Maschinelles Lernen II

Vorlesung “Computerlinguistische Techniken”
Alexander Koller

30. Januar 2015

Heute

- Überwachtes Lernen:
  - Maximum-Entropy-Modelle
- Unüberwachtes Lernen:
  - Clustering

Maximum Entropy: Motivation

- Angenommen, wir entdecken beim POS-Tagging das neue Wort *zyxxy*. Wie ist die W.verteilung P(c|w = *zyxxy*) über POS-Tags?

- Zunächst angenommen, wir wissen nichts über *zyxxy*. Es gibt 45 POS-Tags.

(Beispiel nach Jurafsky & Martin)

Maximum Entropy: Motivation

- Angenommen, wir entdecken beim POS-Tagging das neue Wort *zyxxy*. Wie ist die W.verteilung P(c|w = *zyxxy*) über POS-Tags?

- Zunächst angenommen, wir wissen nichts über *zyxxy*. Es gibt 45 POS-Tags.

NN	JJ	NNS	VB	IN	PRP	CC	CD
1/45	1/45	1/45	1/45	1/45	1/45	1/45	1/45

P(c|w=*zyxxy*)

(Beispiel nach Jurafsky & Martin)

Maximum Entropy: Motivation

- Jetzt haben wir ein bisschen annotierte Daten für *zyxxy*. Alle Instanzen waren mit NN, NNS, JJ oder VB annotiert.
  - d.h.: $P(c \in \{NN, NNS, JJ, VB\} \mid zyxxy) = 1$
- Wie ändert sich Ihre Schätzung der W.verteilung?

Maximum Entropy: Motivation

- Jetzt haben wir ein bisschen annotierte Daten für *zyxxy*. Alle Instanzen waren mit NN, NNS, JJ oder VB annotiert.
  - d.h.: $P(c \in \{NN, NNS, JJ, VB\} \mid zyxxy) = 1$
- Wie ändert sich Ihre Schätzung der W.verteilung?

NN	JJ	NNS	VB	IN	PRP	CC	CD
1/4	1/4	1/4	1/4	0	0	0	0

Maximum Entropy: Motivation

- Wir entdecken jetzt, dass *zyxxy* in 80% der Fälle als NN oder NNS annotiert war.
  - d.h.: P(c=NN v c=NNS | *zyxxy*) = 0.8
- Wie ändert sich Ihre Schätzung der W.verteilung?

Maximum Entropy: Motivation

- Wir entdecken jetzt, dass *zyxxy* in 80% der Fälle als NN oder NNS annotiert war.
  - d.h.: P(c=NN v c=NNS | *zyxxy*) = 0.8

- Wie ändert sich Ihre Schätzung der W.verteilung?

(NB: Alter Constraint P(NN v JJ v NNS v VB|zyxxy) = 1 immer noch erfüllt!)

Maximum Entropy: Motivation

- Wir entdecken jetzt, dass *zyxxy* in 80% der Fälle als NN oder NNS annotiert war.
  - d.h.: P(c=NN v c=NNS | *zyxxy*) = 0.8

- Wie ändert sich Ihre Schätzung der W.verteilung?

NN	JJ	NNS	VB	IN	PRP	CC	CD
4/10	1/10	4/10	1/10	0	0	0	0

(NB: Alter Constraint P(NN v JJ v NNS v VB|zyxxy) = 1 immer noch erfüllt!)

Maximum Entropy: Motivation

- Schließlich finden wir heraus, dass eines von 20 englischen Wörtern ein Verb ist.
  - d.h.: P(c=VB) = 1/20, über alle Wörter gerechnet

- Wie ändert sich Ihre Schätzung der W.verteilung?

Maximum Entropy: Motivation

- Schließlich finden wir heraus, dass eines von 20 englischen Wörtern ein Verb ist.
  - d.h.: P(c=VB) = 1/20, über alle Wörter gerechnet

- Wie ändert sich Ihre Schätzung der W.verteilung?

NN	JJ	NNS	VB	IN	PRP	CC	CD
4/10	3/20	4/10	1/20	0	0	0	0

(NB: Alte Constraints sind immer noch erfüllt!)

Was haben wir gemacht?

- Wir haben drei *Features* definiert:
  - $f_1(c, w) = 1$ gdw w = *zyxxy* und $c \in \{NN, NNS, JJ, VB\}$
  - $f_2(c, w) = 1$ gdw w = *zyxxy* und $c \in \{NN, NNS\}$
  - $f_3(c, w) = 1$ gdw c = VB
- Features sind *Funktionen*, die gleichzeitig Klasse c und zu klassifizierendes Objekt w anschauen.

Was haben wir gemacht?

- Wir haben Erwartungswerte für die Features aus Beobachtungen im Korpus bestimmt.

$$E(f) = \sum_{w,c} P(w,c) \cdot f(w,c)$$

- $E(f_1) = P(zyxxy, NN\ v\ NNS\ v\ JJ\ v\ VB) = P(zyxxy)$
  $E(f_2) = P(zyxxy, NN\ v\ NNS) = 0.8 * P(zyxxy)$
  $E(f_3) = P(c = VB) = 1/20$

- NB: $P(w, c) = P(c \mid w) * P(w)$

Maximum-Entropy-Modelle

- Wir schätzen jetzt eine W.verteilung $\tilde{P}$, so dass
  - $E_{\tilde{P}}(f) = \sum_{w,c} \tilde{P}(w,c) \cdot f(w,c) = E_P(f)$ für alle Features f
  - das Modell unter allen Modellen mit dieser Eigenschaft die wenigsten Zusatzannahmen macht.
    - Formaler Begriff von “wenigste Zusatzannahmen”: maximale *Entropie*.

Entropie

- *Entropie* einer W.verteilung ist fundamentales Konzept der Informationstheorie: Vorhersehbarkeit einer Zufallsvariable.

- Definition: $H(P) = -\sum_{z} P(z) \cdot \log P(z)$

- “Eindeutige” Verteilung hat H(P) = 0
  (P(a) = 1 für ein einziges a, P(x) = 0 sonst):

