

Sachliche Einordnung von Dokumenten in Bibliotheken: praktische Erfahrungen mit maschinellen Lernverfahren

Monika Lösse (Deutsche Nationalbibliothek)

Mathias Lösch (Universitätsbibliothek Bielefeld)

Workshop on Classification and Subject Indexing in Library and Information Science
(LIS'2012)

Motivation

- Zahl der elektronischen Publikationen steigt massiv
- Mehrzahl ist nicht klassifikatorisch erschlossen
- Nachträgliche intellektuelle Klassifikation bei den Aggregatoren aufgrund der Menge nicht möglich/finanzierbar

Automatische Dokumentenklassifizierung in Bibliotheken

- Idee nicht neu
- Ergebnisse jedoch bisher nicht zufriedenstellend, kein Produktiveinsatz
- Seit den 1990er Jahren jedoch zunehmend erfolgreiche Anwendung von maschinellen Lernverfahren zur Textkategorisierung (z.B. Spam-Filter)

Zwei Praxisbeispiele

1. Projekt PETRUS (Deutsche Nationalbibliothek)
 - Automatische Klassifikation von Netzpublikationen nach DDC-Sachgruppen
2. Projekt „Automatische Anreicherung von OAI-Metadaten“ (UB Bielefeld)
 - Automatische Klassifizierung von Metadaten nach DDC-Sachgruppen für die *Bielefeld Academic Search Engine* (BASE)
3. Gemeinsame Erkenntnisse


DDC-Sachgruppen

- Seit Bibliografie-Jahrgang 2004: Gliederung der Bibliografie-Reihen nach DDC-Sachgruppen
- System zur thematischen Ordnung von Titeldaten unabhängig von der Sprache der Publikationen
- System beruht auf der Dewey-Dezimalklassifikation (DDC) und gliedert sich zurzeit in 104 DDC-Sachgruppen

000	Allgemeines, Wissenschaft
004	Informatik
010	Bibliografien
...	
500	Naturwissenschaften
510	Mathematik
520	Astronomie, Kartographie
530	Physik
...	
600	Technik
610	Medizin, Gesundheit
620	Ingenieurwissenschaften und Maschinenbau
621.3	Elektrotechnik, Elektronik
...	

Abläufe im Produktivbetrieb bei der DDC-Sachgruppen-Vergabe

realisiert mit der Averbis Extraction Platform seit Januar 2012
für deutsch- und englischsprachige Netzpublikationen



- (1) Lesende Schnittstelle CBS
- (2) DnBPetrus-Service
- (3) Averbis-Webservice
- (4) Schreibende Schnittstelle CBS
- (Rep) Repository

Modellbildung für die maschinelle Klassifikation

- Modellbildung mit statistischen Lernverfahren (z.B. SVM):
Das System lernt anhand von Trainingsbeispielen und leitet daraus mathematische Gesetzmäßigkeiten ab.
- Trainings- und Testbeispiele sind Netzpublikationen und gescannte Inhaltsverzeichnisse mit intellektuell vergebenen Sachgruppen.

Gewinnung der Merkmalsvektoren für Training und Klassifikation

- Extraktion der Merkmale einer Publikation mit linguistischen Verfahren
(optional: Stemming-, Segment- oder Konzept-Modus)
- Reduktion und Gewichtung der Merkmale
(Entfernen von Stoppwörtern; Gewichtung nach Position, Textgröße, Häufigkeit im Text vs. Häufigkeit in der Kollektion etc.)

