


# Data Mining Tutorial


## Clusteranalyse – Teil I

Erich Schubert, Arthur Zimek

Ludwig-Maximilians-Universität München

2015-05-13 — KDD Übung







Zentroide neu berechnen:

$$\mu \approx (6.0, 4.3)$$

$$\mu \approx (5.0, 6.4)$$




Punkte neu zuordnen




Zentroide neu berechnen:

$$\mu \approx (5.0, 2.7)$$

$$\mu \approx (5.6, 7.4)$$



Punkte neu zuordnen





Zentroide neu berechnen:

$$\mu \approx (4.0, 3.25)$$


$$\mu \approx (6.75, 8.0)$$


Punkte neu zuordnen





Punkte neu zuordnen  
Keine Änderung  
Konvergenz!







Zentroide  
(z.B.: aus  
vorheriger Iteration):

$$\mu \approx (6.0, 4.3)$$


$$\mu \approx (5.0, 6.4)$$



Ersten Punkt zuordnen




Zweiten Punkt zuordnen




Zentroide aktualisieren:

$$\mu \approx (5.0, 4.0)$$

$$\mu \approx (5.75, 7.25)$$




Dritten Punkt zuordnen




Zentroide aktualisieren:

$$\mu \approx (4.6, 4.0)$$


$$\mu \approx (6.7, 8.3)$$



Vierten Punkt neu  
zuordnen




Fünften Punkt neu  
zuordnen




Zentroide aktualisieren:

$$\mu \approx (4.0, 3.25)$$


$$\mu \approx (6.75, 8.0)$$




Weitere Punkte neu  
zuordnen



Weitere Punkte neu  
zuordnen  
ggf. Weitere Iterationen



Weitere Punkte neu  
zuordnen  
ggf. Weitere Iterationen  
Konvergenz



# k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining  
Tutorial

E. Schubert,  
A. Zimek

Aufgabe 4-1

Lloyd/Forgey

MacQueen

MacQueen Alternativ

Qualität

Fazit


Aufgabe 4-2

Aufgabe 4-3

Aufgabe 4-4

Beispiel


Berechnung




Zentroide  
(z.B.: aus  
vorheriger Iteration):

$$\mu \approx (6.0, 4.3)$$


$$\mu \approx (5.0, 6.4)$$




Ersten Punkt zuordnen




Zweiten Punkt zuordnen



Dritten Punkt zuordnen




Vierten Punkt zuordnen




Zentroide aktualisieren:

$$\mu \approx (4.0, 8.5)$$

$$\mu \approx (4.3, 6.2)$$




Fünften Punkt zuordnen




Zentroide aktualisieren:

$$\mu \approx (10.0, 1.0)$$


$$\mu \approx (4.7, 6.3)$$




Weitere Punkte neu  
zuordnen



Weitere Punkte neu  
zuordnen  
ggf. Weitere Iterationen



Weitere Punkte neu  
zuordnen  
ggf. Weitere Iterationen  
Konvergenz



Erste Lösung:  $TD^2 = 61\frac{1}{2}$

$$SSQ(\mu_1, p_1) = |4 - 10|^2 + |3.25 - 1|^2 = 36 + 5\frac{1}{16} = 41\frac{1}{16}$$

$$SSQ(\mu_1, p_2) = |4 - 2|^2 + |3.25 - 3|^2 = 4 + \frac{1}{16} = 4\frac{1}{16}$$

$$SSQ(\mu_1, p_3) = |4 - 3|^2 + |3.25 - 4|^2 = 1 + \frac{9}{16} = 1\frac{9}{16}$$

$$SSQ(\mu_1, p_4) = |4 - 1|^2 + |3.25 - 5|^2 = 9 + 3\frac{1}{16} = 12\frac{1}{16}$$

$$TD^2(C_1) = 58\frac{3}{4}$$

$$SSQ(\mu_2, p_5) = |6.75 - 7|^2 + |8 - 7|^2 = \frac{1}{16} + 1 = 1\frac{1}{16}$$


$$SSQ(\mu_2, p_6) = |6.75 - 6|^2 + |8 - 8|^2 = \frac{9}{16} + 0 = \frac{9}{16}$$

$$SSQ(\mu_2, p_7) = |6.75 - 7|^2 + |8 - 8|^2 = \frac{1}{16} + 0 = \frac{1}{16}$$

$$SSQ(\mu_2, p_8) = |6.75 - 7|^2 + |8 - 9|^2 = \frac{1}{16} + 1 = 1\frac{1}{16}$$

$$TD^2(C_2) = 2\frac{3}{4}$$

Beachte:  $SSQ(\mu, p) = \text{Euclidean}(\mu, p)^2 = L_2^2(\mu, p)$ .



