

# Automatisierte Dossier- Erstellung mittels Text-Mining

Paul Assendorp

Grundseminar

# Gliederung

- Motivation
- Textmining
- Tools
- Aktueller Stand
- Ausblick
- Konferenzen & Forschung

# Gliederung

- **Motivation**
- Textmining
- Tools
- Aktueller Stand
- Ausblick
- Konferenzen & Forschung

# Motivation

## **„Editors don't scale“**

(nach Dr. Carsten Brosda, Amt Medien, Senatskanzlei Hamburg)

# Was ist ein Dossier?

- Zusammenstellung von Dokumenten
- Zu thematischem Hintergrund
- politisch, historisch oder kulturell

**Aber:** Keine eindeutige Definition

# Automatisierte Dossier-Erstellung

“We emphasize that the complexity of language implies that automated content analysis methods [...] are best thought of as amplifying and augmenting careful reading and thoughtful analysis”

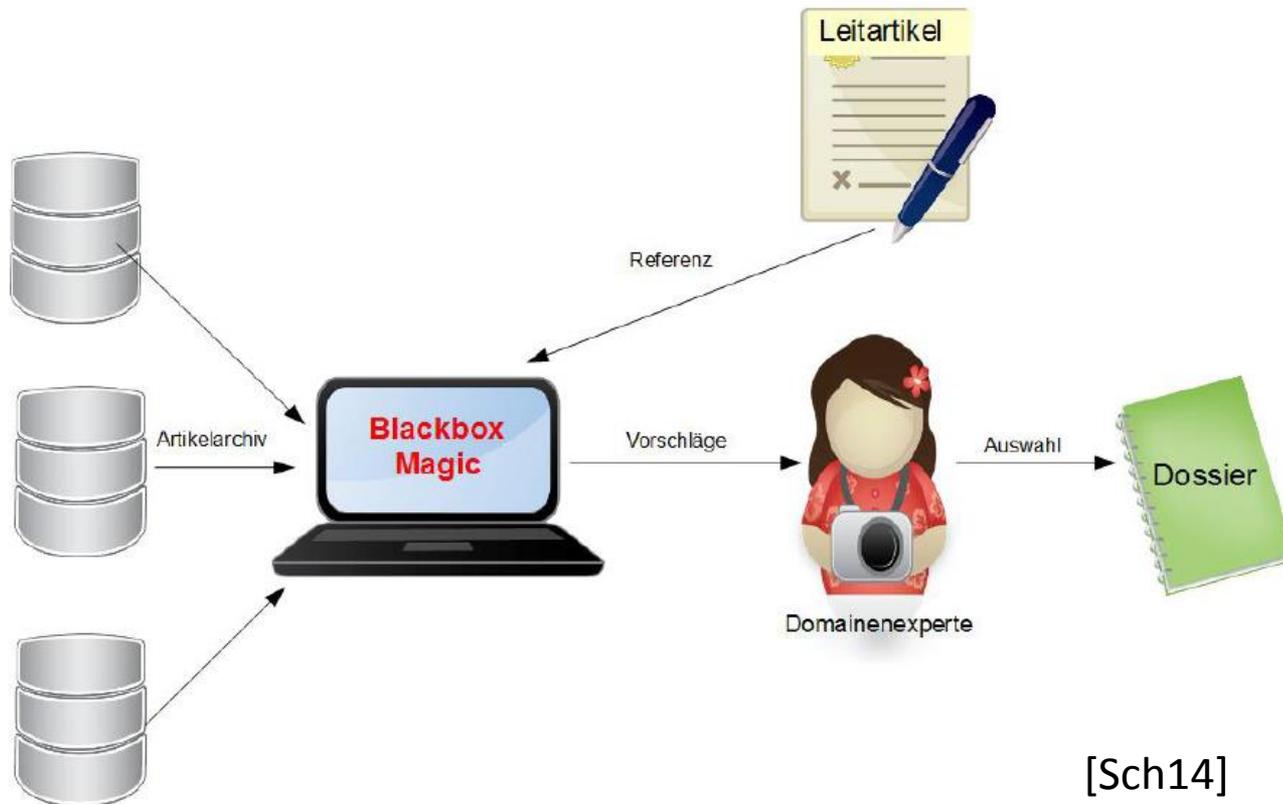
[Grim13]

# Automatisierte Dossier-Erstellung (2)

## Ansatz:

- Optimierung der Dossier-Erstellung
- Vorschläge für Domäne-Experten
- Leitartikel als Vorgabe

