

Cluster-Labeling

Paradigmen und Validierung

Dennis Hoppe

Bauhaus-Universität Weimar

29. Juni 2010

Motivation

The screenshot shows a Google search results page for the query "antibiotics". The search bar at the top contains the text "antibiotics". Below the search bar, it says "Ungefähr 21.100.000 Ergebnisse (0,52 Sekunden)". On the right side of the search bar is a "Suche" button. To the right of the search bar is a link to "Erweiterte Suche".

The search results are listed in three sections:

- Alles**:
Tipp: [Suchen nur nach Ergebnissen auf Deutsch](#). Sie können Ihre bevorzugten Spracheinstellungen in [Einstellungen](#) angeben.
Antibiotic - Wikipedia, the free encyclopedia - [Diese Seite übersetzen]
In common usage, an **antibiotic** (from the Ancient Greek: ἀντί – anti, "against", and βίος – bios, "life") is a substance or compound that kills bacteria or ...
en.wikipedia.org/wiki/Antibiotic - Im Cache - Ähnliche
- Das Web**:
Seiten auf Deutsch
Seiten aus Deutschland
Alle
Letzte 2 Tage
Antibiotics: MedlinePlus - [Diese Seite übersetzen]
Antibiotics are powerful medicines that fight bacterial infections. Used properly, **antibiotics** can save lives. They either kill bacteria or keep them from ...
www.nlm.nih.gov/medlineplus/antibiotics.html - Im Cache - Ähnliche
- Antibiotics** - [Diese Seite übersetzen]
Antibiotics are among the most frequently prescribed medications in modern medicine.
Antibiotics cure disease by killing or injuring bacteria. ...
[www.emedicinehealth.com › home › topics_az_list](http://www.emedicinehealth.com/home/topics_az_list) - Im Cache - Ähnliche

Abbildung: Suchmaschine Google (www.google.de)

Motivation

The screenshot shows the Carrot Search interface. At the top, there is a navigation bar with links to Web, MSN, Yahoo, Wiki, Images, News, Jobs, and PubMed. Below the navigation bar is a search bar containing the query "antibiotics". To the right of the search bar are a "Search" button and a "More options" link. The interface includes tabs for "Tree" and "Visualization", with "Tree" currently selected. On the left, a tree view displays categories such as All Topics (100), Infections (21), Bacteria (14), Drugs (14), and Antibiotics Work (8). The main content area on the right shows search results for "Cluster Infections" with 21 documents. The first result is a link to MedlinePlus titled "Antibiotics: MedlinePlus". Subsequent results include "Using Antibiotics Wisely-Topic Overview", "Antibiotics: Infections: Merck Manual Home Edition", and "Antibiotics and pandemic flu". Each result entry includes a snippet of text, a URL, and small icons for sharing or viewing.

Cluster Infections with 21 documents ([search for more like this](#))

3 | [Antibiotics: MedlinePlus](#)

Antibiotics are powerful medicines that fight bacterial infections.
http://www.nlm.nih.gov/medlineplus/antibiotics.html [Ask, Bluewi]

7 | [Using Antibiotics Wisely-Topic Overview](#)

Dec 17, 2009 ... What are **antibiotics**?**Antibiotics** are medicines
http://www.webmd.com/a-to-z-guides/using-antibiotics-wisely-topi

12 | [Antibiotics: Infections: Merck Manual Home Edition](#)

Although doctors try to use **antibiotics** for specific bacterial infect
http://www.merck.com/mmhe/sec17/ch192/ch192a.html [Ask, E]

27 | [Antibiotics and pandemic flu](#)

The risk of misusing **antibiotics** is increased by the threat posed
http://www.ecdc.europa.eu/en/eaad/antibiotics/Pages/messagesA

Abbildung: Suchmaschine Carrot Search (www.carrotsearch.com)



Agenda

1 Validierung von Cluster-Labeling-Verfahren

2 Paradigmen des Cluster-Labelings

Validierung von Cluster-Labeling-Verfahren

Ziel ist die Bestimmung der Güte eines Cluster-Labels

- a) Übereinstimmung mit einer externen Referenz prüfen
- b) Validierung anhand intrinsischer Qualitätsmaße
- c) Durchführung von Benutzerstudien

