

Elisabeth Mödden

# Maschinelle Klassifikation und Beschlagwortung der Reihe O in der Deutschen Nationalbibliothek Einblicke in die Praxis

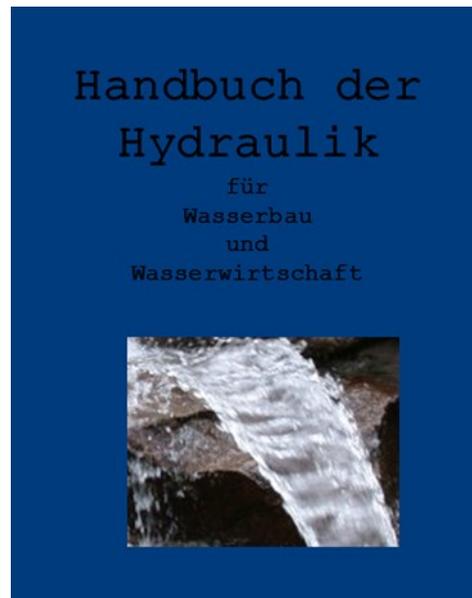
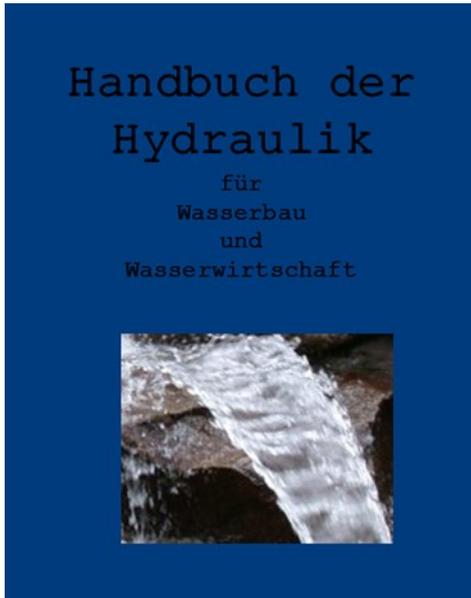
# Automatische Erschließungsverfahren