- Uniforme Verteilung über N mögliche Ereignisse:
  H(P) = log N

Entropie

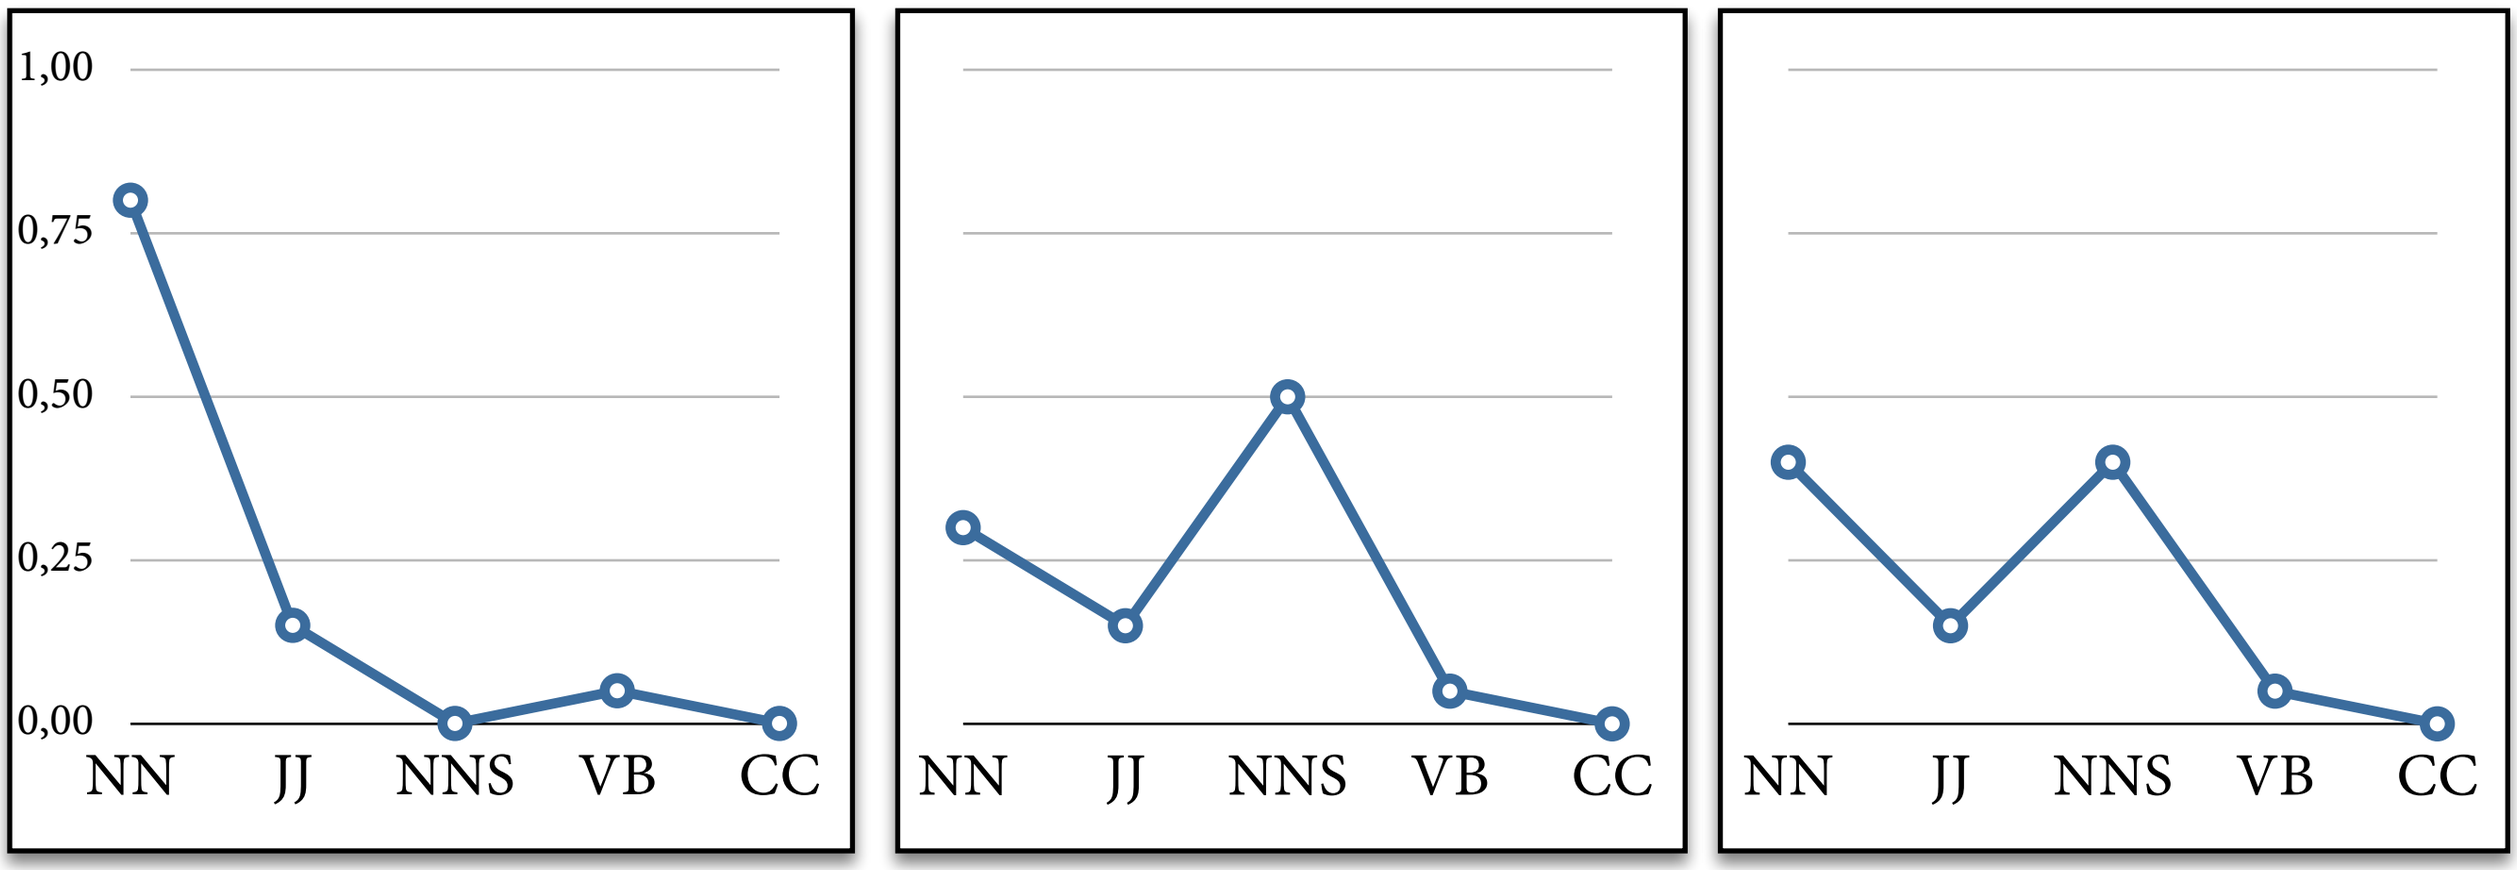

H = 0.61

H = 0.99

H = 1.02

“peaky”

maximum entropy

Featurefunktionen

- Annahme: Menge von Feature-Funktionen $f_i(w, c)$: gemeinsame Eigenschaften von zu klassifizierendem Objekt w und Klasse c

- Eigenschaften völlig beliebig, gerne auch kompliziert. Müssen auch nicht statistisch unabhängig sein.

- Freie Wahl der Ft.funktionen ist eine zentrale Stärke des MaxEnt-Ansatzes.

Maximum-Entropy-Modelle

- Man kann zeigen, dass die W.verteilung maximaler Entropie immer folgende Form hat:

$$P(c|w) = \frac{e^{\theta \cdot f(c,w)}}{\sum_{c'} e^{\theta \cdot f(c',w)}}$$

wobei θ ein Vektor von Gewichten ist und

$$\theta \cdot f(c,w) = \sum_i \theta_i \cdot f_i(c,w).$$

- Training = Lernen von Parametern θ, die zu Beobachtungen passen.

Training

- Training mit iterativen Verfahren.
  - häufige Verfahren: Generative/Improved Iterative Scaling; Quasi-Newton-Verfahren.

- Grundidee: Maximiere log-likelihood

$$\sum_{(w,c)\in \mathrm{Tr}} \mathrm{freq}(c,w) \cdot \log P(c|w)$$

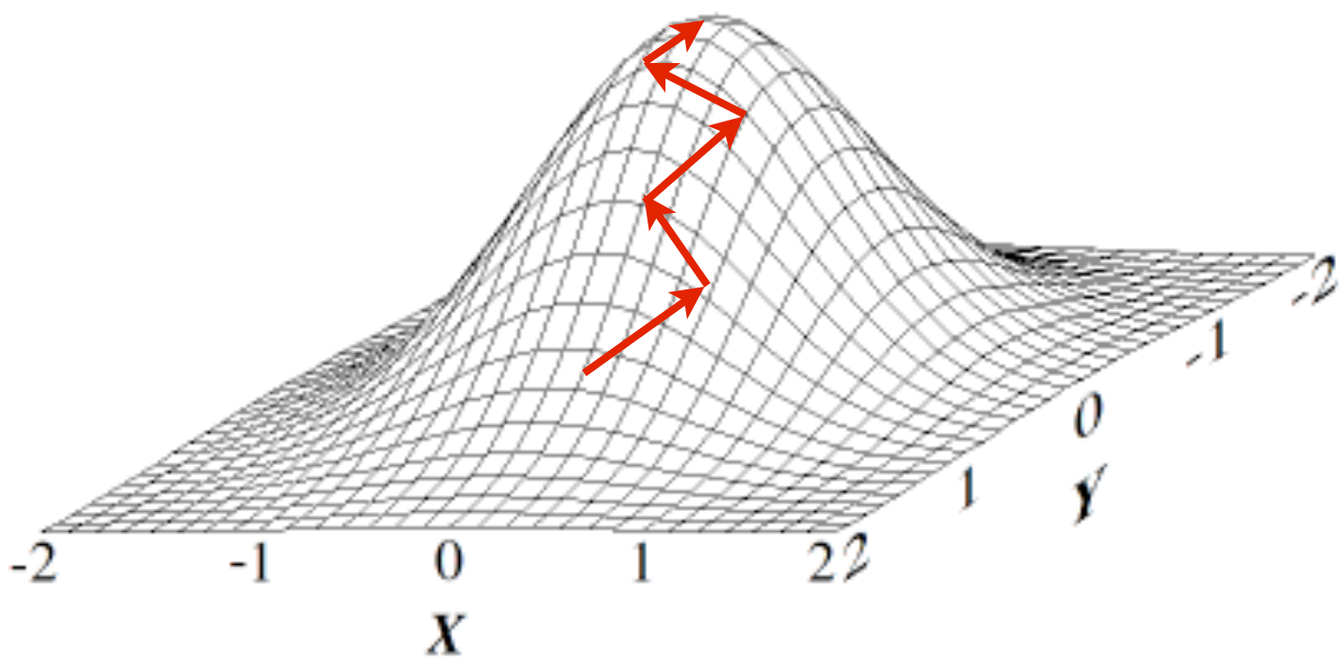

Beispiel

Nigeria ... prince ... bank	Spam
... Viagra ... Tabletten ...	Spam
Nigeria ... president ... bank	Spam
... Vorlesung ... fällt aus ...	kein Spam

$f_1(w, c) = 1$ gdw. w enthält “Nigeria” und c = Spam

$f_2(w, c) = 1$ gdw. w enthält “Vorlesung” und c = kein Spam etc.