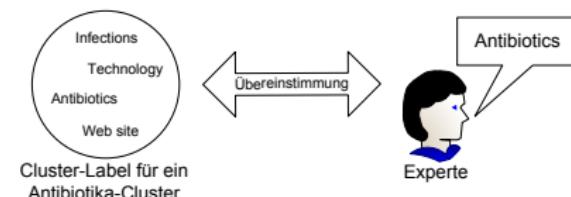
Externe Validierung von Cluster-Labeln



Externe Validierung von Cluster-Labeln

Externe Validierungsmaße

- Precision@N,
- Match@N und
- Mean Reciprocal Rank



Referenz-Label: Antibiotics

Cluster-Label $\tau(c)$: Infections, Antibiotics, Technology, Web site

Maß	$N = 1$	$N = 2$	$N = 3$	$N = 4$
Precision@N	0	1/2	1/3	1/4

Externe Referenz: Open Directory Project (ODP)

The screenshot shows the homepage of the Open Directory Project (ODP). The header features the logo "dmoz open directory project". Below the header is a navigation bar with links for "about", "submit", "privacy", and "FAQ". A search bar is present with the placeholder "Search the entire site".

Top: Health: Pharmacy: Drugs and Medications (2,393)

[[A](#) | [B](#) | [C](#) | [D](#) | [E](#) | [F](#) | [G](#) | [H](#) | [I](#) | [J](#) | [K](#) | [L](#) | [M](#) | [N](#) | [O](#) | [P](#) | [Q](#) | [R](#)]

-
- [Analgesics and Anti-Inflammatories](#) (3)
 - [Antianxiety Agents](#) (5)
 - [Antiasthmatic](#) (3)
 - [Antibiotics](#) (22)
 - [Antidepressants](#) (15)
 - [Anti-Epileptic Drugs](#) (6)
 - [Antihistamines](#) (2)
 - [Antihypertensives](#) (3)
 - [Antipsychotics](#) (3)
 - [Beta Blockers](#) (3)
 - [Chemotherapy Drugs](#) (3)
 - [Lipid-Lowering Agents](#) (4)
 - [Stimulants](#) (4)
 - [Vaccines and Antisera](#) (2)
 - [Vitamins and Minerals](#) (3)

Abbildung: Open Directory Project (www.dmoz.org)



Intrinsische Eigenschaften von Cluster-Labeln

Was wird von einem guten Cluster-Label erwartet?

- Verständlichkeit
- Überdeckung
- Trennschärfe
- Minimale Überlappung
- Eindeutigkeit
- Redundanzfreiheit

Intrinsische Eigenschaft: Verständlichkeit (f_1)

Informell: Ein Nutzer soll eine klare Vorstellung vom Inhalt eines Clusters bekommen.

Formal: $\forall_{c \in \mathcal{C}} \forall_{p \in \tau(c)} : |p| > 1 \wedge p \in L(G)$

Nominalphrasen (NP)

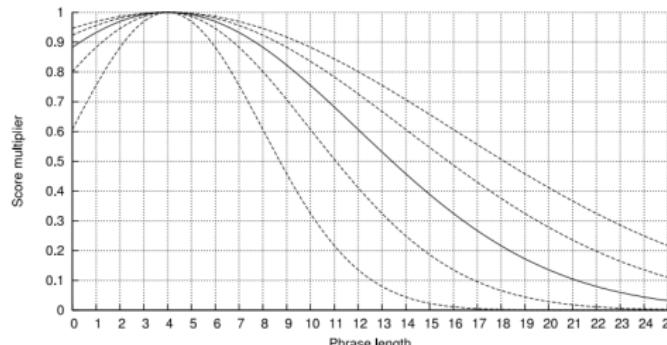
- „Antibiotika sind bakteriell wirkende Arzneistoffe.“
- „Antibiotika“ und „bakteriell wirkende Arzneistoffe“