$$SSQ(\mu_1, p_1) = |10 - 10|^2 + |1 - 1|^2 = 0$$

$$TD^2(C_1) = 0$$

$$SSQ(\mu_2, p_2) \approx |4.7 - 2|^2 + |6.3 - 3|^2 \approx 18.2$$

$$SSQ(\mu_2, p_3) \approx |4.7 - 3|^2 + |6.3 - 4|^2 \approx 8.2$$

$$SSQ(\mu_2, p_4) \approx |4.7 - 1|^2 + |6.3 - 5|^2 \approx 15.4$$

$$SSQ(\mu_2, p_5) \approx |4.7 - 7|^2 + |6.3 - 7|^2 \approx 5.7$$

$$SSQ(\mu_2, p_6) \approx |4.7 - 6|^2 + |6.3 - 8|^2 \approx 4.6$$

$$SSQ(\mu_2, p_7) \approx |4.7 - 7|^2 + |6.3 - 8|^2 \approx 8.2$$


$$SSQ(\mu_2, p_8) \approx |4.7 - 7|^2 + |6.3 - 9|^2 \approx 12.6$$

$$TD^2(C_2) \approx 72.86$$

Erste Lösung:  $TD^2 = 61\frac{1}{2}$

Zweite Lösung:  $TD^2 \approx 72.68$

Beachte:  $SSQ(\mu, p) = \text{Euclidean}(\mu, p)^2 = L_2^2(\mu, p)$ .



$$SSQ(\mu_1, p_2) = |2 - 2|^2 + |4 - 3|^2 = 0 + 1 = 1$$

$$SSQ(\mu_1, p_3) = |2 - 3|^2 + |4 - 4|^2 = 1 + 0 = 1$$

$$SSQ(\mu_1, p_4) = |2 - 1|^2 + |4 - 5|^2 = 1 + 1 = 2$$

$$TD^2(C_1) = 4$$

$$SSQ(\mu_2, p_1) = |7.4 - 10|^2 + |6.6 - 1|^2 = 6\frac{19}{25} + 31\frac{9}{25} = 38\frac{3}{25}$$

$$SSQ(\mu_2, p_5) = |7.4 - 7|^2 + |6.6 - 7|^2 = \frac{4}{25} + \frac{4}{25} = \frac{8}{25}$$

$$SSQ(\mu_2, p_6) = |7.4 - 6|^2 + |6.6 - 8|^2 = 1\frac{24}{25} + 1\frac{24}{25} = 3\frac{23}{25}$$

$$SSQ(\mu_2, p_7) = |7.4 - 7|^2 + |6.6 - 8|^2 = \frac{4}{25} + 1\frac{24}{25} = 2\frac{3}{25}$$

$$SSQ(\mu_2, p_8) = |7.4 - 7|^2 + |6.6 - 9|^2 = \frac{4}{25} + 5\frac{19}{25} = 5\frac{23}{25}$$

$$TD^2(C_2) = 50\frac{2}{5}$$

Erste Lösung:  $TD^2 = 61\frac{1}{2}$

Zweite Lösung:  $TD^2 \approx 72.68$

Optimale Lösung:  $TD^2 = 54\frac{2}{5}$

Beachte:  $SSQ(\mu, p) = \text{Euclidean}(\mu, p)^2 = L_2^2(\mu, p)$ .

## Merke:

- ▶ K-means konvergiert nur gegen ein lokales Minimum
- ▶ K-means ist abhängig von den Startparametern
- ▶ K-means nach MacQueen ist reihenfolgeabhängig
- ▶ K-means ist anfällig gegen Rauschen
  - ▶ Degenerierte 1-Element "Cluster"
  - ▶ Dadurch Reduktion von effektivem  $k$
- ▶ K-means minimiert Varianzen, ist also eigentlich nur für Euklidische Distanz korrekt (oftmals aber auch Konvergenz bei anderen Distanzen)
- ▶ K-means (nach Lloyd) ist dennoch das beliebteste Verfahren, da es sehr einfach und schnell ist und mit geringem Aufwand implementiert werden kann!