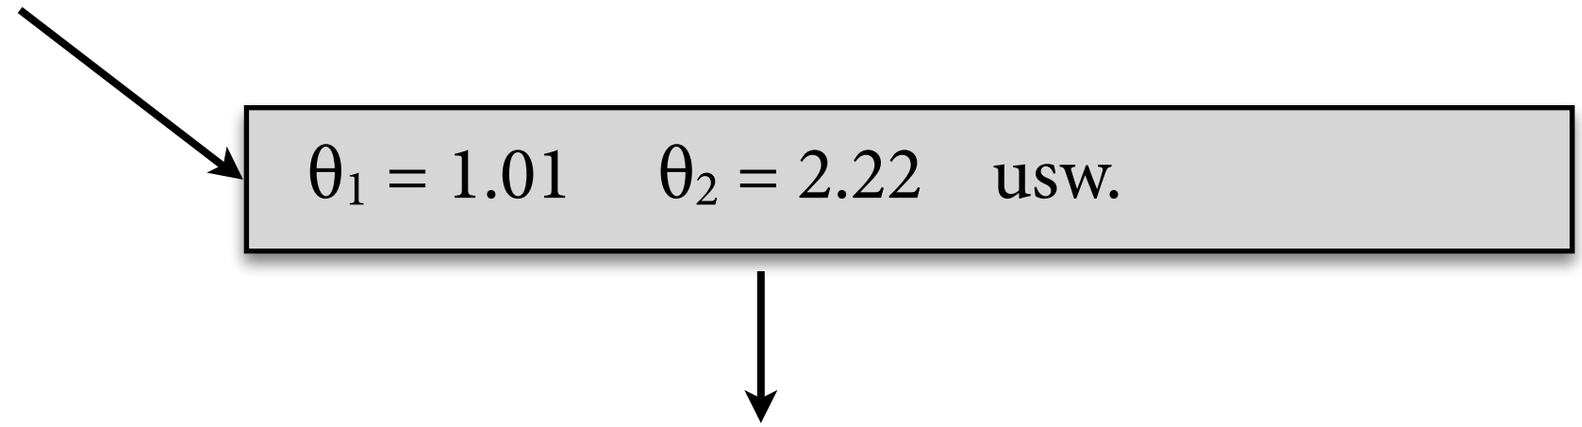

Beispiele für Featuresets

- Übersetzung Englisch - Französisch (Berger et al. 96):
  - ft(e,f) = 1 gdw e_{i+1} = “Canada” und f_i = “à”
  - ft(e,f) = 1 gdw “area” in e_{i+1}, ..., e_{i+3} und f_i = “dans”
  - ft(e,f) = 1 gdw “increase” in e_{i-1}, ..., e_{i-3} und f_i = “de”

- Training auf bilingualem Korpus (Protokolle des kanadischen Parlaments).

Beispiele für Featuresets

- POS-Tagging (Ratnaparkhi 1996)
  verwendet Templates für Features:
  - ft(w, p) = 1 gdw w_i = X und p = Y
  - ft(w,p) = 1 gdw w_i endet in X (z.B. “-ing”) und p = Y
  - ft(w,p) = 1 gdw w_i enthält Großbuchstaben und p = Y

- Erzeugt alle Instanzen (z.B. “w_i endet in -ing und p = VBG”) und wirft zu seltene weg.

- 96.6% tagging accuracy auf WSJ

Log-lineare Modelle

- Maximum-Entropy-Modelle heißen auch *log-lineare* Modelle, weil log P linear (in den Features) ist.

$$\begin{aligned}
\log P(c|w) &= \log \frac{e^{\theta \cdot f(c,w)}}{\sum_{c'} e^{\theta \cdot f(c',w)}} \\
&= \log \frac{e^{\theta \cdot f(c,w)}}{Z(w)} \\
&= \theta \cdot f(c,w) - \log Z(w)
\end{aligned}$$

Vor- und Nachteile

- Featurefunktionen extrem mächtig: jede berechenbare Eigenschaft von (w, c).

- Robust gegenüber statistischen Abhängigkeiten.

- MaxEnt ist *diskriminatives* Modell: Berechnet nur P(c | w), nicht direkt P(c, w) (anders als HMM u.ä.).

- Größerer Trainingsdaten- und Rechenzeitbedarf als Naive Bayes.

Clustering

- Unüberwachtes Lernen:
  - Trainingsdaten sind nicht mit Klassen annotiert
  - Wir wollen die Klassen selbst herausfinden
- Beispiel: Semantische Ähnlichkeit
  - gegeben: Ähnlichkeitsmaß auf Paaren von Wörtern
  - gesucht: Klassen von ähnlichen Wörtern
- Ein Lösungsansatz: Clustering.

