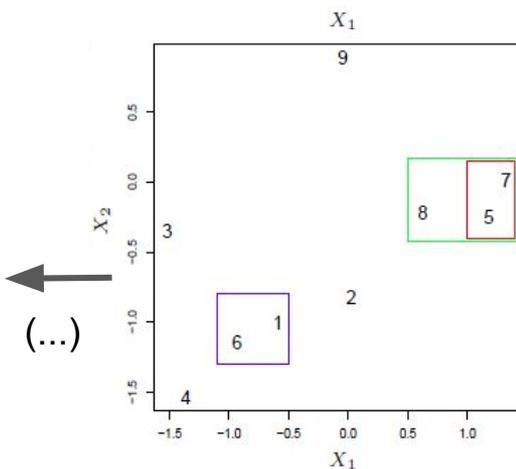
n-1 clusters



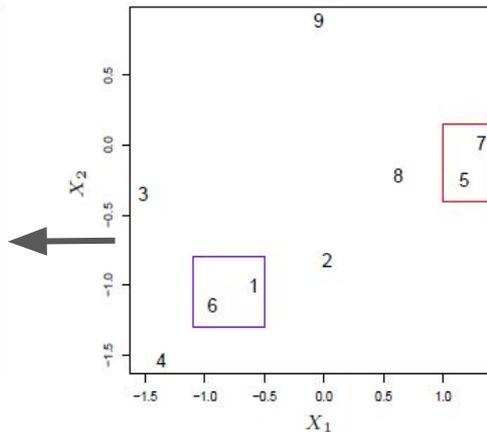
distancia
entre clusters
de ≥ 1
elementos
(*'linkage'*)



1 cluster

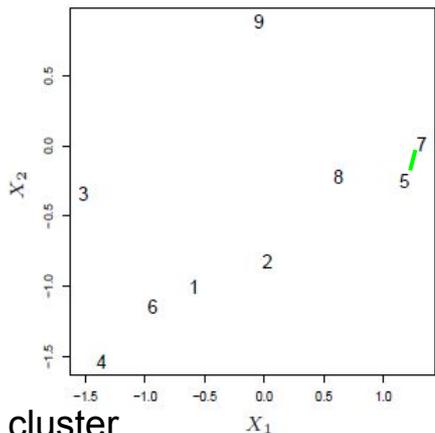


(...)



Clustering Jerárquico: Dendrograma

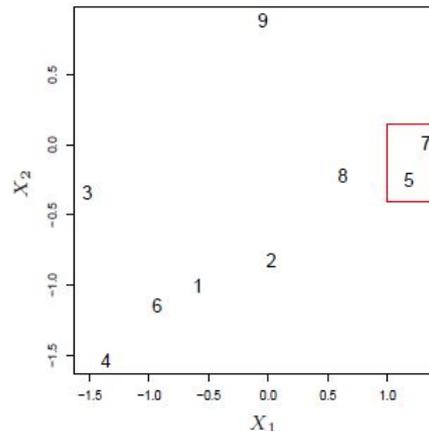
n samples
n clusters



medida de distancia entre samples ('affinity'),
usualmente la euclídea



junto los dos cluster que
están a menor distancia

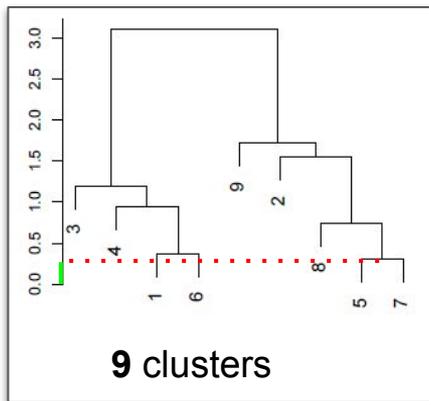


n-1 clusters

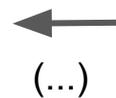


distancia
entre clusters
de ≥ 1
elementos
(*'linkage'*)

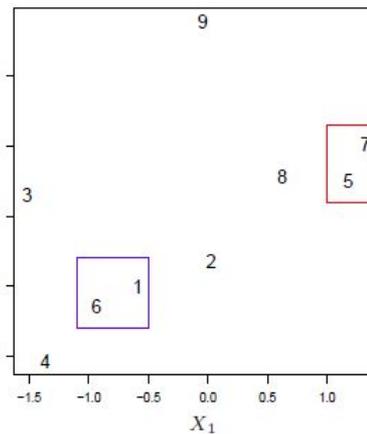
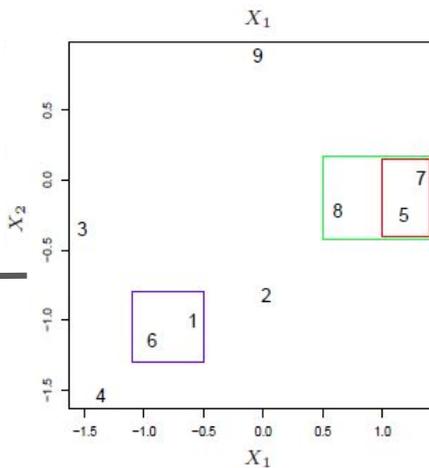
1 cluster



9 clusters

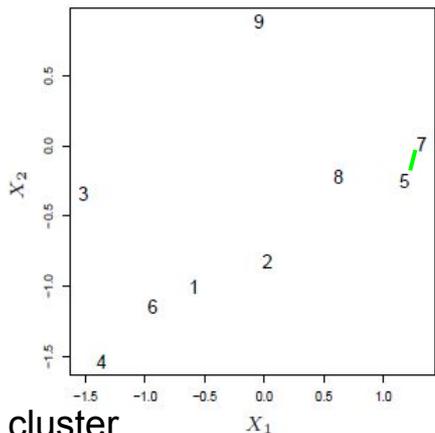


(...)