Sei:

- ▶  $M_i$  = Modell (= Menge der Medoide) nach Iteration  $i$ .
- ▶  $TD(M_i)$  = Kosten von Modell  $M_i$ .

Sei:

- ▶  $M_i$  = Modell (= Menge der Medoide) nach Iteration  $i$ .
- ▶  $TD(M_i)$  = Kosten von Modell  $M_i$ .

PAM konvergiert, wenn

$$TD(M_i) = TD(M_{i+1})$$

Sei:

- ▶  $M_i$  = Modell (= Menge der Medoide) nach Iteration  $i$ .
- ▶  $TD(M_i)$  = Kosten von Modell  $M_i$ .

PAM konvergiert nicht, wenn

$$\forall i \in \mathbb{N} : TD(M_i) > TD(M_{i+1})$$

Sei:

- ▶  $M_i$  = Modell (= Menge der Medoide) nach Iteration  $i$ .
- ▶  $TD(M_i)$  = Kosten von Modell  $M_i$ .

PAM konvergiert nicht, wenn

$$\forall i \in \mathbb{N} : TD(M_i) > TD(M_{i+1})$$

Es gibt  $\binom{n}{k}$  mögliche Modelle,

Sei:

- ▶  $M_i$  = Modell (= Menge der Medoide) nach Iteration  $i$ .
- ▶  $TD(M_i)$  = Kosten von Modell  $M_i$ .

PAM konvergiert nicht, wenn

$$\forall i \in \mathbb{N} : TD(M_i) > TD(M_{i+1})$$

Es gibt  $\binom{n}{k}$  mögliche Modelle, aber  $\mathbb{N}$  Iterationen.

Sei:

- ▶  $M_i$  = Modell (= Menge der Medoide) nach Iteration  $i$ .
- ▶  $TD(M_i)$  = Kosten von Modell  $M_i$ .

PAM konvergiert nicht, wenn

$$\forall i \in \mathbb{N} : TD(M_i) > TD(M_{i+1})$$

Es gibt  $\binom{n}{k}$  mögliche Modelle, aber  $\mathbb{N}$  Iterationen.

$$\Rightarrow \exists_{t_1 < t_2} M_{t_1} = M_{t_2}$$

Sei:

- ▶  $M_i$  = Modell (= Menge der Medoide) nach Iteration  $i$ .
- ▶  $TD(M_i)$  = Kosten von Modell  $M_i$ .

PAM konvergiert nicht, wenn

$$\forall i \in \mathbb{N} : TD(M_i) > TD(M_{i+1})$$

Es gibt  $\binom{n}{k}$  mögliche Modelle, aber  $\mathbb{N}$  Iterationen.

$$\Rightarrow \exists_{t_1 < t_2} M_{t_1} = M_{t_2}$$

$$\Rightarrow TD(M_{t_1}) = TD(M_{t_2})$$

Sei:

- ▶  $M_i$  = Modell (= Menge der Medoide) nach Iteration  $i$ .
- ▶  $TD(M_i)$  = Kosten von Modell  $M_i$ .


PAM konvergiert nicht, wenn

$$\forall i \in \mathbb{N} : TD(M_i) > TD(M_{i+1})$$

Es gibt  $\binom{n}{k}$  mögliche Modelle, aber  $\mathbb{N}$  Iterationen.

$$\Rightarrow \exists_{t_1 < t_2} M_{t_1} = M_{t_2}$$


$$\Rightarrow TD(M_{t_1}) = TD(M_{t_2}) \quad \text{Widerspruch!}$$



Cluster können sein:

- ▶ Kugelförmig (A)
- ▶ Ellipsoid (C)
- ▶ Rotierter Ellipsoid (B)


Aber: es ist immer die gleiche Formel!



Cluster können sein:

- ▶ Kugelförmig (A)
- ▶ Ellipsoid (C)
- ▶ Rotierter Ellipsoid (B)


Aber: es ist immer die gleiche Formel!



Wahrscheinlichkeitsdichte (PDF) der multivariaten Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

Die wichtigste mehrdimensionale Verteilungsfunktion!