Clustering

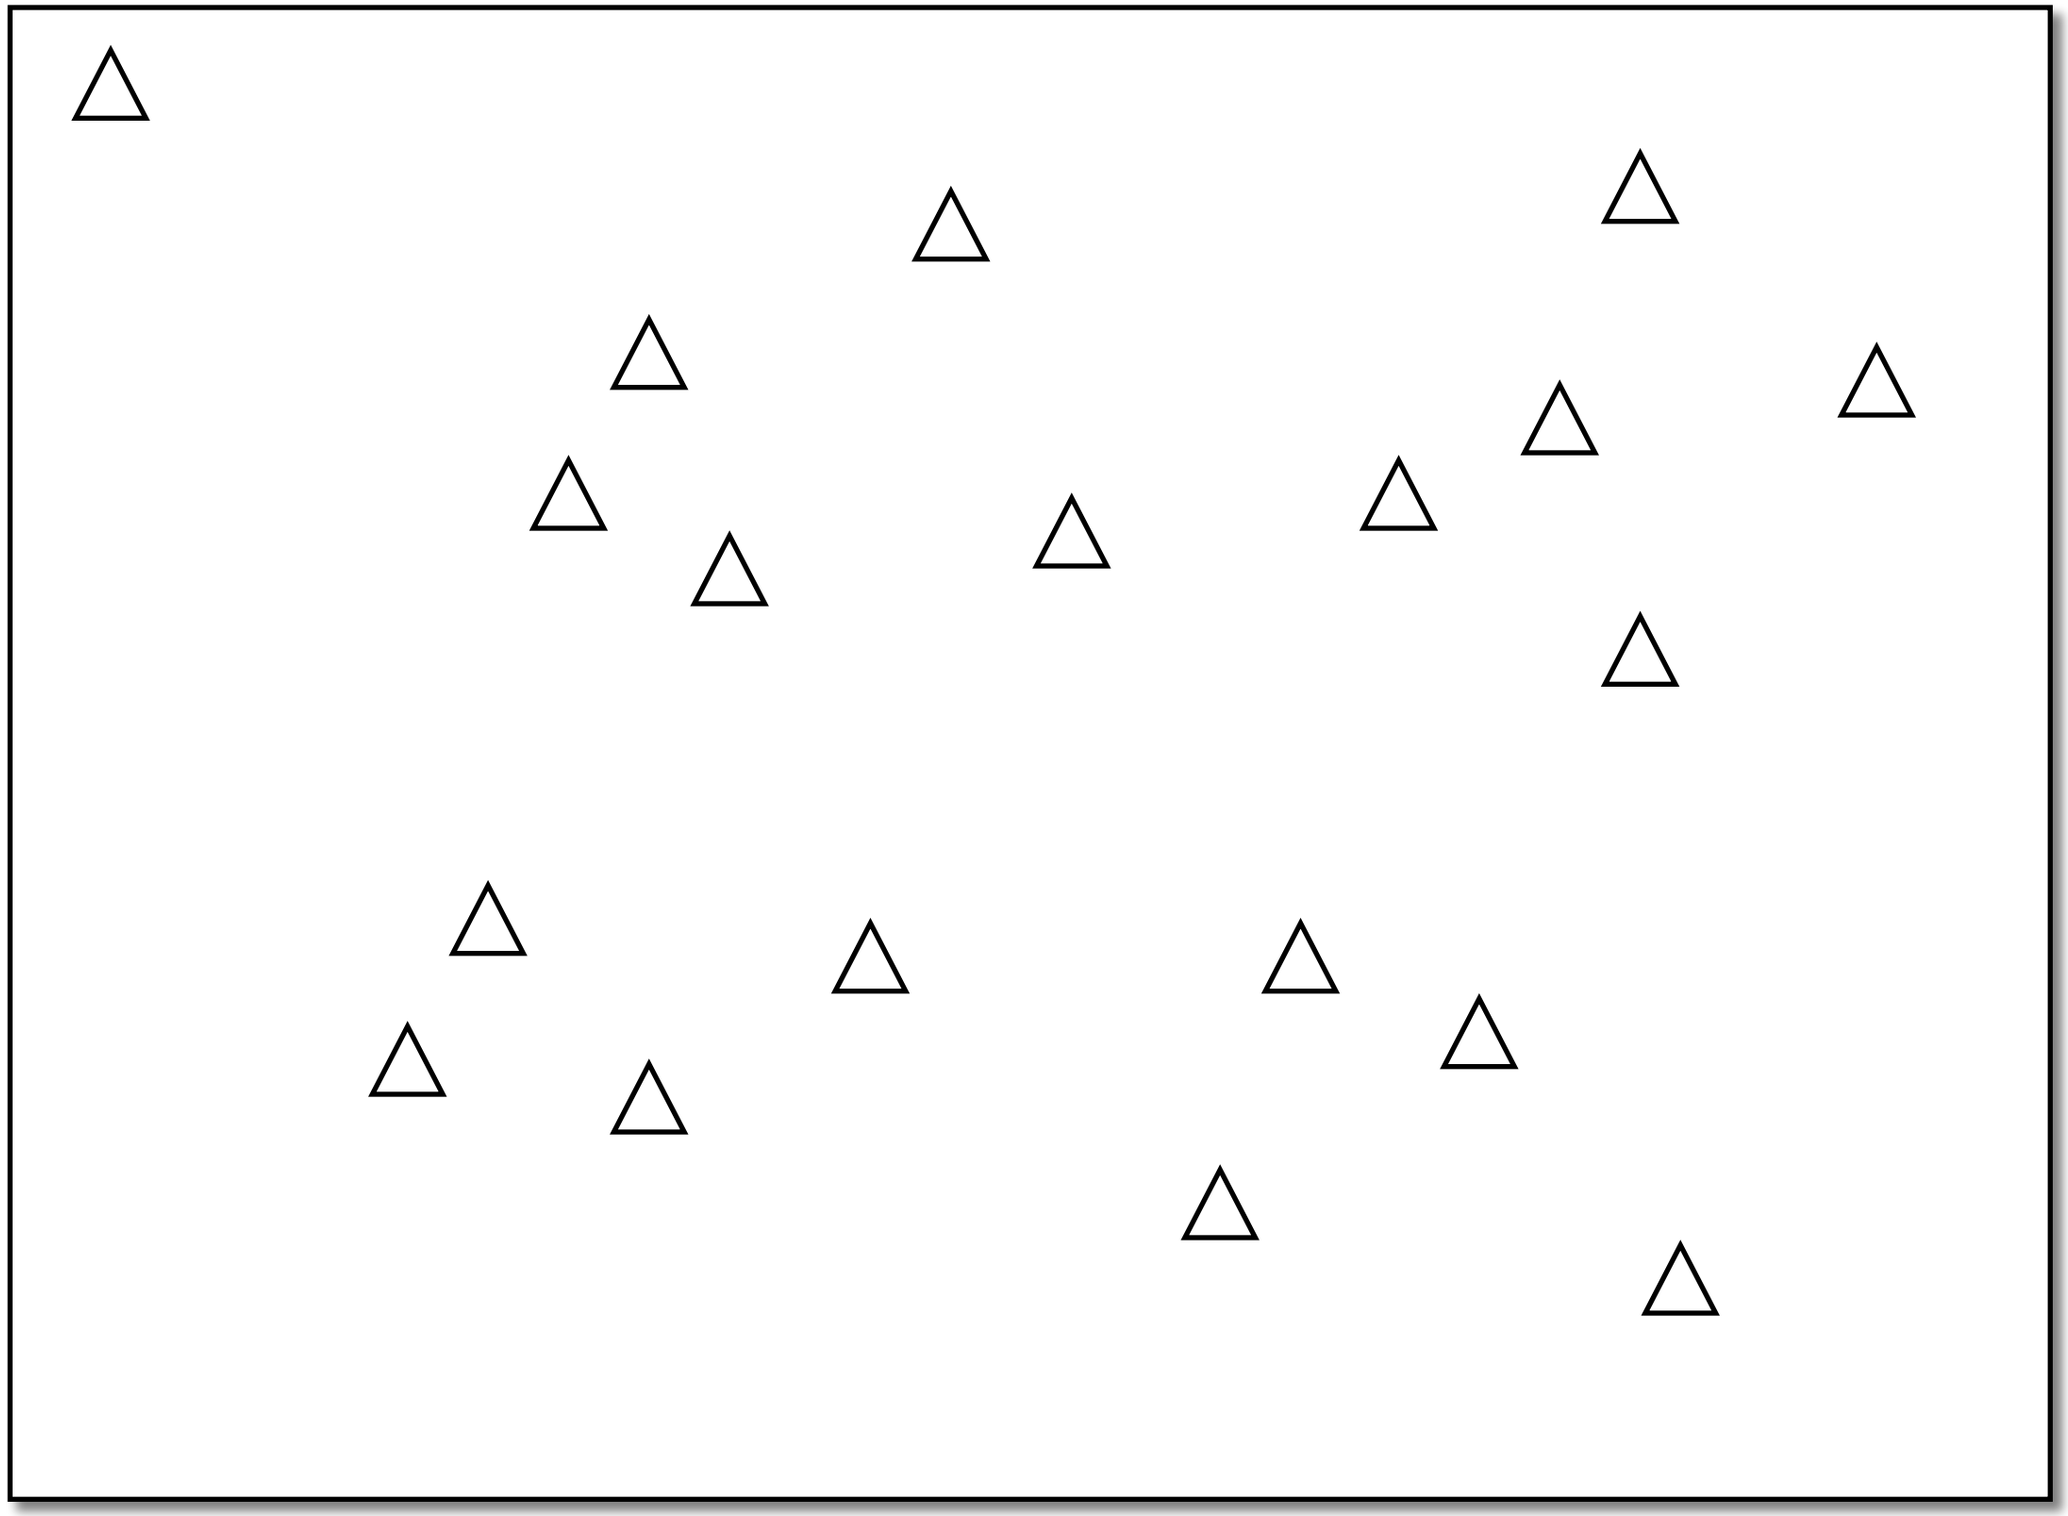

Clustering

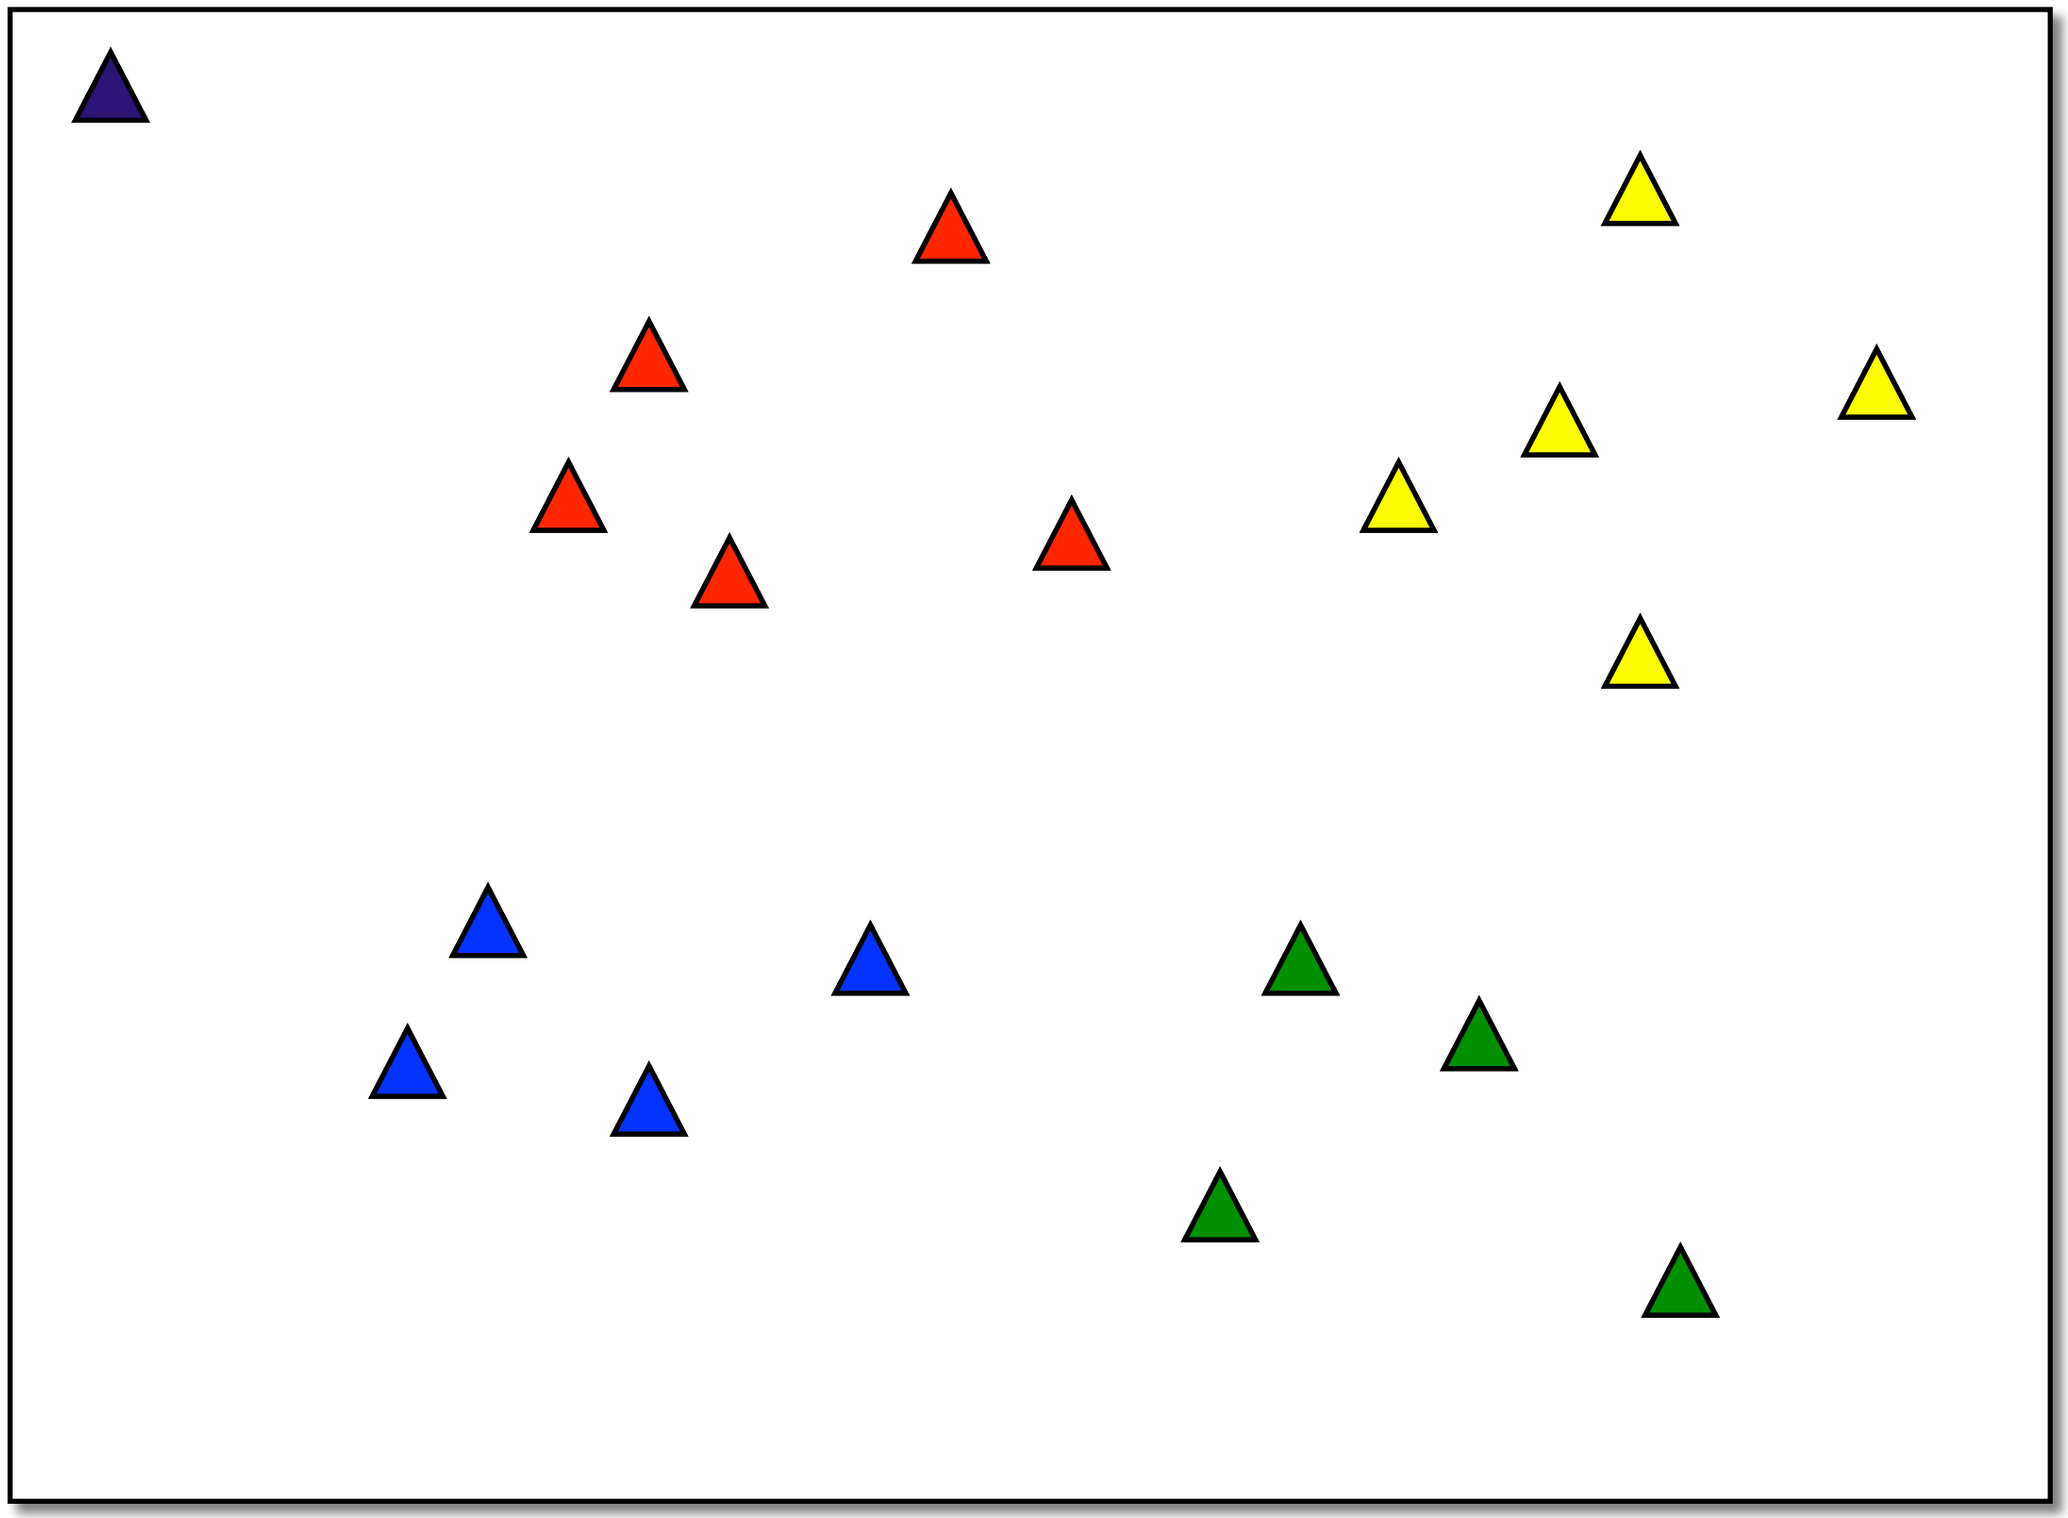

Semantische Ähnlichkeit

- Problemstellung: Wie kann man automatisch Wörter in Gruppen zusammenfassen?
  - “Near-synonymy”: {error, mistake, blunder, faux pas, ...}
  - Gattungen: {Äpfel, Birnen, Kirschen, ...}
  - Verbklassen: {essen, konsumieren, trinken, saufen, ...}

- Gegeben ist ein Ähnlichkeitsmaß.
  - Numerische Features, z.B. aus distributionellem Ansatz: “Wie oft kommt im Korpus in einem Fenster von 5 Wörtern das Wort essen vor?”
  - Daraus numerisches Ähnlichkeitsmaß definieren: in etwa wie bei k-nearest-neighbor.

Clustering

- Gegeben:
  - Menge von Objekten
  - Ähnlichkeitsmaß
- Gesucht: Zuordnung von Objekten zu Clustern, so dass
  - Objekte im gleichen Cluster ähnlich sind
  - Objekte in verschiedenen Clustern unähnlich sind

Clustering

- Grundlegende Ansätze:
  - *agglomerativ / hierarchisch:* mit feinkörnigen Clustern anfangen und sie nach und nach verschmelzen