Clustering Jerárquico: Dendrograma

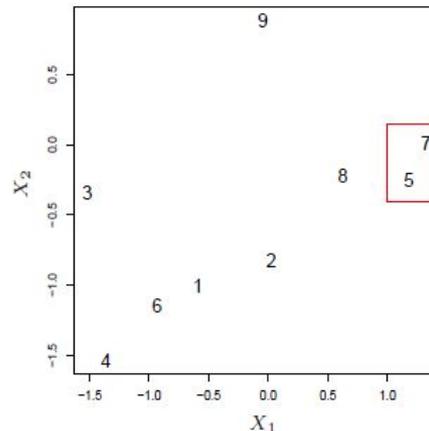
n samples
n clusters



medida de distancia entre samples ('affinity'),
usualmente la euclídea



junto los dos cluster que
están a menor distancia

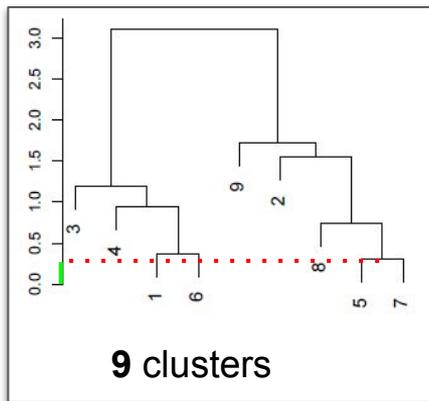


n-1 clusters



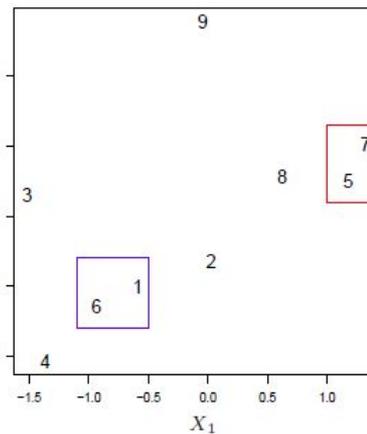
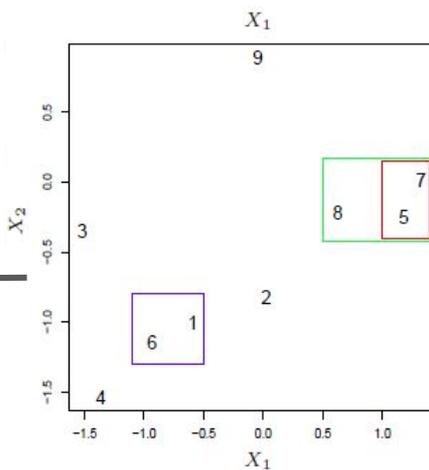
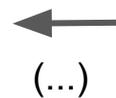
distancia
entre clusters
de ≥ 1
elementos
(*'linkage'*)

1 cluster

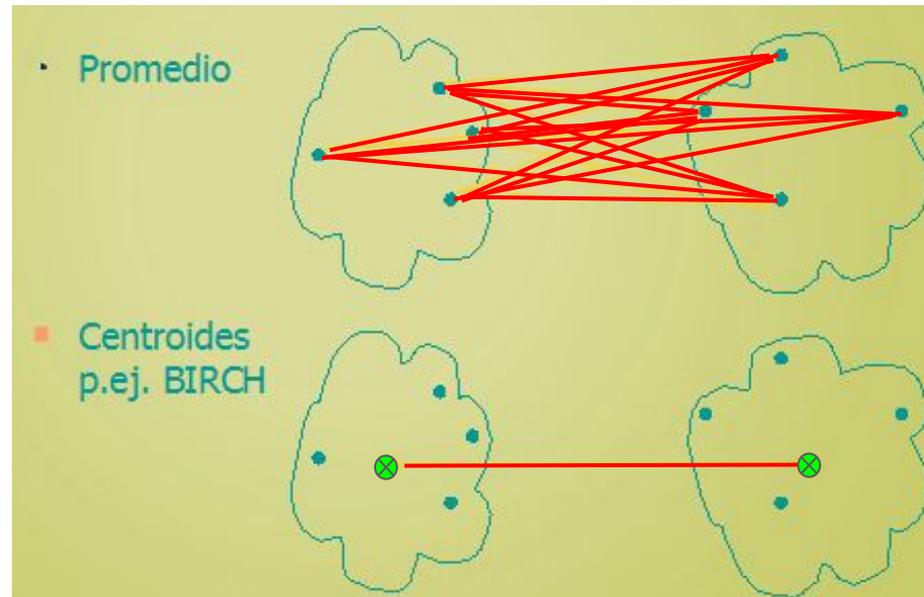
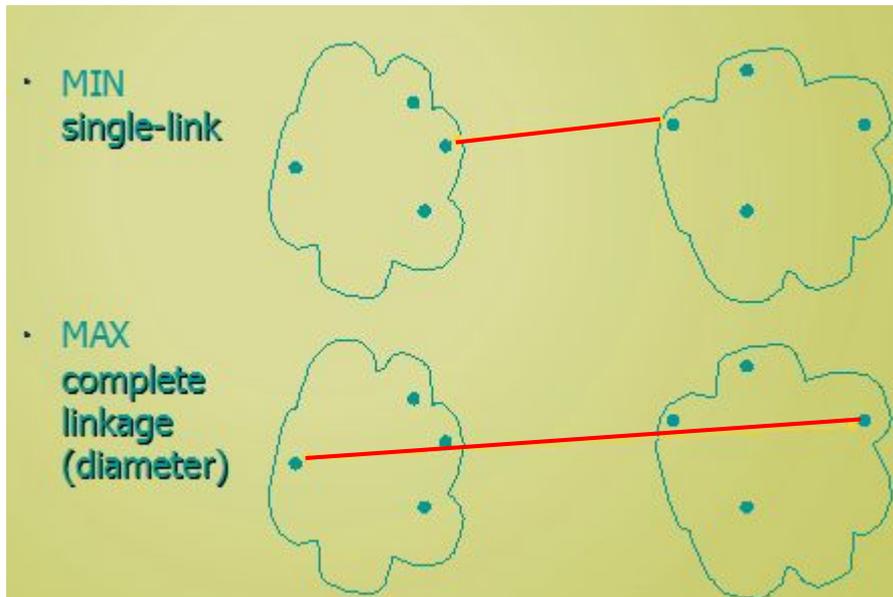