Wahrscheinlichkeitsdichte (PDF) der multivariaten Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

Die wichtigste mehrdimensionale Verteilungsfunktion!

Das sollten wir uns genauer anschauen!

## Multivariate Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

Multivariate Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

1-dimensionale Normalverteilung

$$pdf(x, \mu, \sigma) := \frac{1}{\sqrt{(2\pi)\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{(x-\mu)}{\sigma}\right)^2}$$

Multivariate Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

1-dimensionale Normalverteilung

$$pdf(x, \mu, \sigma) := \frac{1}{\sqrt{(2\pi)\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{(x-\mu)}{\sigma}\right)^2}$$

Multivariate Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

1-dimensionale Normalverteilung

$$pdf(x, \mu, \sigma) := \frac{1}{\sqrt{(2\pi)\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{(x-\mu)}{\sigma}\right)^2}$$

**Normalisierung** (auf Gesamtvolumen 1!) und **quadrierte Abweichung vom Mittelwert**

Multivariate Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

1-dimensionale Normalverteilung

$$pdf(x, \mu, \sigma) := \frac{1}{\sqrt{(2\pi)\sigma^2}} \cdot e^{-\frac{1}{2}((x-\mu)\sigma^{-2}(x-\mu))}$$

**Normalisierung** (auf Gesamtvolumen 1!) und **quadrierte Abweichung vom Mittelwert**

Multivariate Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

1-dimensionale Normalverteilung

$$pdf(x, \mu, \sigma) := \frac{1}{\sqrt{(2\pi)\sigma^2}} \cdot e^{-\frac{1}{2}((x-\mu)\sigma^{-2}(x-\mu))}$$

Mahalanobis-Distanz:

$$d_{Mahalanobis}(x, \mu, \Sigma) := \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)}$$

Multivariate Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

1-dimensionale Normalverteilung

$$pdf(x, \mu, \sigma) := \frac{1}{\sqrt{(2\pi)\sigma^2}} \cdot e^{-\frac{1}{2}((x-\mu)\sigma^{-2}(x-\mu))}$$

Mahalanobis-Distanz:

$$d_{Mahalanobis}(x, \mu, \Sigma)^2 := (x - \mu)^T \Sigma^{-1} (x - \mu)$$

Multivariate Normalverteilung:

$$pdf(p, \mu, \Sigma) := \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \cdot e^{-\frac{1}{2}((p-\mu)^T \Sigma^{-1} (p-\mu))}$$

1-dimensionale Normalverteilung

$$pdf(x, \mu, \sigma) := \frac{1}{\sqrt{(2\pi)\sigma^2}} \cdot e^{-\frac{1}{2}((x-\mu)\sigma^{-2}(x-\mu))}$$

Mahalanobis-Distanz:

$$d_{Mahalanobis}(x, \mu, \Sigma)^2 := (x - \mu)^T \Sigma^{-1} (x - \mu)$$

Was ist die Rolle von  $\Sigma^{-1}$ ?

Kovarianzmatrizen sind symmetrisch und auf der Diagonalen nicht negativ, und können daher normalerweise invertiert werden (es gibt degenerierte Fälle, auch die kann man handhaben!)

Kovarianzmatrizen sind symmetrisch und auf der Diagonalen nicht negativ, und können daher normalerweise invertiert werden (es gibt degenerierte Fälle, auch die kann man handhaben!)

Die Matrix kann zerlegt werden:

$$V\Lambda V^{-1} = \Sigma \quad \equiv \quad V\Lambda^{-1}V^{-1} = \Sigma^{-1}$$

wobei  $V$  die Eigenvektoren und  $\Lambda$  die Eigenwerte enthält.

Kovarianzmatrizen sind symmetrisch und auf der Diagonalen nicht negativ, und können daher normalerweise invertiert werden (es gibt degenerierte Fälle, auch die kann man handhaben!)

Die Matrix kann zerlegt werden:

$$V\Lambda V^{-1} = \Sigma \quad \equiv \quad V\Lambda^{-1}V^{-1} = \Sigma^{-1}$$

wobei  $V$  die Eigenvektoren und  $\Lambda$  die Eigenwerte enthält.  
 $V \cong$  Drehung,  $\Lambda \cong$  Skalierung<sup>2</sup>!  
(Das ist die Kernidee der Hauptachsentransformation=PCA)

Konstruiere  $\Omega$  als  $\omega_i = 1/\sqrt{\lambda_i} = \lambda_i^{-\frac{1}{2}}$ . Dann gilt  $\Omega\Omega = \Lambda^{-1}$ .