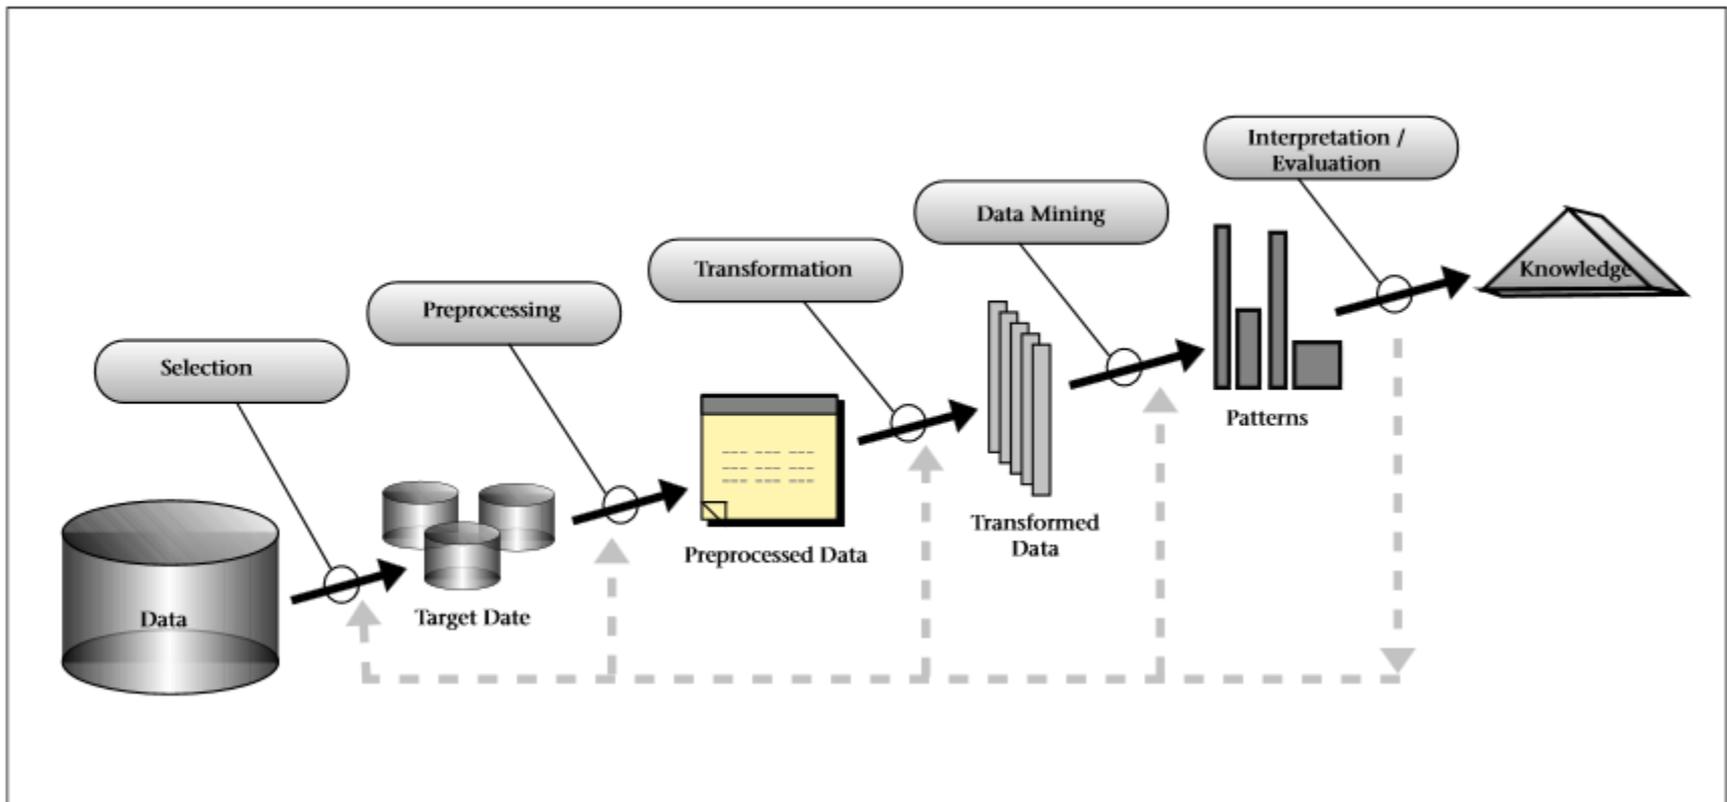
# Automatisierte Dossier-Erstellung (3)



