# Big Data Anwendungen

Aufgabenblatt 4

# Agenda

- Aufgabenblatt 1 – Deskriptive Methoden zur Datenexploration
- Aufgabenblatt 2 – Klassifikation
- Aufgabenblatt 3 – Recommender Systems

- Aufgabenblatt 4 – Clusteringverfahren
  - Aufgabe 1 – Hierarchisches Clustering
  - Aufgabe 2 – kMeans Clustering
  - Aufgabe 3 – Verständnisfragen

- Aufgabenblatt 5 – Stream Mining
- Aufgabenblatt 6 – Social Network Analysis

# Aufgabe 1 (a) - Aufgabenstellung

- Gegeben seien folgende Daten:

| Tag | Anzahl Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Nennen Sie alle Attribute für die mit Hilfe des Jaccard-Index keine Abstände ermittelt werden können und begründen Sie kurz. **(2 Punkte)**

# Wiederholung Vorlesung: Jaccard Abstand

- Idee
  Zählen der Übereinstimmungen
- Grundlage
  Jaccard Abstand: $\mathrm{d_J} = \frac{|A \cup B| - |A \cap B|}{|A \cup B|}$
- Anwendung hier
  $d(p,q) = d(q,p) = \frac{n - \sum_{i=1}^{n}(p_i = q_i)}{n}$
  mit $p = (p_1, \ldots, p_n), q = (q_1, \ldots, q_n)$
- Beispiel
  $d(p,q) = d(q,p) = \frac{2-1}{2} = \frac{1}{2}$

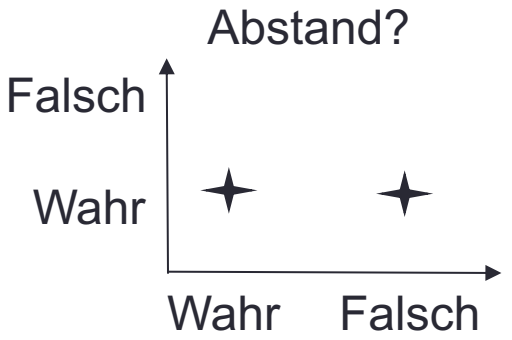

# Aufgabe 1 (a) – Lösung (Jaccard Abstand)

- Sinnvolle Skalentype Jaccard Abstand
  - Kategorische Attribute
  - Überschaubar viele Ausprägungen

| Tag | Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Prinzipiell gilt
  - Jaccard-Index auf alle Skalentypen anwenden
  - Idee Prüfung auf Gleichheit für alle Attribute

- Hier
  - Sinnolle Anwendung des Jaccard Abstand nur auf das Attribut “Regen”
  - Transformation für “Tag“, „Anzahl Sonnenstunden“ und „Temperatur“…
    ... ist nicht sinnvoll

# Aufgabe 1 (b) - Aufgabenstellung

- Gegeben seien folgende Daten:

| Tag | Anzahl Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Nennen Sie zwei Verfahren zur Transformation von Daten auf ähnliche Wertebereiche. **(2 Punkte)**

# Wiederholung Vorlesung: Transformationen

- Min-Max-Skalierung (Normierung auf $[0 \ldots 1]$)
  - Formal: $x_i^t = \frac{x_i - \min_{j=1\ldots n} x_j}{\max_{j=1\ldots n} x_j - \min_{j=1\ldots n} x_j}$
  - Nachteil: Ausreißer beeinflussen Transformation stark

- Standardisierung (Normierung mit Standardabweichung und Mittelwert)
  - Formal: $x_i^t = \frac{x_i - \bar{x}}{\sqrt{\frac{1}{n-1}\sum_{j=1}^{n}(x_j - \bar{x})^2}}$ mit $\bar{x} = \frac{1}{n}\sum_{j=1}^{n} x_j$
  - Nachteil: Wertebereich nicht klar

- Rangtransformation (Normierung auf $[1..n]$)
  - Abbilden des Wertes durch seine Position in aufsteigender Sortierung
  - Bei wiederholten auftreten identischer Werte
    - Vergabe mittleren Rangs oder
    - Vergabe des niedrigsten Rangs
  - Nachteil: Abstände zwischen Werten gehen verloren

# Aufgabe 1 (b) – Lösung (Transformationen)

| Tag | Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Hier
  - Min-Max-Skalierung, Standardisierung und Rangtransformation sinnvoll
  - Tag, Sonnenstunden und Temperatur lassen sich entsprechend abbilden
- Einzelne Attribute besitzen „Ausreißer“
  - Anzahl Sonnenstunden: 1x 10 sonst 2 bis 4
  - Temperatur: 1x 5 sonst -1 bis 2
- Damit bevorzugt anzuwenden
  - Standardisierung bzw. Rangtransformation
  - Präferenz für Standardisierung:
    - Ausreißer wirken plausibel (keine Datenfehler)
    - Abstände liefern zusätzliche Information

# Aufgabe 1 (c) - Aufgabenstellung

- Gegeben seien folgende Daten:

| Tag | Anzahl Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Transformieren Sie die Attribute „Tag“, „Anzahl Sonnenstunden“ und „Temperatur“ so, dass Sie mit Hilfe der Euklidischen Distanz sinnvoll geclustert werden können. **(3 Punkte)**

# Wiederholung Vorlesung: Abstandsmaße

- Euklidischer Abstand
  - Länge direkter Verbindung zwischen Objekten
  - Formal $d(p,q) = d(q,p) = \sqrt{\sum_{i=1}^{n}(q_i - p_i)^2}$ mit $p = (p_1, \dots, p_n), q = (q_1, \dots, q_n)$
  - Beispiel
    $d(p,q) = d(q,p) = \sqrt{(2-1)^2 + (3-6)^2} = \sqrt{10}$