Konstruiere  $\Omega$  als  $\omega_i = 1/\sqrt{\lambda_i} = \lambda_i^{-\frac{1}{2}}$ . Dann gilt  $\Omega\Omega = \Lambda^{-1}$ .

$$\Sigma^{-1} = V\Lambda^{-1}V^{-1} = V\Omega\Omega^T V^T = V\Omega(V\Omega)^T$$

Konstruiere  $\Omega$  als  $\omega_i = 1/\sqrt{\lambda_i} = \lambda_i^{-\frac{1}{2}}$ . Dann gilt  $\Omega\Omega = \Lambda^{-1}$ .

$$\Sigma^{-1} = V\Lambda^{-1}V^{-1} = V\Omega\Omega^T V^T = V\Omega(V\Omega)^T$$

$$d_{\text{Mahalanobis}}^2 = (x - \mu)^T \Sigma^{-1} (x - \mu)$$

Konstruiere  $\Omega$  als  $\omega_i = 1/\sqrt{\lambda_i} = \lambda_i^{-\frac{1}{2}}$ . Dann gilt  $\Omega\Omega = \Lambda^{-1}$ .

$$\Sigma^{-1} = V\Lambda^{-1}V^{-1} = V\Omega\Omega^T V^T = V\Omega(V\Omega)^T$$

$$d_{\text{Mahalanobis}}^2 = (x - \mu)^T V\Omega(V\Omega)^T (x - \mu)$$

Konstruiere  $\Omega$  als  $\omega_i = 1/\sqrt{\lambda_i} = \lambda_i^{-\frac{1}{2}}$ . Dann gilt  $\Omega\Omega = \Lambda^{-1}$ .

$$\Sigma^{-1} = V\Lambda^{-1}V^{-1} = V\Omega\Omega^T V^T = V\Omega(V\Omega)^T$$

$$\begin{aligned} d_{\text{Mahalanobis}}^2 &= (x - \mu)^T V\Omega(V\Omega)^T (x - \mu) \\ &= \langle (V\Omega)^T (x - \mu), (V\Omega)^T (x - \mu) \rangle \end{aligned}$$

Konstruiere  $\Omega$  als  $\omega_i = 1/\sqrt{\lambda_i} = \lambda_i^{-\frac{1}{2}}$ . Dann gilt  $\Omega\Omega = \Lambda^{-1}$ .

$$\Sigma^{-1} = V\Lambda^{-1}V^{-1} = V\Omega\Omega^T V^T = V\Omega(V\Omega)^T$$

$$\begin{aligned}d_{\text{Mahalanobis}}^2 &= (x - \mu)^T V\Omega(V\Omega)^T (x - \mu) \\ &= \langle (V\Omega)^T (x - \mu), (V\Omega)^T (x - \mu) \rangle \\ &= L_2((V\Omega)^T (x - \mu))^2\end{aligned}$$

Konstruiere  $\Omega$  als  $\omega_i = 1/\sqrt{\lambda_i} = \lambda_i^{-\frac{1}{2}}$ . Dann gilt  $\Omega\Omega = \Lambda^{-1}$ .

$$\Sigma^{-1} = V\Lambda^{-1}V^{-1} = V\Omega\Omega^T V^T = V\Omega(V\Omega)^T$$

$$\begin{aligned}d_{\text{Mahalanobis}}^2 &= (x - \mu)^T V\Omega(V\Omega)^T (x - \mu) \\ &= \langle (V\Omega)^T (x - \mu), (V\Omega)^T (x - \mu) \rangle \\ &= L_2((V\Omega)^T (x - \mu))^2\end{aligned}$$

$L_2$  ist die  $L_2$ -Norm (Euclidische Distanz  $d(x, y) = L_2(x - y)$ !)

