

98. Deutscher Bibliothekartag in Erfurt  
Ein neuer Blick auf Bibliotheken  
TK10: Information erschließen und recherchieren  
**Inhalte erschließen – mit neuen Tools**



Fundy-Nationalpark  
ul, 25. Mai 2008

# Automatische DDC-Klassifizierung von bibliografischen Titeldatensätzen

Ulrike Reiner

Verbundzentrale des Gemeinsamen Bibliotheksverbundes (VZG)

# Automatische DDC-Klassifizierung von bibliografischen Titeldatensätzen

## - Inhalt des Vortrages -



Fundy-Nationalpark  
ul, 25. Mai 2008

### ▪ Inhalte erschließen –

- Dewey Dezimalklassifikation (DDC)
- Bibliografische Titeldatensätze

025.47

### mit neuen Tools

- OCLC **classify** (an experimental classification web service)
- VZG Colibri/DDC ***vc\_dcl*** (*vzg colibri\_ddc classifier*)

025.47028

### ▪ VZG-Colibri/DDC-Wettbewerb

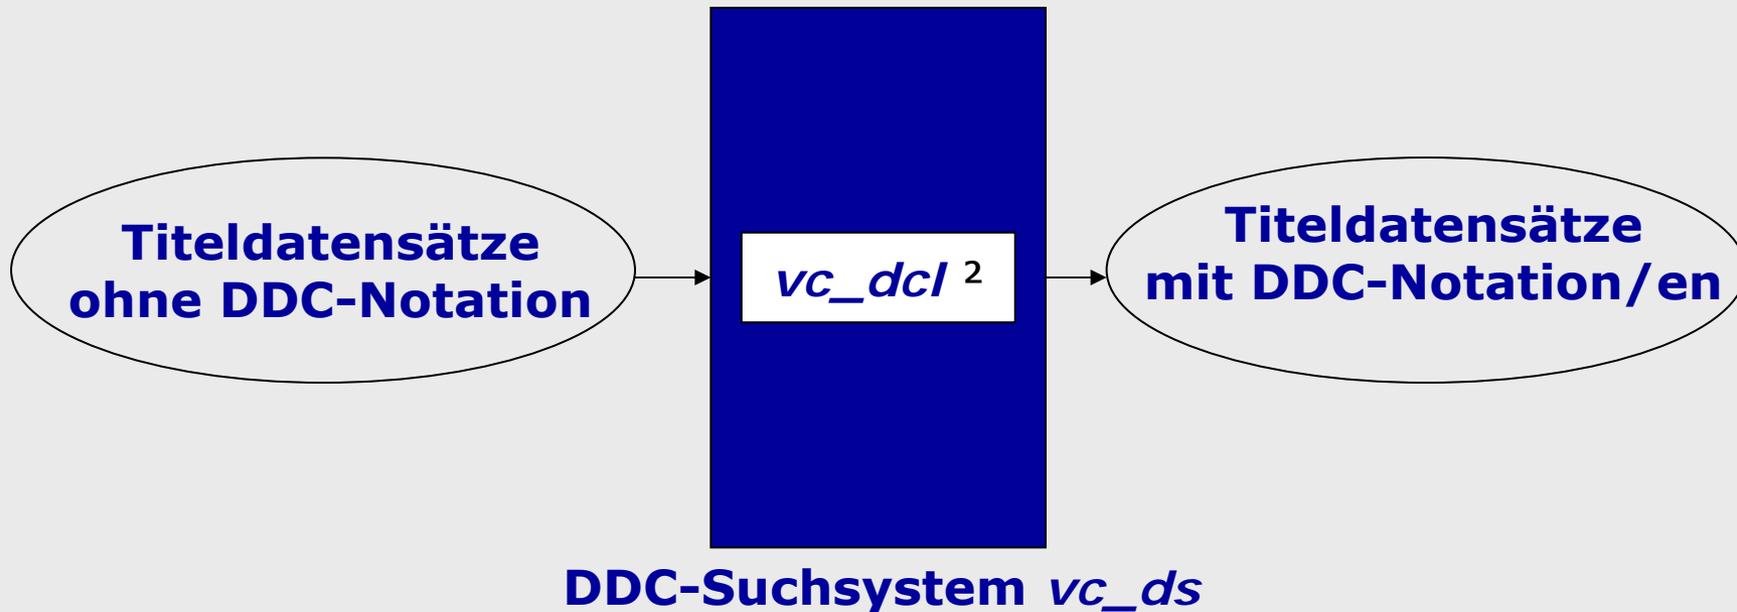
### ▪ Klassifizierungskomponente ***vc\_dcl***: Modell, Tests, Bewertung, Ergebnisse & Perspektiven

# Colibri/DDC - Forschungsfrage Q1



Fundy-Nationalpark  
ul, 25. Mai 2008

Ist es möglich, eine inhaltlich stimmige DDC-Titelklassifikation aller GVK-PLUS<sup>1</sup>-Titeldatensätze automatisch zu erzielen?



<sup>1</sup>GVK-PLUS: Gemeinsamer Verbundkatalog (GVK) und Online Contents (OLC); <sup>2</sup>*vzg colibri\_ddc classifier*

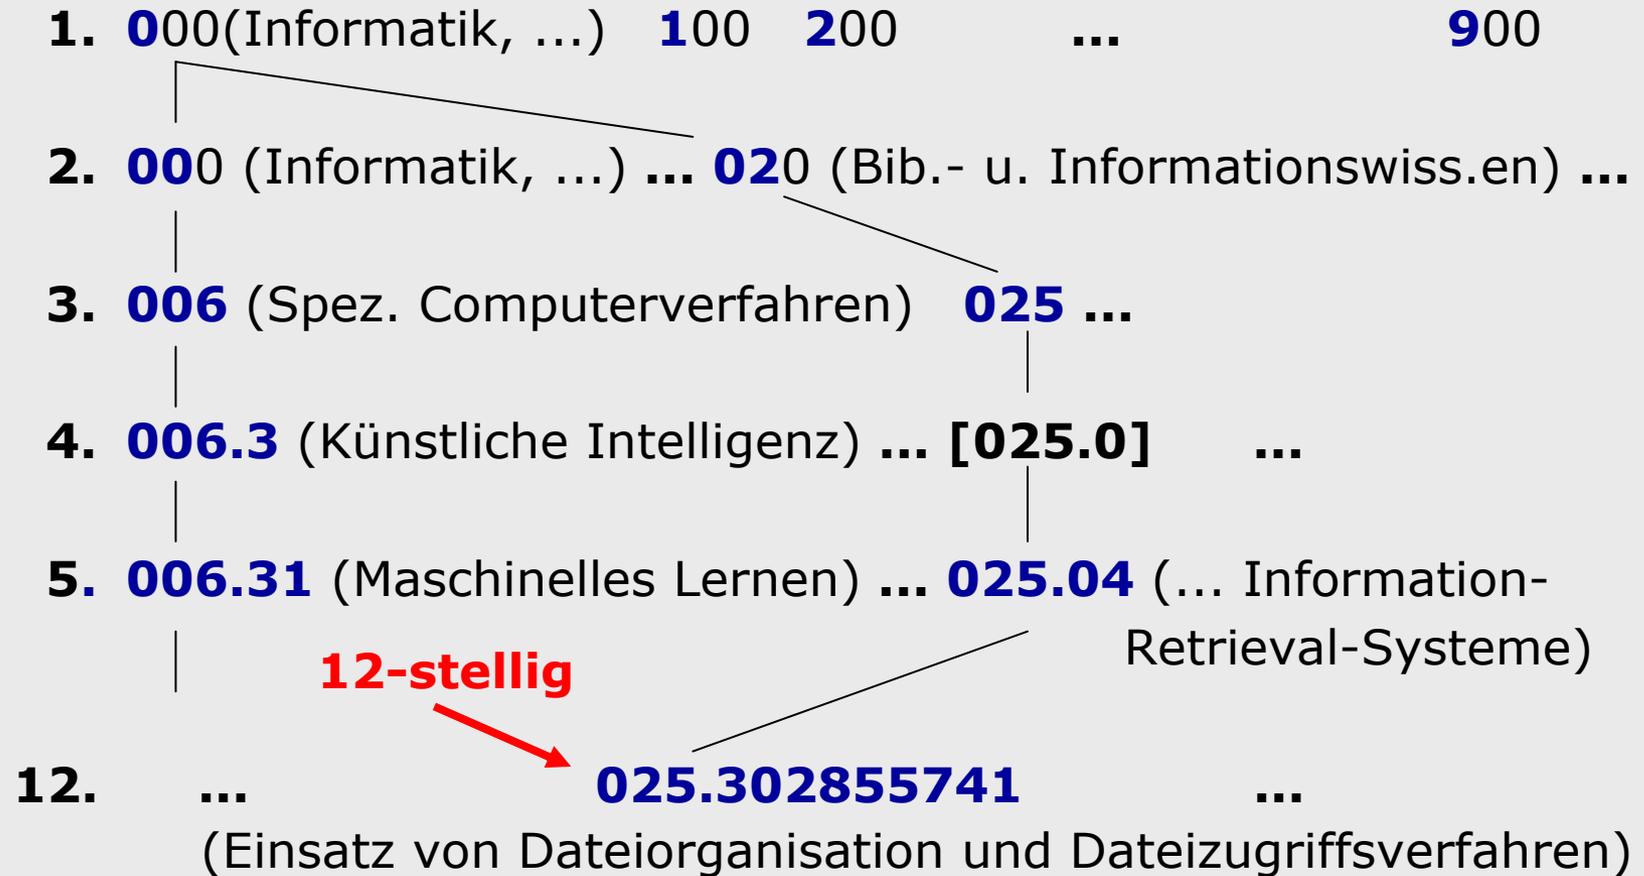
# Dewey-Dezimalklassifikation (DDC)

## DDC-Ausschnitt



Fundy-Nationalpark  
ul, 25. Mai 2008

### Ebene



DDC-Notationen: 26.715 (Haupttafeln); 9.356 (Hilftafeln); 13.919 (mit Regeln gebildete)