Die Deutsche Nationalbibliothek, ehemals Die Deutsche Bibliothek, ist mit ihren Standorten Leipzig (ehemals Deutsche Bücherei, seit 2010 auch Deutsches Musikarchiv) und Frankfurt am Main (ehemals Deutsche Bibliothek) die zentrale Archivbibliothek und das nationalbibliografische Zentrum Deutschlands. [...]




deutsch
nationalbibliothek
bibliothek
standort
leipzig
bucherei
musikarchiv
frankfurt
main
zentral
archivbibliothek
nationalbibliograf
zentrum
deutschland

deutsch
national
bibliothek
ort
leipzig
buch
musik
archiv
frankfurt
main
zentral
bibliografisch
zentrum
deutschland


Durchführung der maschinellen Klassifikation

- Vergleich der Merkmalsvektoren mit den beim Training für jede der DDC-Sachgruppen ermittelten Klassifikatoren
- Berechnung der Konfidenzwerte für jede Klasse (d.h. Bestimmung der Wahrscheinlichkeit der Klassenzugehörigkeit) über den Abstand zu einer Trennebene im mehrdimensionalen Vektorraum



Qualitätssicherung im Geschäftsprozess

- Falls der Konfidenzwert der übernommenen Sachgruppe unterhalb eines Schwellenwerts liegt, wird der Statusindikator für die intellektuelle Nachbearbeitung gesetzt.
- Einmal pro Monat werden die maschinell vergebenen Sachgruppen mit intellektuell zugewiesenen Sachgruppen verglichen. Das sind z.B.:
 - aus parallelen Ausgaben übernommene Sachgruppen,
 - intellektuell vergebene Sachgruppen aus der Qualitätssicherung.
- Der berechnete F-Measure-Wert berücksichtigt gleichermaßen Recall (= Ausbeute) und Precision (= Genauigkeit).



Zurzeit werden pro Monat 5.000 – 10.000 Netzpublikationen maschinell klassifiziert. Dabei wird ein F-Measure-Wert von 0.7 erreicht.

Dokumentation aller Erfassungsarten im bibliografischen Datensatz

• • •

3010 !130464511!Hartinger, Anselm [Hrsg.]

4000 Vergnügte Pleißenstadt : Bach in Leipzig /
Anselm Hartinger

• • •

5050 780\$**Ei**\$D2011-02-10

5050 780\$**Ep**\$D2011-03-05

5050 780\$**Em**\$K0,8\$D2012-01-19

5050 330\$**Ea**\$D2010-03-04

Die dargestellte Reihenfolge entspricht der Rangfolge der Sachgruppen:

- \$Ei – intellektuell erstellt
- \$Ep – aus paralleler Ausgabe
- \$Em – maschinell gewonnen
- \$Ea – aus Fremddaten bei der Ablieferung

Produktivbetrieb 2012

Monat	Anzahl Abgelieferte NP	mSG	pSG + mSG	SG qs
Januar	13.410	9.970	4.110	439
Februar	14.140	8.995	4.117	250
März	13.195	6.248	2.399	231
April	12.347	3.742	1.446	159
Mai	11.596	11.294	3.618	577

Monatlicher Abgleich
aus parallelen Ausgaben übernommene
Sachgruppen mit
maschinell vergebenen Sachgruppen


Monat	F-Measure micro-average
Januar	0,69
Februar	0,76
März	0,61
April	0,70


Probleme: Training

- Gemischtes Trainingsmaterial: Netzpublikationen und gescannte Inhaltsverzeichnisse!
- Ungleichmäßige Verteilung der Netzpublikationen und der gescannten Inhaltsverzeichnisse auf die Sachgruppen!
- Kein Trainingsmaterial für alle Sachgruppen!
- 2004 bis 2006 Vergabe der Sachgruppen vor Einführung der DDC-Notationsvergabe; damit Fehler im Trainingsmaterial.
- 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

Trainingsmaterial Netzpublikationen





Trainingsmaterial
gescannte
Inhaltsverzeichnisse

Diagramm:
Verteilung der gescannten
Inhaltsverzeichnisse
(deutschsprachige) auf die
Sachgruppen

Probleme: Heterogene Netzpublikationstypen

- Sehr heterogene Dokumententypen:
 - Belletristik
 - Hochschulschriften
 - BoD

- Unregelmäßige Ablieferung über die Jahre.