Konstruiere  $\Omega$  als  $\omega_i = 1/\sqrt{\lambda_i} = \lambda_i^{-\frac{1}{2}}$ . Dann gilt  $\Omega\Omega = \Lambda^{-1}$ .


$$\Sigma^{-1} = V\Lambda^{-1}V^{-1} = V\Omega\Omega^T V^T = V\Omega(V\Omega)^T$$

$$\begin{aligned}d_{\text{Mahalanobis}}^2 &= (x - \mu)^T V\Omega(V\Omega)^T (x - \mu) \\ &= \langle (V\Omega)^T (x - \mu), (V\Omega)^T (x - \mu) \rangle \\ &= L_2((V\Omega)^T (x - \mu))^2\end{aligned}$$


$L_2$  ist die  $L_2$ -Norm (Euclidische Distanz  $d(x, y) = L_2(x - y)$ !)

Mahalanobis  $\approx$  Euclidische Distanz nach PCA!


## Old Faithful Geysir Daten (Iteration 0):




## Old Faithful Geysir Daten (Iteration 1):




## Old Faithful Geysir Daten (Iteration 2):




## Old Faithful Geysir Daten (Iteration 3):




## Old Faithful Geysir Daten (Iteration 4):




## Old Faithful Geysir Daten (Iteration 5):




## Old Faithful Geysir Daten (Iteration 6):




## Old Faithful Geysir Daten (Iteration 7):




## Old Faithful Geysir Daten (Iteration 8):




## Old Faithful Geysir Daten (Iteration 9):




## Old Faithful Geysir Daten (Iteration 10):




## Old Faithful Geysir Daten (Iteration 11):




## Old Faithful Geysir Daten (Iteration 12):



## Old Faithful Geysir Daten (Iteration 13):



## Old Faithful Geysir Daten (Iteration 14):



## Aufgabe 4-1

Lloyd/Forgey

MacQueen

MacQueen Alternativ

Qualität

Fazit


## Aufgabe 4-2

## Aufgabe 4-3

## Aufgabe 4-4

Beispiel

Berechnung



## Aufgabe 4-1

Lloyd/Forgey  
MacQueen  
MacQueen Alternativ  
Qualität  
Fazit


## Aufgabe 4-2


## Aufgabe 4-3

## Aufgabe 4-4


Beispiel

Berechnung






$$\Sigma_A = \begin{pmatrix} 3 & 0 \\ 0 & 3 \end{pmatrix} \quad \Sigma_A^{-1} = \begin{pmatrix} \frac{1}{3} & 0 \\ 0 & \frac{1}{3} \end{pmatrix}$$



$$\Sigma_A = \begin{pmatrix} 3 & 0 \\ 0 & 3 \end{pmatrix} \quad \Sigma_A^{-1} = \begin{pmatrix} \frac{1}{3} & 0 \\ 0 & \frac{1}{3} \end{pmatrix}$$


$$p - \mu_A = (0.5, 1)$$



$$\Sigma_A = \begin{pmatrix} 3 & 0 \\ 0 & 3 \end{pmatrix} \quad \Sigma_A^{-1} = \begin{pmatrix} \frac{1}{3} & 0 \\ 0 & \frac{1}{3} \end{pmatrix}$$

$$p - \mu_A = (0.5, 1)$$

$$\text{dist}^2 = (p - \mu)^T \Sigma^{-1} (p - \mu) \approx 0.41666$$




$$\Sigma_A = \begin{pmatrix} 3 & 0 \\ 0 & 3 \end{pmatrix} \quad \Sigma_A^{-1} = \begin{pmatrix} \frac{1}{3} & 0 \\ 0 & \frac{1}{3} \end{pmatrix}$$


$$p - \mu_A = (0.5, 1)$$

$$\text{dist}^2 = (p - \mu)^T \Sigma^{-1} (p - \mu) \approx 0.41666$$

$$\begin{aligned} \text{prob}_A &\approx \frac{1}{\sqrt{(2\pi)^2 \cdot 9}} e^{-\frac{1}{2} \cdot 0.41666} \\ &\approx 0.04307456 \end{aligned}$$




$$\Sigma_B^{-1} \approx \begin{pmatrix} 0.571428 & -0.142857 \\ -0.142857 & 0.285714 \end{pmatrix}$$



$$\Sigma_B^{-1} \approx \begin{pmatrix} 0.571428 & -0.142857 \\ -0.142857 & 0.285714 \end{pmatrix}$$


