

# Maschinelle Indexierung der Deutschen Nationalbibliothek

Elisabeth Mödden | Helga Karg

# Maschinelle Beschlagwortung

Start: 2014

- Deutschsprachige Online-Publikationen der Reihe 0
  - ohne Zeitschriftentitel
  - ohne Belletristik
- Deutschsprachige Online-Zeitschriftenartikel
- Deutschsprachige Print-Publikationen der Reihen B und H über gescannte Inhaltsverzeichnisse (TOC)

Seit Juni 2018

- Englischsprachige Online-Dissertationen der Reihe O

Umfang: 225.000 Publikationen (Stand Juni 2018)

# Maschinelle Beschlagwortung

Methode: computerlinguistisches Verfahren auf der Basis eines Wörterbuches

Basis: bibliografische Titeldaten und elektronische Texte

Terminologie:

GND (nur Datensätze mit Qualitätslevel 1 und Teilbestand s)

NEU:

LCSH (Library of Congress Subject Headings)

in Kombination mit Nicht-Sachbegriffen der GND (Personen, Geografika, Körperschaften, Kongresse und Werke)

Tp – Person (individualisiert)	369.015 Datensätze
Ts – Sachbegriff	184.165 Datensätze
Ts1e – Hinweissatz	4715 Datensätze
Tg – Geografikum	205.244 Datensätze
Tb1 – Körperschaften	142.593 Datensätze
Tf1 – Kongresse	11.831 Datensätze
Tu1 – Werke	87.831 Datensätze

Search results (1)		
ConceptID	Label	
040006263	Ästhetik	GND Sachschlagworte 1420

# Maschinelle Beschlagwortung

## Beispiel Englisch

4000 Reconstructing European Copyright Law for the Digital Single Market :  
Between Old Paradigms and Digital Challenges / Bernd Justin Jütte


4204 \$dDissertation\$eUni. Luxembourg\$f2016

5050 340\$Em\$Haep-sg\$K0,99414\$D2018-06-05

5540[**GND**!]940431181!**Europäische Union** [Tb1]\$K0,00119\$D2018-06-05

5540[**LCSH**]**Copyright**\$Lsh85032446\$u<http://id.loc.gov/authorities/subjects/sh85032446>\$K0,20713\$D2018-06-05

Auslieferung der LCSH ab Januar 2019 geplant




# Abgleich GND-Terminologie


- Original
- Stem
- Segment

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>	-		<b>Myokard</b>	<b>Herzmuskel</b>	
Herzmuskelentzündung	-		Myokard	herzmuskel	
herz muskel entzünd	-		Myo kard	herz muskel	
	-				
<b>Kollektivum</b>	<b>Sammelbezeichnung</b>		<b>Heterogenität</b>	<b>Differenz</b>	<b>Unterschied</b>
Kollektivum	sammelbezeichnung		Heterogen	differenz	unterschied
kollektiv	sammel bezeich		heterogen	differ	unterschied
<b>Entzündung</b>	<b>Inflamatio</b>		<b>Ursache</b>	<b>Ätiologie</b>	
Entzündung	inflammatio		Ursach	atiolog	
entzünd	inflamm		ursach	aetiolog	
<b>Krankheit</b>	<b>krank</b>				
Krank	krank				
Krank	krank				
Annotationen original:	Kollektivum				
Annotationen stems:	Kollektivum, Myokard, Ursache				
Annotationen segments:	Kollektivum, Entzündung, Krankheit, Myokard, Heterogenität, Ursache				

# Maschinelle Erschließung produktiv



# Bibliografiejahrgang 2017 maschinell beschlagwortet



# Maschinelle Beschlagwortung produktiv



Konfiguration *Wissenschaftliche Arbeiten:*

Reihe O: Hochschulschriften, Monographien von  
Universitätsverlagen, Wissenschaftliche Literatur  
verschiedener Verlage

# Maschinelle Beschlagwortung produktiv

Konfiguration *BookonDemand* :

