

## 6. Übungsblatt

### Aufgabe 29 $k$ -Means-Clustering

Gegeben sei der folgende zweidimensionale Datensatz:

$x$	1	6	8	3	2	2	6	6	7	7	8	8
$y$	5	2	1	5	4	6	1	8	3	6	3	7

Bearbeiten Sie diesen Datensatz mit  $k$ -Means-Clustering mit  $k = 3$  (d.h., bilden Sie 3 Cluster)! Verwenden Sie die ersten drei Datentupel als Anfangszentren der Cluster und verfolgen Sie die Wanderung der Zentren.

### Aufgabe 30 $k$ -Means-Clustering

Betrachten Sie den folgenden einfachen Datensatz:

$x$	3	3	4	4	5	6	7	7	8	9	1	2	2	3	4	5	5	6	7	7
$y$	1	2	2	3	3	4	4	6	5	7	3	4	5	6	6	7	8	8	8	9

- a) Welches Problem zeigt sich bei der Bearbeitung dieses Datensatzes mit dem  $k$ -Means-Algorithmus mit  $k = 2$  (d.h., 2 Cluster)?  
Hinweis: Wie sieht das gewünschte Ergebnis aus? Was liefert stattdessen der  $k$ -Means-Algorithmus? (Sie brauchen das exakte Ergebnis des Algorithmus nicht auszurechnen, eine qualitative Beschreibung reicht.)
- b) Wie kann man dieses Problem ggf. beheben?  
Hinweis: Erinnern Sie sich daran, wie sich ein voller von einem naiven Bayes-Klassifikator unterscheidet.

### Aufgabe 31 Lagrange-Theorie

Wenn man Konservendosen (idealisiert: Zylinder) mit einem bestimmten Volumen  $V$  (z.B. 1 Liter) unter Verwendung von möglichst wenig Blech herstellen möchte, welche Abmessungen (Durchmesser  $d$  und Höhe  $h$ ) muß dann eine Konservendose haben? Lösen Sie das Problem mit Hilfe der Methode der Lagrange-Multiplikatoren!

### Aufgabe 32 Fuzzy Clustering

Betrachten Sie die Zielfunktion des Fuzzy Clustering für einen Fuzzifier  $w = 1$ , also

$$J(\mathbf{X}, \mathbf{B}, \mathbf{U}) = \sum_{i=1}^c \sum_{j=1}^n u_{ij} d^2(\beta_i, \vec{x}_j),$$

die unter der Nebenbedingung

$$\forall j \in \{1, \dots, n\} : \sum_{i=1}^c u_{ij} = 1$$

zu minimieren ist. Zeigen Sie, daß sich auch dann, wenn man Zugehörigkeitsgrade  $u_{ij}$  aus dem Intervall  $[0, 1]$  zuläßt, eine scharfe Partitionierung der Datenpunkte ergibt, also für das Minimum der Funktion  $J$  gilt:  $\forall i \in \{1, \dots, c\} : \forall j \in \{1, \dots, n\} : u_{ij} \in \{0, 1\}$ . (Hinweis: Vielleicht finden Sie es einfacher, zunächst den Fall  $c = 2$  (zwei Cluster) zu betrachten und die Summanden für einen Datenpunkt  $\vec{x}_j$  zu untersuchen. Verallgemeinern Sie dann das Ergebnis.)

### Aufgabe 33 Fuzzy Clustering

Betrachten Sie den eindimensionalen Datensatz

1, 3, 4, 5, 8, 10, 11, 12.

Dieser Datensatz soll mit Fuzzy- $c$ -Means-Clustering mit  $c = 2$  (zwei Cluster) und einem Fuzzifizier von  $w = 2$  bearbeitet werden. Die Clusterzentren seien zu 1 und 5 initialisiert. Führen Sie einen Schritt der alternierenden Optimierung des Fuzzy Clustering aus, d.h.:

- Berechnen Sie die Zugehörigkeitsgrade der Datenpunkte für die initialen Clusterzentren!
- Berechnen Sie aus den so bestimmten Zugehörigkeitsgraden neue Clusterzentren!

### Aufgabe 34 Expectation Maximization

Betrachten Sie erneut den eindimensionalen Datensatz aus Aufgabe 33, der in dieser Aufgabe mit dem Expectation-Maximization-Algorithmus zur Schätzung der Parameter einer Mischung von 2 Normalverteilungen bearbeitet werden soll. Die A-priori-Wahrscheinlichkeiten der beiden Cluster seien auf  $\theta_i = \frac{1}{2}$ , die Varianz der beiden Cluster auf  $\sigma_i^2 = 1$ ,  $i = 1, 2$ , fixiert. (Es sollen also nur die Erwartungswerte der Normalverteilungen (Clusterzentren) angepaßt werden.) Benutzen Sie als Startpunkte für die Cluster die gleichen Werte wie in Aufgabe 40, also 1 und 5. Berechnen Sie einen Expectation- und einen Maximization-Schritt, d.h.:

- Berechnen Sie die A-posteriori-Wahrscheinlichkeiten der Datenpunkte für die initialen Clusterzentren!
- Schätzen Sie aus den so bestimmten Fallgewichten neue Clusterzentren!

### Aufgabe 35 Agglomeratives Clustering

Gegeben sei der folgende eindimensionale Datensatz:

2, 5, 11, 12, 17, 21, 32.

Bearbeiten Sie diesen Datensatz mit agglomerativem Clustering unter Verwendung

- der Zentroidmethode,
- der Single-Linkage-Methode,
- der Complete-Linkage-Methode!

Zeichnen Sie jeweils ein Dendrogramm!