Parallel-  
verknüpfung

Sachgruppen-  
vergabe

Schlagwort-  
vergabe

# Parallelverknüpfung



# Netzpublikation

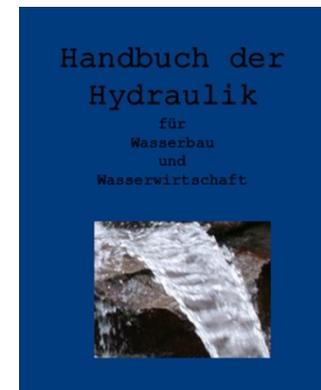
**3000** Aigner, Detlef

**4000** Handbuch der Hydraulik : für Wasserbau und Wasserwirtschaft / Detlef Aigner

**4030** Berlin : Beuth Verlag GmbH

**4060** Online-Ressource

**5050** 620\$Ea\$Honx\$D2015-07-28



## Printpublikation

**3000** [!1033613576!](#)Aigner, Detlef

**4000** Handbuch der Hydraulik für Wasserbau  
und Wasserwirtschaft / Detlef Aigner

**4030** Berlin ; Wien ; Zürich : Beuth

**5050** 624;620

**5100** [!040263126!](#)Hydromechanik

**5101** [!040647005!](#)Wasserbau

**5400** [\[DDC22ger\]627](#)

**5401** [627](#)

Handbuch der  
Hydraulik  
für  
Wasserbau  
und  
Wasserwirtschaft



# Netzpublikation

**3000** **!1033613576!** Aigner, Detlef

**4000** Handbuch der Hydraulik : für Wasserbau und Wasserwirtschaft / Detlef Aigner

**4030** Berlin : Beuth Verlag GmbH

**4060** Online-Ressource

**4243** Druckausg. **!1009964852!**--Aa--Aigner, Detlef: Handbuch der Hydraulik für Wasserbau und Wasserwirtschaft

**4700** |PE|\*Parallelverknüpfung wurde automatisch erstellt

**5050** **624;620\$Ep\$D2015-07-29**

**5050** **620\$Ea\$Honx\$D2015-07-28**

**5100** **!040263126!Hydromechanik**

**5101** **!040647005!Wasserbau**

**5400** [DDC22ger]**627**

**5401** **627**

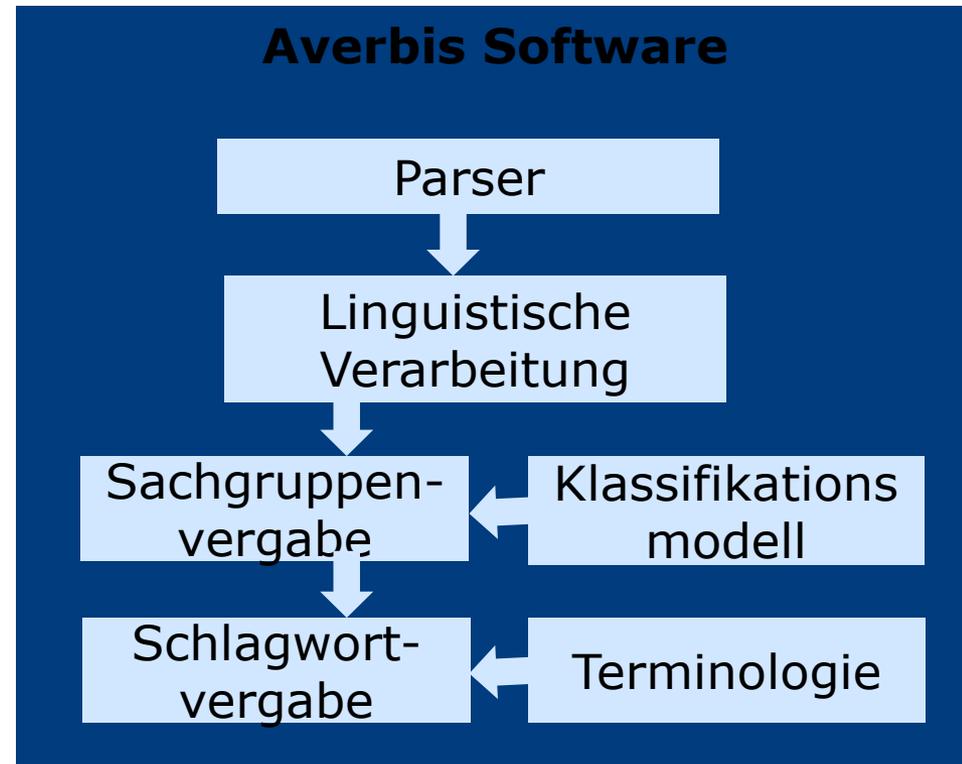
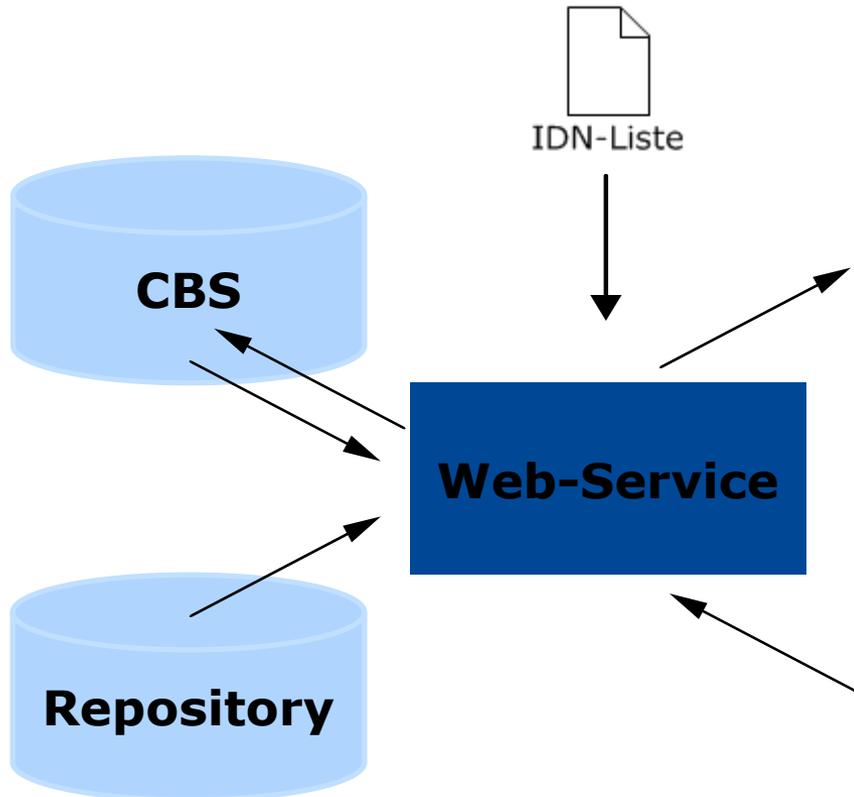
Handbuch der  
Hydraulik  
für  
Wasserbau  
und  
Wasserwirtschaft



