


Data Mining Tutorial


Clusteranalyse – Teil I

Erich Schubert, Arthur Zimek

Ludwig-Maximilians-Universität München

14. und 15.12.2017 — 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 6-1


Lloyd/Forgy

MacQueen

MacQueen Alternativ


Qualität

Fazit



k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge



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

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

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

k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining
Tutorial

E. Schubert,
A. Zimek

Aufgabe 6-1

Lloyd/Forgy


MacQueen

MacQueen Alternativ

Qualität

Fazit

Ersten Punkt zuordnen



k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining
Tutorial

E. Schubert,
A. Zimek

Aufgabe 6-1

Lloyd/Forgy


MacQueen

MacQueen Alternativ

Qualität

Fazit

Zweiten Punkt zuordnen



k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining
Tutorial

E. Schubert,
A. Zimek

Aufgabe 6-1

Lloyd/Forgy


MacQueen

MacQueen Alternativ

Qualität

Fazit

Dritten Punkt zuordnen



k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining
Tutorial

E. Schubert,
A. Zimek

Aufgabe 6-1

Lloyd/Forgy


MacQueen

MacQueen Alternativ

Qualität

Fazit

Vierten Punkt zuordnen



k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining
Tutorial

E. Schubert,
A. Zimek

Aufgabe 6-1


Lloyd/Forgy

MacQueen

MacQueen Alternativ

Qualität

Fazit



Zentroide aktualisieren:

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

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

k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining
Tutorial

E. Schubert,
A. Zimek

Aufgabe 6-1

Lloyd/Forgy


MacQueen

MacQueen Alternativ

Qualität

Fazit

Fünften Punkt zuordnen



k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining
Tutorial

E. Schubert,
A. Zimek

Aufgabe 6-1


Lloyd/Forgy

MacQueen

MacQueen Alternativ

Qualität

Fazit



Zentroide aktualisieren:

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

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

k-Means Clustering – MacQueen Algorithmus

Alternativer Ablauf – andere Reihenfolge

Data Mining
Tutorial

E. Schubert,
A. Zimek

Aufgabe 6-1


Lloyd/Forgy

MacQueen


MacQueen Alternativ

Qualität


Fazit




Weitere Punkte neu
zuordnen



Weitere Punkte neu
zuordnen
ggf. Weitere Iterationen



Weitere Punkte neu
zuordnen
ggf. Weitere Iterationen
Konvergenz



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

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

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

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

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

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

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


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

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

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

Erste Lösung: $TD^2 = 61 \frac{1}{2}$

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!