# Gliederung

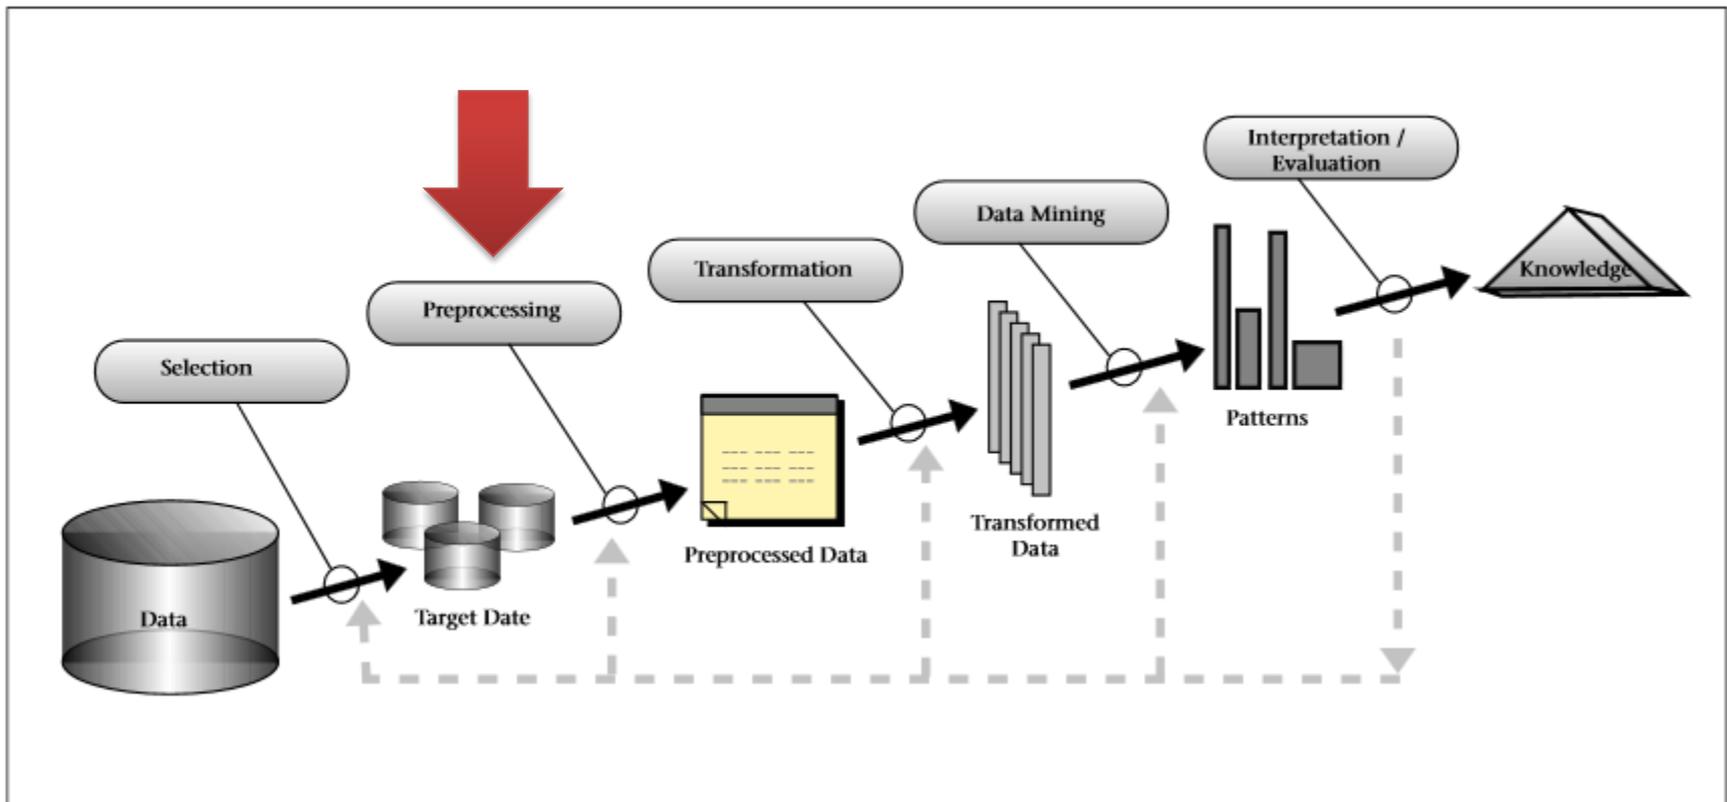
- Motivation
- **Textmining**
- Tools
- Aktueller Stand
- Ausblick
- Konferenzen & Forschung