# DDC-Klassifizierung: ein Thema (**Kleidung**)– mehrere Systemstellen !



Fundy-Nationalpark  
ul, 25. Mai 2008

„Da die einzelnen Teile der DDC nach Fachgebieten und nicht nach Themen geordnet sind, kann **ein Thema mehrere Systemstellen** haben. So kann z. B. das Thema »**Kleidung**« unter verschiedenen Aspekten aus mehreren Fachgebieten gesehen werden. Die psychologische Wirkung von Kleidung gehört zu **155.95**, als Teil des Fachgebiets **Psychologie**; mit Kleidung verbundene Bräuche gehören als Teil des Fachs **Ethnologie** zu **391** und Kleidung im Sinn der Modeschöpfung gehört als Teil des Fachgebiets **Künste** zu **746.92**“

Hervorhebungen (Unterstreichungen, farbliche Markierungen) durch Autorin

[ **DDC 22 Dewey-Dezimalklassifikation und Register** (begr. von Melvil Dewey; hrsg. von Joan, S. Mitchell unter Mitwirk. von Julianne Beall; Giles Martin; Winton E. Matthews, Jr.; Gregroy R. New; Mitarbeit: Heidrun Alex; Anne Betz; Winfried Gödert; Magda Heiner-Freiling; Melanie Jackenkroll; Marlene Lambert; Tina Mengel; Michael Preuss; Esther Scheven; Lars G. Svensson). Dt. Ausgabe (hrsg. von Der Deutschen Bibliothek). Band 1, K.G. Saur, München, 2005, S. I ]

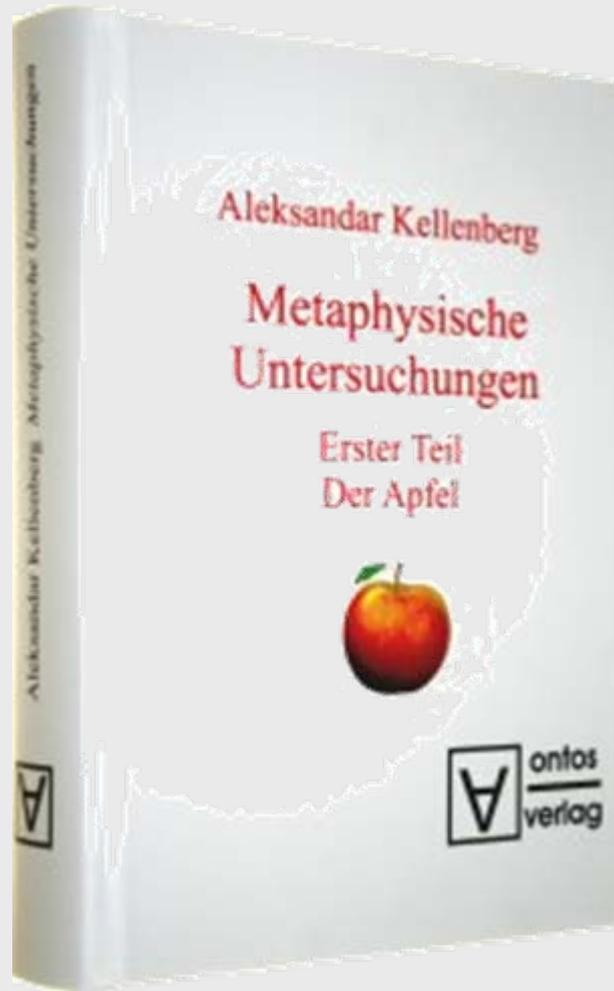


# Intellektuelle DDC-Klassifizierung

## Der Apfel: 110 (Metaphysik)



Fundy-Nationalpark  
ul, 25. Mai 2008



[ <http://cover.deutschesfachbuch.de/books/3938793627/bx.jpg> ]

# OCLC Classify

(an experimental classification web service)

## Der Apfel {372.133}



Fundy-Nationalpark  
ul, 25. Mai 2008

Classify - Mozilla Firefox

http://deweybrowser.oclc.org/classify2/Classify?swid=198826610

Jockweg, Bernd der apfel

Meistbesuchte Seiten Yahoo! Mail

Google Jockweg, Bernd der apfel Suche Lesezeichen PageRank Rechtschreibprüfung Übersetzen Senden an Jockweg Bernd der apfel Einstellungen

Classify EDUG 2009 025.431: Th... 98. Deutsch... GWK - Comm... OCLC Conn... Classify 9th Internat... Geocaching... Geocaching... Niedersächs... W Diagramm...

**Title:** Der Apfel  
**Author:** Jockweg, Bernd  
**Format:** Books & Audio Books **Editions:** 1 **Total Holdings:** 1

**Classification Summary**

DDC:	Class Number	Holdings
Most Frequent	<a href="#">372.133</a>	1
Most Recent	372.133	1

**Jockweg, Bernd: Der Apfel**  
**DDC Klasse: 372.133 (100%)**  
**(Unterrichtsmaterialien--Primärbildung)**

All DDC

372.133 (100.00%)

**Edition Details**

Editions: 1 to 1 of 1

[ <http://www.curriculum-online.de/itemsimages/9783867230179.jpg> ]

Title / Author	Lang.	Holdings	Tag	Class #	Library	Src.
Suchen: zelle Abwärts Aufwärts Hervorheben Groß-/Kleinschreibung Das Seitenende wurde erreicht, Suche vom Seitenanfang fortgesetzt						

Fertig

Start 9 12 C.. O.. C.. L.. 2 e.. N.. 12 M.. DE 17:39



# Intellektuelle DDC-Klassifizierung

**Mitt liv, min frihet : {297,...,920.72}**

Beispiel aus: [ Ingebjørg Rype; Magdalena Svanberg: Dewey in Scandinavia: exploring new translation models of Dewey]. Vortrag auf 3. EDUG-Symposium „Dewey goes Europe - On the Use and Development of the Dewey Decimal Classification (DDC) in European Libraries“, Vienna 28 April, 2009. [ <http://www.onb.ac.at/events/files/rype.ppt> ], p. 8



**Mitt liv, min frihet : en selvbiografi / Ayaan Hirsi Ali ; oversatt av Poul Henrik Poulsen**

**DDC Classification:**  
 297  
 305.486  
 305.486092  
 305.48697  
 305.486971092  
 920.0092  
 920.72

# OCLC Classify

## Mein Leben, meine Freiheit : {324.2092}



Fundy-Nationalpark  
ul, 25. Mai 2008

Classify - Mozilla Firefox

http://deweybrowser.oclc.org/classify2/Classify?swid=180710878

Meistbesuchte Seiten Yahoo! Mail

Google oclc classify Suche Lesezeichen PageRank Rechtschreibprüfung Übersetzen

OCLC Conn... Classify 9th Internat... Geocaching... Geocaching... Niedersächs... W Diagramm... solving myst... MelviClass /... WEB.DE Ask - Subjects Classify

### Summary

**Title:** Mein Leben, meine Freiheit Auszüge aus der Autobiographie ; gekürzte Lesung  
**Author:** Hirsi Ali, Ayaan  
**Format:** Computer Files **Editions:** 1 **Total Holdings:** 1

### Classification Summary

DDC:	Class Number	Holdings
Most Frequent	<a href="#">324.2092</a>	1
Most Recent	324.2092	1

All DDC

DDC

324.2092 (100.00%)

### Edition Details

Editions: 1 to 1 of 1

Suchen: hervor Abwärts Aufwärts Hervorheben Groß-/Kleinschreibung

Fertig

Start Start 9 12 C.. O.. 2 L.. 2 E.. 14 N.. W. DE 17:24

Hirsi Ali, Ayaan: **Mein Leben, meine Freiheit** (Holdings: 1)  
 DDC Klasse: 324.2092 (100%)  
 (Politiker--Biografien)

# OCLC Classify: The caged virgin - an emancipation proclamation for women and Islam {297.082,...,922.97}



Classify - Mozilla Firefox

http://deweybrowser.oclc.org/classify2/Classify?swid=058843388

**Title:** The caged virgin : an emancipation proclamation for women and Islam /  
**Author:** Hirsi Ali, Ayaan,  
**Format:** Books & Audio Books **Editions:** 16 **Total Holdings:** 1407

**Classification Summary**

DDC:	Class Number	Holdings
Most Frequent	<a href="#">297.082</a>	1251
Most Recent	305.48697	94
Latest Edition: 22	297.082	1251
Latest Edition: 22	305.48697	93
Latest Edition: 22	922.97	50

LCC:	Class Number	Holdings
Most Frequent	<a href="#">BP173.4</a>	1216
Most Recent	BP173.4	1216

**DDC**

**DDC Klassen:**

297.082	(88.91%)
305.48697	( 6.68%)
922.97	( 3.55%)
Unclassified	( 4.41%)

**Edition Details**

Editions: 1 to 16 of 16

Title / Author	Lang.	Holdings	Tag	Class #	Library	Src.
Suchen: zelle						

Hirsi Ali, Ayaan: The caged virgin – an emancipation proclamation for women and Islam (Holdings: 1407)