Intrinsische Eigenschaft: Verständlichkeit (f_1)

Validierungsmaß: $f_1(p) = \text{penalty}(p) \cdot \text{NP}(p)$, mit

$$\text{penalty}(p) := \begin{cases} \exp \frac{-(|p| - |p|_{\text{opt}})^2}{2 \cdot d^2} & , \text{ wenn } |p| > 1 \\ 0,5 & , \text{ sonst} \end{cases}$$

$$\text{NP}(p) := \begin{cases} 1 & , \text{ wenn } p \in L(G) \\ 0 & , \text{ sonst} \end{cases}$$



Intrinsische Eigenschaft: Überdeckung (f_2)

Informell: Cluster-Label sollen in allen Dokumenten des Clusters vorkommen.

Formal: $\forall_{c \in \mathcal{C}} \exists_{p \in \tau(c)} \forall_{\substack{p' \in P_c \\ p' \notin \tau(c)}} : df_c(p') \ll df_c(p)$,

mit P_c der Menge von Phrasen im Cluster c .

Validierungsmaß: $f_2(c, p) = 1 - \frac{1}{|P_c \setminus \tau(c)|} \sum_{\substack{p' \in P_c \\ p' \notin \tau(c)}} \frac{df(p')}{df(p)}$

Intrinsische Eigenschaft: Trennschärfe (f_3)

Informell: Cluster-Label sollen *nur* in Dokumenten des eigenen Clusters vorkommen.

Formal: $\forall_{c_i, c_j \in \mathcal{C}} \exists_{p \in \tau(c_j)} : \frac{\text{df}_{c_i}(p)}{|c_i|} \ll \frac{\text{df}_{c_j}(p)}{|c_j|}$

Validierungsmaß: $f_3(c_j, p) = 1 - \frac{1}{k-1} \sum_{\substack{c_i \in \mathcal{C} \\ c_i \neq c_j}} \frac{|c_j|}{|c_i|} \frac{\text{df}_{c_i}(p)}{\text{df}_{c_j}(p)}$

Intrinsische Eigenschaft: Minimale Überlappung (f_4)

Informell: Jedes Dokument soll nur in einem Cluster vorkommen.

Formal: $\forall_{\substack{c_i, c_j \in \mathcal{C} \\ c_i \neq c_j}} \exists_{p \in \tau(c_j)} : \frac{|c_i(p) \cap c_j(p)|}{|c_i(p) \cup c_j(p)|} \ll 1$

Validierungsmaß: $f_4(c_j, p) = 1 - \frac{1}{k-1} \sum_{\substack{c_i \in \mathcal{C} \\ c_i \neq c_j}} \frac{|c_i(p) \cap c_j(p)|}{|c_i(p) \cup c_j(p)|}$

Beispiel: Trennschärfe und Minimale Überlappung

$p = \text{Antibiotics}$

$$|c_j| = 20$$

$$df_{c_j}(p) = 20$$

$$|c_i| = 10$$

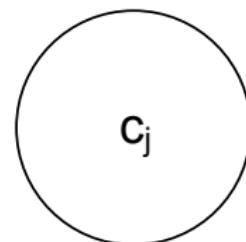
$$df_{c_i}(p) = 10$$

$$c_j \cap c_i = \emptyset$$

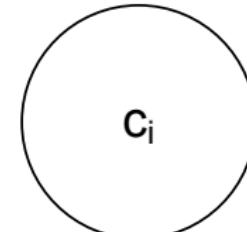
$$f_3(c_j, p) = 0 \text{ (Trennschärfe)}$$

$$f_4(c_j, p) = 1 \text{ (Minimale Überlappung)}$$

Antibiotics



Health



Intrinsische Eigenschaft: Eindeutigkeit (f_5)

Informell: Cluster-Label eines Clusterings sollen unterschiedlich sein.