  - *k-means-Clustering:* festgelegte Anzahl *k* von *Centroids* berechnen; jeder Cluster besteht aus Objekten, die dem gleichen Centroid am ähnlichsten sind

Agglomeratives Clustering

- Form von hierarchischem Clustering:
  Große Cluster bestehen rekursiv aus kleinen.

- Ablauf:
  - Initialisierung: ein eigenes Cluster für jedes Objekt
  - Schritt: zwei ähnlichste Cluster verschmelzen
  - Ende: nur ein Cluster bleibt übrig

- Verschiedene Ansätze, um Ähnlichkeit von Clustern aus Ähnlichkeit der Element zu berechnen.

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

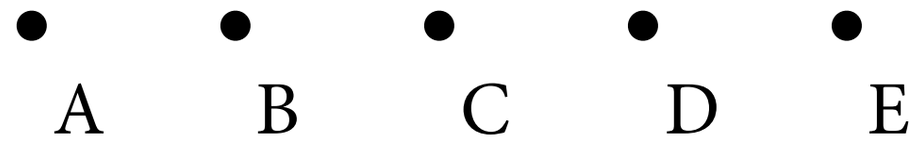

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

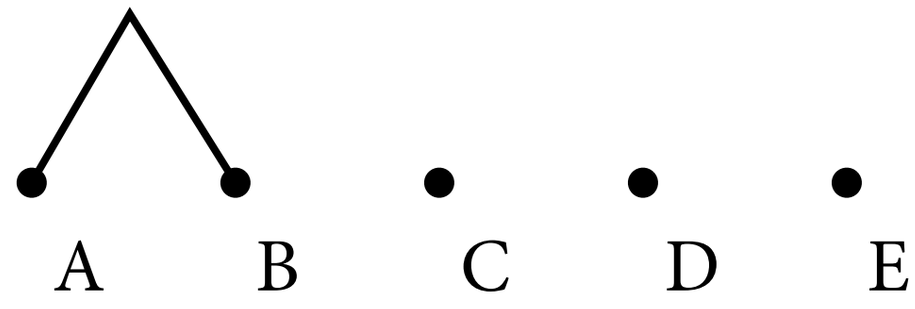

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

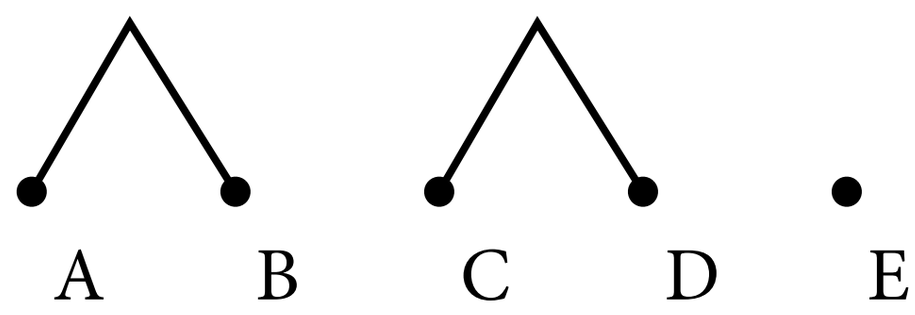

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

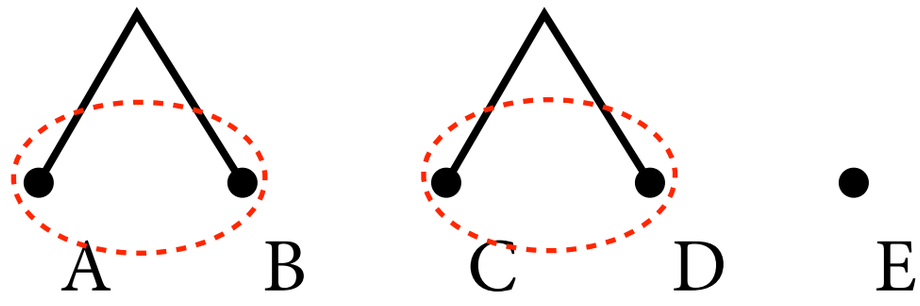

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

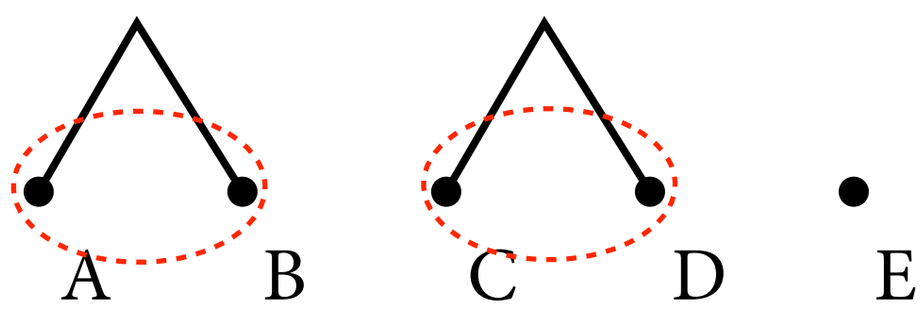

Single-Link Clustering:
Ähnlichkeit von Clustern = maximale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