Publikationen von BOD-Verlagen

# Maschinelle Beschlagwortung produktiv

Konfiguration *TableOfContents* :

Verarbeitung von gedruckten Publikationen mittels  
TOCs: Reihe B und Reihe H (Monografien)  
produktiv seit 20. April 2017

# Maschinelle Beschlagwortung produktiv



Konfiguration *Artikel:*

Online-Artikel von Universitätsverlagen,  
Wissenschaftliche Papers verschiedener Verlage inkl.  
Springer de

# Maschinelle Beschlagwortung produktiv

Konfiguration *Englisch*:

englischsprachige Dissertationen der Reihe O

# Fünf Konfigurationen – Fünf Ergebnismengen

- Die eingesetzten Konfigurationen führen täglich zu fünf Ergebnismengen der maschinellen Beschlagwortung.
- Der Anzahl an Publikationen pro Ergebnismenge kann täglich stark schwanken: Zwischen 1 und ca. 1.000 Publikationen können innerhalb eines Tages beschlagwortet worden sein.
- Analyse der Beschlagwortung von zufällig ausgewählten Publikationen (Stichproben) über alle Ergebnismengen.
- Produktionsanalyse in der Tiefe, statt in der Breite.

# Qualitätskontrolle - Vorgehensweise

- Intellektuell
- Stichprobenartig
- Publikationen der Reihe O – auf der Basis von Volltexten
- Reihen H und B – auf der Basis von Inhaltsverzeichnissen
- In möglichst vielen Fachgebieten
- Regel der RSWK zur Schlagwortfolgenbildung bleiben unberücksichtigt
- Bewertung der einzelnen Schlagwörter nach festgelegten Kriterien
- Bewertung des Gesamtindexats

# Bewertung der maschinellen Beschlagwortung

## Qualitätsanforderungen:

- **Informationsqualität** der maschinell erstellten Metadaten
- **Rechercheanforderungen** der digitalen Wissens- und Informationsgesellschaft
- Verbesserte Auffindbarkeit orientiert an den **Suchfragen der Nutzer**

# Qualitätsanforderungen

Die einzelnen GND-Terme sollen das Thema der Publikation richtig und sinnvoll wiedergeben durch:

- Nützliche, gebräuchliche Schlagwörter
- Angemessene Anzahl der relevanter Schlagwörter
- Aktuelle / Gültige Schlagwörter
- Spezifität / Genauigkeit der Schlagwörter im Hinblick auf das vorhandene Vokabular
- Konsistente Vergabe von Schlagwörtern

# Bewertungskriterien - Schlagwort

Das einzelne Schlagwort beschreibt einen wesentlichen Aspekt des Textes ausreichend und trifft absolut zu

Sehr nützlich 3

Das einzelne Schlagwort beschreibt einen wichtigen Aspekt des Textes aus einer etwas weiteren/engeren Perspektive zutreffend

Nützlich 2

Das einzelne Schlagwort beschreibt einen wichtigen Aspekt des Textes nicht ausreichend, ist aber auch nicht völlig unzutreffend oder falsch

Wenig nützlich 1

Das einzelne Schlagwort beschreibt keinen wichtigen Aspekt des Textes und ist falsch oder nicht nützlich

Falsch 0

# Stichprobenprüfung Beispiel

**Titel:** Numerische Analyse des Nachstroms und Propellereffektivität am manövrierenden Schiff

## Schlagwörter:

- |  |                |
|--|----------------|
| <b>5540</b> [GND]!...! <b>Schiff</b> \$K0,476...               | wenig nützlich |
| <b>5540</b> [GND]!...! <b>Manöver</b> \$gSchiffahrt\$K0,356... | sehr nützlich  |
| <b>5540</b> [GND]!...! <b>Wirbelschleppe</b> \$K0,312...       | falsch         |
| <b>5540</b> [GND]!...! <b>Schiffsantrieb</b> \$K0,041...       | nützlich       |
| <b>5540</b> [GND]!...! <b>Nachstrom</b> \$K0,003...            | falsch         |

