

# 38. Deutscher Bibliothekartag, Erfurt



Fundy-Nationalpark  
ul, 25. Mai 2008

**Für eilige Leser**

**Ulrike Reiner**  
**Automatische DDC-Klassifizierung von**  
**bibliografischen Titeldatensätzen**

Version: **Lite**

# Automatische DDC-Klassifizierung von bibliografischen Titeldatensätzen

- Inhalt des Vortrages -



Fundy-Nationalpark  
ul, 25. Mai 2008

**DDC System, Bibliografische Titeldatensätze**

**OCLC classify**

**VZG Colibri/DDC (Klassifizierungskomponente,  
Wettbewerb, Ergebnisse und Bewertung)**

# Colibri/DDC - Forschungsfrage Q1



Fundy-Nationalpark  
ul, 25. Mai 2008

**Ist es möglich, eine inhaltlich stimmige  
DDC-Titelklassifikation aller GVK-PLUS-Titeldatensätze  
automatisch zu erzielen?**

# Dewey-Dezimalklassifikation (DDC)

## Mini-DDC-Ausschnitt



Fundy-Nationalpark  
ul, 25. Mai 2008

### Ebene

- 1. **000** (Informatik, ...) ...
  - ...
- 2. ... **020** (Bibliotheks- und Informationswissen. ...) ...
  - ...
- 3. ... **006** (Spezielle Computerverfahren) ...
  - ...
- ...
- ...
- 12. ... **025.302855741** (Einsatz von Dateiorganisation ...)

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



Fundy-Nationalpark  
ul, 25. Mai 2008

**Kleidung** wird z. B. abgehandelt in **Psychologie**,  
**Ethnologie** und **Künste**

# DDC-Klassifizierung: ein Thema (**Der Apfel**) – welche Systemstelle?



Fundy-Nationalpark  
ul, 25. Mai 2008

**DNB-Titeldatensatz DNB984784829 im MAB2-Format**

...

026 **DNB984784829**

...

037b**ger**

...

331 **Der Apfel**

...

540a**ISBN 978-3-938793-62-6** Pp. : EUR 98.00

540a**ISBN 3-938793-62-7** Pp. : EUR 98.00

...

700 |**100ÎDNB**

705a□a**110**□c110□eDDC22ger

# Intellektuelle DDC-Klassifizierung

## Der Apfel: 110 (Metaphysik)



Fundy-Nationalpark  
ul, 25. Mai 2008

Aleksandar Kellenberg:  
Metaphysische Untersuchungen –  
Erster Teil: **Der Apfel**

**OCLC Classify**  
(an experimental classification web service)  
**Der Apfel {372.133}**



Fundy-Nationalpark  
ul, 25. Mai 2008

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

# Intellektuelle DDC-Klassifizierung

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



Fundy-Nationalpark  
ul, 25. Mai 2008

**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

Beispiel aus: [ <http://www.onb.ac.at/events/files/rype.ppt> ], p. 8

# OC LC Classify

**Mein Leben, meine Freiheit : {324.2092}**



Fundy-Nationalpark  
ul, 25. Mai 2008

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}**



Fundy-Nationalpark  
ul, 25. Mai 2008

**Hirsi Ali, Ayaan: The caged virgin – an emancipation  
proclamation for women and Islam (Holdings: 1.407)**


**DDC Klassen:** 297.082 (88.91%), 305.48697(6.68%),  
922.97 (3.55%), Unclassified (4.41%)

# 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

Modell / Beschreibung des Systems  
Zu testende Hypothesen  
Bewertungskriterien und -maße  
Daten ermitteln und bewerten

# Automatische DDC-Klassifizierung (1)

## Colibri/DDC-Modell (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

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

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

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

**vc\_DB := { 000, 006.31, 025.302855741, 634 , ..., 999.23 }**

# Automatische DDC-Klassifizierung (2)

## Colibri/DDC-Modell (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

### IR-Komponente

Vektorprodukt als Ähnlichkeitsmaß

**DDC-Notationskandidat(en): DDC-Klasse mit größtem Ähnlichkeitswert**

# Automatische DDC-Klassifizierung (3)

## Colibri/DDC-Modell (3)



Fundy-Nationalpark  
ul, 25. Mai 2008

### KI-Komponente

#### Heuristische Funktion

Obergrenze für Berücksichtigung von Häufigkeitswerten von Deskriptorwerten, Wert wird zur Laufzeit durch heuristische Regeln dynamisch bestimmt