# Maschinelle Sachgruppen- und Schlagwortvergabe

- Technologie: Averbis Extraction Platform der Firma Averbis GmbH Freiburg i.Br.
- Schlagwortvergabe durch Extraktion gezielter Informationen aus Texten und Abgleich mit der GND-Terminologie
- DDC-Sachgruppenvergabe durch Klassifikation von Texten anhand maschineller Lernverfahren

# Maschinelle Sachgruppen- und Schlagwortvergabe

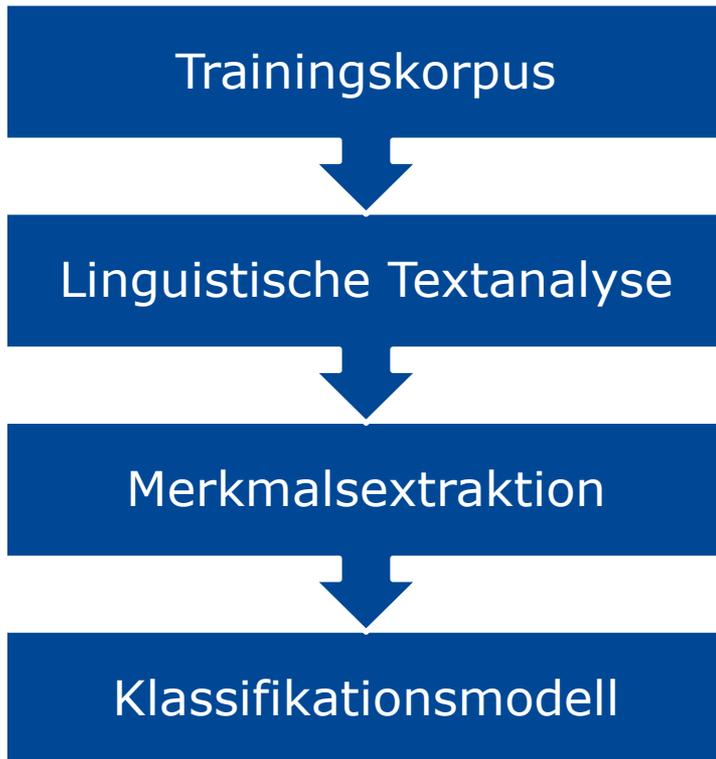


# Maschinelle Sachgruppenvergabe

- Der Klassifikator ordnet Netzpublikationen in die Kategorien der DDC-Sachgruppen mit ca. 100 Klassen ein.
- Training von Klassifikationsmodellen durch Einsatz statistischer Lernverfahren z. B. Support Vector Machine (SVM)..
- Das System lernt anhand von Trainingsbeispielen und leitet Gesetzmäßigkeiten aus diesen Trainingsbeispielen ab.
- Trainingsbeispiele sind Netzpublikationen und gescannte Inhaltsverzeichnisse mit Sachgruppen, die durch die Inhaltserschließung vergeben wurden.

Produktive Anwendung für deutsch- und englischsprachige Netzpublikationen seit 2012

# Training



Trainingsdaten mit Sachgruppe

Netzpublikationen:

- ca. 111.000 in deutscher Sprache
- ca. 57.000 in englischer Sprache

Gescannte Inhaltsverzeichnisse:

- ca. 300.000 in deutscher Sprache
- ca. 48.000 in englischer Sprache

# Maschinelles Lernen

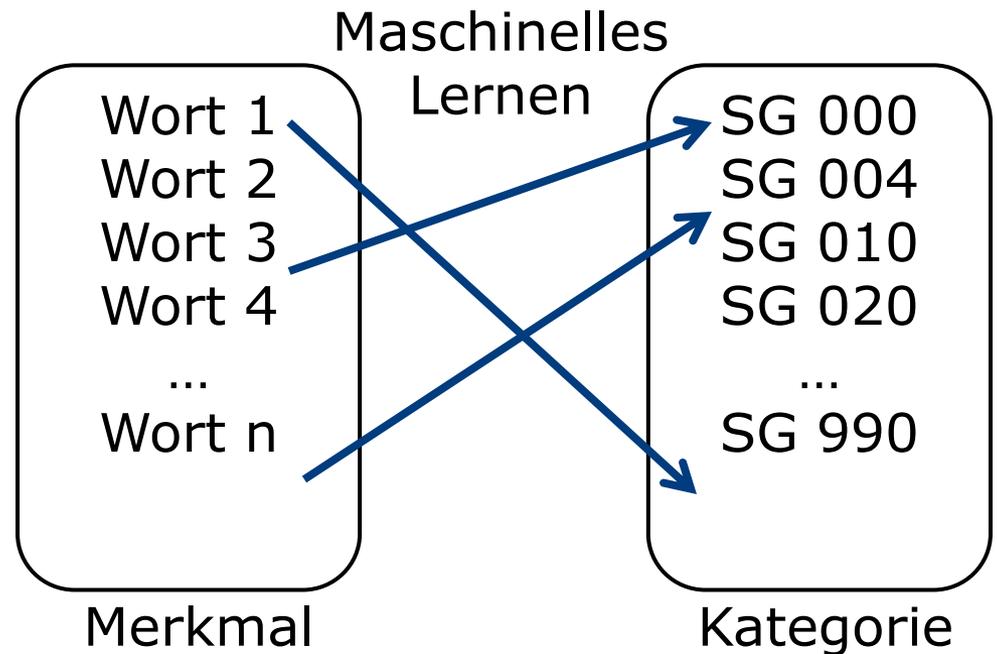
Merkmalsgewinnung



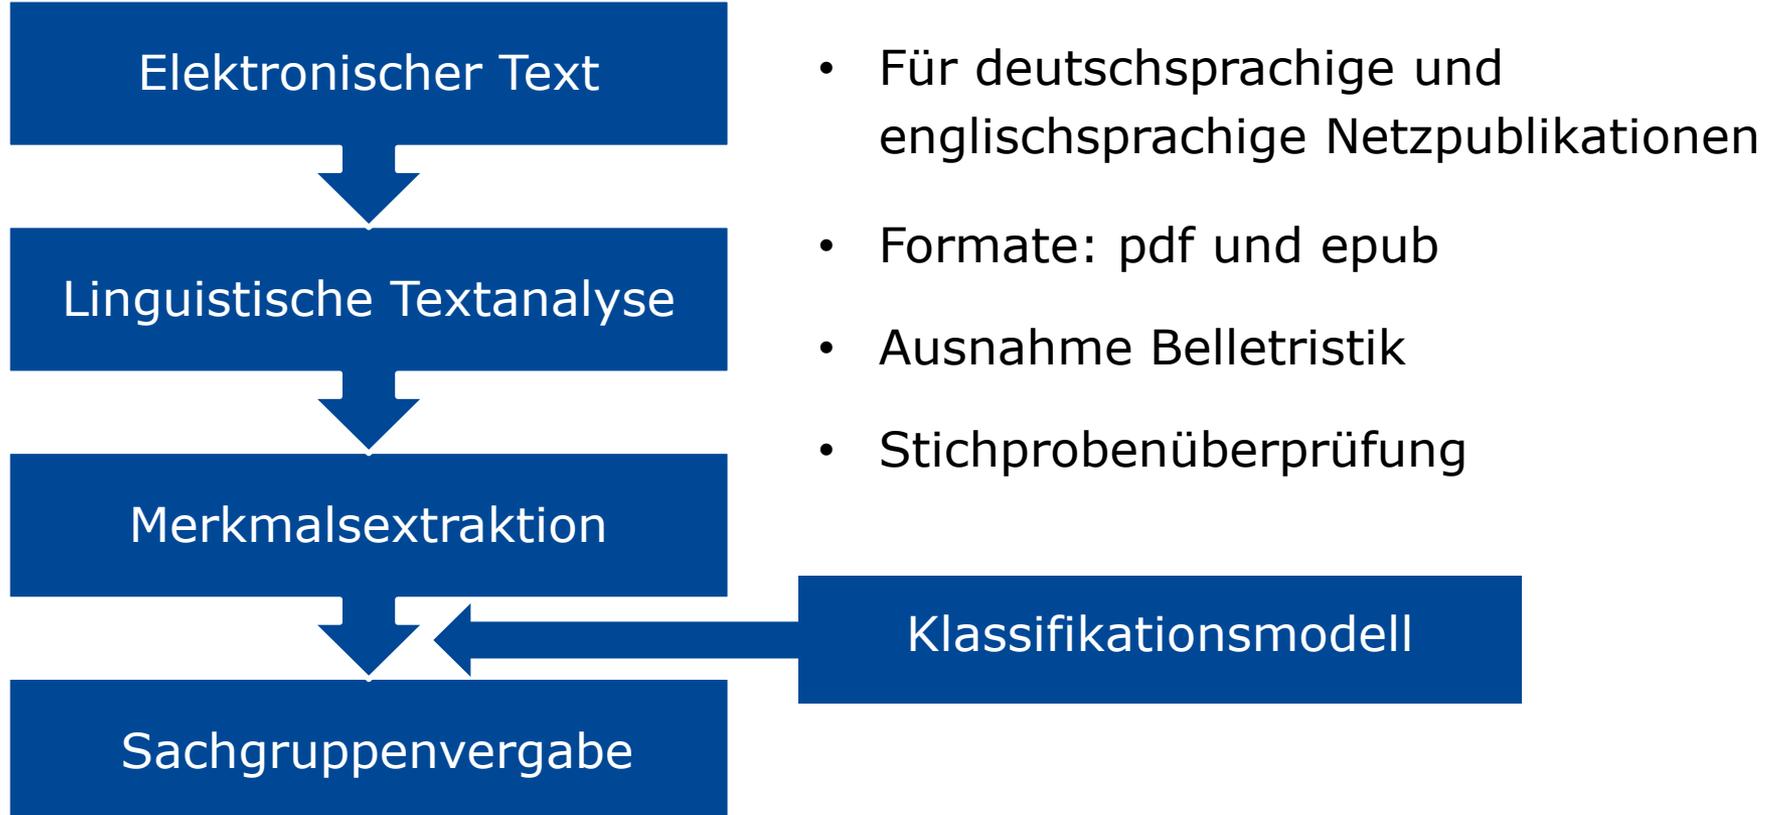
Merkmalsreduktion



Merkmalsgewichtung



# Maschinelle Sachgruppenvergabe



# Maschinelle Sachgruppenvergabe

0500 Oaf

0600 ro;ra;pb

3000 |m|[1031805168](#)!Colverson, Michael

**4000 Bist Du schon wach oder schläfst Du noch? : In Geiselhaft der Großbanken und Großkonzerne werden wir entweder geschoren oder geschlachtet! / Michael Colverson**

5050 330\$Ei\$D2013-03-05

5050 330\$Ep\$D2013-03-08

5050 330\$Em\$Hdnb\$K0,8\$D2013-03-0

5050 000\$Ea\$Honx\$D2013-03-01

Die dargestellte Reihenfolge entspricht der Rangfolge der Sachgruppen:

- \$Ei – intellektuell erstellt
- \$Ep – aus paralleler Ausgabe
- \$Em – maschinell gewonnen
- \$Ea – abgeliefert (Fremddaten)

## Herausforderungen

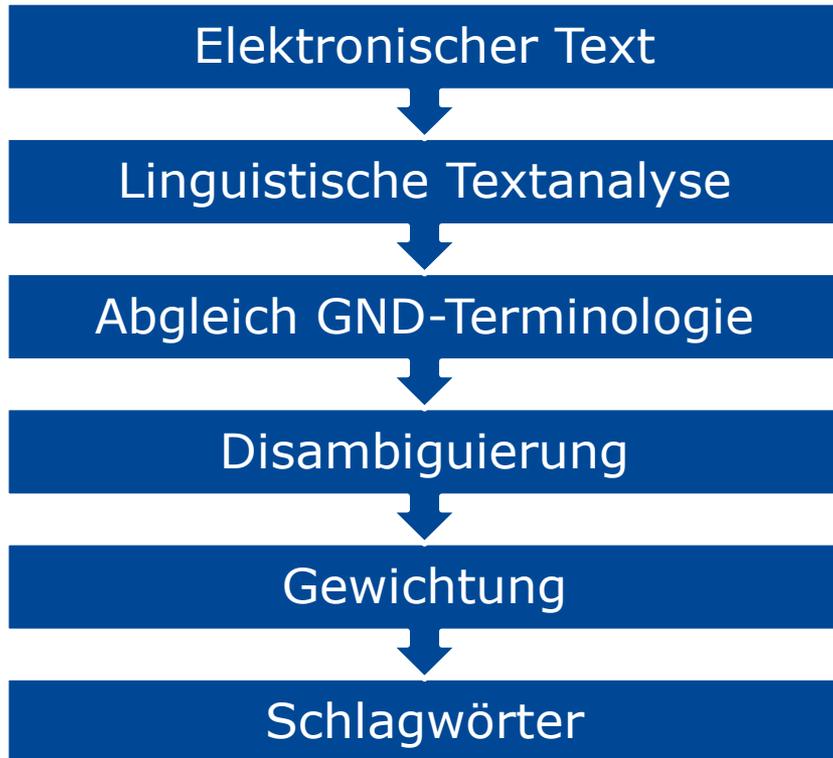
- Ungleichmäßige Verteilung der Netzpublikationen auf die Sachgruppen!
- Kein Trainingsmaterial für alle Sachgruppen!
- 2004 bis 2006 Vergabe der Sachgruppen, ohne Kenntnis der DDC. Fehler im Trainingsmaterial. (16.000 Netzpublikationen müssten überprüft werden)!
- Neue Sachgruppe seit 2010:
  - 333.7 Natürliche Ressourcen, Energie und Umwelt
  - 620 Ingenieurwissenschaften und Maschinenbau
  - 621.3 Elektrotechnik, Elektronik
  - 624 Ingenieurbau und Umwelttechnik
  - 491.8 Slawische Sprachen
  - 891.8 Slawische Literatur