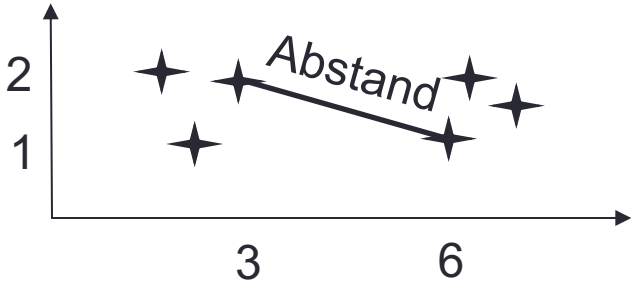


- Manhattan Abstand
  - Länge der Verbindung bei Lauf parallel zu Achsen
  - Formal $d(p,q) = d(q,p) = \sum_{i=1}^{n} |q_i - p_i|$ mit $p = (p_1, \dots, p_n), q = (q_1, \dots, q_n)$
  - Beispiel
    $d(p,q) = d(q,p) = |2-1| + |3-6| = 4$

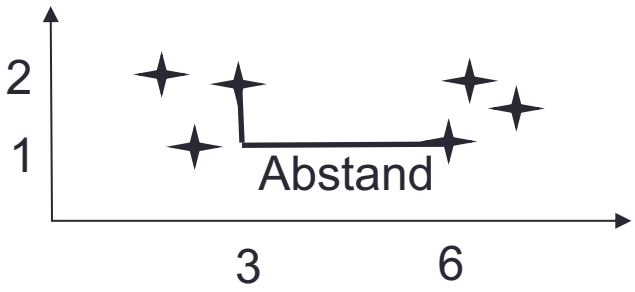


- Vorteil Manhattan Abstand:
  Höhere Robustheit gegenüber Ausreißern

# Aufgabe 1 (c) – Lösung (Standardisierung)

| Tag | Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Vorgehen
  - Standardisierung

    $x_i^t = \frac{x_i - \bar{x}}{s}$

    mit $\bar{x} = \frac{1}{n}\sum_{j=1}^{n} x_j$ und $s = \sqrt{\frac{1}{n-1}\sum_{j=1}^{n}(x_j - \bar{x})^2}$
  - Zunächst Ermittlung Mittelwerte ($\bar{x}$) und Standardabweichungen ($s$)

- Tag
  - $\bar{x} = \frac{1}{n}\sum_{j=1}^{n} x_j = \frac{18+17+25+30}{4} = \frac{90}{4} = 22{,}50$
  - $s = \sqrt{\frac{1}{4-1}\left((18-22{,}5)^2 + (17-22{,}5)^2 + (25-22{,}5)^2 + (30-22{,}5)^2\right)}$

    $= \sqrt{\frac{1}{3}\left((-4{,}5)^2 + (-5{,}5)^2 + (2{,}5)^2 + (7{,}5)^2\right)}$

    $= \sqrt{\frac{1}{3}(20{,}25 + 30{,}25 + 6{,}25 + 56{,}25)} \approx \sqrt{37{,}67} \approx 6{,}14$

# Aufgabe 1 (c) – Lösung (Standardisierung)

| Tag | Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Vorgehen
  - Standardisierung

    $x_i^t = \frac{x_i - \bar{x}}{s}$

    mit $\bar{x} = \frac{1}{n}\sum_{j=1}^{n} x_j$ und $s = \sqrt{\frac{1}{n-1}\sum_{j=1}^{n}(x_j - \bar{x})^2}$
  - Zunächst Ermittlung Mittelwerte ($\bar{x}$) und Standardabweichungen ($s$)

- Sonnenstunden
  - $\bar{x} = \frac{1}{n}\sum_{j=1}^{n} x_j = \frac{10+2+4+3}{4} = \frac{19}{4} = 4{,}75$
  - $s = \sqrt{\frac{1}{4-1}\left((10-4{,}75)^2 + (2-4{,}75)^2 + (4-4{,}75)^2 + (3-4{,}75)^2\right)}$

    $= \sqrt{\frac{1}{3}\left((5{,}25)^2 + (-2{,}25)^2 + (-0{,}75)^2 + (-1{,}75)^2\right)}$

    $\approx \sqrt{\frac{1}{3}(27{,}56 + 7{,}56 + 0{,}56 + 3{,}06)} \approx \sqrt{12{,}92} \approx 3{,}59$

# Aufgabe 1 (c) – Lösung (Standardisierung)

| Tag | Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Vorgehen
  - Standardisierung

    $x_i^t = \frac{x_i - \bar{x}}{s}$

    mit $\bar{x} = \frac{1}{n}\sum_{j=1}^{n} x_j$ und $s = \sqrt{\frac{1}{n-1}\sum_{j=1}^{n}(x_j - \bar{x})^2}$
  - Zunächst Ermittlung Mittelwerte ($\bar{x}$) und Standardabweichungen ($s$)

- Temperatur
  - $\bar{x} = \frac{1}{n}\sum_{j=1}^{n} x_j = \frac{-1+5+1+2}{4} = \frac{7}{4} = 1{,}75$
  - $s = \sqrt{\frac{1}{4-1}\left((-1-1{,}75)^2 + (5-1{,}75)^2 + (1-1{,}75)^2 + (2-1{,}75)^2\right)}$

    $= \sqrt{\frac{1}{3}\left((-2{,}75)^2 + (3{,}25)^2 + (-0{,}75)^2 + (0{,}25)^2\right)}$

    $\approx \sqrt{\frac{1}{3}(7{,}56 + 10{,}56 + 0{,}56 + 0{,}06)} \approx \sqrt{6{,}25} \approx 2{,}5$