# Textmining



[FPSS96]

# Textmining



[FPSS96]

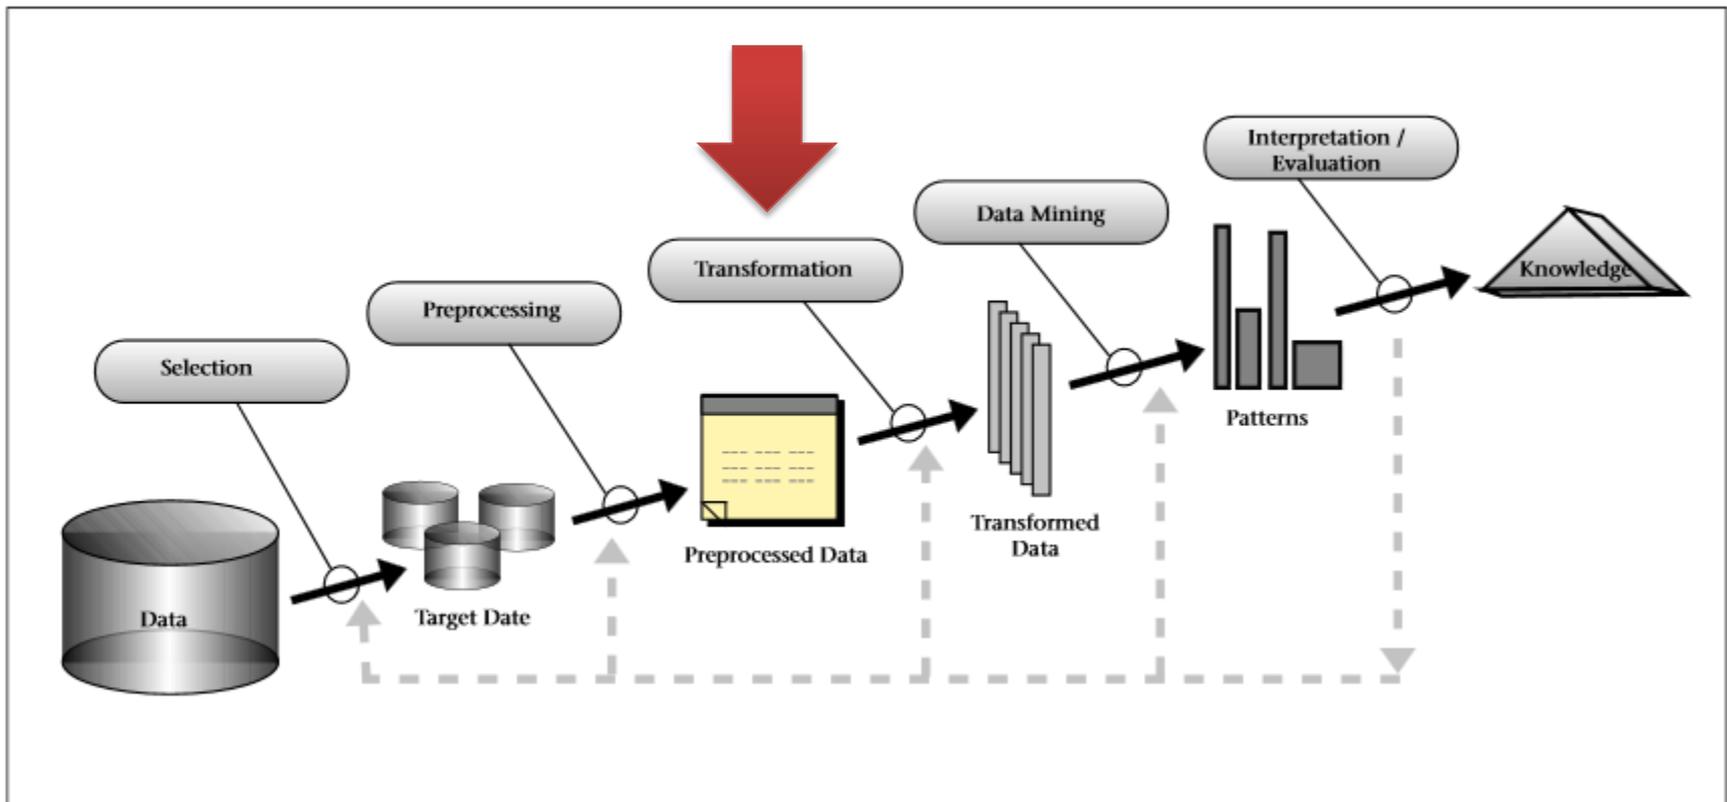
# Preprocessing von Dokumenten

- Wie sehen Dokumente aus?
  - Semistrukturierte Text-Dokumente

# Preprocessing von Dokumenten

- Normalisierung
- Stemming
- Stopword-Eliminierung

# Textmining



[FPSS96]