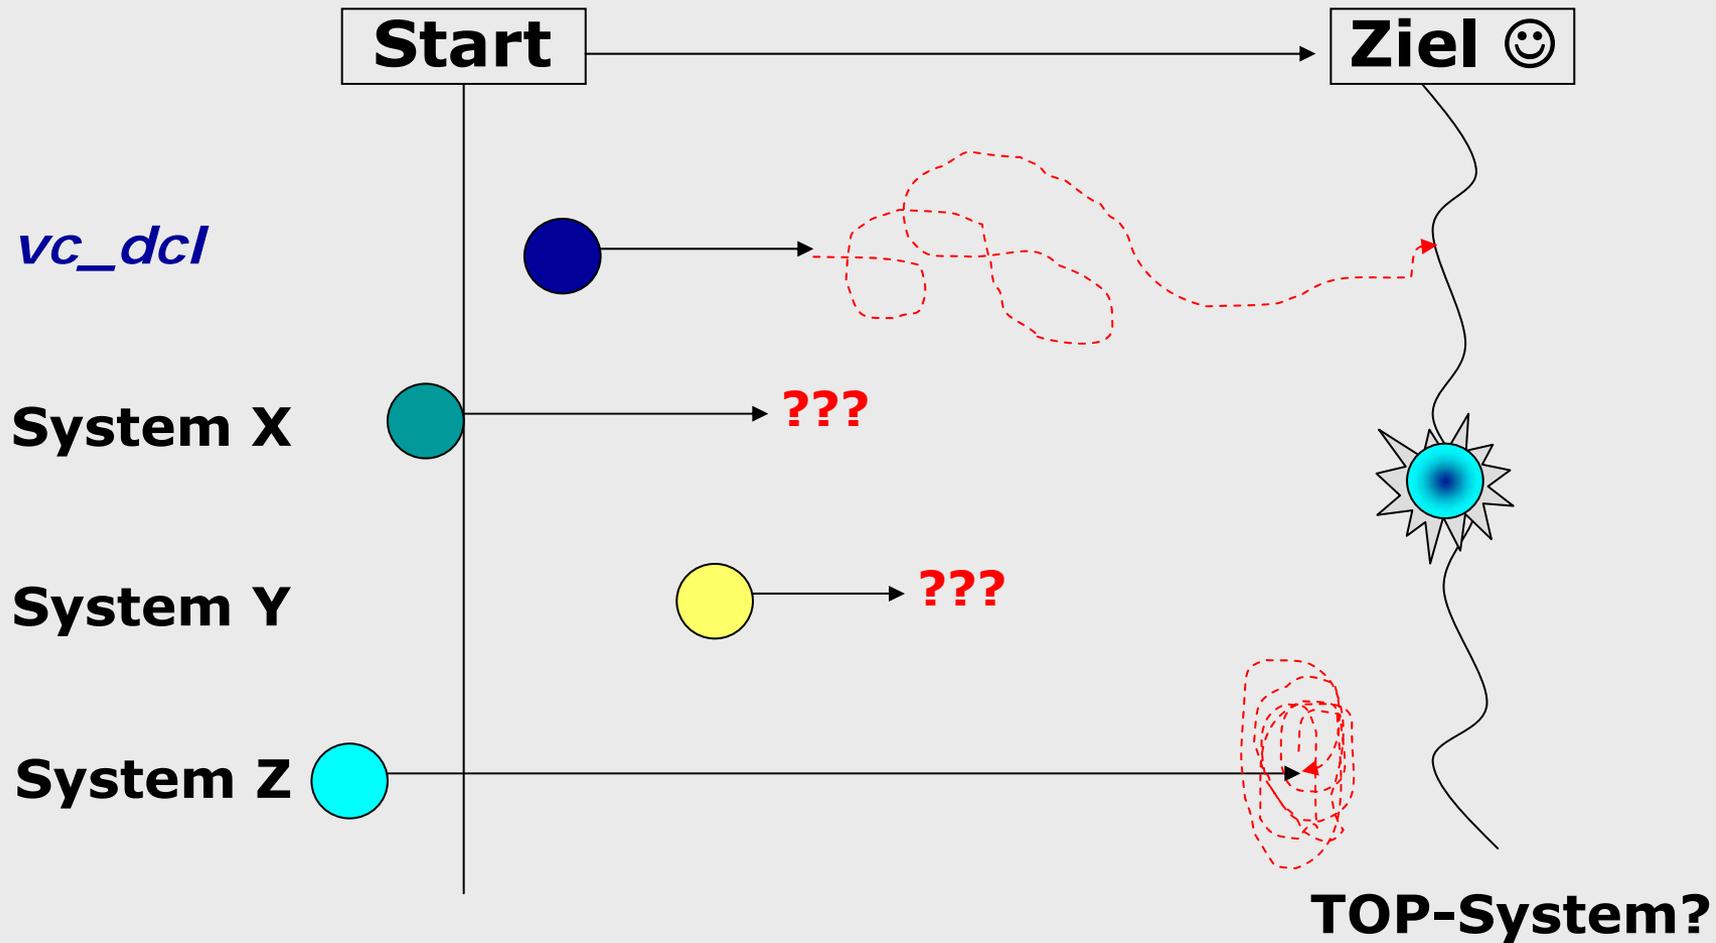
297.082 Frauen—Religion—Islam  
 305.48697 Musliminnen--soziale Gruppe, ...  
 922.97 (Adherents of Islam)

# Initiative Colibri/DDC-Wettbewerb (Juni 2009)

## Ziel: bester automatischer DDC-Klassifizierer für bibliografische Titeldatensätze gesucht



Fundy-Nationalpark  
ul, 25. Mai 2008



# Initiative Colibri/DDC-Wettbewerb (Juni 2009)

## Ziel: bester automatischer DDC-Klassifizierer für bibliografische Titeldatensätze gesucht



Fundy-Nationalpark  
ul, 25. Mai 2008

## Systemtest<sup>1</sup>

- **Modell des Systems oder detaillierte Beschreibung des Systems und seiner Komponenten**
- **Zu testende Hypothesen**
- **Bewertungskriterien und Maße, die diese Kriterien widerspiegeln**
- **Methoden, Daten zu ermitteln und zu bewerten**

<sup>1</sup> [ Salton 1983 ] Gerard Salton; Michael J. McGill, : Introduction to Modern Information Retrieval. McGraw-Hill, New York u.a. , 1983. S. 158

# Automatische DDC-Klassifizierung (1)

## Colibri/DDC-Modell (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

**Deskriptor (*descr*):** Pica+ / MAB2-Kategorie, deren Werte zur inhaltlichen Charakterisierung beitragen

**Pica+ :** {..., 021A, ..., 044K, ...}; **MAB2:** {..., 310, ..., 410, ...}

**Deskriptorwert (*descr\_val*):** Wert eines Deskriptors

{Apfel, Apfelbeere, Aronia}

**DDC-Klasse:** Menge von Deskriptorwerten

**634:=** {..., <021A>-aronia, ...}

**Titeldatensatz:** Menge von Deskriptorwerten

**DNB991499077 :=** {..., <331>-aronia, <902s>-aronia, ...}

**DDC-Datenbasis *vc\_DB*:** Menge von DDC-Klassen, repräsentiert durch DDC-Notationen (*dnos*)

{000, 006.31, 025.302855741, 634 , ..., 999.23}

# Automatische DDC-Klassifizierung (2)

## Colibri/DDC-Modell (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

### IR<sup>1</sup>-Komponente von *vc\_dcl*

Vektorprodukt<sup>2</sup> als Ähnlichkeitsmaß *s*:

$$s_{uc} = \sum_{i=1}^l u_i c_i$$

Bestimmung der Ähnlichkeit zwischen den binären Vektoren  $u^3$  und  $c^4$  mit *s*: similarity (Ähnlichkeit); *i*: *i*-te Gewicht (1: Deskriptorwert vorhanden; 0: Deskriptorwert nicht vorhanden); *l*: Anzahl der Deskriptorwerte von *u*.

### DDC-Notationskandidat(en) für einen Titeldatensatz

**DDC-Notationskandidat:** DDC-Klasse mit größtem Ähnlichkeitswert zwischen *u* und *c*:  $s_{uc \max}$

**Menge von DDC-Notationskandidaten (*dno\_cand\_set*):**  
DDC-Klassen mit gleichen Ähnlichkeitswerten

<sup>1</sup> IR: Information Retrieval; <sup>2</sup> [ Salton 1968 ] Gerard Salton: Automatic Information Organization and Retrieval. McGraw-Hill, New York, 1968, p. 237;

<sup>3</sup> *u*: unclassified (Deskriptorwerte eines nicht klassifizierten Titeldatensatzes);

<sup>4</sup> *c*: classified (Deskriptorwerte einer DDC-Klasse)

# Automatische DDC-Klassifizierung (3)

## Colibri/DDC-Modell (3)



Fundy-Nationalpark  
ul, 25. Mai 2008

### KI<sup>1</sup>-Komponente von *vc\_dcl* (1)

#### Heuristische Funktion *cutoff\_val*<sup>2</sup>

**Annahme:** Deskriptorwerte, die in zu vielen DDC-Klassen auftreten, sind (mit bestimmter Ausnahme) für die automatische DDC-Klassifizierung ungeeignet.

#### *cutoff\_val*

Obergrenze für Berücksichtigung von Häufigkeitswerten von Deskriptorwerten

#### *cutoff\_val\_dyn*

Wert wird zur Laufzeit durch heuristische Regeln dynamisch bestimmt

#### *cutoff\_val\_stat*

statischer (= konstanter) Wert für Testzwecke

#### *in\_descr\_val\_lim* = 6

Anzahl der zu berücksichtigenden Deskriptorwerte (Anfangswert)

<sup>1</sup> KI: Künstliche Intelligenz; <sup>2</sup> [ Reiner 2009 ], S. 12ff

# Automatische DDC-Klassifizierung (4)

## Colibri/DDC-Modell (4)



Fundy-Nationalpark  
ul, 25. Mai 2008

### KI-Komponente von *vc\_dcl* (2)

Heuristische Regeln, z. B.<sup>1</sup>

#### H2. Berücksichtigung spezifischer Begriffe

**Wenn** Differenz zwischen zwei Häufigkeitswerten größer als „200“  
**dann** *cutoff\_val\_dyn* := kleinerer Wert der beiden Häufigkeitswerte

#### H3. Berücksichtigung auch allgemeiner Begriffe

**Wenn** Summe der 1- bis 3-stelligen Häufigkeiten kleiner als  
Anzahl der größer als 3-stelligen Häufigkeiten  
**dann** *cutoff\_val\_dyn* := größter Häufigkeitswert (allgemeine  
Begriffe überwiegen im Titeldatensatz).