# Aufgabe 1 (c) – Lösung (Standardisierung)

- Bisher
  - $\bar{x}$ und $s$ für Attribute

| Kennzahl | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| $\bar{x}$ | 22,50 | 4,75 | 1,75 |
| $s$ | 6,14 | 3,59 | 2,50 |

  - Jetzt Standardisierung: $x_i^t = \frac{x_i - \bar{x}}{s}$

| Tag | Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Ergebnis

| Tag | Sonnenstunden | Temperatur |
|---|---|---|
| $\frac{18-22{,}50}{6{,}14} = -0{,}73$ | $\frac{10-4{,}75}{3{,}59} = 1{,}46$ | $\frac{-1-1{,}75}{2{,}50} = -1{,}10$ |
| $\frac{17-22{,}50}{6{,}14} = -0{,}90$ | $\frac{2-4{,}75}{3{,}59} = -0{,}77$ | $\frac{5-1{,}75}{2{,}50} = 1{,}30$ |
| $\frac{25-22{,}50}{6{,}14} = 0{,}41$ | $\frac{4-4{,}75}{3{,}59} = -0{,}21$ | $\frac{1-1{,}75}{2{,}50} = -0{,}30$ |
| $\frac{30-22{,}50}{6{,}14} = 1{,}22$ | $\frac{3-4{,}75}{3{,}59} = -0{,}49$ | $\frac{2-1{,}75}{2{,}50} = 0{,}10$ |

# Aufgabe 1 (d) - Aufgabenstellung

- Gegeben seien folgende Daten:

| Tag | Anzahl Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Nutzen Sie hierarchisch agglomeratives Clustering zum Clustern der Daten aus (c). **(10 Punkte)**

# Wiederholung Vorlesung: Hierarchisches Clustering

- Gegeben
  Lerndatensatz mit $g$ Beobachtungen mit $n$ numerischen Attributen
  (also, wie bisher: $g = (g_1, \dots, g_n)$)
- Gesucht
  Partitionierung des Datensatz in Cluster (Keine Anzahl gegeben!)
- Initialisierung
  - Jede Beobachtung bildet eines von $k = |g|$ Clustern $z^i = (z_1^i, \dots, z_n^i)$
  - Ermittlung Distanz zwischen allen Clustern $(d(z^i, z^j))$ mit $i, j \in (1, \dots k)$
- Reduktion der Clusterzentren
  - Identifikation der Cluster $z^i, z^j$ mit dem geringsten Abstand...
    ... $((i,j) = \underset{i,j}{\operatorname{argmin}}\, d(z^i, z^j))$
  - Zusammenfassung der Cluster zu neuem Cluster $z^l$

# Wiederholung Vorlesung: Hierarchisches Clustering

- Abbruchkriterium
  Ist Anzahl der Cluster gleich 1 - Abbruch

- Aktualisierung der Daten
  - Ermittlung des Abstands zwischen neuem Cluster ...
    ... und alle bestehenden Clustern ($d(z^l, z^j)$) mit $j \in (1, \dots k)$
  - Fortfahren mit Schritt „Reduktion der Clusterzentren“

- Anmerkungen
  - Anders als bei K-Means werden ein Mal getroffene...
    ... Gruppenzuordnungen nicht mehr geändert
  - Speicherbedarf bei großen Datensätzen groß verglichen mit K-Means
    - Bei K-Means: Distanz aller Knoten zu den $k$ Clusterzentren
    - Hier: Distanz aller Cluster (initial aller Beobachtungen!) zueinander

# Aufgabe 1 (d) – Lösung (Hierarchisches Clustering)

- Vorgehen
  - Initiales Clustering (jede Beobachtung)
  - Rekursiv
    - Ermittlung Abstand der Cluster
    - Kombination der zwei nächsten Cluster

| Tag | Sonnenstunden | Temperatur |
|---|---|---|
| −0,73 | 1,46 | −1,10 |
| −0,90 | −0,77 | 1,30 |
| 0,41 | −0,21 | −0,30 |
| 1,22 | −0,49 | 0,10 |

- Initiales Clustering

| Cluster | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| **A** | −0,73 | 1,46 | −1,10 |
| **B** | −0,90 | −0,77 | 1,30 |
| **C** | 0,41 | −0,21 | −0,30 |
| **D** | 1,22 | −0,49 | 0,10 |

# Aufgabe 1 (d) – Lösung (Hierarchisches Clustering)

- Vorgehen
  - Initiales Clustering (jede Beobachtung)
  - Rekursiv
    - Ermittlung Abstand der Cluster
    - Kombination der zwei nächsten Cluster

| Cluster | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| A | −0,73 | 1,46 | −1,10 |
| B | −0,90 | −0,77 | 1,30 |
| C | 0,41 | −0,21 | −0,30 |
| D | 1,22 | −0,49 | 0,10 |

| Cluster | B | C | D |
|---|---|---|---|
| A | $\sqrt{(-0{,}73+0{,}90)^2+(1{,}46+0{,}77)^2+(-1{,}10-1{,}30)^2}=3{,}28$ | $\sqrt{(-0{,}73-0{,}41)^2+(1{,}46+0{,}21)^2+(-1{,}10+0{,}30)^2}=2{,}17$ | $\sqrt{(-0{,}73-1{,}22)^2+(1{,}46+0{,}49)^2+(-1{,}10-0{,}10)^2}=3{,}01$ |
| B | - | $\sqrt{(-0{,}90-0{,}41)^2+(-0{,}77+0{,}21)^2+(1{,}30+0{,}30)^2}=2{,}14$ | $\sqrt{(-0{,}90-1{,}22)^2+(-0{,}77+0{,}49)^2+(1{,}30-0{,}10)^2}=2{,}45$ |
| C | - | - | $\sqrt{(0{,}41-1{,}22)^2+(-0{,}21+0{,}49)^2+(-0{,}30-0{,}10)^2}=0{,}95$ |