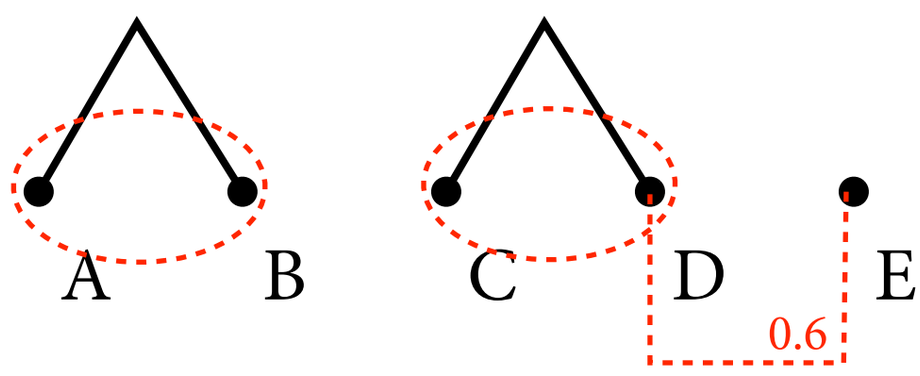

Single-Link Clustering:
Ähnlichkeit von Clustern = maximale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

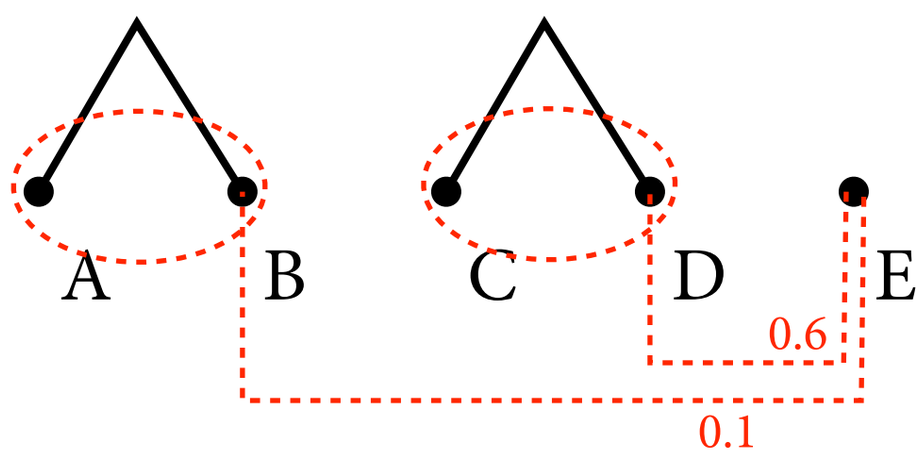

Single-Link Clustering:
Ähnlichkeit von Clustern = maximale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

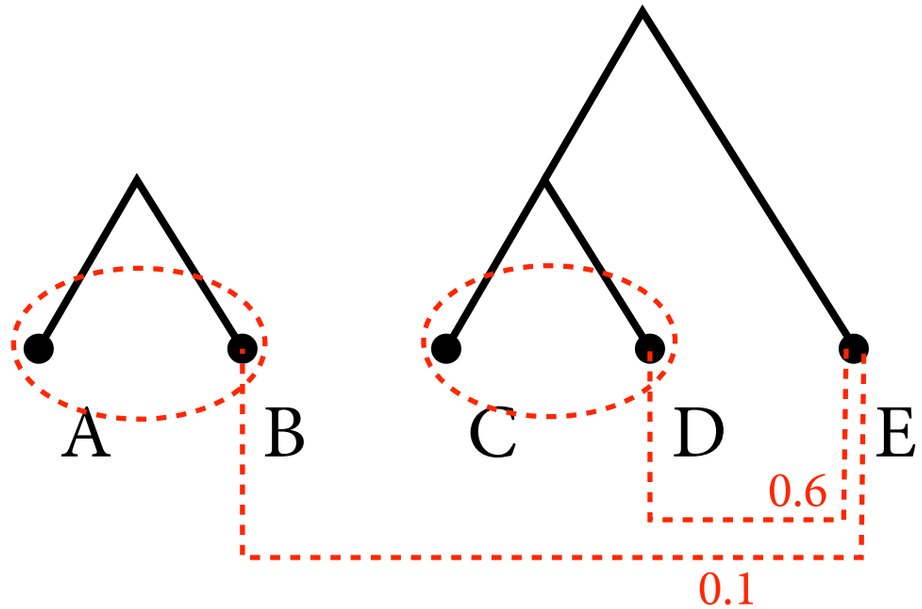

Single-Link Clustering:
Ähnlichkeit von Clustern = maximale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

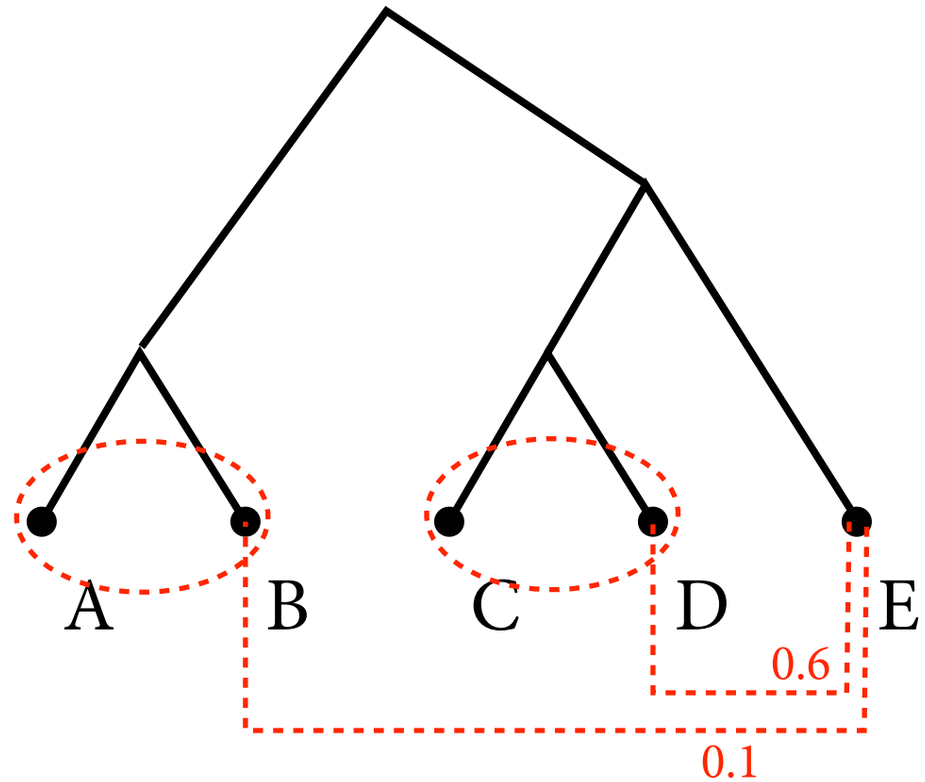

Single-Link Clustering:
Ähnlichkeit von Clustern = maximale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

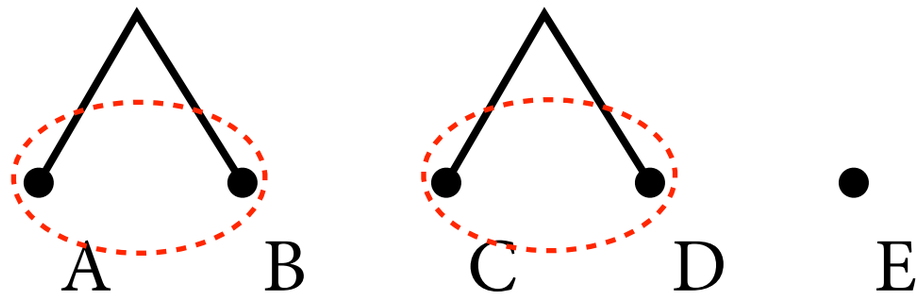

Complete-Link Clustering:
Ähnlichkeit von Clustern = minimale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