linkage

9 clusters

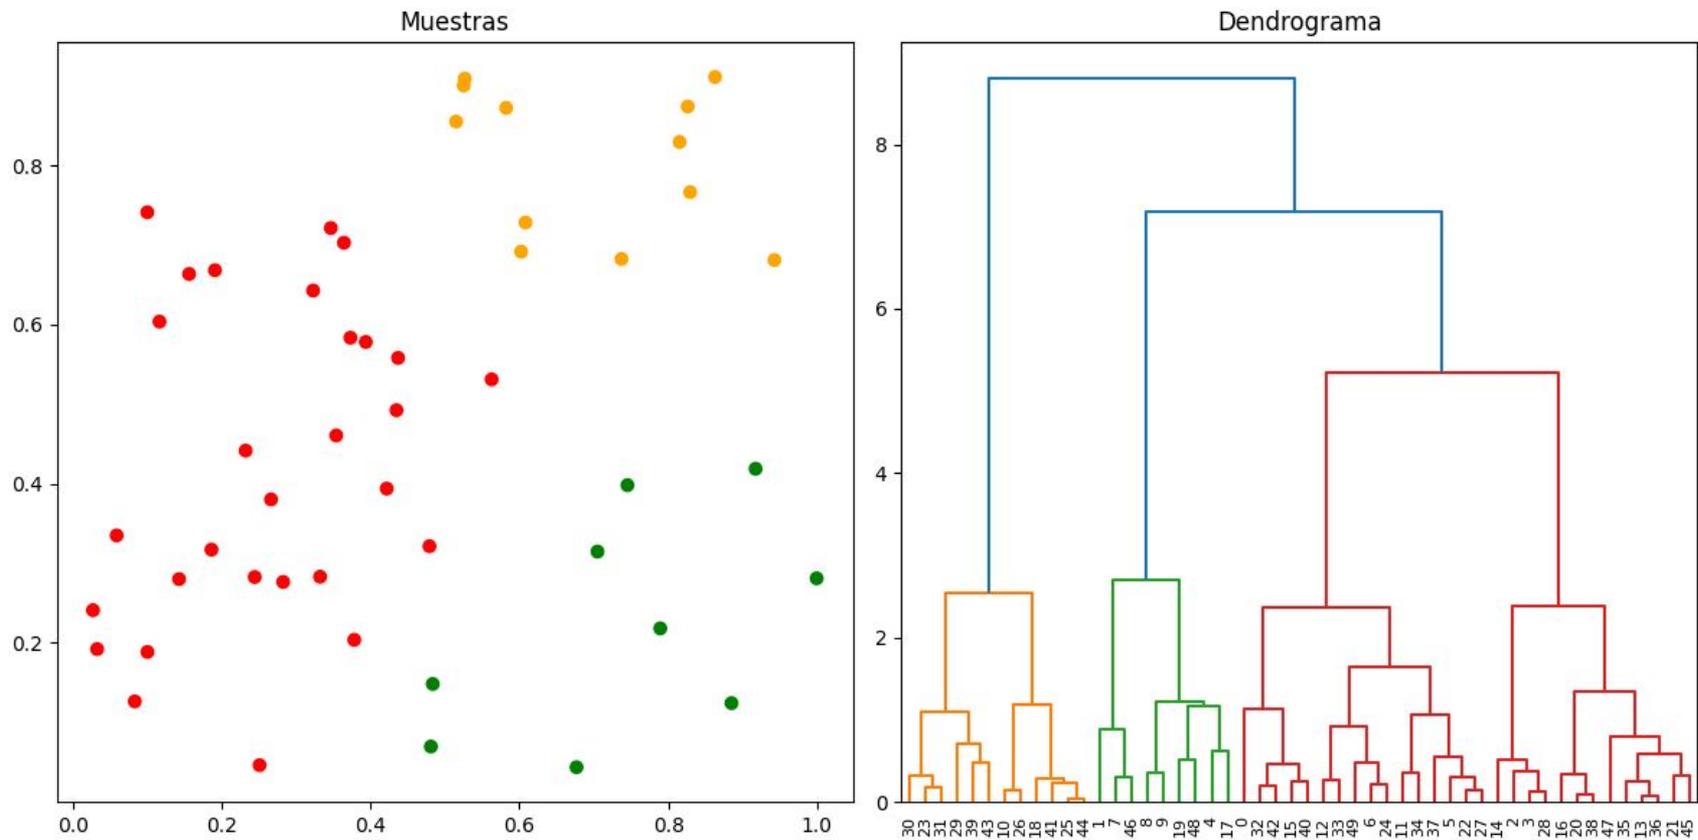


Clustering Jerárquico: Linkage

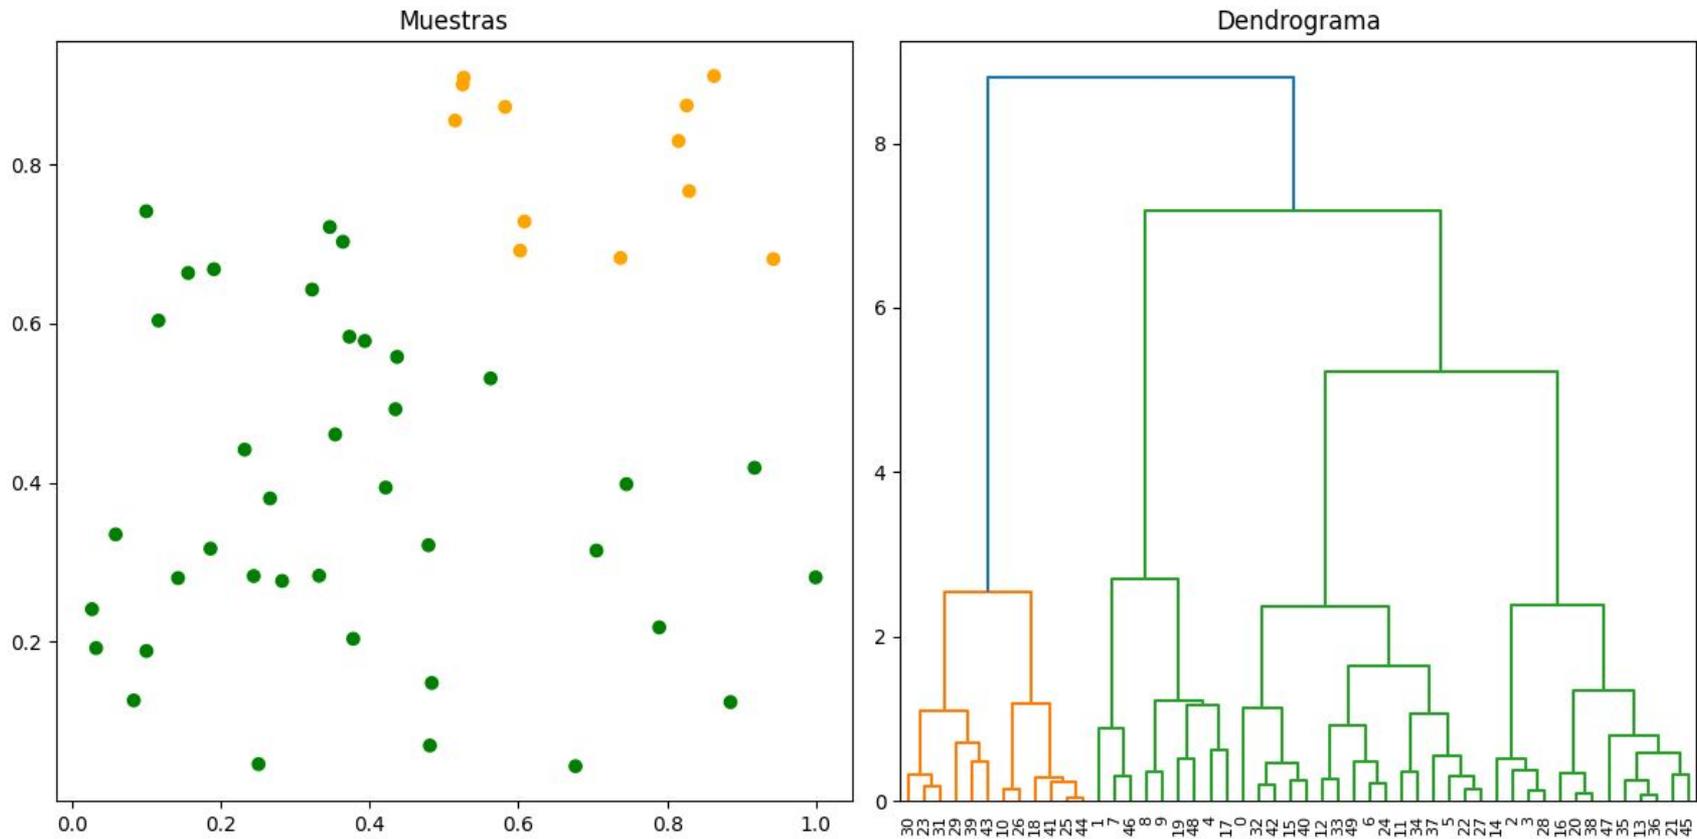


- **Ward linkage:** minimiza la varianza del cluster que se va a *mergear*

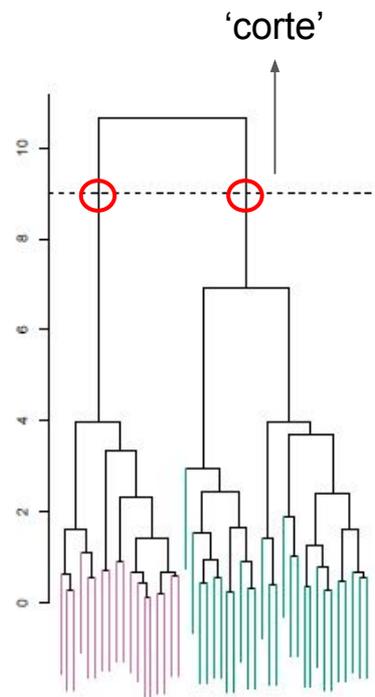