# Transformation

- Dokument „Bag of Words“
- Feature-Vektor über Vector Space Model (VSP)
- Jeder Term als eine Dimension:

	(Apple,	banana,	cat,	window)	
doc1 =	( 5,	3,	0,	4	)
doc2 =	( 4,	6,	0,	3	)
doc3 =	( 0,	3,	7,	5	)
doc4 =	( 8,	0,	9,	0	)
doc5 =	( 5,	0,	0,	3	)

[LIU12]

- Key-Words Extraction

# Distanzfunktion

- Einfache Distanz nach Euklid:

$$\text{dist}_{\text{Euklid}}(v, w) = \sqrt{\sum_i (v_i - w_i)^2}$$

[CLEV14]

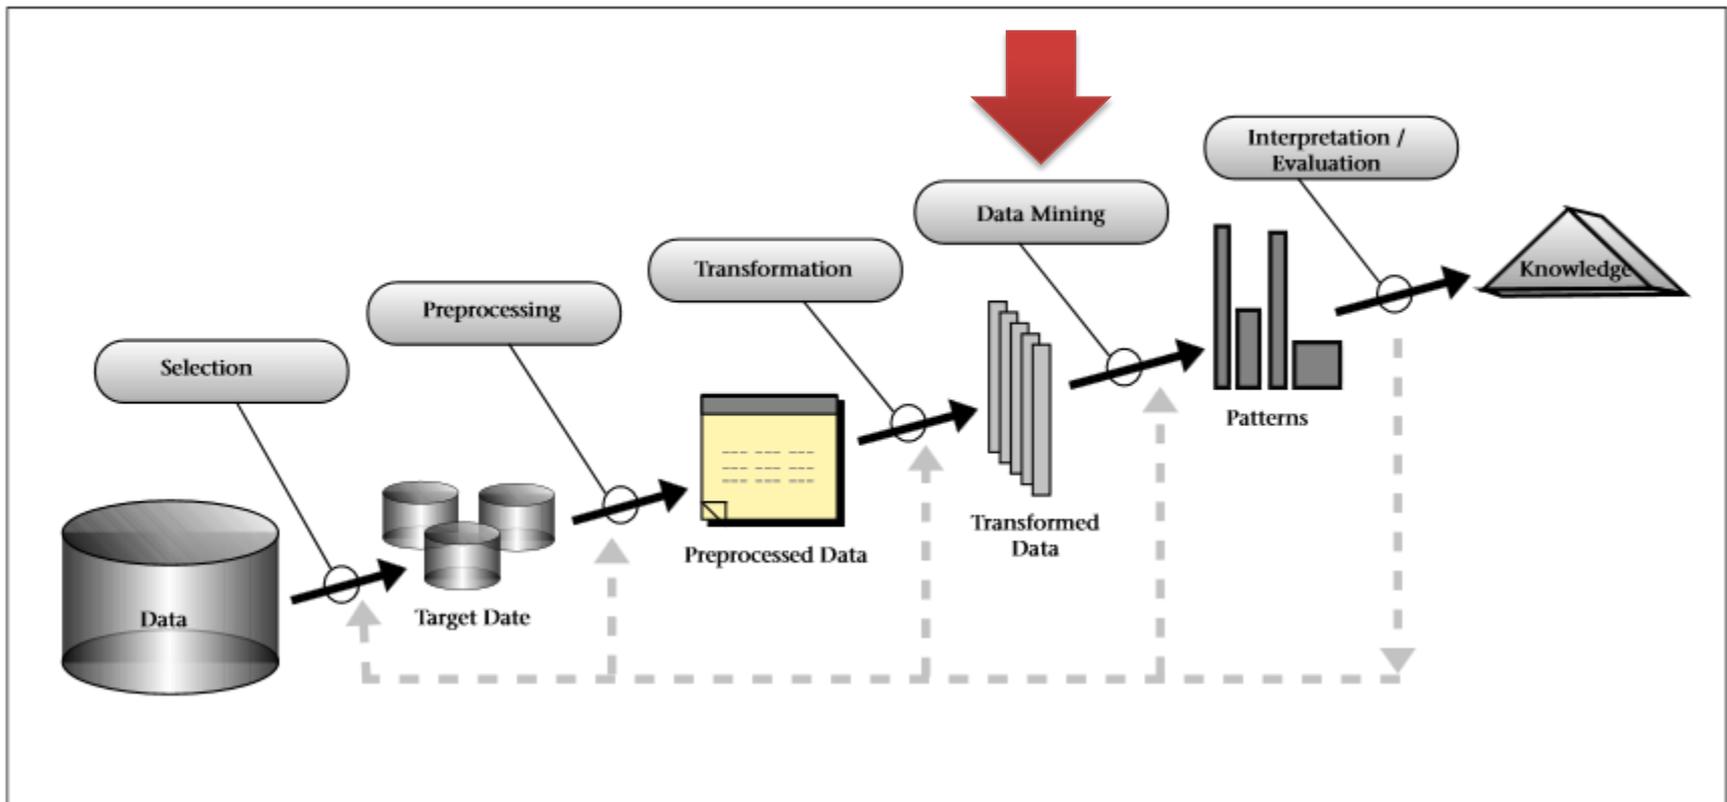
# Distanzfunktion (2)