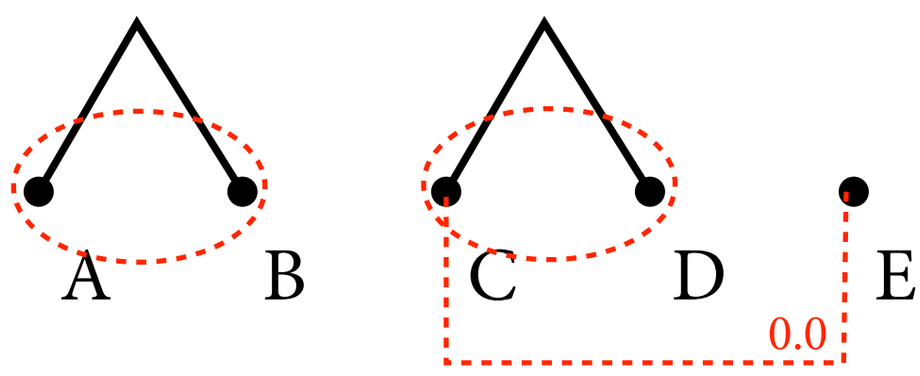

Complete-Link Clustering:
Ähnlichkeit von Clustern = minimale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

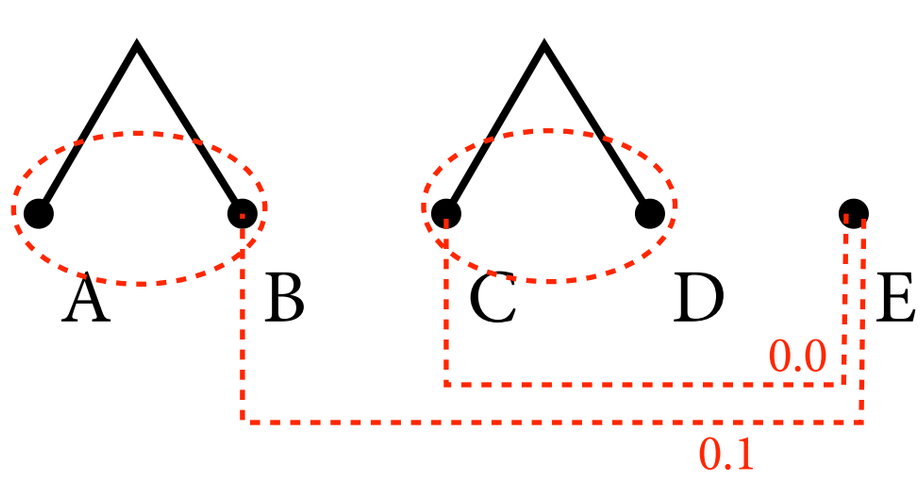

Complete-Link Clustering:
Ähnlichkeit von Clustern = minimale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

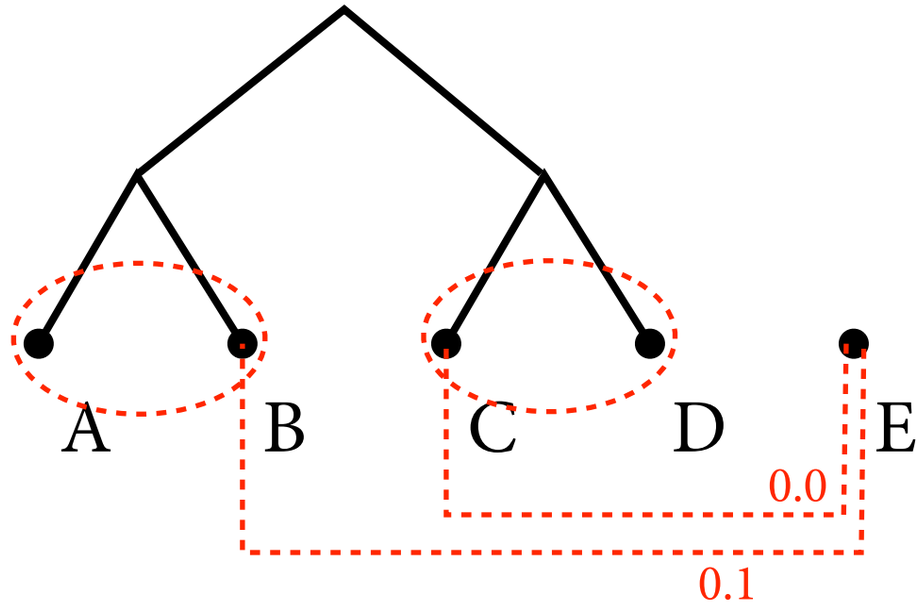

Complete-Link Clustering:
Ähnlichkeit von Clustern = minimale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

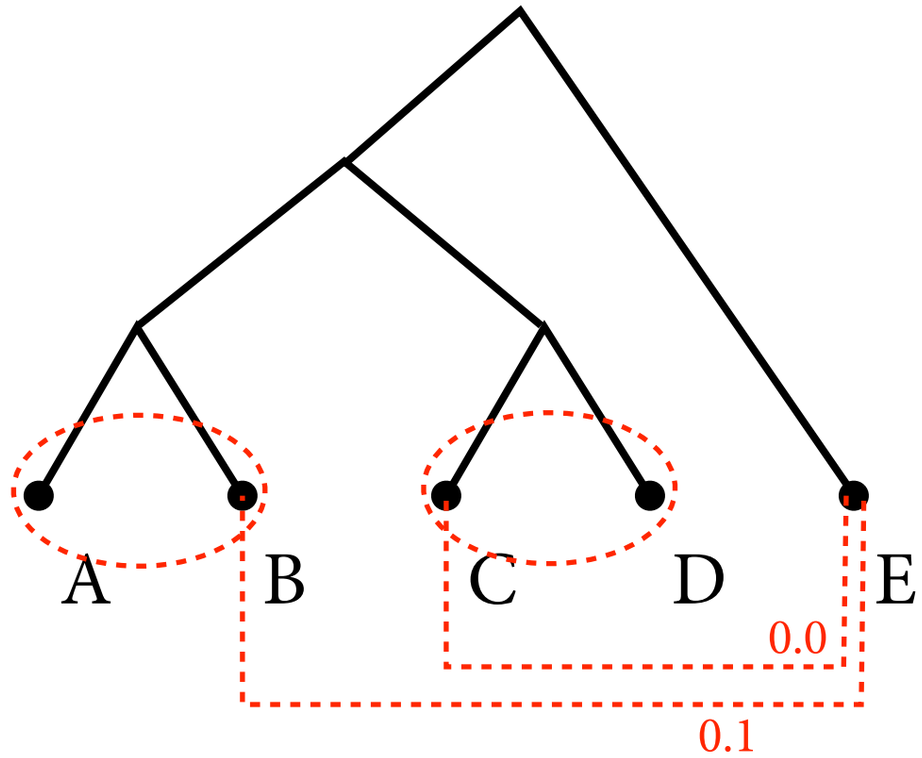

Complete-Link Clustering:
Ähnlichkeit von Clustern = minimale Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

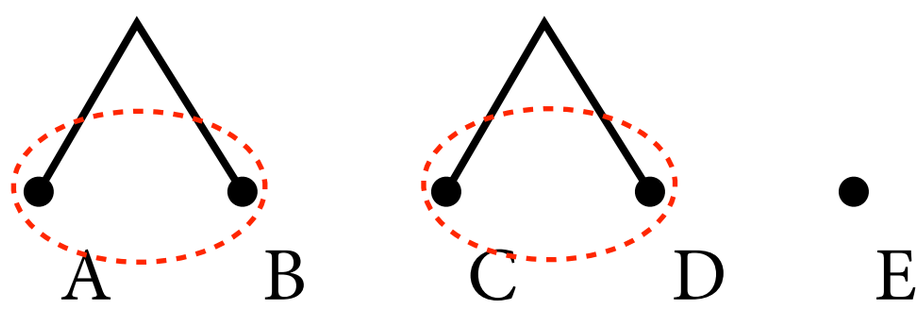

Average-Link Clustering:
Ähnlichkeit von Clustern = durchschnittliche Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

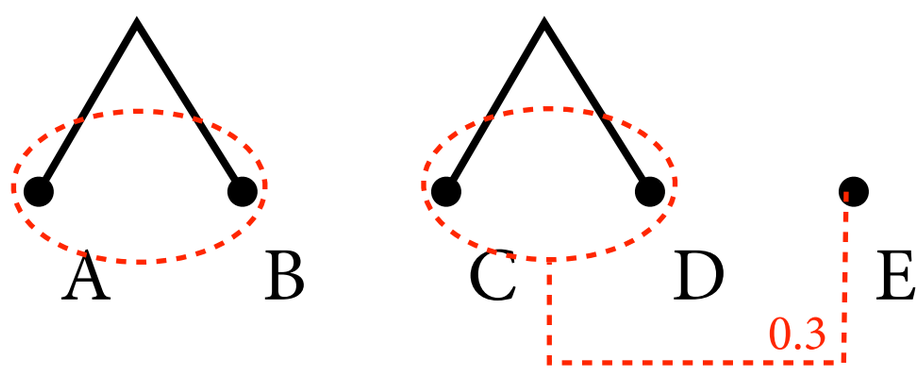

Average-Link Clustering:
Ähnlichkeit von Clustern = durchschnittliche Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