# Automatische DDC-Klassifizierung (4)

## Colibri/DDC-Modell (4)



Fundy-Nationalpark  
ul, 25. Mai 2008

### KI -Komponente

Heuristische Regel, z. B. Berücksichtigung spezifischer Begriffe

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

# Automatische DDC-Klassifizierung (5)

## VZG Colibri/DDC-Suchsystem



Fundy-Nationalpark  
ul, 25. Mai 2008

**DDC-basierte Anfragen -> DDC-Suchsystem ->  
DDC-basierte Antworten**

# Automatische DDC-Klassifizierung (6)

## Softwaresystem-Architektur DDC-Suchsystem



Fundy-Nationalpark  
ul, 25. Mai 2008

**Eingabedaten -> DDC-Suchsystem mit  
Systemkomponenten (DDC-Klassifizierung,  
Frage-Beantwortung, DDC-Notationssynthese  
und -Analyse) -> Ausgabedaten**

# Automatische DDC-Klassifizierung (7)

## Standard-Testbestände: Information Retrieval



Fundy-Nationalpark  
ul, 25. Mai 2008

**Cranfield, TREC, GOV2, CLEF, Reuters-21578, RCV1,  
20 NEWSGROUPS**

# Automatische DDC-Klassifizierung (8)

## Colibri/DDC-Systemtest: Testbestände



Fundy-Nationalpark  
ul, 25. Mai 2008

**DDC-Daten-/Wissensbasis 2004/2008**  
**DNB-DDC-Testbestände 2007/2009**

**Andere Testbestände? Z. B.**

100.000 BASE-Titeldatensätze  
426.254 NORBOK-Titeldatensätze

# Automatische DDC-Klassifizierung (9)

## Colibri/DDC-Systemtest



Fundy-Nationalpark  
ul, 25. Mai 2008

**Kriterium für Tests/Experimente: Wiederholbarkeit!**

**Verwendete Hard- und Software: 2.2 GHz, 16GB  
Hauptspeicher. SuSE Linux Enterprise 10, gawk-3.1.5,  
ca. 1.250 Zeilen Programmcode.**

# Automatische DDC-Klassifizierung (10) Eingabedaten



Fundy-Nationalpark  
ul, 25. Mai 2008

- DDC-System 2004:** Elektronische Form als XML-Datei
- DDC-Daten-Wissensbasis 2004:** 3,0 Mio. Titeldatensätze
- DDC-Daten-Wissensbasis 2008:** 4,3 Mio. Titeldatensätze
- DNB-DDC-Testbestand 2007:** 25.653 Titeldatensätze
- DNB-DDC-Testbestand 2009:** 30.717 Titeldatensätze

# Automatische DDC-Klassifizierung (11) Datenkonvertierung (1)



Fundy-Nationalpark  
ul, 25. Mai 2008

## Datenkonvertierung

Eliminierung: irrelevante Deskriptorwerte, Sonderzeichen  
Deskriptorwerte: Transliterierung, Kleinschreibung

## Berücksichtigte MAB2-Felder

026, 037, 100, 310, 331, 335, 341, 370, 410, 412, 451, 540,  
542, 700, 705, 902/12/22 s/g, 907/17/27 s/g

# Automatische DDC-Klassifizierung (12)

## Datenkonvertierung (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Berücksichtigte Pica+ - Kategorien

001A, 003@, 004A, 004B, 004D, 005A, 006G, 006L, 006Y,  
007G, 021A, 022A/01, 027D, 028A, 028B, 028C, 028E, 033A,  
036C, 039B, 041A, 044A, 044C, 044E, 044F, 044G, 044K,  
044L, 045A, 045F, 045Q, 045U, 144Z/244Z, 145Z/245Z