- Cosinus-Ähnlichkeitsmaß
  - Am meisten verbreitet beim Clustering [Feld07]

$$\cos(x, y) = \frac{\sum_i x_i * y_i}{\sqrt{\sum_i x_i^2 * \sum_i y_i^2}}$$

[CLEV14]

# Textmining



[FPSS96]

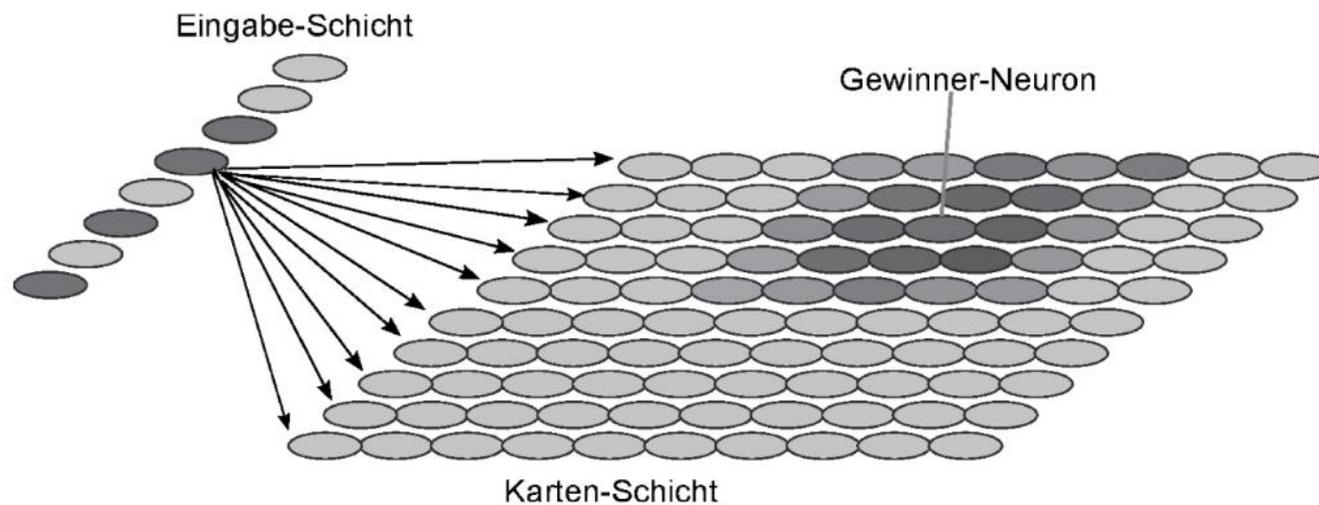
# Anwendungsklassen des Data Mining

- Klassifizierung ( ✓ )
- Cluster-Analyse ✓
- Assoziationsanalyse ✗
- Numerische Vorhersage ✗