# Maschinelle Schlagwortvergabe

- maschinelle Beschlagwortung von deutschsprachigen Online-Hochschulschriften mit dem Vokabular der Gemeinsamen Normdatei (GND)
- GND-Vokabular
  - Qualitätslevel 1
  - Teilbestand s

Tp - Person (individualisiert) / 369.015 Datensätze  
Ts - Sachbegriff / 184.165 Datensätze  
Ts1e - Hinweissatz / 4.715 Datensätze  
Tg - Geografikum / 205.244 Datensätze  
Tb1 - Körperschaft / 142.593 Datensätze  
Tf1 - Kongress/ 11.831 Datensätze  
Tu1 - Werk / 87.831 Datensätze

# Maschinelle Schlagwortvergabe



- pro Online-Hochschulschriften bis zu 10 GND-Schlagwörter, gesteuert über einen Konfidenzwert
- Workflow für Stichprobenprüfung
- Wörterbuchpflege

Produktive Anwendung für deutschsprachige Online-Hochschulschriften seit April 2014

## Linguistische Analyse

### Original Text

...zur Bewertung der  
Tragfähigkeit von  
Asphaltstraßen-  
befestigungen  
aufgrund von FWD-  
Messungen...



Satzerkennung

Worterkennung

Wortartenerkennung

Phrasenerkennung  
(Nominalphrasen)

Stammformbildung

Morpho-Semantische  
Analyse



# Abgleich GND-Terminologie

Die	<b>Myokarditis ist</b> myokarditis myo kard itis	eine	<b>Sammelbezeichnung</b> sammelbezeichn sammel bezeich	<b>Stems</b>  <b>Segments</b>
für	<b>entzündliche</b> entzünd entzünd	<b>Erkrankungen</b> erkrankung krank	des <b>Herzmuskels</b> herzmuskel herz muskel	
mit	<b>unterschiedlichen</b> unterschied unterschied	<b>Ursachen.</b> ursach ursach		
<b>Deskriptor:</b>	<b>Synonyme:</b>	<b>Deskriptor:</b>	<b>Synonyme:</b>	
<b>Herzmuskelentzündung</b> Herzmuskelentzündung herz muskel entzünd	- - - -	<b>Myokard</b> Myokard Myo kard	<b>Herzmuskel</b> herzmuskel herz muskel	
<b>Kollektivum</b> Kollektivum kollektiv	<b>Sammelbezeichnung</b> sammelbezeichnung sammel bezeich	<b>Heterogenität</b> Heterogen heterogen	<b>Differenz</b> differenz differ	<b>Unterschied</b> unterschied unterschied
<b>Entzündung</b> Entzündung entzünd	<b>Inflamatio</b> inflammatio inflamm	<b>Ursache</b> Ursach ursach	<b>Ätiologie</b> atiolog aetiolog	
<b>Krankheit</b> Krank Krank	<b>krank</b> krank krank			
Annotationen original:	Kollektivum			
Annotationen stems:	Kollektivum, Myokard, Ursache			
Annotationen segments:	Kollektivum, Entzündung, Krankheit, Myokard, Heterogenität, Ursache			

auf unterschiedlichen Ebenen:

- Original
- Stem
- Segment

# Ambiguität

005 Ts1  
011 s  
065 10.9a;10.2ea  
083 332.456  
150 Wechselkurs  
450 Devisenkurs  
450 **Kurs**\$gDevisen

005 Ts1  
011 s  
065 10.9c  
083 332.63222  
150 Aktienkurs  
450 **Kurs**\$gAktie  
450 Aktienpreis

005 Ts1  
011 s  
065 10.9c  
083 332.63222  
150 Wertpapierkurs  
450 Effektenkurs  
450 **Kurs**\$gWertpapier

005 Ts1  
011 s  
065 10.9c  
083 332.63222  
150 Börsenkurs  
450 **Kurs**\$gBörse  
450 Börsenpreis

005 Ts1  
011 s  
065 6.4  
083 T1--071  
150 **Kurs**  
450 Lehrgang  
450 Seminar\$gKurs  
450 Seminar\$gLehrgang  
450 Workshop  
450 Kurse

005 Ts1  
011 s  
065 10.6a  
083 387.52  
150 **Kurs**\$gNavigation  
550 Navigation\$4obal

# Disambiguierung

**Configuration**

General | Linguistics | Train | Classify | Keywording

Standard

Basics | Terminologies | Disambiguation | General Boosting | Category Boosting

The order of the stages can be changed, some stages may be deactivated selectively:

Stage 1:	MatchedVariantCoveredTextDis
Stage 2:	DocumentCountryCodeFingerp
Stage 3:	GNDEntityDisambiguator
Stage 4:	DocumentCategoryFingerprint
Stage 5:	
Stage 6:	FrequencyDisambiguator
Stage 7:	LookaroundDisambiguator
Stage 8:	FallbackDisambiguator

Das Verfahren durchläuft mehrere Stufen.

# Document-Fingerprint basierend auf der GND-Systematik

Link zu diesem Datensatz: <http://d-nb.info/968571956>

Titel: **Wissen im Fluß** [Elektronische Ressource] : **Prozeßorientierung im Wissensmanagement unter Verwendung grafischer Modelle** / Katja Franziska Pook

Schlagwörter: Wissensmanagement ; Kognitive Psychologie ; Online-Publikation; Mitarbeiter ; Einarbeitung ; Wissensvermittlung ; Informationssystem ; Prozesskette ; Graphische Darstellung  
Sachgruppe(n): 150 Psychologie ; 650 Management

## Top 5 GND-Systematik Topics gemäß Document Fingerprint

(GND-Systematik Nummer=Anzahl, GND-Systematik Notationsbenennung)

4.3=106, Erkenntnistheorie, Logik

1=82, Allgemeines, Interdisziplinäre Allgemeinwörter

30=64, Informatik, Datenverarbeitung

9.3c=61, Gruppe, Organisationssoziologie, Interaktion

10.11a=61, Betriebswirtschaftslehre (Allgemeines), Unternehmen, Management

6.5=45, Wissenschaft

10.9a=1, 10.9c=1, 0.1a=1, 12.10=1, 25.2a=1, 7.13a=1, 0.4=1, 10.00=1, 9.3a=1, 19.10=1,  
19.1a=1, 7.5c=1, 10.4=1, 31.14=1, 18=1, 10.7b=1, 28p=1, 21.1=1, 27.4=1, 16.1p=1, 13.1c=1,  
12.1p=1, 30m=1, 8.2a=1, 10.6a=1, 13.1cy=1, 10.11g=1, 6.4p=1, 15.4=1, 15.3=1, 15.1=1,  
12.4y=1, 10.12a=1, 7.6a=1, 13.5=1, 14.1=1, 27.20=1, 12.4=1, 24.2b=1, 2.3p=1, 13.6p=1,

# Stichprobenprüfung

- Titel-Stichproben

Vierstufige Bewertungsskala:

sehr nützlich / nützlich / wenig nützlich / falsch

- Schlagwort-Stichproben

Überprüfung der Erschließungskonsistenz

- Gezielte Suche nach systematischen Fehlern
- Abgleich mit parallel erschlossenen Publikationen