Abstand von C und D am geringsten: Kombination

# Aufgabe 1 (d) – Lösung (Hierarchisches Clustering)

- Vorgehen
  - Initiales Clustering (jede Beobachtung)
  - Rekursiv
    - Ermittlung Abstand der Cluster
    - Kombination der zwei nächsten Cluster

| Cluster | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| A | $-0{,}73$ | $1{,}46$ | $-1{,}10$ |
| B | $-0{,}90$ | $-0{,}77$ | $1{,}30$ |
| C | $0{,}41$ | $-0{,}21$ | $-0{,}30$ |
| D | $1{,}22$ | $-0{,}49$ | $0{,}10$ |

- Kombination von C und D zu CD

| Cluster | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| A | $-0{,}73$ | $1{,}46$ | $-1{,}10$ |
| B | $-0{,}90$ | $-0{,}77$ | $1{,}30$ |
| C | $0{,}41$ | $-0{,}21$ | $-0{,}30$ |
| D | $1{,}22$ | $-0{,}49$ | $0{,}10$ |
| CD | $\frac{0{,}41+1{,}22}{2} = 0{,}81$ | $\frac{-0{,}21-0{,}49}{2} = -0{,}35$ | $\frac{-0{,}30+0{,}10}{2} = -0{,}10$ |

# Aufgabe 1 (d) – Lösung (Hierarchisches Clustering)

- Vorgehen
  - Initiales Clustering (jede Beobachtung)
  - Rekursiv
    - Ermittlung Abstand der Cluster
    - Kombination der zwei nächsten Cluster

| Cluster | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| A | $-0{,}73$ | $1{,}46$ | $-1{,}10$ |
| B | $-0{,}90$ | $-0{,}77$ | $1{,}30$ |
| CD | $0{,}81$ | $-0{,}35$ | $-0{,}10$ |

- Abstände der Cluster

| Cluster | B | CD |
|---|---|---|
| A | $\sqrt{(-0{,}73+0{,}90)^2+(1{,}46+0{,}77)^2+(-1{,}10-1{,}30)^2} = 3{,}28$ | $\sqrt{(-0{,}73-0{,}81)^2+(1{,}46+0{,}35)^2+(-1{,}10+0{,}10)^2} = 2{,}58$ |
| B | - | $\sqrt{(-0{,}90-0{,}81)^2+(-0{,}77+0{,}35)^2+(1{,}30+0{,}10)^2} = 2{,}25$ |

Abstand von B und CD am geringsten: Kombination

# Aufgabe 1 (d) – Lösung (Hierarchisches Clustering)

- Vorgehen
  - Initiales Clustering (jede Beobachtung)
  - Rekursiv
    - Ermittlung Abstand der Cluster
    - Kombination der zwei nächsten Cluster

| Cluster | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| A | $-0{,}73$ | $1{,}46$ | $-1{,}10$ |
| B | $-0{,}90$ | $-0{,}77$ | $1{,}30$ |
| CD | $0{,}81$ | $-0{,}35$ | $-0{,}10$ |

- Kombination von CD und B zu BCD

| Cluster | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| A | $-0{,}73$ | $1{,}46$ | $-1{,}10$ |
| B | $-0{,}90$ | $-0{,}77$ | $1{,}30$ |
| C | $0{,}41$ | $-0{,}21$ | $-0{,}30$ |
| D | $1{,}22$ | $-0{,}49$ | $0{,}10$ |
| CD | $\frac{0{,}41+1{,}22}{2} = 0{,}81$ | $\frac{-0{,}21-0{,}49}{2} = -0{,}35$ | $\frac{-0{,}30+0{,}10}{2} = -0{,}10$ |
| BCD | $\frac{-0{,}90+0{,}41+1{,}22}{3} = 0{,}24$ | $\frac{-0{,}77-0{,}21-0{,}49}{3} = -0{,}49$ | $\frac{1{,}30-0{,}30+0{,}10}{3} = 0{,}37$ |

# Aufgabe 1 (d) – Lösung (Hierarchisches Clustering)

- Vorgehen
  - Initiales Clustering (jede Beobachtung)
  - Rekursiv
    - Ermittlung Abstand der Cluster
    - Kombination der zwei nächsten Cluster

| Cluster | Tag | Sonnenstunden | Temperatur |
|---|---|---|---|
| **A** | $-0{,}73$ | $1{,}46$ | $-1{,}10$ |
| **BCD** | $0{,}24$ | $-0{,}49$ | $0{,}37$ |

- Abstände der Cluster

| Cluster | BCD |
|---|---|
| **A** | $\sqrt{(-0{,}73-0{,}24)^2+(1{,}46+0{,}49)^2+(-1{,}10-0{,}37)^2}=2{,}63$ |

- Schritt für weitere Kombination irrelevant…
  … für Erstellung des Dendrogramms aber nötig

# Aufgabe 1 (e) - Aufgabenstellung

- Gegeben seien folgende Daten:

| Tag | Anzahl Sonnenstunden | Temperatur | Regen |
|---|---|---|---|
| 18 | 10 | -1,0 | Ja |
| 17 | 2 | 5,0 | Nein |
| 25 | 4 | 1,0 | Ja |
| 30 | 3 | 2,0 | Ja |