# Cluster-Analyse

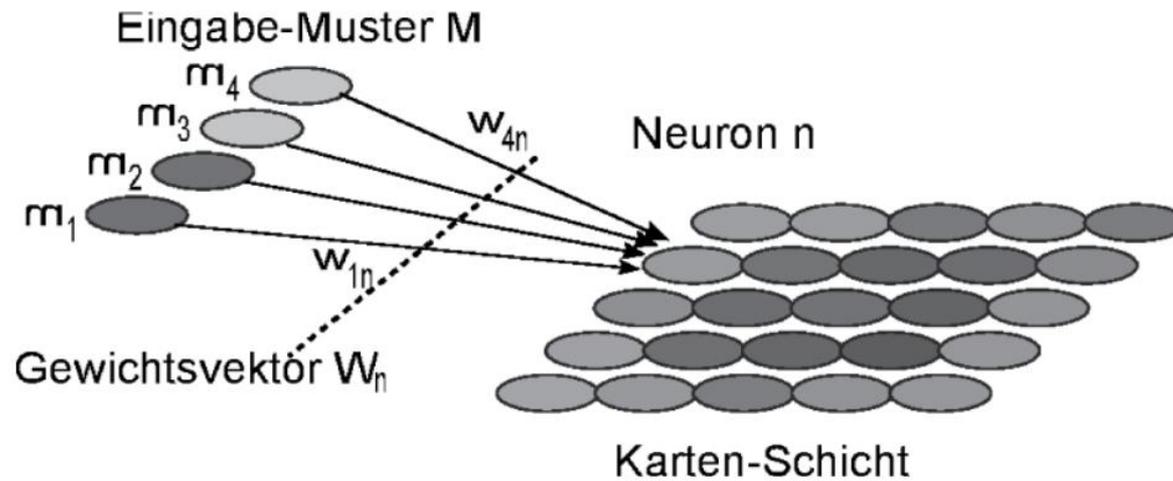
- K-means Algorithmus
  - Einfaches, populäres Verfahren nach MacQueen [Mac67]
- Künstliche neuronale Netze
  - Selbstorganisierte Karten
  - Neuronale Gase
  - ART-Netze

# Clusterbildung mittels Self Organizing Map (SOM)



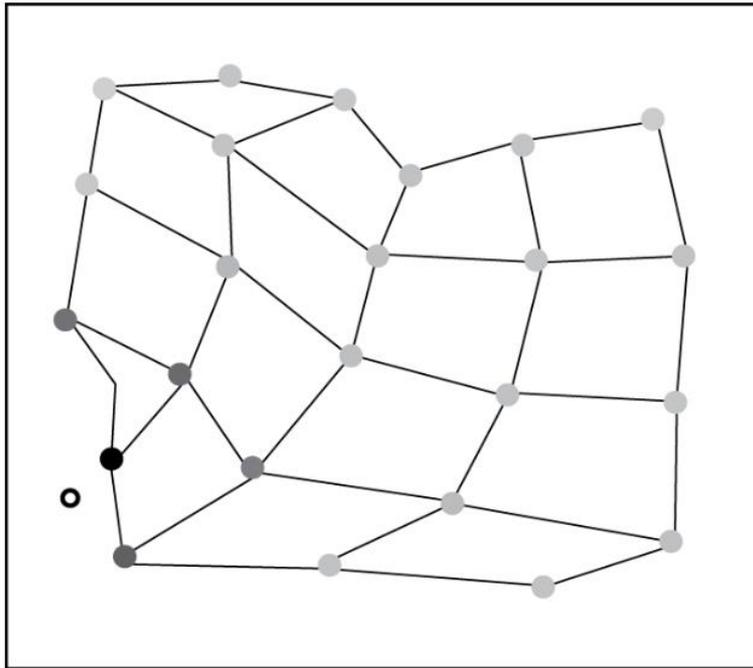
[CLEV14]

# SOM (2)



[CLEV14]

# SOM (3)



Ring - Eingabe  
schwarz - Gewinner-Neuron  
grau - Nachbarschaft  
hellgrau - unbeeinflusst

[CLEV14]

# SOM (4)

Position	Merkmal	Position	Merkmal
1	klein	8	Mähne
2	mittel	9	Federn
3	groß	10	jagt
4	2 Beine	11	rennt
5	4 Beine	12	fliegt
6	Haare	13	schwimmt
7	Hufe		


[CLEV14]

# SOM (5)

Tier	1	2	3	4	5	6	7	8	9	10	11	12	13
Taube	1	0	0	1	0	0	0	0	1	0	0	1	0
Henne	1	0	0	1	0	0	0	0	1	0	0	0	0
Ente	1	0	0	1	0	0	0	0	1	0	0	0	1
Gans	1	0	0	1	0	0	0	0	1	0	0	1	1
Eule	1	0	0	1	0	0	0	0	1	1	0	1	0
Falke	1	0	0	1	0	0	0	0	1	1	0	1	0
Adler	0	1	0	1	0	0	0	0	1	1	0	1	0
Fuchs	0	1	0	0	1	1	0	0	0	1	0	0	0
Hund	0	1	0	0	1	1	0	0	0	0	1	0	0
Wolf	0	1	0	0	1	1	0	1	0	1	1	0	0
Katze	1	0	0	0	1	1	0	0	0	1	0	0	0
Tiger	0	0	1	0	1	1	0	0	0	1	1	0	0
Loewe	0	0	1	0	1	1	0	1	0	1	1	0	0
Pferd	0	0	1	0	1	1	1	1	0	0	1	0	0
Zebra	0	0	1	0	1	1	1	1	0	0	1	0	0
Kuh	0	0	1	0	1	1	1	0	0	0	0	0	0