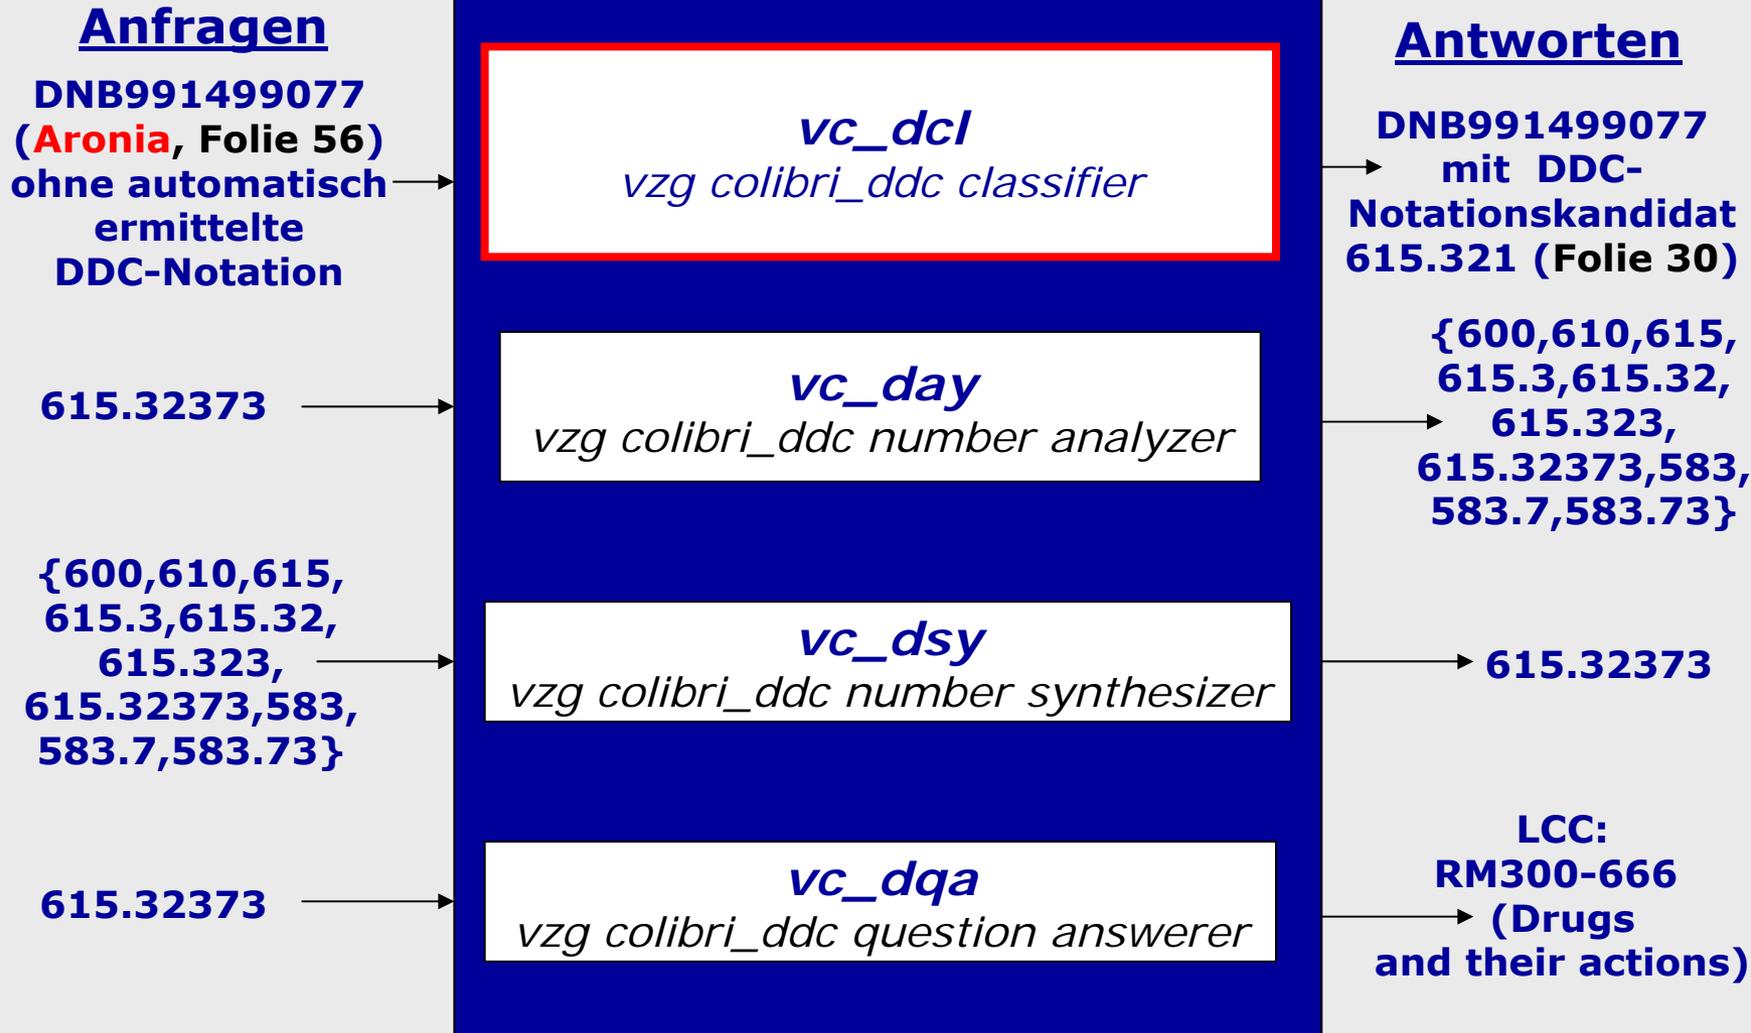
<sup>1</sup> [ Reiner 2009 ], S. 12

# Automatische DDC-Klassifizierung (5)

## VZG Colibri/DDC-Suchsystem *vc\_ds*



Fundy-Nationalpark  
ul, 25. Mai 2008



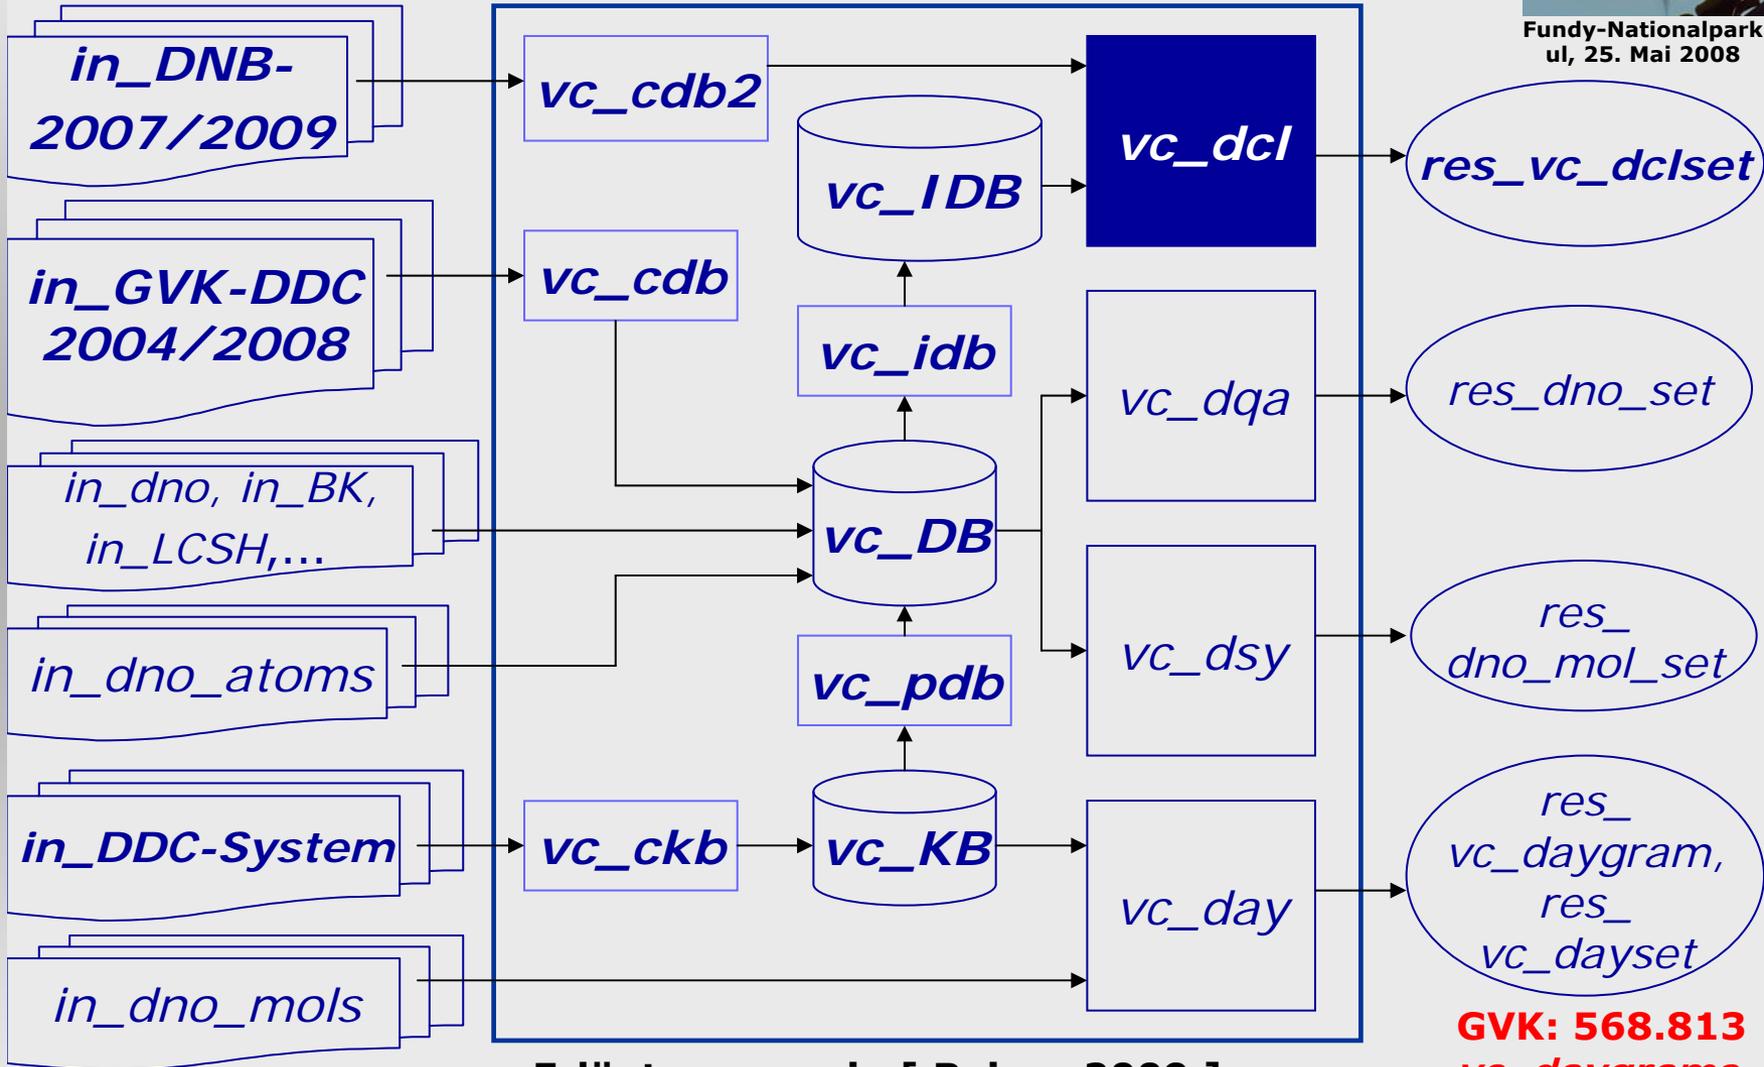
# Automatische DDC-Klassifizierung (6)