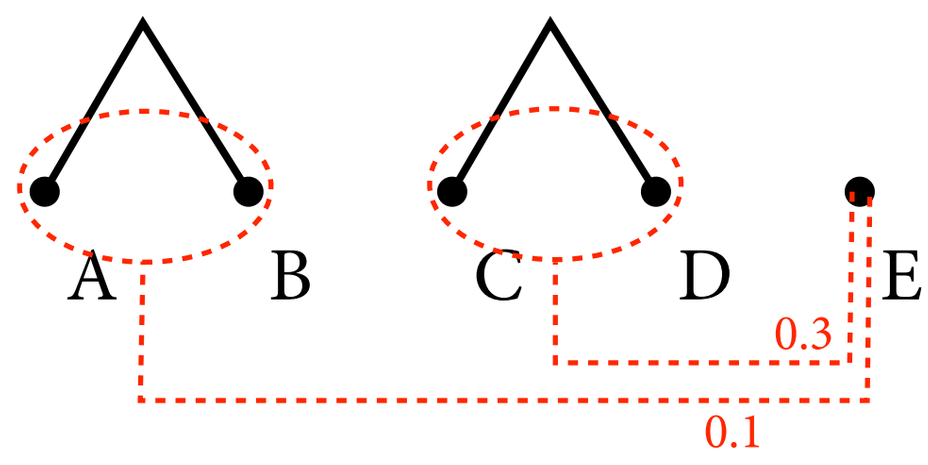

Average-Link Clustering:
Ähnlichkeit von Clustern = durchschnittliche Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

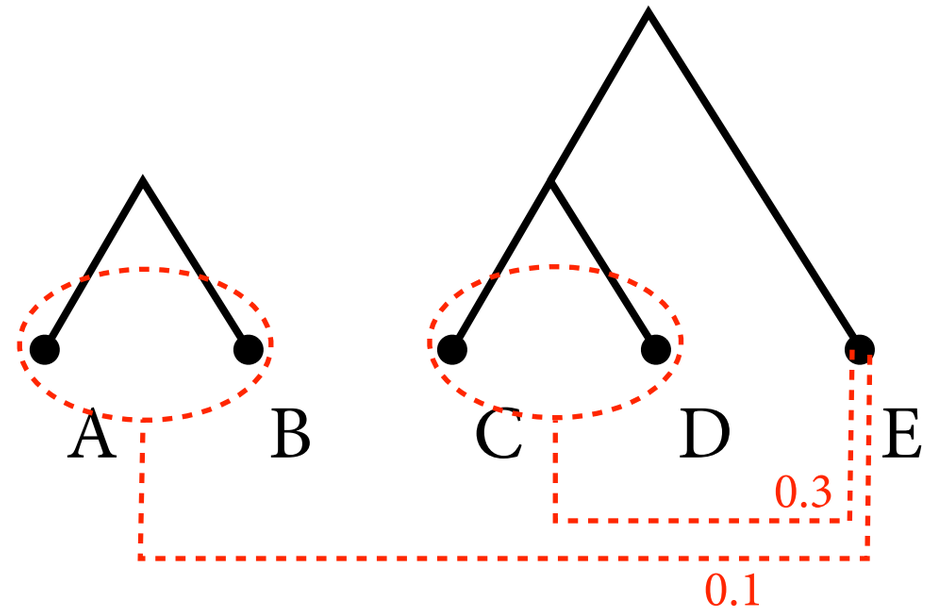

Average-Link Clustering:
Ähnlichkeit von Clustern = durchschnittliche Ähnlichkeit der Elemente

Agglomeratives Clustering

	E	D	C	B
A	0.1	0.2	0.2	0.8
B	0.1	0.1	0.2	
C	0.0	0.7		
D	0.6			

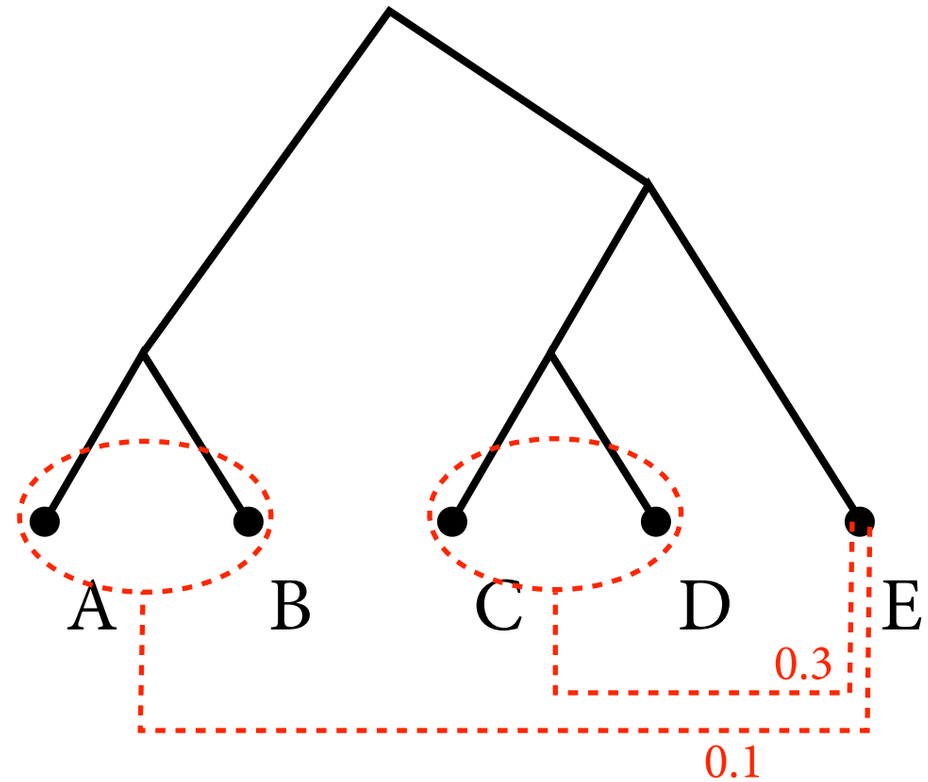

Average-Link Clustering:
Ähnlichkeit von Clustern = durchschnittliche Ähnlichkeit der Elemente

Ähnlichkeitsklassen

Beispielanwendung: Hierarchie von ähnlichen Wörtern.

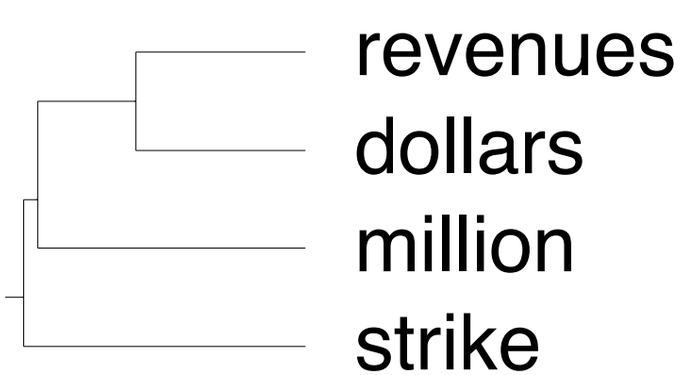

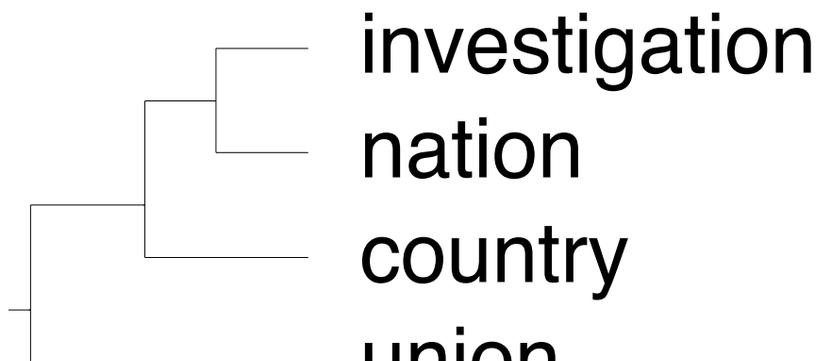

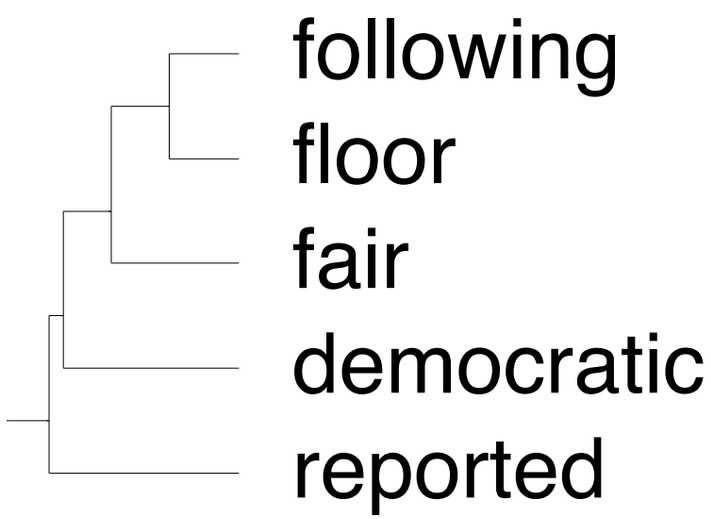

Diskussion

- Ähnlichkeitsklassen nützlich in Anwendungen.
  - Clustering ist Standardverfahren
  - Finden oft erstaunlich nichttriviale Klassen
- Einschränkungen:
  - Features zu flach
  - Ähnlichkeitsmaß zu flach
  - Wie viele Cluster?

Zusammenfassung

- Maschinelles Lernen:
  - überwacht: Klassen sind vorgegeben
    (Memory-Based, Naive Bayes, Maximum Entropy)
  - unüberwacht: Lerner findet Klassen selbst
    (z.B. Clustering)

- ML ist aus moderner CL nicht wegzudenken.
  - Es lohnt sich, separate Vorlesung dazu zu besuchen.