[CLEV14]

# SOM (6)



[CLEV14], Tool: SoKo-Wismar (Self-Organizing Kohonen Map)

# Gliederung

- Motivation
- Textmining
- **Tools**
- Aktueller Stand
- Ausblick
- Konferenzen & Forschung

# Tools zum Textmining

- Rapidminer (YALE)
- Weka (Waikato Environment for Knowledge Analysis)
- Beagle Search (Apache Lucene)
- Hadoop mit z.B. Apache Tez oder Apache Mahout auf Spark

# Gliederung

- Motivation
- Textmining
- Tools
- **Aktueller Stand**
- Ausblick
- Konferenzen & Forschung

# Aktueller Stand

- Vorarbeit durch Marcel Schöneberg (M.-Inf.), Nina Hälker (M.-Next Media)
- Datenbasis Eurozine Netzwerk ([www.eurozine.com](http://www.eurozine.com)) [Sch2014]
  - 2700 Journalistische Artikel
  - Meta-Informationen
  - semi-strukturiert in XML (Autor, Abstract, Überschriften usw.)
  - Größtenteils englisch

# Aktueller Stand (2)

- Einfache Distanzfunktion
  - Distanz nach Euklid gemäß Gewichtung
- Dossier-Vorschläge anhand ähnlicher Dokumente
- Keine multimedialen Dossiers

# Gliederung

- Motivation
- Textmining
- Tools
- Aktueller Stand
- **Ausblick**
- Konferenzen & Forschung

# Ausblick

- Verbesserung der Gewichtung durch Kenntnis der Fachdomäne
- Linguistische Verbesserungen
- Optimierung der Distanzfunktion
- Evaluierung von Methoden zum Clustering
- Entwicklung einer Toolchain

# Gliederung

- Motivation
- Textmining
- Tools
- Aktueller Stand
- Ausblick
- **Konferenzen & Forschung**

# Konferenzen

- ACM SIGKDD
  - Knowledge Discovery & Data Mining
- ACM SIGMOD
  - Management of Data
- IEEE Big Data 2014
- ISC Big Data

# Forschung (Digital Journalism)

- Center for Digital Journalism
  - Jay Rosen
- Digital Storytelling
  - Bryan Alexander

# Quellen

- [Clev14] CLEVE, Jürgen; LÄMMEL, Uwe: *Data Mining*. De Gruyter, 2014
- [Grim13] GRIMMER, Justin; STEWARD, Brandon M.: *Text as Data: The Promise and Pitfalls of Automatic Content Analysis Methods for Political Texts*. Stanford University, 2013
- [FPSS96] FAYYAD, Usma M.; PIATETSKY-SHAPIRO, Gregory; SMYTH, Padhraic: *From Data Mining to Knowledge Discovery: An Overview*. In: FAYYAD, Usama M.; PIATETSKY-SHAPIRO, Gregory; SMYTH, Padhraic; UTHURU-SAMY, Ramasamy (Hrsg.): *Advances in Knowledge Discovery and Data Mining*. Menlo Park, Cambridge, London: MIT Press, 1996, S. 1-34
- [Sch14] SCHÖNEBERG, Marcel: *Automatisierte Erstellung von Pressedossiers durch Textmining: Kontextualisierung im journalistischen Umfeld*. 2014 – Masterseminar Ausarbeitung
- [Feld07] FELDMAN, Ronen; SANGER, James: *The Text Mining Handbook: Advanced Approaches in Analysing Unstructured Data*. Cambridge University Press, 2007
- [Mac67] MACQUEEN, J.: *Some methods for classification and analysis of multivariate observations*. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1: 281–97. London, UK: Cambridge University Press 1967.
- [Lui12] LIU, Yuan-Chao; LIU, Ming; WANG, Ming: *Application of Self-Organizing Maps in Text Clustering: A Review, Applications of Self-Organizing Maps*. 2012

Vielen Dank für die Aufmerksamkeit!

Gibt es Fragen?