## Softwaresystem-Architektur DDC-Suchsystem *vc\_ds*



Fundy-Nationalpark  
ul, 25. Mai 2008

VZG Projekt Colibri/DDC



Erläuterungen in [ Reiner 2009 ]

**GVK: 568.813**  
***vc\_daygrams***  
**(24.3.09)**



# Automatische DDC-Klassifizierung (7)

## Standard-Testbestände: Information Retrieval



Fundy-Nationalpark  
ul, 25. Mai 2008

- **Cranfield** (1950)<sup>2</sup>  
1398 Kurzfassungen (Aerodynamik-Zeitschriftenartikel),  
225 Anfragen, Relevanzurteile
- **TREC** (NIST, 1992)<sup>2</sup>  
"Ad Hoc track" für TREC1 – TREC8 (1992-1999),  
6 CD's: 1.89 Mio. Dokumente, 450 Anfragen ("topics"), Relevanzurteile, "TREC 6-8": 528.000 Artikel, 150 Anfragen
- **GOV2** (2004)<sup>1</sup>  
27 Mio. WWW-Seiten, 15 KB durchschnittliche Dokumentengröße
- **Cross Language Evaluation Forum (CLEF)** (2000)<sup>3</sup>  
Europäische Sprachen, sprachübergreifendes Information Retrieval
- **REUTERS** (1996-2004)<sup>2</sup>  
**Reuters-21578**: 21.578 Artikel von Nachrichtenagenturen  
**RCV1** (Reuters Corpus Volume, 1GB): 806.791 Dokumente (z. B. aus Politik, Wirtschaft, Sport, Wissenschaft)
- **20 NEWSGROUPS**<sup>2</sup>  
1000 Artikel von 20 Usenet-Newsgroups

<sup>1</sup> [ Voorhees/Harman 2005 ], S. 21-52; <sup>3</sup> [ CLEF ]; <sup>2</sup> [ Manning/Raghavan/Schütze 2008 ], S. 153. Online: <http://nlp.stanford.edu/IR-book/pdf/08eval.pdf>;

# Automatische DDC-Klassifizierung (8)

## Colibri/DDC-Systemtest: Testbestände



Fundy-Nationalpark  
ul, 25. Mai 2008

### Basis für die automatische Klassifizierung

**DDC-Datenbasis<sup>1</sup>**

*vc\_DB-2004, vc\_DB-2008*

**DDC-Wissensbasis<sup>1</sup>**

*vc\_KB-2004*

**DDC-Testbestände** (Testdokumente)

*in\_DNB-2007, in\_DNB-2009*

### Andere Kollektionen als DDC-Testbestände?

**100.000 BASE-Titeldatensätze<sup>2</sup>**

**426.254 NORBOK-Titeldatensätze<sup>3</sup>**

<sup>1</sup> [ Reiner 2009 ] ; analog zu DDC-Daten-/Wissensbasis auch Fallbasis/Trainingsdokumente (Maschinelles Lernen); z. B. [ Pfeffer 2008 ]; [ Oberhauser 2004 ]; [ Wille 2006 ]; [ Mehler/Waltinger 2009a ]; [ Mehler/Waltinger 2009b ] ;

<sup>2</sup> [[http://base.ub.uni-bielefeld.de/en/lab\\_browse\\_menu.php?menu=5](http://base.ub.uni-bielefeld.de/en/lab_browse_menu.php?menu=5) ]

<sup>3</sup> [[http://nabo.nb.no/trip?\\_b=baser&navn=norbok&\\_h=0](http://nabo.nb.no/trip?_b=baser&navn=norbok&_h=0) ]

# Automatische DDC-Klassifizierung (9)

## Colibri/DDC-Systemtest



Fundy-Nationalpark  
ul, 25. Mai 2008

## Kriterium für Tests / Experimente

**Wiederholbarkeit!**

## Verwendete Hard- und Software ([colibri2.gbv.de](http://colibri2.gbv.de))

HP Proliant DL585 G1, 4xAMD Opteron 275, 2.2 GHz, 16GB  
Hauptspeicher. SuSE Linux Enterprise 10, gawk-3.1.5.

*vc\_dcl\_srv.awk* (Server): 1.222 Zeilen Programmcode;  
*vc\_dcl\_cli.awk* (Client): 27 Zeilen Programmcode.

# Automatische DDC-Klassifizierung (10) Eingabedaten



Fundy-Nationalpark  
ul, 25. Mai 2008

## *in\_DDC-System*

Elektronische Form als XML-Datei (22. Aufl., in Englisch, Januar 2004)

## *in\_GVK-DDC-2004* (Pica+ - Format)

3,0 Mio. Titeldatensätze

## *in\_GVK-DDC-2008*<sup>1</sup> (Pica+ - Format)

4,3 Mio. Titeldatensätze<sup>2</sup>

## *in\_DNB-2007* bzw. *in\_DNB-2009* (MAB2-Format)

12 DNB-Wochen/Monatslieferungen der Deutschen Nationalbibliografie der Reihen A, B und H mit intellektuell vergebenen DDC-Notationen aus den Jahren 2007 bzw. 2009

- *in\_DNB-2007* (25.653 Titeldatensätze, 10,5 Deskriptorwerte im Ø)
- *in\_DNB-2009* (30.717 Titeldatensätze, 11,0 Deskriptorwerte im Ø)

<sup>1</sup> Zum Vergleich: GVK: 28,2 Mio. Titeldatensätze, Nov. 2008; <sup>2</sup> LoC: 54,7%; BNB: 23,8%;  
Quelle nicht rekonstruierbar: 23,5%

# Automatische DDC-Klassifizierung (11)

## Datenkonvertierung (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Datenkonvertierung

- Eliminierung: irrelevante Deskriptorwerte, Sonderzeichen
- Deskriptorwerte: Transliterierung, Kleinschreibung

### Berücksichtigte MAB2-Felder (*vc\_cdb2*)

**026** (Regionale Identifikationsnummer); **037** (Sprachencode nach ISO 639); **100** (Name der 1. Person in Ansetzungsform); **310** (Hauptsachtitel in Ansetzungsform); **331** (Hauptsachtitel in Vorlageform oder Mischform); **335** (Zusätze zum Hauptsachtitel); **341** (1. Parallelsachtitel in Vorlageform oder Mischform); **370** (Weitere Sachtitel); **410** (Ort(e) des 1. Verlegers, Druckers usw.); **412** (Name des 1. Verlegers, Druckers usw.); **451** (1. Gesamttitel); **540** (Internationale Standardbuchnummer (ISBN)); **542** (Internat. Standardnr. für fortlauf. Sammelwerke); **700** (Systematik der katalogisierenden Institution); **705** (DDC analytisch); **902/12/22 s/g**, **907/17/27 s/g** (Sach-/geographisch-ethnographische Schlagworte);

# Automatische DDC-Klassifizierung (12)

## Datenkonvertierung (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Berücksichtigte Pica+ - Kategorien (*vc\_cdb*)

**001A** (Kennung der Ersterfassung); **003@** (Pica production number);  
**004A** (ISBN); **004B** (2. und weitere ISBN); **004D** (formal falsche ISBN);  
**005A** (ISSN); **006G** (DNB-Nummer); **006L** (Weitere Verbundidentifikationsnummern); **006Y** (Verbundidentifikationsnummer); **007G** (Identifikationsnummer der ersterfassenden Institution); **021A** (Hauptsachtitel, Verfasser); **022A/01** (Einheitssachtitel); **027D** (Titel in Bandsätzen); **028A** (1. Verfasser); **028B** (2. und weitere Verfasser); **028C** (Sonstige beteiligte Personen); **028E** (Interpreten); **033A** (Ort, Verlag); **036C** (Gesamtheit und Abteilungen in Vorlageform); **039B** (Verknüpfung zur größeren Einheit); **041A** (Kettenglied einer RSWK-Kette); **044A** (Library of Congress Subject Headings (LCSH)); **044C** (Medical Subject Headings (MESH)); **044E** (PRECIS); **044F** (DNB-Schlagwörter); **044G** (British Library Subject Headings (BLSH)); **044K** (Einzelschlagwort); **044L** (Einzelschlagwort (Projekte)); **045A** (Library of Congress Classification (LCC)); **045F** (DDC); **045Q** (Basisklassifikation); **045U** ZDB (Notation bei Zeitschriften); **144Z/244Z** (Lokale Schlagwörter); **145Z/245Z** (Lokale Notationen);