- Zeichnen Sie ein Dendrogramm für die Daten aus (d). **(3 Punkte)**

# Aufgabe 1 (d) – Lösung (Dendrogramm)

- Bisher
  - Kombination der Cluster
  - Abstände der Cluster bei Kombination

| Cluster | Abstände |
|---|---|
| C und D | 0,95 |
| B und CD | 2,25 |
| A und BCD | 2,63 |

- Jetzt: Ableitung Dendrogramm

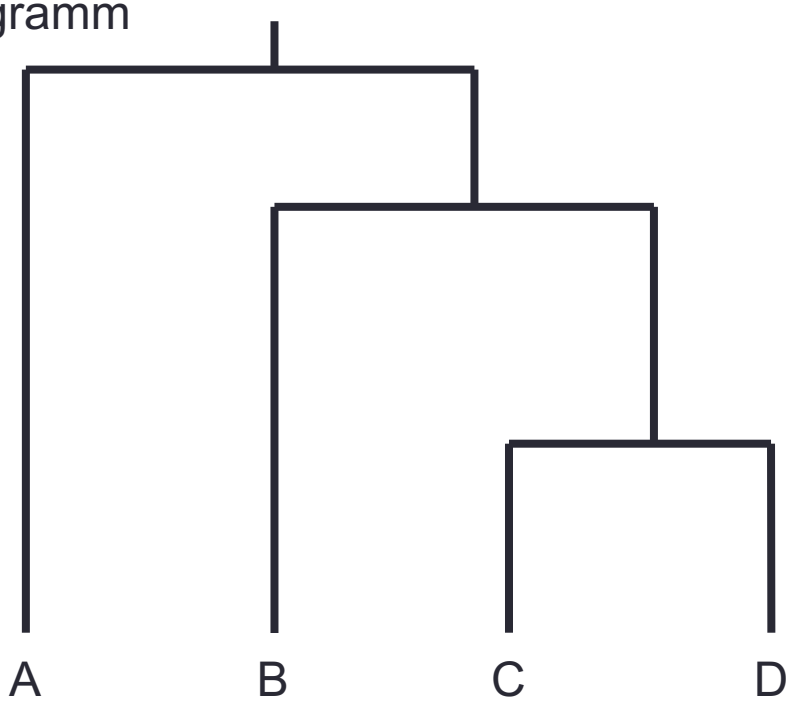

# Agenda

- Aufgabenblatt 1 – Deskriptive Methoden zur Datenexploration
- Aufgabenblatt 2 – Klassifikation
- Aufgabenblatt 3 – Recommender Systems

- Aufgabenblatt 4 – Clusteringverfahren
  - Aufgabe 1 – Hierarchisches Clustering
  - Aufgabe 2 – kMeans Clustering
  - Aufgabe 3 – Verständnisfragen

- Aufgabenblatt 5 – Stream Mining
- Aufgabenblatt 6 – Social Network Analysis

# Aufgabe 2 (a) - Aufgabenstellung

- Gegeben seien folgende Daten:

| Höhe | Breite | Farbe | Preis |
|---|---|---|---|
| 15 | 10 | rot | 50 |
| 20 | 15 | gelb | 50 |
| 17 | 15 | rot | 200 |
| 13 | 12 | gelb | 180 |
| 11 | 16 | rot | 110 |
| 15 | 12 | gelb | 120 |

- Geben Sie an welches Attribut Sie für ein kMeans Clustering ohne Transformation nicht nutzen können. Schlagen Sie eine Strategie vor, wie Sie dieses Attribut umwandeln können um es doch zu nutzen. **(3 Punkte)**

# Wiederholung Vorlesung – kMeans Clustering

- Gegeben
  Lerndatensatz mit $g$ Beobachtungen mit $n$ numerischen Attributen
  (also, wie bisher: $g = (g_1, \dots, g_n)$)
- Gesucht
  Partitionierung des Datensatz in $k$ Cluster
- Initialisierung
  Wähle zufällige $k$ Cluster-Zentren mit $z^k = (z_1^k, \dots, z_n^k)$
- Zuordnung zu Clusterzentren
  - Ermittlung Euklidischer Distanz ($d(g, z^j) = \sqrt{\sum_{i=1}^{n} (g_i - z_i^j)^2}$)...
    ... für jeden Datenpunkt zu allen Cluster-Zentren ($j = (1, \dots k)$)
  - Zuordnung des Datenpunkts $g$ zu dem Clusterzentrum...
    ... mit geringstem Abstand ($j = \underset{j}{\operatorname{argmin}}\, d(g, z^j)$)

# Wiederholung Vorlesung – kMeans Clustering

- Neuberechnung der Clusterzentren
  - Bilden der Beobachtungsmenge für jedes Clusterzentrum...
    ... $G_j = \{g | d(g, z^j) = \min d(g, z^j) \text{ mit } j \in (1, \dots, k)\}$
  - Bestimmung neuer Clusterzentren $z^k = (\sum_{g \in G_j} \frac{g_1}{|G_j|}, \dots, \sum_{g \in G_j} \frac{g_n}{|G_j|})$
  - Neues Clusterzentrum ist “Mittelwert“...
    ... über alle zugeordneten Beobachtungen

- Wiederholung der Schritte
  „Zuordnung zu Clusterzentren“ und „Neuberechnung der Clusterzentren“...
  ... bis Clusternzentren stabil, d.h.
  - Keine Anpassung der Zuordnung der Beobachtungen oder
  - Verschiebung der Clusterzentren nur noch minimal

# Aufgabe 2 (a) – Lösung (kMeans Clustering)

- Kritisch
  - kMeans Clustering nutzt Euklidische Distanz
  - Euklidische Distanz nur auf numerischen Attributen