# Automatische DDC-Klassifizierung (13)



Fundy-Nationalpark  
ul, 25. Mai 2008

**Erstellung der (invertierten) DDC-Daten-/  
Wissensbasis aus Daten des DDC-Systems und aus  
GVK-DDC-Titeldatensätzen**

**Größe der invertierten DDC-Daten-/Wissensbasis**

**2004** (510 MB): ca. 3 Min. Einlesezeit in den Hauptspeicher

**2008** (712 MB): ca. 5 Min. Einlesezeit in den Hauptspeicher

# Intellektuelle DDC-Klassifizierung

## Der Apfel: 110 (Metaphysik)



Fundy-Nationalpark  
ul, 25. Mai 2008

Aleksandar Kellenberg: **Metaphysische Untersuchungen** –  
Erster Teil: **Der Apfel**

# Automatische DDC-Klassifizierung (14)

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



Fundy-Nationalpark  
ul, 25. Mai 2008

```
correlation(dnb_A0745_DNB0984784829#ger#dno_i{1
10}#dno_a{M300,D330,S338,s334.683411,s338.108,s
338.10942,s338.13,s338.17411,s343.73084,s391.0092
}#consi: 2#matched: 1,1{apfel}): 00x.xxx xxx xxx xxx
(0)
```

# Automatische DDC-Klassifizierung (15)

?