# Automatische DDC-Klassifizierung (13)

## Erstellung der DDC-Daten-/Wissensbasis



Fundy-Nationalpark  
ul, 25. Mai 2008

***vc\_ckb*** (*vzg colibri\_create ddc knowledge base*)

**Erstellung der DDC-Wissensbasis *vc\_KB-2004* aus Daten des DDC-Systems (Januar 2004)**

***vc\_cdb*** (*vzg colibri\_create ddc data base*)

**Erstellung der DDC-Datenbasis *vc\_DB* aus GVK-DDC-Titeldatensätzen (Pica+ -> *vc\_DB*-Repräsentation)**

***vc\_cdb2*** (*vzg colibri\_create ddc data base2*)

**Konvertierung der DNB-Titeldatensätze in *vc\_DB*-Repräsentation (MAB2 -> *vc\_DB*-Repräsentation)**

***vc\_pdb*** (*vzg colibri\_prepare ddc data base*) und ***vc\_idb*** (*vzg colibri\_create inverted ddc data base*)

**Erstellung der invertierten DDC-Datenbasis *vc\_IDB***

***vc\_IDB-2004*** (510 MB): ca. 3 Min. Einlesezeit in den Hauptspeicher

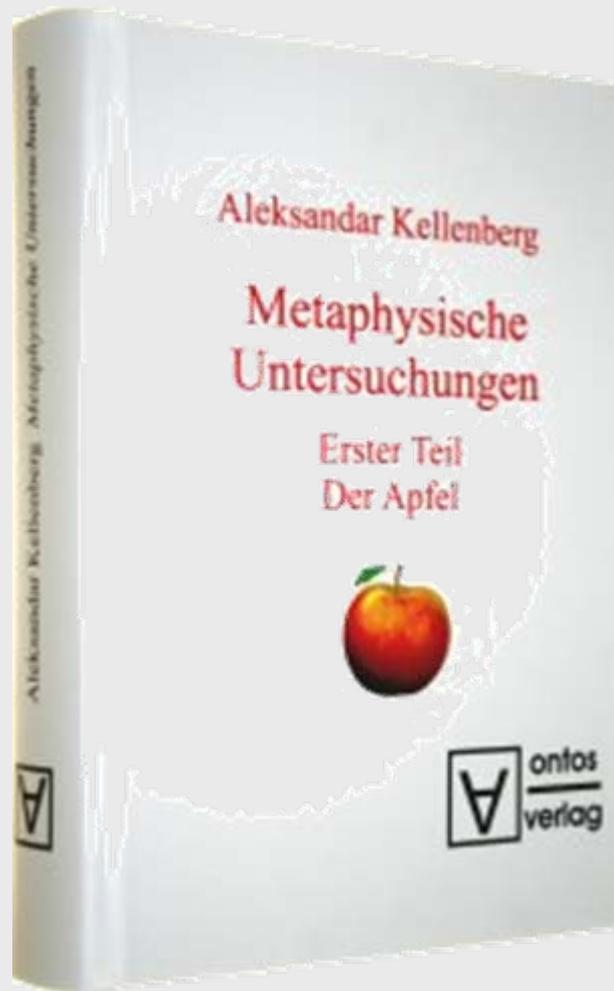
***vc\_IDB-2008*** (712 MB): ca. 5 Min. Einlesezeit in den Hauptspeicher

# Intellektuelle DDC-Klassifizierung

## Der Apfel: 110 (Metaphysik)



Fundy-Nationalpark  
ul, 25. Mai 2008



[<http://cover.deutschesfachbuch.de/books/3938793627/bx.jpg>] ]

# Automatische DDC-Klassifizierung (14)

**Der Apfel: {334.683411, ... ,391.0092}**



Fundy-Nationalpark  
ul, 25. Mai 2008

```

number of ddc-classified title:      1197
identifier (dno,schedno):            DNB0984784829 (110,110) DNB DDC
notation (MAB2 field 700):          {100}
DDC notation (MAB2 field 705):      {110}
calculated cutoff value:             31
title:                               Der Apfel
considered descriptor values:        |2| {<331>-apfel[31], <540a>-3-938793-
62-7[0]}
matched descriptor values:           |1| {apfel}
max. match value of matched descriptor values: |1|
calculated1 ddc classes (subdiv):    |31| {070.924, 170, 300, 334.683411,
338.108, 338.10942, 338.13, 338.17411, 338.174110942, 343.73084, 370,
380.1414110943, 391.0092, 581.12, 634.11, 634.116, 634.117, 634.1193,
634.11943, 635.08, 641.341109748, 791.430233092, 813.54, 822.33,
823.0872909, 823.7, 823.914, 823.92, 833.914, 839.3135, 892.493}
calculated1 ddc classes (sections):  |7| {300, 334, 338, 343, 370, 380, 391}
calculated1 ddc classes (main):      |1| {300}
calculated2 ddc classes (subdiv):    |7| {334.683411[1], 338.108[1],
338.10942[1], 338.13[1], 338.17411[1], 343.73084[1], 391.0092[1]}
calculated2 ddc classes (sections):  {338[5]}
calculated2 ddc classes (divisions): {330[6]}
calculated2 ddc classes (main):      {300[11]}
correlation(dnb_A0745_DNB0984784829#ger#dno_i{110}#dno_a{M300,D330,S338,s33
4.683411,s338.108,s338.10942,s338.13,s338.17411,s343.73084,s391.0092}#consi
: 2#matched: 1,1{apfel}): 00x.xxx xxx xxx xxx (0)

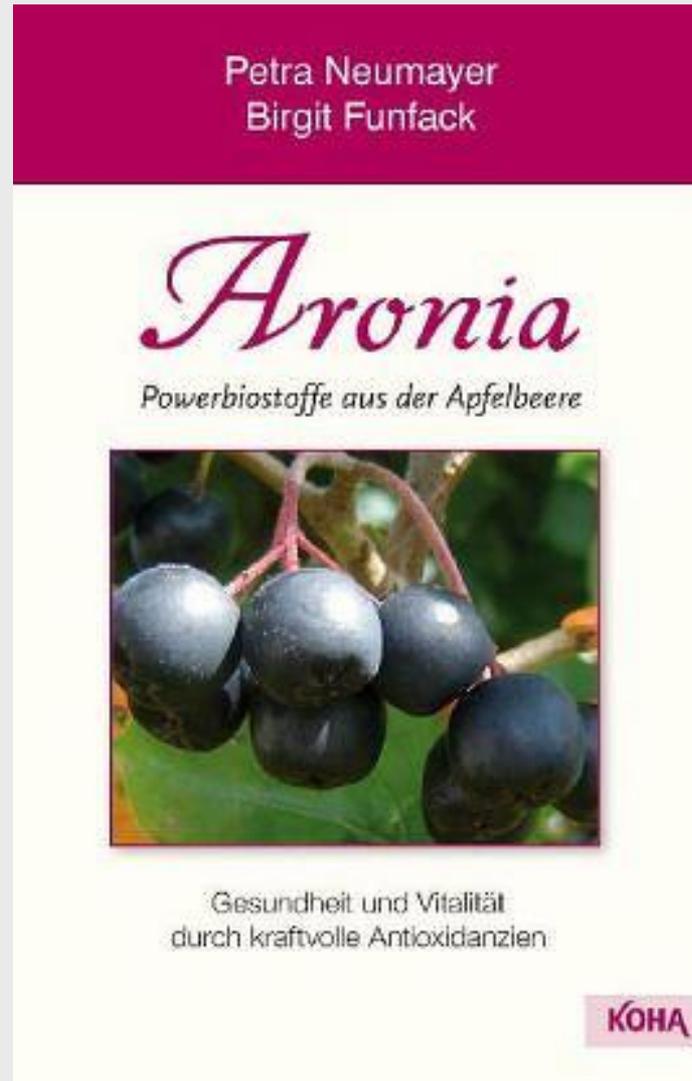
```

**Ethik**

# Automatische DDC-Klassifizierung (15) ?



Fundy-Nationalpark  
ul, 25. Mai 2008



[ <http://picture.yatego.com/images/428b84fecc19b0.4/pid4748589.jpg> ]

# Automatische DDC-Klassifizierung (16)

## Powerbiostoffe aus der Apfelbeere : {615.321}



Fundy-Nationalpark  
ul, 25. Mai 2008

```

number of ddc-classified title:      996
identifier (dno,schedno):            DNB0991499077 (615.32373,615.32373)
DNB DDC notation (MAB2 field 700):  {610}
DDC notation (MAB2 field 705):      {615.32373}
calculated cutoff value:             79
title:                               Aronia
title (remainder):                  Powerbiostoffe aus der Apfelbeere ;
Gesundheit und Vitalitaet durch kraftvolle Antioxidanzien
considered descriptor values:        |11| {<100>-petra#neumayer[0], <331>-
aronia[1], <335>-apfelbeere[0], <335>-gesundheit[823], <335>-vitalitaet[79],
<335>-kraftvolle[1], <335>-antioxidanzien[0], <335>-powerbiostoffe[0],
<412@410>-<033A>-koha@burgrain[0], <540a>-978-3-86728-084-6[0],
<902s1>-naturheilmittel[10]}
matched descriptor values:           |2| {naturheilmittel, vitalitaet}
max. match value of matched descriptor values: |2|
calculated1 ddc classes (subdiv):    |1| {615.321}
calculated1 ddc classes (sections):  |1| {615}
calculated1 ddc classes (main):      |1| {600}
calculated2 ddc classes (subdiv):    |1| {615.321[1]}
calculated2 ddc classes (sections):  {615[1]}
calculated2 ddc classes (divisions): {610[1]}
calculated2 ddc classes (main):      {600[1]}
correlation(dnb_A0912_DNB0991499077#ger#dno_i{615.32373}#dno_a{M600,D610,S61,
s615.321}#consi: 11#matched: 2,2{naturheilmittel, vitalitaet}):
111.110 00x xxx xxx (0.625)

```

# Automatische DDC-Klassifizierung (17)

## Bewertung (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Projekt Colibri/DDC<sup>1</sup>: Korrelationsmaße $C$ , $CP^2$ und $CN^2$

Stellenweiser Ziffernvergleich von links nach rechts zwischen intellektuell vergebener ( $dno_i$ ) und automatisch ermittelter DDC-Notation ( $dno_a$ ). Annahme:  $dno_i$  ist optimal.  $L_i$ : Länge von  $dno_i$ .