- Problem
  - Attribut “Farbe” ist kategorisch
  - Anwendung hier nicht möglich

- Lösungsvorschlag
  - Umkodierung der Daten
  - Beispiel: 0 – gelb und 1 – rot

| Höhe | Breite | Farbe | Preis |
|---|---|---|---|
| 15 | 10 | rot | 50 |
| 20 | 15 | gelb | 50 |
| 17 | 15 | rot | 200 |
| 13 | 12 | gelb | 180 |
| 11 | 16 | rot | 110 |
| 15 | 12 | gelb | 120 |

# Aufgabe 2 (b) - Aufgabenstellung

- Gegeben seien folgende Daten:

| Höhe | Breite | Farbe | Preis |
|---|---|---|---|
| 15 | 10 | rot | 50 |
| 20 | 15 | gelb | 50 |
| 17 | 15 | rot | 200 |
| 13 | 12 | gelb | 180 |
| 11 | 16 | rot | 110 |
| 15 | 12 | gelb | 120 |

- Sehen Sie sich die Daten an. Gehen Sie davon aus, dass Sie die Daten in 3 Cluster unterteilen wollen. Geben Sie an, welche Zuordnung der Datenpunkte zu Clustern Sie erwarten, wenn Sie die Euklidische Distanz als Distanzmaß wählen. Erörtern Sie kurz, wie sie zu einem weniger vorhersehbaren Ergebnis gelangen können. **(3 Punkte)**

# Aufgabe 2 (b) – Lösung (kMeans Clustering)

| Höhe | Breite | Farbe | Preis |
|---|---|---|---|
| 15 | 10 | rot | 50 |
| 20 | 15 | gelb | 50 |
| 17 | 15 | rot | 200 |
| 13 | 12 | gelb | 180 |
| 11 | 16 | rot | 110 |
| 15 | 12 | gelb | 120 |

- Hier relevant
  - Euklidische Distanz auf numerischen Attributen
  - Attribute gehen identisch in Euklidische Distanz ein
  - Je größer der Wertebereich eines Attributs…
    … umso größer die Bedeutung des Attributs
- Konsequenz
  - Wertebereich von Preis deutlich größer als andere Wertebereiche
  - Erwartetes Clustering
    - Cluster 1: 1. und 2. Beobachtung
    - Cluster 2: 3. und 4. Beobachtung
    - Cluster 3: 5. und 6. Beobachtung
- Lösungsmöglichkeit
  - Transformation der Datenpunkt auf ähnliche Intervalle
  - Konkret: Standardisierung, Min-Max-Skalierung oder Rangtransformation

# Aufgabe 2 (c) - Aufgabenstellung

- Gegeben seien folgende Daten:

| Höhe | Breite | Farbe | Preis |
|---|---|---|---|
| 15 | 10 | rot | 50 |
| 20 | 15 | gelb | 50 |
| 17 | 15 | rot | 200 |
| 13 | 12 | gelb | 180 |
| 11 | 16 | rot | 110 |
| 15 | 12 | gelb | 120 |

- Wenden Sie den kMeans Algorithmus an um die Daten auf Basis der 3 numerischen Attribute in 3 Cluster zu zerlegen. Nutzen Sie dabei die Euklidische Distanz und lösen Sie das Problem rechnerisch. **(12 Punkte)**

# Aufgabe 2 (c) – Lösung (kMeans Clustering)

| Höhe | Breite | Farbe | Preis |
|---|---|---|---|
| 15 | 10 | rot | 50 |
| 20 | 15 | gelb | 50 |
| 17 | 15 | rot | 200 |
| 13 | 12 | gelb | 180 |
| 11 | 16 | rot | 110 |
| 15 | 12 | gelb | 120 |

- Vorgehen
  - Initiale Clusterzentren
  - Rekursiv
    - Ermittlung Abstand zu den Clustern
    - Zuordnung zu den Clustern
    - Ermittlung neuer Clusterzentren

- Initiale Clusterzentren

| | Höhe | Breite | Preis |
|---|---|---|---|
| Zentrum 1 | 15 | 10 | 50 |
| Zentrum 2 | 17 | 15 | 200 |
| Zentrum 3 | 11 | 16 | 110 |

- Anmerkung
  - Wahl der Clusterzentren auf Basis der Ergebnisse in (a) und (b)
  - Clusterzentren sollten schnell zum Ziel führen

# Aufgabe 2 (c) – Lösung (kMeans Clustering)

- Vorgehen
  - Initiale Clusterzentren
  - Rekursiv
    - Ermittlung Abstand zu den Clustern
    - Zuordnung zu den Clustern
    - Ermittlung neuer Clusterzentren

| | Höhe | Breite | Preis |
|---|---|---|---|
| Beobachtung | 15 | 10 | 50 |
| | 20 | 15 | 50 |
| | 17 | 15 | 200 |
| | 13 | 12 | 180 |
| | 11 | 16 | 110 |
| | 15 | 12 | 120 |
| Z. 1 | 15 | 10 | 50 |
| Z. 2 | 17 | 15 | 200 |
| Z. 3 | 11 | 16 | 110 |