Formal: $\forall_{\substack{c_i, c_j \in \mathcal{C} \\ c_i \neq c_j}} : \tau(c_i) \cap \tau(c_j) = \emptyset$

Validierungsmaß: $f_5(c_j, p) = 1 - \frac{1}{k-1} \sum_{\substack{c_i \in \mathcal{C} \\ c_i \neq c_j}} \frac{|p \cap \tau(c_i)|}{|p \cup \tau(c_j)|}$

Intrinsische Eigenschaft: Redundanzfreiheit (f_6)

Informell: Cluster-Label sollen keine Synonyme enthalten.

Formal: $\forall_{c \in \mathcal{C}} \forall_{\substack{p, p' \in \tau(c) \\ p \neq p'}} : p \text{ und } p' \text{ sind nicht synonym}$

Validierungsmaß: $f_6(c, p) = 1 - \frac{1}{|\tau(c)|-1} \sum_{\substack{p' \in \tau(c) \\ p' \neq p}} \text{syn}(p, p')$,

mit $\text{syn} : p \times p \mapsto \{0, 1\}$

Bewertung der Relevanz einer Phrase für ein Cluster

- Relevanz rel einer Phrase p für ein Cluster c ist definiert mit

$$rel = \sum_{i=1}^6 f_i(c, p)$$

- f_1 Verständlichkeit
- f_2 Überdeckung
- f_3 Trennschärfe
- f_4 Minimale Überlappung
- f_5 Eindeutigkeit
- f_6 Redundanzfreiheit

Validierung quantifizierter intrinsischer Label-Eigenschaften

Wählen Qualitätsmaße gute Phrasen aus?

ODP-Kategorie	Besten 5 Phrasen	Schlechteste 5 Phrasen
Antibiotics	used Antibiotics other Antibiotics Antibiotics Health Antibiotics Antibiotics Antibiotics Work	Technology queries project Print time
Psycho	Psycho Bates Motel Norman Marion Crane Janet Leigh shower scene Hitchcock Martin Balsam	User TOPIC mail list release

Neues internes Validierungsmaß

Normalized Discounted Cumulative Gain (NDCG) (Järvelin & Kekäläinen, 2002)

- $DCG@N = \sum_{i=1}^N (2^{rel_i} - 1) / (\log_2(1 + i))$
- Normierung anhand der idealen Relevanzliste $\rightarrow NDCG$

N	Phrase	Relevanz
1	Infections	4
2	Web site	1
3	Technology	0
4	Antibiotics	6
NDCG@4		0,27

N	Phrase	Relevanz
1	Antibiotics	6
2	Infections	4
3	Technology	0
4	Web site	1
NDCG@4		0,45

Korrelation von NDCG mit externem Validierungsmaß

Linearen Zusammenhang zwischen P@N & NDCG@N zeigen

- Korrelationskoeffizient (Kor) nach Pearson
- t-Test belegt statistisch signifikanten Zusammenhang beider Merkmale, wenn für die Prüfgröße (PG) gilt: $PG > t$

N	Kor(P@N,NDCG@N)	PG	$t_{(0,99;10)}$
1	0,72	3,28	3,169
2	0,90	6,70	3,169
3	0,93	8,46	3,169
4	0,96	11,71	3,169
5	0,97	13,99	3,169

Agenda

1 Validierung von Cluster-Labeling-Verfahren

2 Paradigmen des Cluster-Labelings

Paradigmen des Cluster-Labelings

1 Datenzentrierte Ansätze

- Frequent Predictive Words
- Weighted Centroid Covering

2 Beschreibungsbeachtende Ansätze

- Suffixbaum-Clustering

3 Beschreibungszentrierte Ansätze

- Topical k -Means
- Descriptive k -Means
- Lingo

Beispiel: Frequent Predictive Words

Um welche Kategorien handelt es sich?