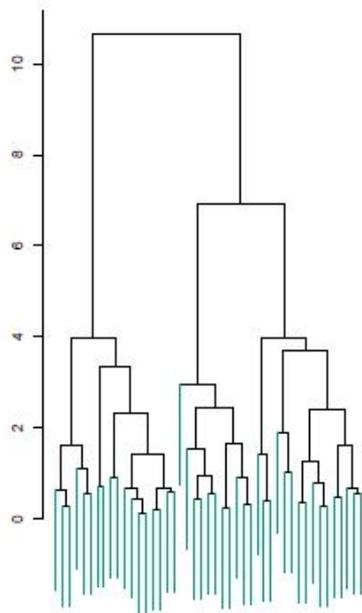
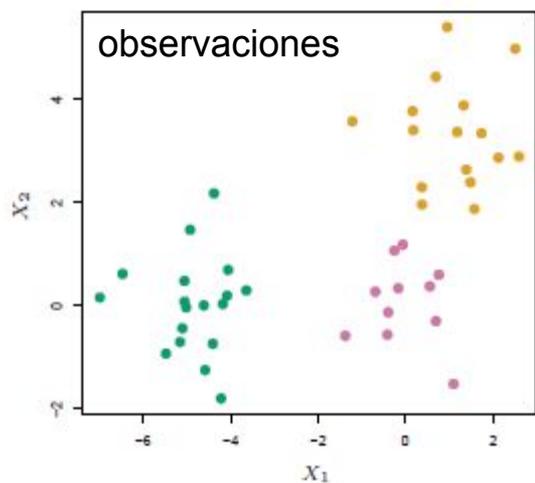
Clustering Jerárquico: De vuelta al dendrograma



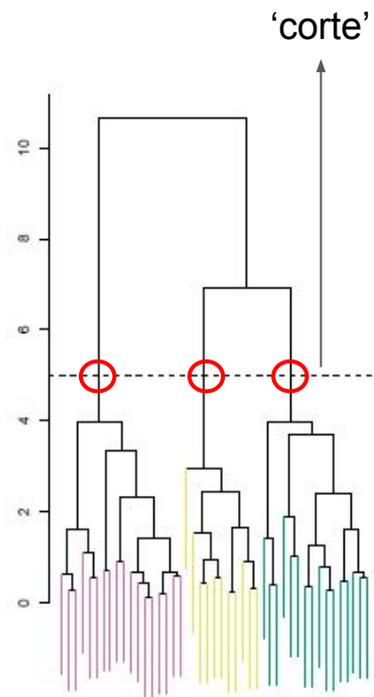
Clustering Jerárquico: De vuelta al dendrograma