Fundy-Nationalpark  
ul, 25. Mai 2008

Petra Neumayer; Birgit Funfack: **Aronia –  
Powerbiostoffe aus der Apfelbeere**

# Automatische DDC-Klassifizierung (16)

## Powerbiostoffe aus der Apfelbeere : {615.321}



Fundy-Nationalpark  
ul, 25. Mai 2008

```
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

Korrelationsmaße *C*, *CP* und *CN*

Stellenweiser Ziffernvergleich von links nach rechts zwischen intellektuell vergebener (*dno\_i*) und automatisch ermittelter DDC-Notation (*dno\_a*)

# Automatische DDC-Klassifizierung (18)

## Bewertung (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Projekt Colibri/DDC

*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

# Automatische DDC-Klassifizierung (19)

## Bewertung (3)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Projekt Scorpion/DDC

Bewertungsmaße H (=S1), T(=S2), O (=S3), G (=S4),  
Sp (=S4), Co (=S5), Sy (=S6), B (=S7),  
E (=S8), Cl (=S9), R (=S10)

# Automatische DDC-Klassifizierung (20)

## Bewertung (4)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Projekt Pfeffer/RVK

Vergleich der automatischen und manuellen Klassifikation  
Suche des nächsten gemeinsamen Vaterknoten im RVK-Baum

Bewertungsmaß: perfekt (=P1), gut (=P2),  
mäßig (=P3), schlecht (=P3)

# 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
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

**Vergleichende Betrachtung mit unterschiedlichen  
Bewertungsmaßen**

# Automatische DDC-Klassifizierung (22)

## Bewertung (6)



Fundy-Nationalpark  
ul, 25. Mai 2008

Klasse K	Mensch urteilt: (korrekte Zuordnung)	
	gehört zu K	gehört nicht zu K
Maschine ermittelt: gehört zu K	a	b
Maschine ermittelt: gehört nicht zu K	c	d

**Vierfeldertafel**

# Automatische DDC-Klassifizierung (23)

## Bewertung (7)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Bewertungsmasse

$$\text{Precision } P = a / (a+b)$$

$$\text{Recall } R = a / (a+c)$$

$$\text{Fallout } F = b / (b+d)$$

$$\text{F-Measure} = 2 * P * R / (P+R)$$

# Automatische DDC-Klassifizierung (24) Bewertung (8)



Fundy-Nationalpark  
ul, 25. Mai 2008

## Weitere Bewertungsmasse

Accuracy, Error, Percent too specific, Percent too general,  
Average overlap, Accuracy at level, Eleven-point average  
precision, Precision-recall breakeven point

# Automatische DDC-Klassifizierung (25)

## Bewertung (9)



Fundy-Nationalpark  
ul, 25. Mai 2008

**DNB-Titeldatensätze mit intellektuell vergebener  
DDC-Notation -> DDC-Suchsystem -> DNB-  
Titeldatensätze mit intellektuell und automatisch  
vergebenen DDC-Notationen ->  
automatische Bewertung -> automatisch bewertete  
Klassifizierungsergebnisse**

# Automatische DDC-Klassifizierung (26)

## Klassifizierungsergebnisse



Fundy-Nationalpark  
ul, 25. Mai 2008

Name der Ergebnisdatei <i>res...</i>	res (Anz.)	tit (Anz.)	t [min]
<i>res_vc_IDB-2004_in_DNB-2007</i>	16.694	25.653	133
<i>res_vc_IDB-2008_in_DNB-2007</i>	15.365	25.653	136
<i>res_vc_IDB-2004_in_DNB-2009</i>	21.591	30.717	120
<i>res_vc_IDB-2008_in_DNB-2009</i>	21.422	30.717	140

# 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

# Automatische DDC-Klassifizierung (28)

## Automatisch bewertete Ergebnisse (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

**Übereinstimmung mindestens in der DDC-Hauptklasse**  
63,85% (CN>0)

**Verteilung der Übereinstimmungen, z. B.**  
36,15% (C=0); 13,71% (C=1); 26,29% (C=2)

# Automatische DDC-Klassifizierung (29)

## Automatisch bewertete Ergebnisse (3)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Hypothese

Es gibt signifikante Unterschiede zwischen den DDC-Klassen  
(gemessen mit *CM*)

# Automatische DDC-Klassifizierung (30)

## Automatisch bewertete Ergebnisse (4)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Hypothese

Es gibt signifikante Unterschiede  
zwischen den DDC-Klassen  
(gemessen mit Recall, Precision, F-Measure)

# Automatische DDC-Klassifizierung (31)

## Automatisch bewertete Ergebnisse (5)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Hypothese

Es gibt keinen signifikanten Unterschied zwischen deutschen und englischen Titeldatensätzen

# 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

# Automatische DDC-Klassifizierung (33)

## Automatisch bewertete Ergebnisse (7)



Fundy-Nationalpark  
ul, 25. Mai 2008

### Hypothese

Es gibt signifikante Unterschiede hinsichtlich der Stelligkeit der DDC-Notationen

# Stand der automatischen DDC-Klassifizierung



Fundy-Nationalpark  
ul, 25. Mai 2008

## Eingabedaten

einzelne - ggf. mehrere zusammenhängende – Wörter,  
keine Volltexte, keine linguistischen Verfahren, kein Lexikon

## Ermittlung der DDC-Notationskandidaten

Algorithmus verwendet IR- und KI-Verfahren

**IR**: Vektorprodukt, binäre Vektoren

**KI**: heuristische Regeln

2 Klassenaggregationen für **Ergebnisausgabe**

**Automatische Bewertung** der Klassifizierungsergebnisse

# 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** 😊

# Perspektiven zur automatischen DDC-Klassifizierung (2)



Fundy-Nationalpark  
ul, 25. Mai 2008

**Zuallererst neue Energie aufnehmen ...**



Fundy Nationalpark, ul, 25. Mai 2008

**Vielen Dank für  
Ihr Interesse  
am VZG-Projekt  
Colibri/DDC**

**Für Colibri-Unterstützung und –Diskussionen gilt mein Dank:**

Dipl.-Kfm. Reiner Diedrichs, Direktor der Verbundzentrale (VZG) des GBV, Göttingen

Prof. Dr. Erhard Konrad (i.R.), Fakultät Elektrotechnik und Informatik, TU Berlin, Berlin

Dipl.-Inform. (FH) Alfred Vogelbacher, Network Support Engineer Solaris, Sun Microsystems GmbH, Berlin

# 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.

**Für an Details interessierte Leser**

**Ulrike Reiner**  
**Automatische DDC-Klassifizierung von**  
**bibliografischen Titeldatensätzen**

Version: **Full**

[http://www.opus-bayern.de/bib-  
info/volltexte/2009/736/](http://www.opus-bayern.de/bib-info/volltexte/2009/736/)



Fundy-Nationalpark  
ul, 25. Mai 2008