

2.3.3 k-Means

Teile jede Klasse Ω_{κ} in L_{κ} (Teil-)Gebiete, die jeweils durch ihren Schwerpunkt oder Mittelpunktvektor $\vec{\mu}_{\kappa}^l$ repräsentiert werden.

Im restlichen Abschnitt lassen wir die Klassenindizes κ zur Vereinfachung weg:

- sei $\Omega = \{\vec{c}_i | i = 1, \dots, N\}$ die (einzige) Klasse
- sie wird in L disjunkte Teilgebiete R^l zerlegt:
$$\Omega = R^1 \dot{\cup} R^2 \dot{\cup} \dots \dot{\cup} R^L$$
- jedes Teilgebiet R^l wird durch seinen Schwerpunkt repräsentiert:

$$\vec{\mu}^l = \frac{1}{|R^l|} \sum_{\vec{c}_i \in R^l} \vec{c}_i$$

- Ziel ist Minimierung des Quantisierungsfehlers

$$\epsilon = \frac{1}{N} \sum_{l=1}^L \sum_{\vec{c}_i \in R^l} d(\vec{c}_i, \vec{\mu}^l)$$

2.3 Abstandsmessung zur Klassifikation

wähle aufgrund von Vorwissen oder zufällig (z.B. die ersten L Vektoren der Stichprobe mit der Größe N) initiale Mittelpunkte $\vec{\mu}^l, l = 1, \dots, L$

$\epsilon^0 := \infty$; der Quantisierungsfehler in der Iteration 0

$t = 0$; Iterationszähler

$t := t + 1, \quad \epsilon^{(t)} := 0$

FOR alle Gebiete $l = 1, \dots, L$

$N^l := 0; \quad \hat{\vec{\mu}}^l := \vec{0}$

FOR alle Vektoren \vec{c}_i der Stichprobe

bestimme $\vec{\mu}^l$ mit minimalem Abstand zu \vec{c}_i

$\epsilon^{(t)} := \epsilon^{(t)} + d(\vec{c}_i, \vec{\mu}^l)$

berechne neuen Schätzwert für den Mittelpunkt $\hat{\vec{\mu}}^l := \vec{\mu}^l + \vec{c}_i$

$N^l := N^l + 1$

$\epsilon^{(t)} := \epsilon^{(t)} / N$

FOR alle Gebiete $l = 1, \dots, L$

$\vec{\mu}^l := \hat{\vec{\mu}}^l / N^l$

UNTIL $(\epsilon^{(t-1)} - \epsilon^{(t)}) / \epsilon^{(t)} \leq \epsilon$

2.3 Abstandsmessung zur Klassifikation

- k-means konvergiert “fast immer”
- es gibt keine Garantie in eine (lokales) Minimum des Quantisierungsfehlers zu kommen
starte den -means mit unterschiedlichen Initialisierungen und nimm bestes Ergebnis
wir werden später noch eine Variante kennenlernen, die garantiert zu einem lokalen Minimum konvergiert
- es wird (praktisch immer) der eulidische Abstand verwendet
- neben der Vektorquantisierung wird das k-means eine Verfahren oft zum Clustern benutzt:
eine gegebene Menge von Datenpunkten soll in (eine vorgegebene Anzahl von) Cluster/Häufungsgebiete aufgeteilt werden