Clustering Jerárquico: De vuelta al dendrograma

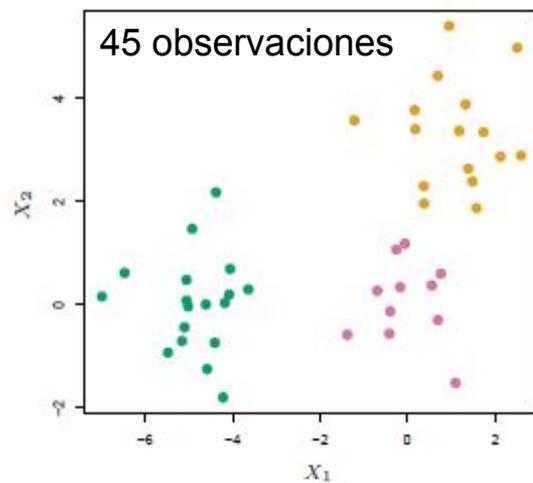


dos clusters

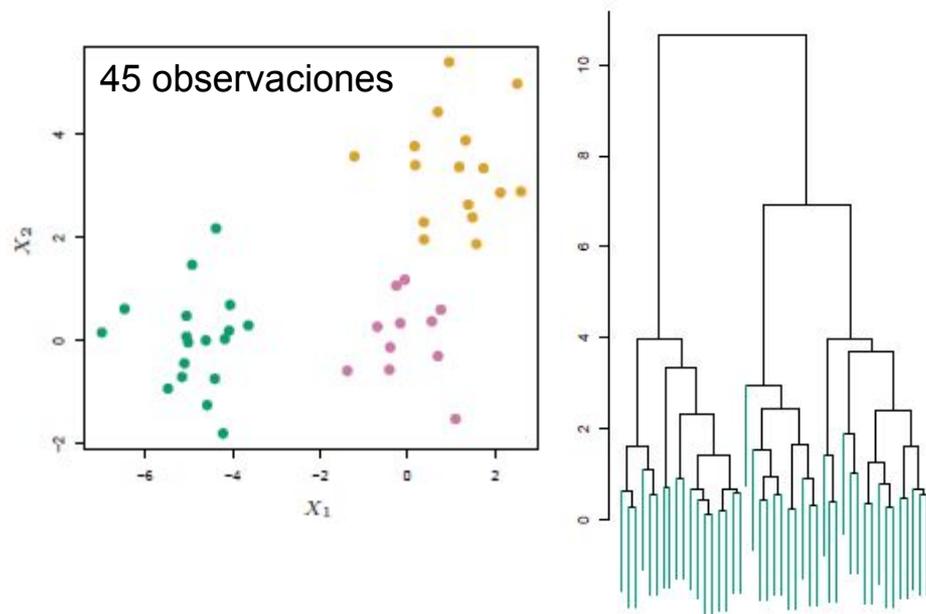


tres clusters

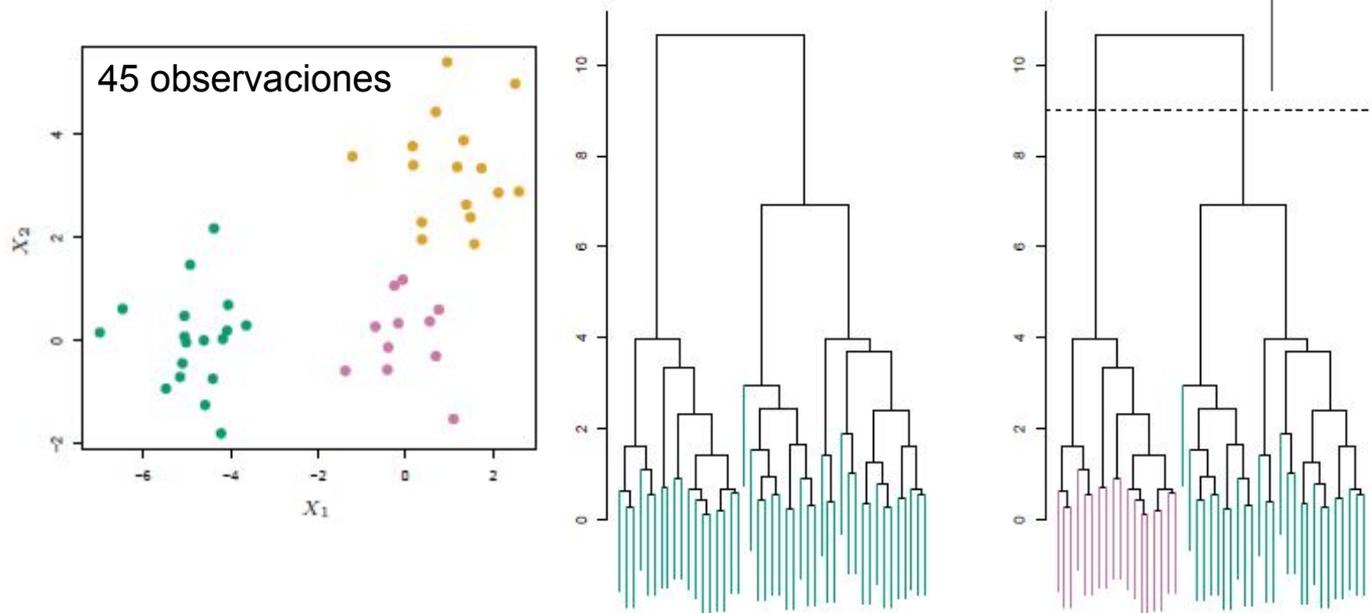
Clustering Jerárquico: De vuelta al dendrograma



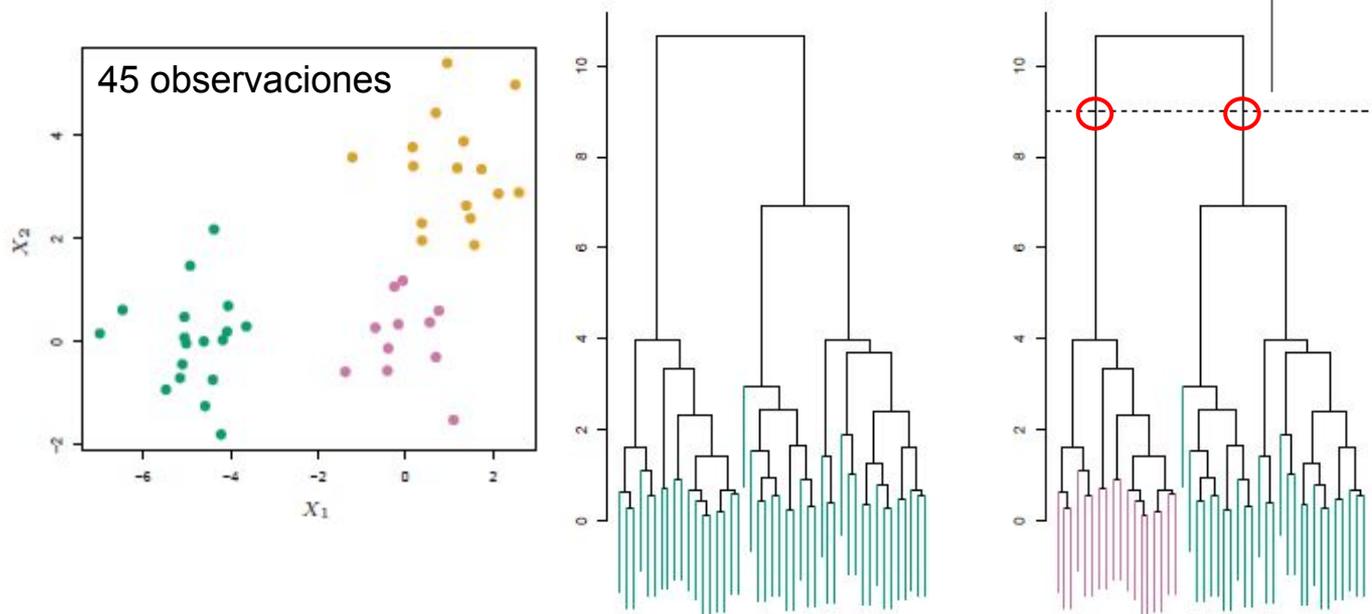
Clustering Jerárquico: De vuelta al dendrograma



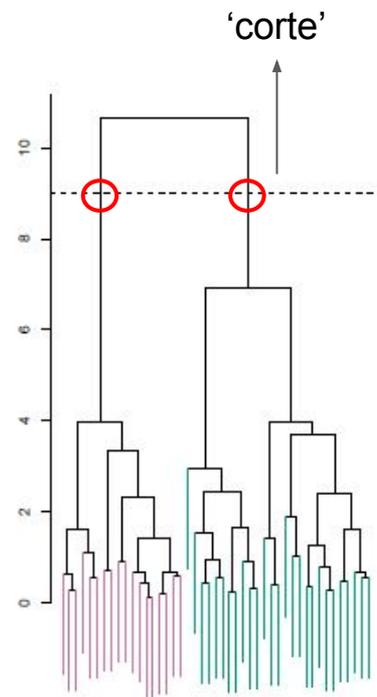
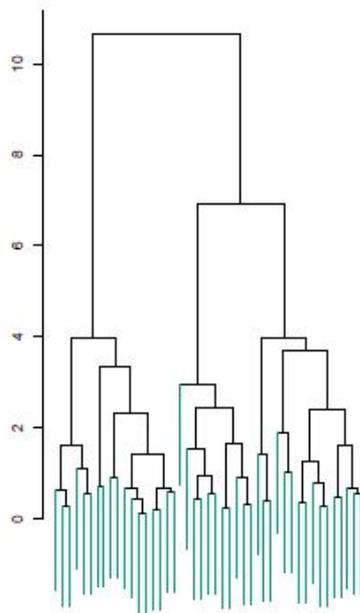
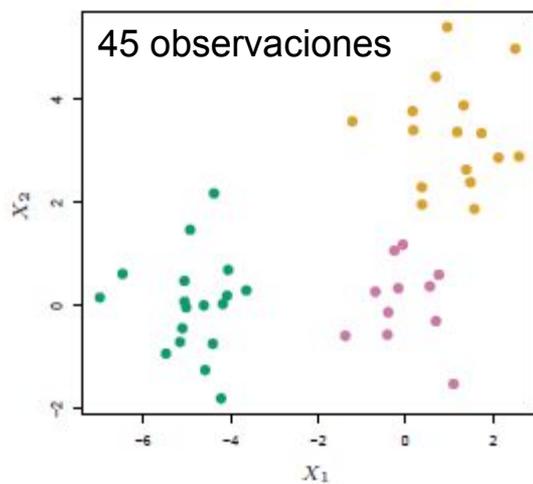
Clustering Jerárquico: De vuelta al dendrograma