- Ermittlung Abstand zu den Clustern

| ID | Distanz zu Zentrum 1 | Distanz zu Zentrum 2 | Distanz zu Zentrum 3 |
|---|---|---|---|
| 1 | $0$ | $\sqrt{2^2+5^2+150^2}=150{,}10$ | $\sqrt{4^2+6^2+60^2}=62{,}39$ |
| 2 | $\sqrt{5^2+5^2+0^2}=7{,}07$ | $\sqrt{3^2+0^2+150^2}=150{,}03$ | $\sqrt{9^2+1^2+60^2}=60{,}68$ |
| 3 | $\sqrt{2^2+5^2+150^2}=150{,}10$ | $0$ | $\sqrt{6^2+1^2+60^2}=90{,}21$ |
| 4 | $\sqrt{2^2+2^2+130^2}=130{,}03$ | $\sqrt{4^2+3^2+20^2}=20{,}62$ | $\sqrt{2^2+4^2+70^2}=70{,}14$ |
| 5 | $\sqrt{4^2+6^2+60^2}=60{,}43$ | $\sqrt{6^2+1^2+90^2}=90{,}21$ | $0$ |
| 6 | $\sqrt{2^2+0^2+70^2}=70{,}03$ | $\sqrt{2^2+3^2+80^2}=80{,}08$ | $\sqrt{4^2+4^2+10^2}=11{,}49$ |

# Aufgabe 2 (c) – Lösung (kMeans Clustering)

- Vorgehen
  - Initiale Clusterzentren
  - Rekursiv
    - Ermittlung Abstand zu den Clustern
    - Zuordnung zu den Clustern
    - Ermittlung neuer Clusterzentren

| | Höhe | Breite | Preis |
|---|---|---|---|
| Beobachtung | 15 | 10 | 50 |
| | 20 | 15 | 50 |
| | 17 | 15 | 200 |
| | 13 | 12 | 180 |
| | 11 | 16 | 110 |
| | 15 | 12 | 120 |
| Z. 1 | 15 | 10 | 50 |
| Z. 2 | 17 | 15 | 200 |
| Z. 3 | 11 | 16 | 110 |

- Zuordnung zu den Clustern

| ID | Distanz zu Z. 1 | Distanz zu Z. 2 | Distanz zu Z. 3 | Zuordnung zu |
|---|---|---|---|---|
| 1 | 0,00 | 150,10 | 62,39 | Z. 1 |
| 2 | 7,07 | 150,03 | 60,68 | Z. 1 |
| 3 | 150,10 | 0,00 | 90,21 | Z. 2 |
| 4 | 130,03 | 20,62 | 70,14 | Z. 2 |
| 5 | 60,43 | 90,21 | 0,00 | Z. 3 |
| 6 | 70,03 | 80,08 | 11,49 | Z. 3 |

# Aufgabe 2 (c) – Lösung (kMeans Clustering)

- Vorgehen
  - Initiale Clusterzentren
  - Rekursiv
    - Ermittlung Abstand zu den Clustern
    - Zuordnung zu den Clustern
    - Ermittlung neuer Clusterzentren

| | | Höhe | Breite | Preis |
|---|---|---|---|---|
| Beobachtung | | 15 | 10 | 50 |
| | | 20 | 15 | 50 |
| | | 17 | 15 | 200 |
| | | 13 | 12 | 180 |
| | | 11 | 16 | 110 |
| | | 15 | 12 | 120 |
| Z. 1 | 1. und 2. Beobachtung | | | |
| Z. 2 | 3. und 4. Beobachtung | | | |
| Z. 3 | 5. und 6. Beobachtung | | | |

- Ermittlung neuer Clusterzentren

| | Höhe | Breite | Preis |
|---|---|---|---|
| **Zentrum 1** | $(15 + 20)/2 = 17{,}5$ | $(10 + 15)/2 = 12{,}5$ | $(50 + 50)/2 = 50$ |
| **Zentrum 2** | $(17 + 13)/2 = 15{,}0$ | $(15 + 12)/2 = 13{,}5$ | $(200 + 180)/2 = 190$ |
| **Zentrum 3** | $(11 + 15)/2 = 13{,}0$ | $(16 + 12)/2 = 14{,}0$ | $(110 + 120)/2 = 115$ |

# Aufgabe 2 (c) – Lösung (kMeans Clustering)

- Vorgehen
  - Initiale Clusterzentren
  - Rekursiv
    - Ermittlung Abstand zu den Clustern
    - Zuordnung zu den Clustern
    - Ermittlung neuer Clusterzentren

| | Höhe | Breite | Preis |
|---|---|---|---|
| Beobachtung | 15 | 10 | 50 |
| | 20 | 15 | 50 |
| | 17 | 15 | 200 |
| | 13 | 12 | 180 |
| | 11 | 16 | 110 |
| | 15 | 12 | 120 |
| Z. 1 | 17,5 | 12,5 | 50 |
| Z. 2 | 15,0 | 13,5 | 190 |
| Z. 3 | 13,0 | 14,0 | 115 |

- Ermittlung Abstand zu den Clustern

| ID | Distanz zu Zentrum 1 | Distanz zu Zentrum 2 | Distanz zu Zentrum 3 |
|---|---|---|---|
| 1 | $\sqrt{2{,}5^2 + 2{,}5^2 + 0^2} = 3{,}54$ | $\sqrt{0^2 + 3{,}5^2 + 40^2} = 140{,}04$ | $\sqrt{2^2 + 4^2 + 65^2} = 65{,}15$ |
| 2 | $\sqrt{2{,}5^2 + 2{,}5^2 + 0^2} = 3{,}54$ | $\sqrt{5^2 + 1{,}5^2 + 40^2} = 140{,}10$ | $\sqrt{7 + 1^2 + 65^2} = 65{,}38$ |
| 3 | $\sqrt{0{,}5^2 + 2{,}5^2 + 150^2} = 150$ | $\sqrt{2^2 + 1{,}5^2 + 10^2} = 10{,}31$ | $\sqrt{4^2 + 1^2 + 85} = 85{,}10$ |
| 4 | $\sqrt{4{,}5^2 + 0{,}5^2 + 130^2} = 130$ | $\sqrt{2^2 + 1{,}5^2 + 10^2} = 10{,}31$ | $\sqrt{0^2 + 2^2 + 65^2} = 65{,}03$ |
| 5 | $\sqrt{6{,}5^2 + 3{,}5^2 + 60^2} = 60{,}45$ | $\sqrt{4^2 + 2{,}5^2 + 80^2} = 80{,}14$ | $\sqrt{2^2 + 2^2 + 5^2} = 5{,}74$ |
| 6 | $\sqrt{2{,}5^2 + 0{,}5^2 + 70^2} = 70{,}05$ | $\sqrt{0^2 + 1{,}5^2 + 70^2} = 70{,}02$ | $\sqrt{2^2 + 2^2 + 5^2} = 5{,}74$ |