**C (Correlation)**: Anzahl der übereinstimmenden Ziffern in  $dno_i$  und  $dno_a$ .

**CP (Correlation Pattern)**: 16-stelliges Muster mit „.“ (Dewey Punkt) an Stelle 4; „1“, wenn  $dno_i$  und  $dno_a$  an Stelle  $s$  übereinstimmen; „0“, wenn sie nicht übereinstimmen; „x“ an Stellen größer  $L_i$ .

**CN (Correlation Number)**: auf  $L_i$  normiertes Korrelationsmaß  
 $CN = C / L_i$ .

<sup>1</sup> Mathematische Definitionen in [ Reiner 2009 ], S. 13ff; <sup>2</sup> eingeführt in [ Reiner 2008 ], S. 127

# Automatische DDC-Klassifizierung (18)

## Bewertung (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Projekt Colibri/DDC<sup>1</sup>

*dno\_i* = 150 (Psychologie)

*dno\_a* = 158.1 (Persönliche Weiterentwicklung und Analyse)

*CP* = 110.xxx xxx xxx xxx; *CN* = (1+1+0)/3 = 0.66666

*dno\_i* = 158.1 (Persönliche Weiterentwicklung und Analyse)

*dno\_a* = 158 (Angewandte Psychologie)

*CP* = 111.0xx xxx xxx xxx; *CN* = (1+1+1+0)/4 = 0.75

*dno\_i* = 591.513 (Intelligenz) [ Oberklasse: 590 (Tiere) ]

*dno\_a* = 156.39 (Intelligenz bei Tieren--vergleichende Psychologie, ...)

*CP* = 000.000 xxx xxx xxx; *CN* = (0+0+0+0+0+0)/6 = 0

<sup>1</sup> [ Reiner 2009 ], S. 15



# Automatische DDC-Klassifizierung (20)

## Bewertung (4)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Projekt Pfeffer/RVK<sup>1</sup>

#### „Bewertung

- Vergleich der automatischen und manuellen Klassifikation
- Suche des nächsten gemeinsamen Vaterknoten im RVK-Baum
- Perfekt: Übereinstimmung
- Gut: Abstand 1-3
- Mäßig: Abstand >3, aber noch gleiches Fach
- Schlecht: anderes Fach“

<sup>1</sup> [ Pfeffer 2008 ], S. 10

# Automatische DDC-Klassifizierung (21)

## Bewertung (5)



Fundy-Nationalpark  
ul, 25. Mai 2008

Colibri/DDC			Scorpion/DDC						Pfeffer/RVK				
Bsp.dno_i	dno_a	CP	C	CN	S1	S2	S3	S4	S8	S9	S10	P	
8.	529.326	529.326	111.111	6	1	x	x	x		x	x	P1	
9.	529	529.3	111	3	1	x	x	x	G		x	x	P2
10.	529.3	529	111.0	3	0.75	x	x	x	Sp		x	x	P2
11.	111	115	110	2	0.66	x	x					x	P2
12.	520	529	110	2	0.66	x	x					x	P2
13.	571.68	571.58	111.00	3	0.60	x	x	x				x	P2
14.	111.8	110	110.0	2	0.50	x	x					x	P2
15.	571.5929	571	111.0000	3	0.43	x	x	x	Sp		x	x	P3
16.	111.85	110	110.00	2	0.40	x	x					x	P2
17.	111.850952	111	111.000000	3	0.33	x	x	x	Sp		x	x	P4
18.	572.6	500	100.0	1	0.25	x						x	P2
19.	111.85	100	100.00	1	0.20	x						x	P3
20.	529.326	500	100.000	1	0.16	x						x	P3
21.	571.5929	500	100.0000	1	0.14	x						x	P3
22.	100	500	000	0	0								P4
23.	170	570	000	0	0								P4

**Abb. 8: Vergleichende Betrachtung mit unterschiedlichen Bewertungsmaßen; Auszug aus [ Reiner 2009 ], S. 18**



# Automatische DDC-Klassifizierung (23)

## Bewertung (7)



Fundy-Nationalpark  
ul, 25. Mai 2008

## Bewertungsmasse<sup>1</sup> (2)

- **Precision P** =  $a / (a+b)$
- **Recall R** =  $a / (a+c)$
- **Fallout F** =  $b / (b+d)$
- **F-Measure** =  $2 * P * R / (P+R)$

<sup>1</sup> [ Salton 1968 ]; [ Sasaki 2007 ] Yutaka Sasaki: The truth of the F-measure. School of Computer Science, University of Manchester MIB, 131 Princess Street, Manchester, M1 7DN, October 26, 2007. Online: <http://personalpages.manchester.ac.uk/staff/yutaka.sasaki/F-measure-YS-26Oct07.pdf>

# Automatische DDC-Klassifizierung (24)

## Bewertung (8)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Weitere Bewertungsmasse<sup>1</sup> (3)

- Accuracy =  $a+d / (a+b+c+d)$
  - Error =  $1 - \text{Accuracy}$
  - Percent too specific
  - Percent too general
  - Average overlap
  - Accuracy at level
- } <sup>2</sup>
- Eleven-point average precision
  - Precision-recall breakeven point

<sup>1</sup> [ Oberhauser 2004 ], S. 21 ff. ; <sup>2</sup> [ Frank/Paynter ]: Predicting Library of Congress Classifications From Library of Congress Subject Headings. Journal of the American Society for Information Science and Technology, Vol. 55, No. 3; p. 222



# Automatische DDC-Klassifizierung (26)

## Klassifizierungsergebnisse mit *vc\_dcl*



Fundy-Nationalpark  
ul, 25. Mai 2008

**Aus Gründen der Bewertung wird eine automatische Klassifizierung nur durchgeführt, wenn der Titeldatensatz**

- eine korrekte DDC-Notation enthält,
- noch nicht klassifiziert wurde (Prüfung: MAB2-Feld 026)
- nicht in der DDC-/Wissensbasis enthalten ist (Prüfung: MAB2-Felder 540a, 540b, 004A mit Pica+ - Kategorien 004A, 004B, 004D, 005A)

Name der Ergebnisdatei <i>res...</i>	res (Anz.) <sup>1</sup>	tit (Anz.) <sup>2</sup>	t <sup>3</sup>
<i>res_vc_IDB-2004_in_DNB-2007</i>	<b>16.694</b>	<b>25.653</b>	<b>133</b>
<i>res_vc_IDB-2008_in_DNB-2007</i>	<b>15.365</b>	<b>25.653</b>	<b>136</b>
<i>res_vc_IDB-2004_in_DNB-2009</i>	<b>21.591</b>	<b>30.717</b>	<b>120</b>
<i>res_vc_IDB-2008_in_DNB-2009</i>	<b>21.422</b>	<b>30.717</b>	<b>140</b>

<sup>1</sup> Anzahl der Klassifizierungsergebnisse; <sup>2</sup> Anzahl der Titeldatensätze;

<sup>3</sup> Laufzeit der automatischen Klassifizierung in Minuten

# Automatische DDC-Klassifizierung (27)

## Automatisch bewertete Ergebnisse (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Hypothesen

- a) Unterschied bei unterschiedlichen Daten-/Wissensbasen ist signifikant
- b) Unterschied bei verschiedenen Testbeständen ist nicht signifikant

Testbestand	Daten-/Wissensbasis vc_DB-2004	vc_DB-2008	Differenz
in_DNB-2007	57.33%	62.84%	+5.51%
in_DNB-2009	57.26%	63.85%	+6.59%
Differenz	-0.07%	+1.01%	

**CN-Werte > 0**

**Übereinstimmung mindestens in der DDC-Hauptklasse**

# Automatische DDC-Klassifizierung (28)

## Automatisch bewertete Ergebnisse (2)

*res\_vc\_IDB-2008\_in\_DNB-2009*



Fundy-Nationalpark  
ul, 25. Mai 2008

----- CN for all dnos -----

CN=0:	7743;	36,15%	} 63,85%
0<CN<1:	10954;	51,13%	
CN=1:	2725;	12,72%	

-----

## Übereinstimmung mindestens in der DDC-Hauptklasse

-----C-----

C=0	C=1	C=2	C=3	C=4	C=5	C=6	C=7	C=8	C=9
36,15%	13,71%	26,29%	10,27%	6,07%	3,29%	2,81%	0,98%	0,29%	0,13%

-----

## Verteilung der Übereinstimmungen

# Automatische DDC-Klassifizierung (29)

## Automatisch bewertete Ergebnisse (3)

*res\_vc\_IDB-2008\_in\_DNB-2009*



Fundy-Nationalpark  
ul, 25. Mai 2008

### Hypothese: Es gibt signifikante Unterschiede zwischen den DDC-Klassen

----- CN (Anzahl pro DDC-Klasse) -----										
	dno0	dno1	dno2	dno3	dno4	dno5	dno6	dno7	dno8	dno9
CN=0	249	311	252	849	178	1426	3188	639	141	510
0<CN<1	230	174	347	3015	142	1326	4471	528	207	514
CN=1	77	60	73	421	55	290	1136	204	77	332
CN>0	307	234	420	3436	197	1616	5607	732	284	846

----- CN (Prozentwerte pro DDC-Klasse) -----										
	dno0	dno1	dno2	dno3	dno4	dno5	dno6	dno7	dno8	dno9
CN=0	44,78%	57,06%	37,50%	19,81%	47,47%	46,88%	36,25%	46,61%	33,18%	37,61%
0<CN<1	41,37%	31,93%	51,64%	70,36%	37,87%	43,59%	50,84%	38,51%	48,71%	37,91%
CN=1	13,85%	11,01%	10,86%	9,82%	14,67%	9,53%	12,92%	14,88%	18,12%	24,48%
CN>0	55,22%	42,94%	62,50%	80,18%	52,54%	53,12%	63,76%	53,39%	66,83%	62,39%