- Analyse der Stichproben
- Einordnung in Fehlerklassen

## Stichprobenprüfung Bewertung

**4000** Numerische Analyse des Nachstroms und  
Propellereffektivität am manövrierenden Schiff

**5540** [GND]...Schiff\$K0,476... wenig nützlich

**5540** [GND]...Manöver\$gSchiffahrt\$K0,356... sehr nützlich

**5540** [GND]...Wirbelschleppe\$K0,312... falsch

**5540** [GND]...Schiffsantrieb\$K0,041... nützlich

**5540** [GND]...Nachstrom\$K0,003... falsch

Vierstufige

Bewertungsskala:

sehr nützlich / nützlich /

wenig nützlich / falsch

005 Ts1

006 <http://d-nb.info/gnd/4776222-6>

011 s

035 gnd/4776222-6

039 swd/4776222-6\$**v**zg

065 31.9a

083 621.31\$d2\$t2009-09-29

150 Nachstrom

550 !040707458!Elektrischer Strom\$4obal

670 Lex. Elektrotechn.

## Stichprobenprüfung Ergänzung FA

**4000** Numerische Analyse des Nachstroms und  
Propellereffektivität am manövrierenden Schiff

**5540** [GND]...Schiff\$K0,476...

wenig nützlich

**5540** [GND]...Manöver\$gSchiffahrt\$K0,356...

sehr nützlich

**5540** [GND]...Wirbelschleppe\$K0,312...

falsch

**5540** [GND]...Schiffsantrieb\$K0,041...

nützlich

**5540** [GND]...Nachstrom\$K0,003...

falsch

**5540** [FA]...Nachstrom\$gStrömungsmechanik

**5540** [FA]...Schiffspropeller

**5540** [FA]...Numerische Strömungssimulation



Neuansetzung

# Wörterbuch Aufbau und Pflege

- regelmäßiges Einspielen der GND-Terminologie, wahlweise als Voll-Update oder als inkrementelles Update
- Pflege der Wörterbuch-Profile (Terminologie-Plattform): bevorzugte Benennungen, Synonyme, komplette Datensätze oder auch ganze Teilbäume der GND können hinsichtlich der gewünschten Verarbeitungsform markiert werden

DEFAULT – Term wird segmentiert

EXACT – Term wird nicht segmentiert (also in der exakten Schreibweise prozessiert)

IGNORE – Term wird „stillgelegt“  
(also nicht in das Wörterbuch eingelesen)

## Ausblick maschinelle Schlagwortvergabe

- Auslieferung der maschinell ermittelten Schlagwörter
- Verbesserung des Verfahrens
- Ausweitung auf andere Netzpublikationstypen wie E-Books, Zeitschriftenartikel etc.
- Weiterentwicklung für englischsprachige Netzpublikationen z.B. über Crosskonkordanzen GND – LCSH

# LC SH – GND

## Monetary policy

URI(s)...

Instance Of...

Scheme Membership(s)

[Library of Congress Subject Headings](#)

Collection Membership(s)...

Variants

 [Monetary management](#)

Broader Terms

 [Economic policy](#)

Narrower Terms

 [Credit control](#)

 [Devaluation of currency](#)

 [Dollarization](#)

 [Inflation targeting](#)

 [Open market operations](#)

 [Quantitative easing \(Monetary policy\)](#)

 [Transmission mechanism \(Monetary policy\)](#)

 [Unemployment--Effect of monetary policy on](#)

Related Terms

 [Currency boards](#)

 [Money supply](#)

## Exact Matching Concepts from Other Schemes

 [monetary policy](#) 

## Closely Matching Concepts from Other Schemes

 [Geldmengenpolitik](#) 

 [Geldmengensteuerung](#) 

 [Geldpolitik](#) 

 [Geldverfassung](#) 

 [Notenbankpolitik](#) 

 [Politica monetaria](#) 

 [Politique monétaire](#) 

 [Währungspolitik](#) 

 [Währungssystem](#) 

## LC Classification

HG230.3

## Change Notes

1986-02-11: [new](#)

1998-01-09: [revised](#)

## Alternate Formats ...

## Ausblick maschinelle Schlagwortvergabe

- Auslieferung der maschinell ermittelten Schlagwörter
- Verbesserung des Verfahrens
- Ausweitung auf andere Netzpublikationstypen wie E-Books, Zeitschriftenartikel etc.
- Weiterentwicklung für englischsprachige Netzpublikationen z.B. über Crosskonkordanzen GND – LCSH
- Weiterentwicklung für gescannte Inhaltsverzeichnisse
- Vorschlagstool zur GND-Pflege

# **Vielen Dank für Ihre Aufmerksamkeit**

Elisabeth Moedden

Automatische Erschließungsverfahren, Netzpublikationen

Deutsche Nationalbibliothek

Telefon: +49-69-1525-1533

E-Mail: [e.moedden@dnb.de](mailto:e.moedden@dnb.de)