# Aufgabe 2 (c) – Lösung (kMeans Clustering)

- Vorgehen
  - Initiale Clusterzentren
  - Rekursiv
    - Ermittlung Abstand zu den Clustern
    - Zuordnung zu den Clustern
    - Ermittlung neuer Clusterzentren

| | Höhe | Breite | Preis |
|---|---|---|---|
| Beobachtung | 15 | 10 | 50 |
| | 20 | 15 | 50 |
| | 17 | 15 | 200 |
| | 13 | 12 | 180 |
| | 11 | 16 | 110 |
| | 15 | 12 | 120 |
| Z. 1 | 15 | 10 | 50 |
| Z. 2 | 17 | 15 | 200 |
| Z. 3 | 11 | 16 | 110 |

- Zuordnung zu den Clustern

| ID | Distanz zu Z. 1 | Distanz zu Z. 2 | Distanz zu Z. 3 | Zuordnung zu |
|---|---|---|---|---|
| 1 | 3,54 | 140,04 | 65,15 | Z. 1 |
| 2 | 3,54 | 140,10 | 65,38 | Z. 1 |
| 3 | 150,00 | 10,31 | 85,10 | Z. 2 |
| 4 | 130,00 | 10,31 | 65,03 | Z. 2 |
| 5 | 60,45 | 80,14 | 5,74 | Z. 3 |
| 6 | 70,05 | 70,02 | 5,74 | Z. 3 |

- Keine weiteren Schritte nötig, da Clusterzentren unverändert

# Agenda

- Aufgabenblatt 1 – Deskriptive Methoden zur Datenexploration
- Aufgabenblatt 2 – Klassifikation
- Aufgabenblatt 3 – Recommender Systems

- Aufgabenblatt 4 – Clusteringverfahren
  - Aufgabe 1 – Hierarchisches Clustering
  - Aufgabe 2 – kMeans Clustering
  - Aufgabe 3 – Verständnisfragen

- Aufgabenblatt 5 – Stream Mining
- Aufgabenblatt 6 – Social Network Analysis

# Aufgabe 3 (a) - Aufgabenstellung

- Erläutern Sie, wie k Nearest Neighbor Klassifikation funktioniert. Diskutieren Sie dann Vor- und Nachteile des Verfahrens gegenüber anderen Klassifikationsalgorithmen. **(6 Punkte)**

# Wiederholung: kNearest Neighbor Klassifikation

- Algorithmus: K-Nearest-Neighbor Klassifikation
- Gegeben:
  - Trainingsdatensatz $T$
- Vorgehen zur Klassifikation einer Beobachtung $g_i$:
  - Menge $S$: $k$ ($k\ modulo\ 2 = 1$) nächsten Nachbarn von $g_i$ in $T$
  - Klassifikation von $g_i$ durch Klasse mit meisten Elementen in $S$
- Anmerkungen:
  - „Nähe“ über Distanzmaß (z.B. euklidische oder Manhattan Distanz)
  - Kein „Lernen“ wie bei anderen Klassifikationsalgorithmen nötig
  - Klassifikation mit großen Trainingsdatensätzen $T$ aufwendig
    ⇒ Einsatz repräsentativer Stichproben von $T$
- Anwendung auf Regressionsprobleme
  Beispielsweise durch Rückgabe das Mittelwerts der k-Nearest-Neighbors

# Aufgabe 3 (a) – Lösung (kNearest Neighbor)

- Vorteile
  - Kein Lernen notwendig
  - Anwendung auf Regressionsprobleme möglich
  - Funktioniert gut bei numerischen Attributen

- Nachteile
  - Aufwendig bei großen Trainingsdaten
  - Trainingsdaten müssen repräsentativ sein
  - Transformation der Attribute nötig

# Aufgabe 3 (b) - Aufgabenstellung

- Erläutern Sie kurz was der Unterschied zwischen supervised und unsupervised learning Verfahren ist. **(2 Punkte)**

# Aufgabe 3 (b) – Lösung (Unsupervised Learning)

- Supervised learning
  - Vorherzusagende Eigenschaft bekannt
  - Typische Beispiele: Klassifikation, Regression

- Unsupvervised learning
  - Vorherzusagende Eigenschaft nicht bekannt
  - Typisches Beispiel: Clustering

# Aufgabe 3 (c) - Aufgabenstellung

- Erläutern Sie warum die Rangskalierung von Attributen für die Anwendung von Clusteringverfahren hilfreich sein kann und gehen Sie auf Nachteile des Ansatzes ein. **(2 Punkte)**

# Aufgabe 3 (c) – Lösung (Rangskalierung)

- Vorteile
  - Abstände zwischen Attributen werden eliminiert
  - Vorhersagbarer Wertebereich
  - Eliminierung von Ausreißern
  - Anonymisierung der Daten

- Nachteile
  - Abstände zwischen Attributen werden eliminiert
  - Ausreißer werden nicht berücksichtigt
  - Daten müssen sortiert werden
  - Kaum übertragbar auf neue Daten