$$p - \mu_B = (-2.5, 0)$$



$$\Sigma_B^{-1} \approx \begin{pmatrix} 0.571428 & -0.142857 \\ -0.142857 & 0.285714 \end{pmatrix}$$

$$p - \mu_B = (-2.5, 0)$$

$$\text{dist}^2 = (p - \mu)^T \Sigma^{-1} (p - \mu) \approx 3.5714285$$




$$\Sigma_B^{-1} \approx \begin{pmatrix} 0.571428 & -0.142857 \\ -0.142857 & 0.285714 \end{pmatrix}$$


$$p - \mu_B = (-2.5, 0)$$

$$\text{dist}^2 = (p - \mu)^T \Sigma^{-1} (p - \mu) \approx 3.5714285$$

$$\begin{aligned} \text{prob}_B &\approx \frac{1}{\sqrt{(2\pi)^2 \cdot 7}} e^{-\frac{1}{2} 3.5714285} \\ &\approx 0.01008661 \end{aligned}$$




$$\Sigma_C = \begin{pmatrix} 16 & 0 \\ 0 & 4 \end{pmatrix} \quad \Sigma_C^{-1} = \begin{pmatrix} \frac{1}{16} & 0 \\ 0 & \frac{1}{4} \end{pmatrix}$$



$$\Sigma_C = \begin{pmatrix} 16 & 0 \\ 0 & 4 \end{pmatrix} \quad \Sigma_C^{-1} = \begin{pmatrix} \frac{1}{16} & 0 \\ 0 & \frac{1}{4} \end{pmatrix}$$


$$p - \mu_C = (1.5, -1)$$



$$\Sigma_C = \begin{pmatrix} 16 & 0 \\ 0 & 4 \end{pmatrix} \quad \Sigma_C^{-1} = \begin{pmatrix} \frac{1}{16} & 0 \\ 0 & \frac{1}{4} \end{pmatrix}$$

$$p - \mu_C = (1.5, -1)$$

$$\text{dist}^2 = (p - \mu)^T \Sigma^{-1} (p - \mu) \approx 0.390625$$




$$\Sigma_C = \begin{pmatrix} 16 & 0 \\ 0 & 4 \end{pmatrix} \quad \Sigma_C^{-1} = \begin{pmatrix} \frac{1}{16} & 0 \\ 0 & \frac{1}{4} \end{pmatrix}$$


$$p - \mu_C = (1.5, -1)$$

$$\text{dist}^2 = (p - \mu)^T \Sigma^{-1} (p - \mu) \approx 0.390625$$


$$\begin{aligned} \text{prob}_C &\approx \frac{1}{\sqrt{(2\pi)^2 \cdot 64}} e^{-\frac{1}{2} \cdot 0.390625} \\ &\approx 0.01636466 \end{aligned}$$




	<i>A</i>	<i>B</i>	<i>C</i>
<i>prob</i>	0.043075	0.010087	0.016365
<i>size</i>	30%	20%	50%




	<i>A</i>	<i>B</i>	<i>C</i>
<i>prob</i>	0.043075	0.010087	0.016365
<i>size</i>	30%	20%	50%
<i>score</i>	0.012922	0.002017	0.008182



	<i>A</i>	<i>B</i>	<i>C</i>
<i>prob</i>	0.043075	0.010087	0.016365
<i>size</i>	30%	20%	50%
<i>score</i>	0.012922	0.002017	0.008182
<i>sum</i>	dividiert durch 0.023122		



	<i>A</i>	<i>B</i>	<i>C</i>
<i>prob</i>	0.043075	0.010087	0.016365
<i>size</i>	30%	20%	50%
<i>score</i>	0.012922	0.002017	0.008182
<i>sum</i>	dividiert durch 0.023122		
<i>weight</i>	≈ 55.9%	≈ 8.2%	≈ 35.4%



	<i>A</i>	<i>B</i>	<i>C</i>
<i>prob</i>	0.043075	0.010087	0.016365
<i>size</i>	30%	20%	50%
<i>score</i>	0.012922	0.002017	0.008182
<i>sum</i>	dividiert durch 0.023122		
<i>weight</i>	≈ 55.9%	≈ 8.2%	≈ 35.4%

Punkt *p* gehört primär zu Cluster A!