


$$d_2 = \sqrt{1^2 + 3^2} < \sqrt{3^2 + 3^2} = d_1$$

Problem 1 (2 credits)



$$d_2 = \sqrt{1^2 + 8^2} \approx 8, \dots$$

$$d_1 = \sqrt{2^2 + 6^2} \approx 6, 3$$

Cluster 1 D, A
Cluster 2 E, C, B

$$X_1^{(1)} = \frac{A + D}{2} = \frac{\begin{pmatrix} 9 \\ 9 \end{pmatrix} + \begin{pmatrix} 10 \\ 1 \end{pmatrix}}{2} = \frac{\begin{pmatrix} 19 \\ 10 \end{pmatrix}}{2} = \begin{pmatrix} 9.5 \\ 5 \end{pmatrix}$$


$$X_2^{(2)} = \frac{E + C + B}{3} = \frac{\begin{pmatrix} 2 \\ 4 \end{pmatrix} + \begin{pmatrix} 4 \\ 6 \end{pmatrix} + \begin{pmatrix} 5 \\ 7 \end{pmatrix}}{3} =$$

The plot above displays a random initialization of a k-Means algorithm with $k=2$. X_1, X_2 are the randomly positioned centroids and A to E are the points of the 2-dimensional dataset to be clustered. Report the new positions of the centroids after the first iteration. Use the Euclidean distance. No standardization of the variables shall be applied. Justify your answer and provide relevant intermediate calculations. (1 point for the correct justification. If the justification is correct, 1 further point for the correct calculations.)

Problem 4 (2 credits)

Given the following data manually perform k-means clustering. Clearly state the assignment and centroids after each iteration. Start with the centroids $(1, 1)$ and $(2, 1)$.

```
##   x y
## 1: 1 1 A
## 2: 2 1 B
## 3: 4 1 C
## 4: 5 1 D
```



\downarrow iteration

$\downarrow k$

	$X_1^{(k)}$	$X_2^{(k)}$
0	$\langle 1 \rangle$	$\langle 2 \rangle$
1	$\langle 1 \rangle$	$\langle 3, 6 \rangle$
2	$\langle 1, 5 \rangle$	$\langle 4, 5 \rangle$
3		

$$X_2^{(1)} = \frac{B+C+D}{3} = \frac{\langle 2 \rangle + \langle 4 \rangle + \langle 5 \rangle}{3} = \frac{\langle 11 \rangle}{3} = \langle 3, 6 \rangle$$

Cluster 1

A

Cluster 2
B, C, D

C, D



C, D

11

11


Problem 5 (3 credits)

You clustered a dataset using K-means clustering with $K = 2$ and hierarchical clustering using the single linkage rule. In the case of the hierarchical clustering the clustering tree was cut at a height which provides two clusters. Which of the two clustering results shown in Panel A and B corresponds to which algorithm? Justify your answer stating the main steps of each algorithm.



K-means - clustering

Beispiel für hierarchical clustering



- 1) Finde zwei Punkte/Punktgruppen, deren Distanz am geringsten

Beispiel: 10-wal Würfen mit Würfel
 $p = \text{W'keit für Kopf}$

$$H_0: p \leq \frac{1}{2} \quad H_1: p > \frac{1}{2}$$

Ramdtat: Wenn nicht Köpfe kommen, wird H_0 abgelehnt.

K, K, K, Z, Z, K, K, K, K, K

Kann dann H_0 zum Niveau $\alpha = 2\%$ abgelehnt werden?

$X = \text{Anzahl Köpfe} \sim \text{Binom}\left(n=10, p=\frac{1}{2}\right)$ unter H_1 .

$p\text{-Wkt} =$ W'keit unter H_0 einen Wert zu erhalten, der mindestens so extrem ist wie der beobachtete Wert,

$$\begin{aligned} &= P_{H_0}(X \geq 8) = P_{H_0}(X=8) + P_{H_0}(X=9) + P_{H_0}(X=10) = \\ &= \binom{10}{8} \cdot \underbrace{\left(\frac{1}{2}\right)^8 \cdot \left(\frac{1}{2}\right)^2}_{=\left(\frac{1}{2}\right)^{10}} + \binom{10}{9} \cdot \underbrace{\left(\frac{1}{2}\right)^9 \cdot \left(\frac{1}{2}\right)^1}_{=\left(\frac{1}{2}\right)^{10}} + \binom{10}{10} \cdot \underbrace{\left(\frac{1}{2}\right)^{10} \cdot \left(\frac{1}{2}\right)^0}_{=1} \\ &= \left(\frac{1}{2}\right)^{10} \cdot \left(\binom{10}{8} + 10 + 1 \right) \approx 0,05 \end{aligned}$$

DU musst einen Zoom-Link schicken

$\Rightarrow p\text{-Wkt} \rightarrow \alpha = 0,02$
 $\Rightarrow H_0 \text{ wird nicht abgelehnt}$

Ramdtat: KKKKKKZZZZ

$$p\text{-Wkt} = P_{H_0}(X \geq 5) \approx \frac{1}{2}$$

Wir dürfen die Nullhypothese nicht ablehnen
 Je größer der Wert, desto mehr spricht das für eine wahre Nullhypothese

$p\text{-Wkt} < \alpha$
 $\Rightarrow H_0 \text{ wird abgelehnt}$

$$X \sim \text{Binom}(n|p)$$

$$P(X=k) = \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k}$$

Problem 8 (1 credit)

In which of the following cases do you accept the null hypothesis? Justify.

- i) P-value < 0.01 ✓
- ii) P-value > 0.9
- iii) Both i) and ii)
- iv) None of the above

Problem 8 (2 credits)

We have two vectors:

$$a = [0, 2.5, 5, 7.5, 10]$$

$$b = [0.2, 1.1, 1.9, 2.8, x]$$

Suppose we run:

`t.test(a, b)$p.value`

State the value of x such that the P -value returned by the code above is maximized.

$$H_0: \mu_1 = \mu_2$$

$$H_1: \mu_1 \neq \mu_2$$

Wert von x um μ_1 zu stimmen für H_0 (d.h. für p).

$$\bar{a} = \bar{b}$$

x muss so gewählt werden, dass die Mittelwerte gleich sind

$$\bar{s} = \frac{6+x}{5}$$

$$x = 5 \cdot 5 - 6 = 25 - 6 = 19$$

Mittelwert μ_1



Stichprobe stammt aus einer Normalverteilung (z.B. Blutdruck aller grauhaarigen Deutschen)

Mittelwert μ_2



Stichprobe aus einer anderen Normalverteilung (z.B. Blutdruck aller rothaarigen Deutschen)

$\rightarrow x = 19$