GND: Nachstrom  
OB Elektrischer Strom

# Ergänzung Fehlender Aspekte Disambiguierung

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

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

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

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

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

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

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

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

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

# Bewertungskriterien - Gesamtindexat

Das Indexat ist vollständig und bildet den Inhalt / das Thema der Publikation vollständig ab

Sehr gut 3

Das Indexat ist nicht vollständig, enthält aber das / die wesentlichen Schlagwörter

Gut 2

Das Indexat ist unvollständig und die Schlagwörter bilden den Inhalt / das Thema zu weit, zu eng oder nur zu einem Teil ab

Mäßig 1


Das Indexat bildet den Inhalt / das Thema nicht ab oder es wurden zu viele falsche Schlagwörter vergeben

Unbrauchbar 0

# Evaluationsgebnisse der intellektuellen Bewertung maschinell vergebenen Schlagwörter


Betrachtungszeitraum: 20.04-14.11.2017

## Reihe H



# Evaluationsergebnisse der intellektuellen Bewertung des Gesamtindexats

Betrachtungszeitraum: 20.04-14.11.2017



# Beobachtungen der Fachreferenten

- Höhere **Präzision der Titelstichwörter** bezogen auf den Inhalt des Werks führt zu besseren Ergebnissen
- **Werbende Titel, Wortspiele, Metaphern** oder andere rhetorische Figuren (oder auch oftmals auch Zitate aus Primärquellen) führen zu falschen Ergebnissen
- Besonders **abstrakte Fachsprache** bzw. ein metaphorischer Sprachgebrauch in bestimmten Wissenschaftsfächern ist problematisch, da sich ihre Sprache von der Alltagssprache stark unterscheidet.
- **Viele verschiedene Themen**, die sich im Inhaltsverzeichnis angemessen widerspiegeln sind oft besser erschlossen als stringent auf nur ein bestimmtes inhaltliches Merkmal fokussierte Dokumente

# Beobachtungen der Fachreferenten

- Erkennen der richtigen **Körperschaft oder Person** ist über alle Fächer hinweg problematisch.  
Bsp.: Akzidenzschriften, Sammelbände, bei denen immer wieder die in Inhaltsverzeichnissen aufgeführten Namen der Verfasser der Einzelbeiträge als Schlagwörter zur Beschreibung des Inhalts verwendet werden.
- Erkennung von **Geographika**
- Es konnten bisher keine filterbaren **Dokumentgruppen** innerhalb der Reihe B erkannt werden, die für bes. gute oder schlechte Qualität steht
- Verbesserung der ToC basierten Erschließung der Reihen B /H durch Erweiterung der **Textbasis** auf Abstracts und Klappentexte

# Fehleranalyse - Hauptursachen

Falsche Beschlagwortung durch:

- GND-Vokabular:
  - Falsche Auflösung von Mehrdeutigkeiten  
(Bank -> Sitzgelegenheit oder Bank -> Kreditinstitut)
  - Fehlende Schlagwörter, Synonyme
- Kein passendes Schlagwort in der GND -> falsches Schlagwort wird vergeben
- Linguistische Analyse der Software führt zu falscher Beschlagwortung
- Schlagwort wird korrekt vergeben, ist für die Abbildung des Publikationsinhaltes aber irrelevant

# Optimierungsstrategien

- Pflege des Vokabulars, der GND mit Hilfe von Tools zur Visualisierung, Vorschlagssystem für neue Deskriptoren etc.
- Wörterbuchpflege
- Suchmaschinenoptimierung
- Verbesserung der maschinellen Verfahren durch Qualitätsmanagement
- Entwicklung neuer Komponenten
- Verbesserung der Scans sowie der Qualität der OCR

Vielen Dank für Ihre Aufmerksamkeit