Clustering Jerárquico: De vuelta al dendrograma

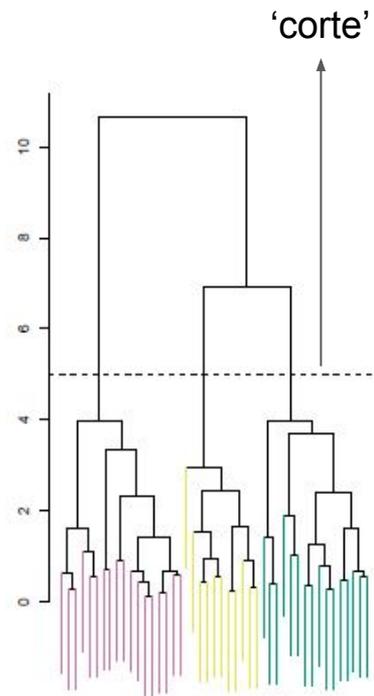
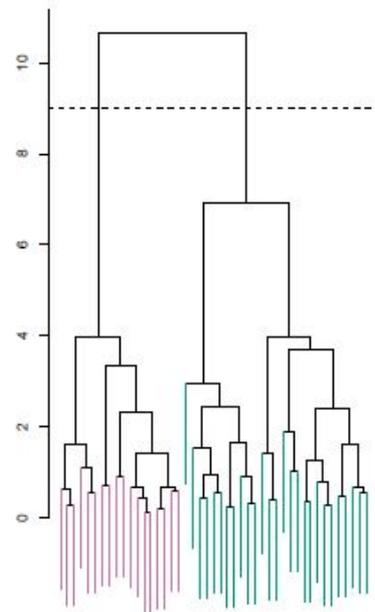
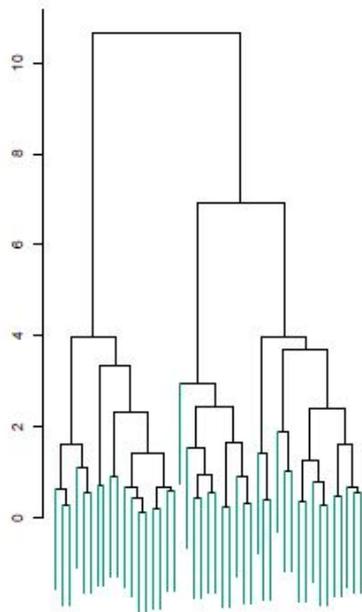
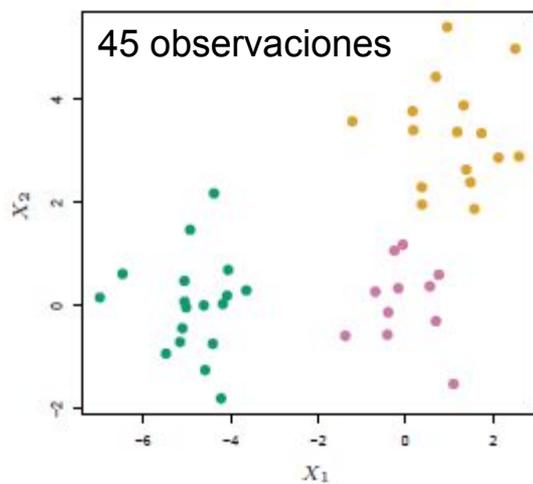


Clustering Jerárquico: De vuelta al dendrograma

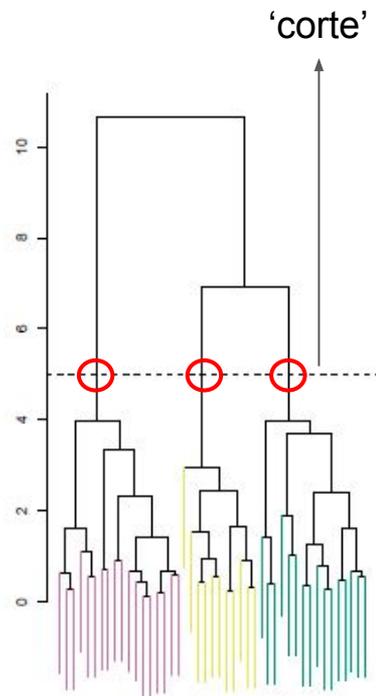
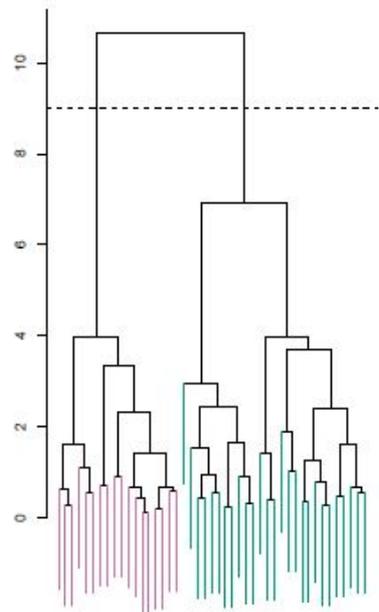
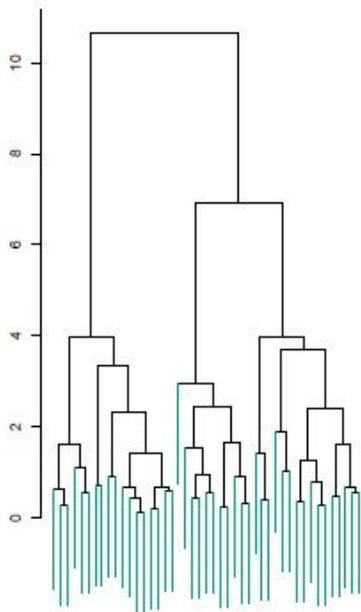
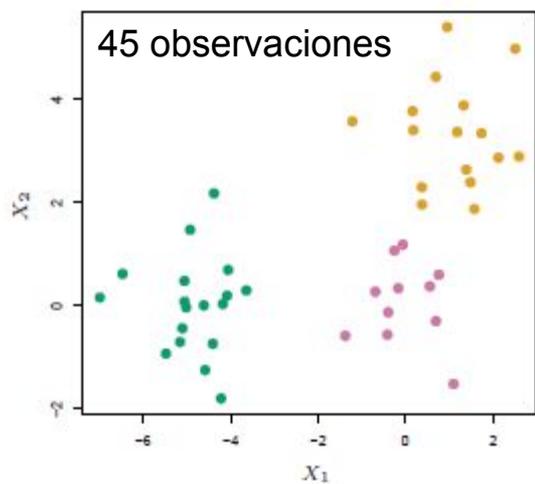