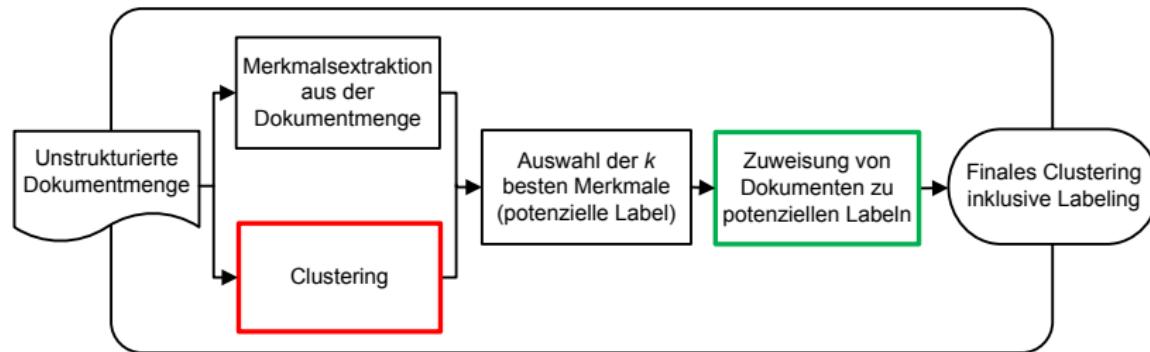
ODP-Kategorie	Cluster-Label
?	spice, slicer, told, fred, baker
?	excel, jeremy, demo, authentic, forum
?	hat, document, project, string, release
?	data, address, match, bow, custom
?	antibiotics, disease, infection, bacteria, drug

Beispiel: Frequent Predictive Words

Um welche Kategorien handelt es sich?

ODP-Kategorie	Cluster-Label
IBM DB2	spice, slicer, told, fred, baker
MySQL	excel, jeremy, demo, authentic, forum
PostgreSQL	hat, document, project, string, release
Data Warehousing	data, address, match, bow, custom
Antibiotics	antibiotics, disease, infection, bacteria, drug

Beschreibungsorientierte Ansätze



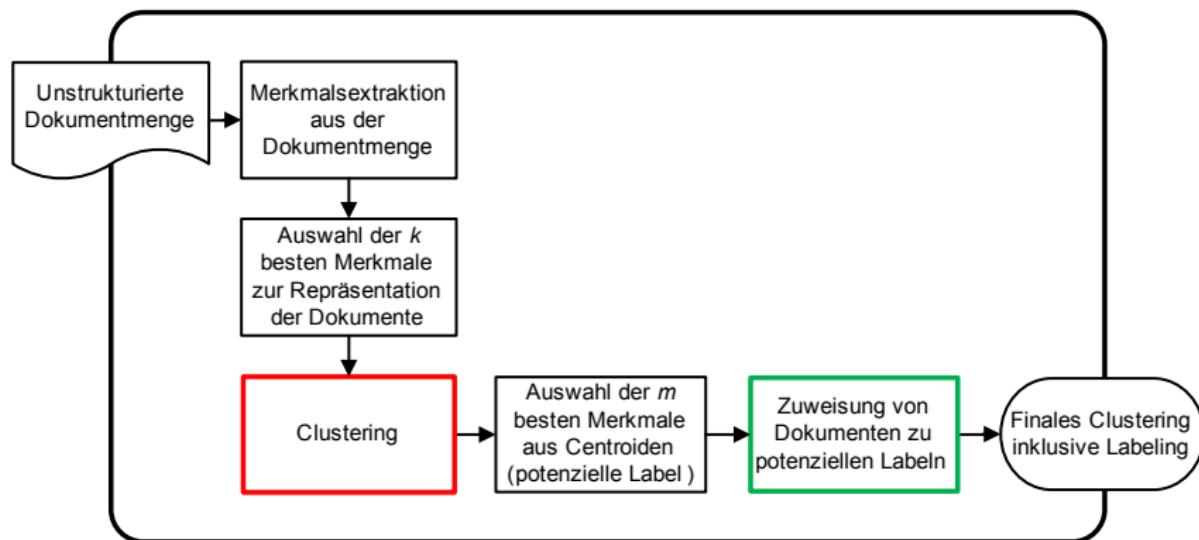
Untersuchte Verfahren

- Descriptive k -Means (Weiss, 2006)
- Lingo (Osinski u. a., 2004)