# Automatische DDC-Klassifizierung (30)

## Automatisch bewertete Ergebnisse (4)

*res\_vc\_IDB-2008\_in\_DNB-2009*



Fundy-Nationalpark  
ul, 25. Mai 2008

**Hypothese: Es gibt signifikante Unterschiede zwischen den DDC-Klassen**

	a	b	c	d	a+b	a+c	Precision	Recall	Fallout	F-Measure
dno0	307	453	241	20421	760	548	0,404	0,560	0,022	0,469
dno1	234	751	311	20126	985	545	0,238	0,429	0,036	0,306
dno2	420	334	251	20417	754	671	0,557	0,626	0,016	0,589
dno3	3436	3613	842	13531	7049	4278	0,487	0,803	0,211	0,607
dno4	197	174	178	20873	371	375	0,531	0,525	0,008	0,528
dno5	1616	1123	1388	17295	2739	3004	0,590	0,538	0,061	0,563
dno6	5607	1801	3130	10884	7408	8737	0,757	0,642	0,142	0,695
dno7	732	601	630	19459	1333	1362	0,549	0,537	0,030	0,543
dno8	284	1428	141	19569	1712	425	0,166	0,668	0,068	0,266
dno9	846	939	506	19131	1785	1352	0,474	0,626	0,047	0,539

# Automatische DDC-Klassifizierung (31)

## Automatisch bewertete Ergebnisse (5)

*res\_vc\_IDB-2008\_in\_DNB-2009*



Fundy-Nationalpark  
ul, 25. Mai 2008

**Hypothese: Es gibt keinen signifikanten Unterschied zwischen deutschen und englischen Titeldatensätzen**

----- CN for ger -----

ger: CN=0:	6338;	36,55%	
ger: 0<CN<1:	8923;	51,46%	} 63,45%
ger: CN=1:	2079;	11,99%	

-----

----- CN for eng -----

eng: CN=0:	1400;	33,14%	
eng: 0<CN<1:	2188;	51,79%	} 66,86%
eng: CN=1:	637;	15,08%	

-----

# Automatische DDC-Klassifizierung (32)

## Automatisch bewertete Ergebnisse (6)



Fundy-Nationalpark  
ul, 25. Mai 2008

**Hypothese: Es gibt signifikante Unterschiede zwischen den Reihen A, B und H**

Name der Ergebnisdatei <i>res...</i>	A	B	H
<i>res_vc_IDB-2004_in_DNB-2007</i>	62.32%	50.37%	55.24%
<i>res_vc_IDB-2008_in_DNB-2007</i>	67.72%	58.69%	60.92%
<i>res_vc_IDB-2004_in_DNB-2009</i>	59.56%	49.35%	57.10%
<i>res_vc_IDB-2008_in_DNB-2009</i>	67.42%	56.33%	62.96%

**CN-Werte > 0**

**Übereinstimmung mindestens in der DDC-Hauptklasse**

# Automatische DDC-Klassifizierung (33)

## Automatisch bewertete Ergebnisse (7)

*res\_vc\_IDB-2008\_in\_DNB-2009*



Fundy-Nationalpark  
ul, 25. Mai 2008

**Hypothese: Es gibt signifikante Unterschiede hinsichtlich der Stelligkeit der DDC-Notationen**

	1-3-digit	4-digit	5-digit	6-digit	7-digit	8-digit	9-digit
SUM:	2922	5319	5009	4924	1985	764	317
CN=0:	28,27%	37,75%	38,07%	36,94%	37,38%	35,21%	33,12%
0<CN<1:	47,23%	47,77%	52,67%	52,36%	54,06%	57,98%	58,68%
CN=1:	24,50%	14,48%	9,26%	10,70%	8,56%	6,81%	8,20%
CN>0:	<b>71,73%</b>	62,25%	<b>61,93%</b>	63,06%	62,62%	64,79%	66,88%

# Stand: Automatisches Klassifizierungsverfahren mit der Klassifizierungskomponente *vc\_dcl*



- Ermittlung der DDC-Notationskandidaten: Algorithmus verwendet IR<sup>1</sup>- und KI<sup>2</sup>-Verfahren
- IR: einfachstes Ähnlichkeitsmaß (binäre Vektoren, Vektorprodukt); KI: heuristische Regeln
- 2 Klassenaggregationen für Ergebnisausgabe
- keine Volltexte, sondern einzelne - ggf. mehrere zusammenhängende - Wörter
- keine linguistischen Verfahren, kein Lexikon

<sup>1</sup> IR: Information Retrieval; <sup>2</sup>KI: Künstliche Intelligenz

# Perspektiven zur automatischen DDC-Klassifizierung (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

- Vergrößerung der DDC-Daten-/Wissensbasis
- Verbesserung der Sacherschliessung bei unzureichend erschlossenen Titeldatensätzen
- Erweiterung der heuristischen Funktion, Verwendung weiterer (KI/IR)-Algorithmen, Lexikonerstellung
- Eliminierung weiterer irrelevanter Deskriptorwerte
- Andere Methode der (Klassenaggregation zur) Ergebnisausgabe
- Anreiz durch **Colibri/DDC-Wettbewerb** 😊



# Literatur:

## Information Retrieval & Bewertung (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

- [ SALTON 1971 ] **The SMART Retrieval System – Experiments in Document Processing** (ed. Gerard Salton). Prentice-Hall, Englewood Cliffs, NJ, 1971.
- [ Jones 1981 ] Karen Spärck Jones: **Information Retrieval Experiment**. Butterworths, London, 1981.
- [ Jones 1996 ] Karen Spärck Jones; Julia R. Galliers: **Evaluating Natural Language Processing Systems. An Analysis and Review**. Lecture Notes in Artificial Intelligence 1083. Springer, Berlin, 1996.
- [ Voorhees/Harman 2005 ] **TREC: Experiment and Evaluation in Information Retrieval** (ed. by Ellen M. Voorhees; Donna K. Harman). MIT Press, Cambridge Massachusetts, 2005.

# Literatur:

## Information Retrieval & Bewertung (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

- [ Moens 2000 ] Marie-Francine Moens: **Automatic Indexing and Abstracting of Document Texts**. Kluwer Academic Publishers, London, 2000.
  
- [ Manning/Raghavan/Schütze 2008 ] Christopher D. Manning; Prabhakar Raghavan; Hinrich Schütze: **Introduction to Information Retrieval**. Cambridge University Press, Juli 2008. Online: <http://www-csli.stanford.edu/~hinrich/information-retrieval-book.html>.
  
- [ CLEF ] **Cross-Language Evaluation Forum (CLEF)** . Online: <http://www.clef-campaign.org/>.

# Literatur:

## Automatische Klassifizierung & Bewertung (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

- [ Reiner 2008 ] Ulrike Reiner: **DDC-based Search in the Data of the German National Bibliography**. In: New Perspectives on Subject Indexing and Classification. Essays in Honour of Magda Heiner-Freiling. Deutsche Nationalbibliothek. Leipzig, Frankfurt am Main, Berlin, 2008, pp. 121-129.
  
- [ Reiner 2009 ] Ulrike Reiner: **Bewertung von automatisch DDC-klassifizierten Titeldatensätzen der Deutschen Nationalbibliothek (DNB)**. VZG-Colibri-Bericht 1/2008. Online: <http://taipan.dyndns.org/~ul/colibri05.pdf>.
  
- [ Oberhauser 2004 ] Otto Oberhauser: **Automatisches Klassifizieren. Verfahren zur Erschließung elektronischer Dokumente**. Master's Thesis. Zusatzstudiengang Bibliotheks- und Informationswissenschaft. Fakultät für Informations- und Kommunikationswissenschaften, Fachhochschule Köln, 2004.

# Literatur:

## Automatische Klassifizierung & Bewertung (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

- [ Wille 2006 ] Jens Wille: **Automatisches Klassifizieren bibliographischer Beschreibungsdaten - Vorgehensweise und Ergebnisse**. Diplomarbeit. Studiengang Bibliothekswesen Fakultät für Informations- und Kommunikationswissenschaften, Fachhochschule Köln, 2006.
- [ Pfeffer 2008 ] Magnus Pfeffer: **Automatische Vergabe von RVK-Notationen mittels fallbasiertem Schließen**. Vortrag: 97. Deutscher Bibliothekartag. 5. Juni 2008, Mannheim.
- [ Mehler/Waltinger 2009a ] Alexander Mehler; Ulli Waltinger: **Automatic Enrichment of Metadata**. Vortrag: „9th International Bielefeld Conference“. 4. Februar 2009, Bielefeld.
- [ Mehler/Waltinger 2009b ] Alexander Mehler; Ulli Waltinger: **Enhancing Document Modeling by Means of Open Topic Models: Crossing the Frontier of Classification Schemes in Digital Libraries by Example of the DDC**. Wird publiziert in: Library Hi Tech, 2009.



# DNB-Titeldatensatz zu **Aronia**



Fundy-Nationalpark  
ul, 25. Mai 2008

001 991499077  
 002a20081128  
 003 20090303090118  
 004 20090310  
 025a991499077  
 026 DNB991499077

...  
 037bger

...  
 100 Neumayer, Petra  
 102a120295911  
 104aFunfack, Birgit  
 106a137378009

331 **Aronia**

335 **Powerbiostoffe aus der Apfelbeere ; Gesundheit und Vitalität durch kraftvolle Antioxidanzien**

359 Petra Neumayer ; Birgit Funfack

...  
 540aISBN 978-3-86728-084-6 kart. : EUR 7.95 (DE), EUR 8.20 (AT)

...  
 700 |610ÎDNB  
 705a□a**615.32373**□c615.32□d583.73□eDDC22ger  
 902s 7636533-5                      **Aronia**  
 902s1 4288415-9                     **Naturheilmittel**  
 902f11|Ratgeber  
 903 213

intellektuell  
 vergebene  
 DDC-Notation







***E N D E***



Fundy-Nationalpark  
ul, 25. Mai 2008