dos clusters

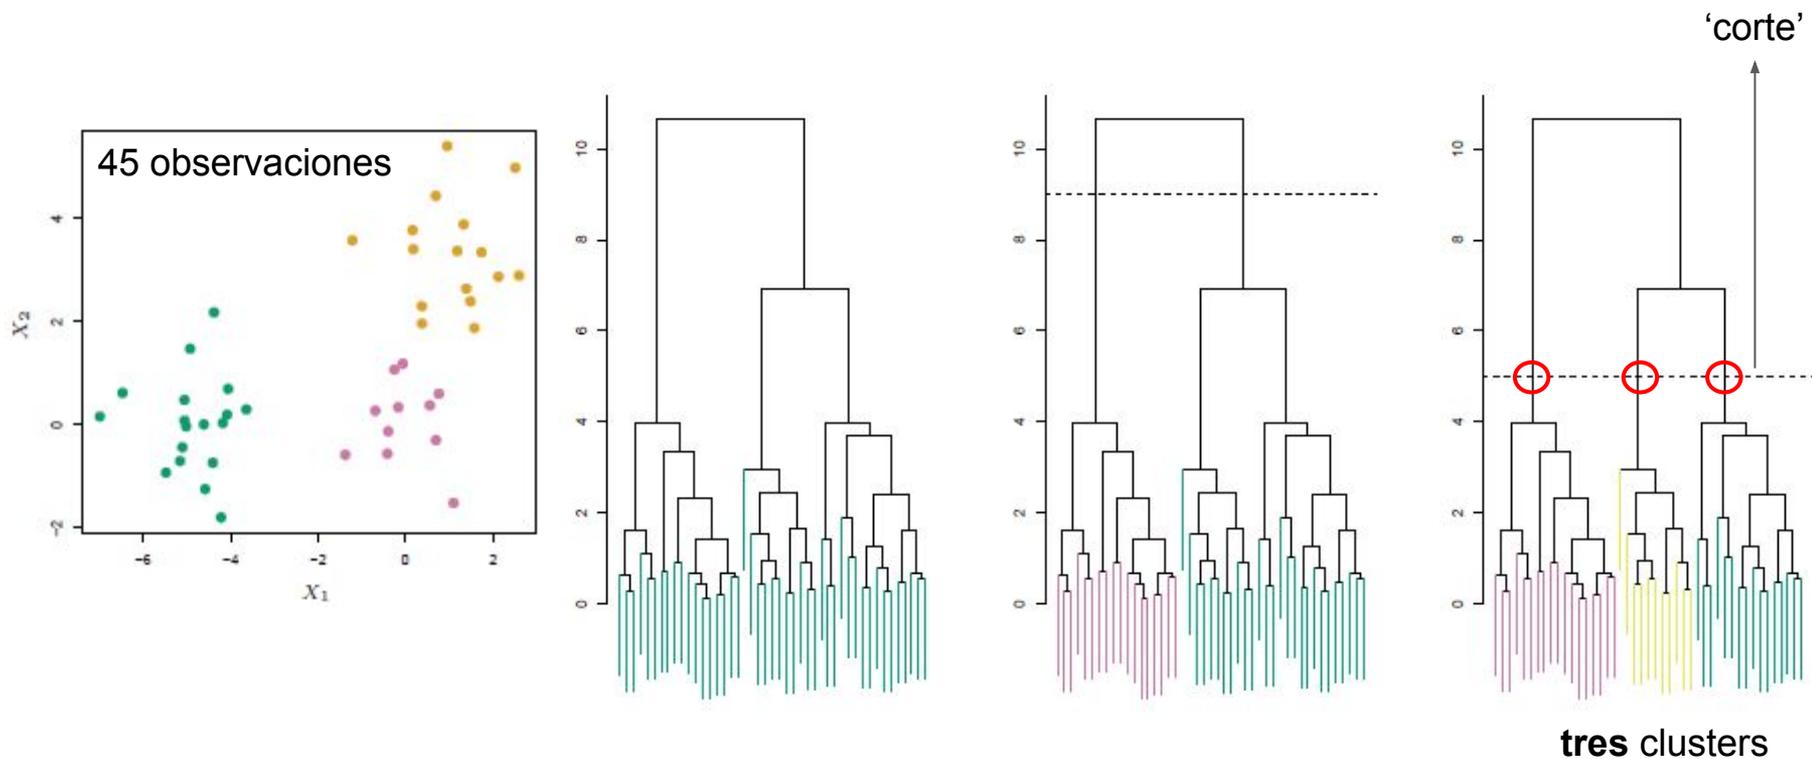
Clustering Jerárquico: De vuelta al dendrograma



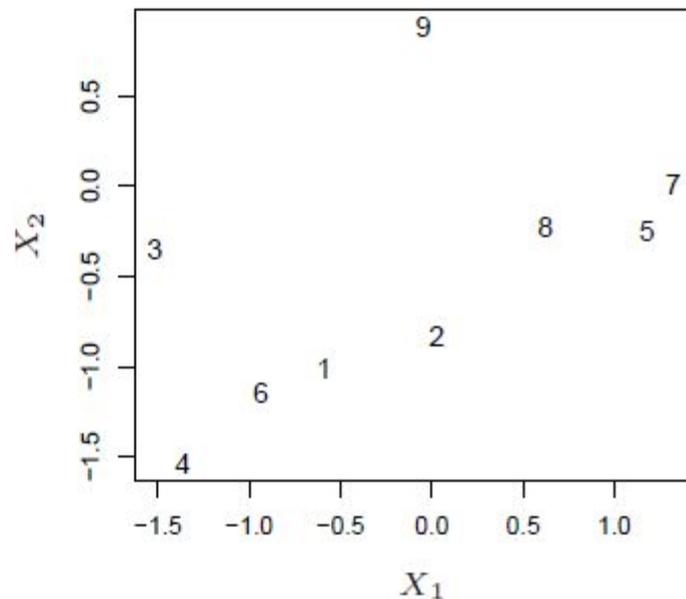
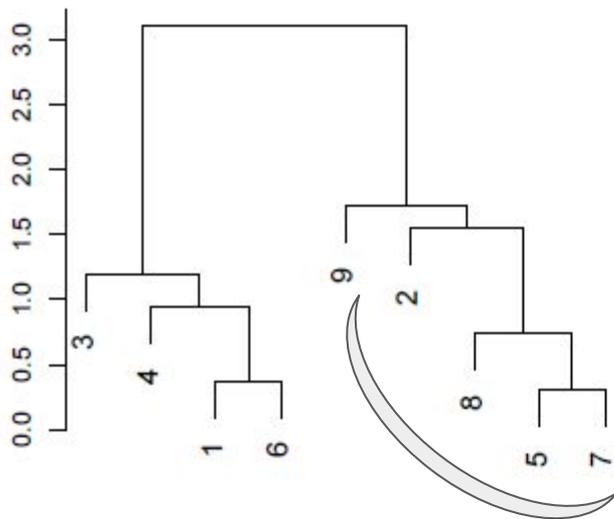
Clustering Jerárquico: De vuelta al dendrograma