Beispiel: Descriptive k -Means

ODP-Kategorie	Cluster-Label
IBM DB2	IBM Data Management, IBM SQL Partners
MySQL	SQL Server, MySQL database server
PostgreSQL	PostgreSQL database system
Data Warehousing	data quality management solutions
Antibiotics	Antibiotic Resistant Bacteria

Neues Verfahren: Topical k -Means



Topical k -Means

Informativeness einer Phrase (Tomokiyo & Hurst, 2003)

- Welche Phrase sagt am meisten über ein Cluster aus?
- Abgrenzung einer Phrase von den restlichen Clustern

Sinnvolle Phrase für Cluster c_j ?

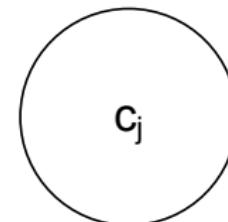
$p_1 = \text{MySQL}$

$p_2 = \text{SQL}$

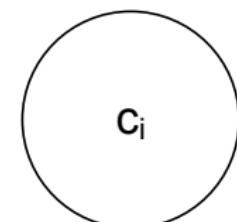
$p_3 = \text{Database}$

$p_4 = \text{PostgreSQL}$

MySQL



PostgreSQL



Auswertung

Verfahren	Precision@1	NDCG@1
Nominalphrasen	0,40	0,74
Frequent and Predictive Words	0,20	0,64
Descriptive k -Means	0,61	0,82
Topical k -Means	0,55	0,84

Qualität von Cluster-Labeln steigt bei Verwendung von

- Nominalphrasen
- einer Referenzkategorisierung

Auswertung

Verfahren	f_1	f_2	f_3	f_4	f_5	f_6
Schlüsselwortverfahren	0.79	0.66	0.37	1.00	0.94	0.99
Datenzentrierte Ansätze	0.39	0.59	0.63	1.00	0.97	1.00
Beschreibungsbeachtende Ansätze	0.73	0.70	0.89	0.68	1.00	0.99
Beschreibungszentrierte Ansätze	0.91	0.64	0.91	0.44	1.00	1.00

f_1 Verständlichkeit

f_2 Überdeckung

f_3 Trennschärfe

f_4 Minimale Überlappung

f_5 Eindeutigkeit

f_6 Redundanzfreiheit

Zusammenfassung

- 1 Validierung von Cluster-Labeling-Verfahren
- 2 Paradigmen des Cluster-Labelings

Ausblick

- Hierarchisches Cluster-Labeling
- Gewichtung intrinsischer Validierungsmaße
- Einsatz neuer Schlüsselwortverfahren
- Verwendung von externem Wissen

Erkennung von Themen in Dokumentmengen

automatic-taxonomy-generation
text-summarization automatic-
labeling faceted-search keyword-
extraction labeling-of-topic-models
search-result-clustering self-organizing-maps tag-clouds text-
classification topic-detection-and-
tracking

Referenzen

- [Järvelin & Kekäläinen 2002] Järvelin, Kalervo ; Kekäläinen, Jaana: Cumulated gain-based evaluation of IR techniques. In: *ACM Transactions on Information Systems* 20 (2002), Oktober, Nr. 4, 446.
<http://dx.doi.org/10.1145/582415.582418>. – DOI 10.1145/582415.582418. – ISSN 10468188
- [Osinski u. a. 2004] Osinski, S. ; Stefanowski, J. ; Weiss, D.: Lingo: Search results clustering algorithm based on singular value decomposition. In: *Intelligent information processing and web mining: proceedings of the International IIS: IIPWM'04 Conference held in Zakopane, Poland, Mai 17-20, 2004*, Springer Verlag, 2004, 359
- [Tomokiyo & Hurst 2003] Tomokiyo, T. ; Hurst, M.: A language model approach to keyphrase extraction. In: *Proceedings of the ACL Workshop on Multiword Expressions*, 2003, 3440
- [Weiss 2006] Weiss, D.: *Descriptive clustering as a method for exploring text collections*. 2006