Clustering Jerárquico: De vuelta al dendrograma



Clustering Jerárquico: De vuelta al dendrograma

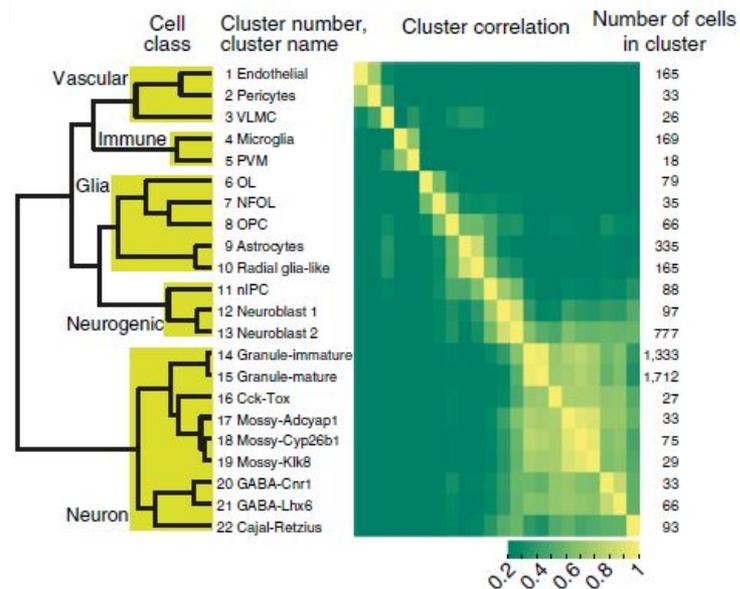


Los clusters que se obtienen cortando el dendrograma a una dada altura están anidados con los clusters que se obtienen al cortar el dendrograma en una altura superior.

Este puede ser un requisito fuerte para un dataset real donde no necesariamente la mejor clusterización de los datos en 3 grupos resulta de tomar la mejor clusterización de los datos en dos grupos y separarlos

Clustering Jerárquico: Pros y Cons

- + Pueden revelar detalles finos en la relación de los datos
- + Proveen un dendrograma interpretable
- + Son determinísticos - producen el mismo resultado si se corre el mismo modelo con el mismo input
- Son computacionalmente costosos



Consideraciones

- Tanto K-means como clustering jerárquico asignan un cluster a cada sample, por lo que los clusters encontrados pueden **distorsionarse fuertemente debido a la presencia de outliers** que no pertenecen a algún determinado grupo -> modelos mixtos están pensados para lidiar con outliers.
- Los algoritmos de clusterización **no suelen ser robustos ante permutaciones en los datos**. Si computamos un set de k clusters en nuestros datos, removemos algunas muestras de forma aleatoria y volvemos a clusterizar los resultados pueden ser muy distintos.
- Los resultados de una clusterización **no deberían ser vistos como una verdad absoluta** sino que deberían dar un puntapié inicial al desarrollo de una hipótesis científica e investigación futura, preferentemente, en un dataset independiente.

Sugerencias

- Realizar varias inicializaciones de los modelos cambiando los parámetros para ver las estructuras que emergen consistentemente
- Testear la robustez del método aplicándolo sobre subsets aleatorios de los datos

(sklearn) K-means clustering

sklearn.cluster.KMeans

```
class sklearn.cluster.KMeans(n_clusters=8, *, init='k-means++', n_init=10, max_iter=300, tol=0.0001,
precompute_distances='deprecated', verbose=0, random_state=None, copy_x=True, n_jobs='deprecated', algorithm='auto') \[source\]
```

El parámetro es *n_clusters* con el cual indicamos al modelo el número de clusters que queremos obtener

init - es el método de inicialización de los k centroids (random, k-means++)

n_init - cuantas veces queremos inicializar el modelo ya que no es determinista (output es el de menor SSE)

max_iter - el número máximo de iteraciones si es que no converge antes

(sklearn) Clustering Jerárquico

`sklearn.cluster.AgglomerativeClustering`

```
class sklearn.cluster.AgglomerativeClustering(n_clusters=2, *, affinity='euclidean', memory=None, connectivity=None, compute_full_tree='auto', linkage='ward', distance_threshold=None, compute_distances=False)
```

[\[source\]](#)

affinity - medida de disimilaridad de para el primer paso del algoritmo (distancia euclídea o basada en correlación)

linkage - medida de disimilaridad cuando un cluster tiene más de un elemento

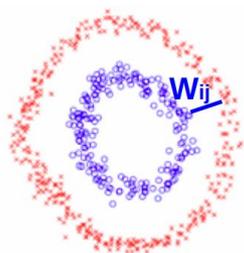
Spectral clustering

Similarity graph construction

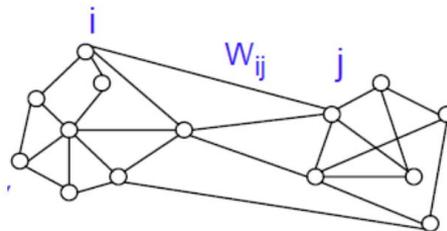
Similarity Graphs: Model local neighborhood relations between data points

E.g. Gaussian kernel similarity function

$$W_{ij} = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}} \longrightarrow \text{Controls size of neighborhood}$$



Data clustering



$G = \{V, E\}$

Spectral clustering

¿Qué hace exactamente?

1. **Construye un grafo**: cada punto de datos es un nodo, y las conexiones (aristas) se basan en la similitud entre puntos (por ejemplo, con una función de afinidad tipo gaussiana).
2. **Calcula el Laplaciano del grafo**, una matriz que codifica la estructura del grafo.
3. **Obtiene los vectores propios** del Laplaciano (espectro del grafo).
4. **Proyecta los datos** en un espacio de menor dimensión usando esos eigenvectores.
5. **Aplica K-means** (u otro método de clustering) en ese nuevo espacio reducido.

Intuición general:

- El Laplaciano "lee" la conectividad del grafo.
- Los vectores propios del Laplaciano extraen la estructura global.
- Al proyectar los datos usando esos vectores propios, obtenemos una representación que revela los clústeres ocultos.

¿Por qué usar Spectral Clustering?

- Detecta **clústeres no convexos** o con formas arbitrarias (por ejemplo, en forma de anillos).
- Muy útil cuando la estructura de los datos **no se ajusta bien a K-means**.

Spectral clustering

Luego particionamos el grafo usando los valores y vectores propios de la matriz Laplaciana.