Verschiedene Dokumententypen Netzpublikationen	2010 Anzahl NP	2011 Anzahl NP
NP BoD	87.885	27.783
NP Springer	6.932	53.777
NP Hochschulschriften	12.984	12.265
NP Reihe A ohne Springer	998	928
Alle abgelieferten NP	112.765	101.181

Probleme: Häufig vertauschte Sachgruppen

004 Informatik	↔	620 Ingenieurwissenschaften
150 Psychologie	↔	610 Medizin, Gesundheit
330 Wirtschaft	↔	650 Management
360 Soziale Probleme, Sozialdienste, Versicherungen	↔	610 Medizin, Gesundheit
570 Biowissenschaften, Biologie	↔	610 Medizin, Gesundheit

Weitere Probleme:

- Nur 40.000 kB des Volltextes stehen zur Verfügung!
- Fehler bei der Spracherkennung! Z.B. russische Netzpublikationen werden oft nicht erkannt und bekommt fälschlicherweise eine Sachgruppe.
- Nur Netzpublikationen im PDF-Format bekommen maschinell eine Sachgruppe zugewiesen. EPUB und andere Formate können nicht bearbeitet werden.
- Laden der Trainingskorpora sehr langsam, deshalb wurde bisher nur mit 22% des zur Verfügung stehenden Trainingsmaterials Modelle erstellt.


Lösung der Probleme?

- Durch schrittweise Optimierung der Trainingskorpora sollen die Modelle laufend weiter verbessert werden, insbesondere hinsichtlich der „schwierigen“ Sachgruppen:
 - Sachgruppen, für die nicht genügend Trainingsbeispiele vorhanden sind (z.B. seltene oder neue Sachgruppen),
 - Sachgruppen, die inhaltlich schwer trennbar sind (z.B. 330 Wirtschaft vs. 650 Management).
- Verbesserung der Klassifizierungs-Software in einem Folgeprojekt durch die Firma Averbis.
- Verbesserung des Produktivprozesses:
 - durch Ausweitung auf weitere Formate, insbesondere EPUB
 - Verbesserung der Spracherkennung
 - Strukturanalyse
 - Nutzung der abgelieferten Warengruppen in der Belletristik

DFG-Projekt „Automatische Anreicherung von OAI-Metadaten“

- Automatische Klassifikation wissenschaftlicher Dokumente im Index der *Bielefeld Academic Search Engine* (BASE) nach DDC
- Ziele:
 - DDC-Browsinginterface für BASE
 - BASE als Content-Provider für virtuelle Fachportale

Workflow der automatischen Anreicherung



Trainingsmaterial

- Nutzung von Metadaten (Abstracts) aus der BASE-Datenbasis als Trainingsdokumente
- DDC-Sachgruppen in deutschen Repositorien verbreitet (z.B. Bedingung für das DINI-Zertifikat)
- Derzeit sind rund 500.000 intellektuell nach DDC-Sachgruppen klassifizierte Dokumente in BASE indexiert

Konstruktion des Klassifikators

- Vorfilterung der Metadatenätze:
 - Enthält DDC-Sachgruppe
 - Mindestlänge des Abstracts von 500 Zeichen
 - Abstract in Deutsch oder Englisch
- Konstruktion eines „balancierten“ Trainingskorpus (gleiche Anzahl von Dokumenten pro Klasse)
- Stoppworteliminierung und Merkmalsextraktion
- Lernen des Modells (zur Zeit SVMs)

Produktivbetrieb: BASE

- Schrittweise Klassifizierung der BASE-Datenbasis
- Aktuell ~ 3 Mio. Dokumente nach DDC klassifiziert, davon ~ 2,5 Mio. automatisch
- DDC-Browsinginterface wurde freigeschaltet


Produktivbetrieb: Nachnutzung

- Nachnutzung des Klassifikators
 - Möglich über offenen Webservice
 - Nachnutzung durch DFG-Projekt OA-Netzwerk wird evaluiert
- Pilotpartner für fachbezogenen Dokumentlieferungen: EconBiz.de (ZBW Kiel)


Probleme: Fehlende Trainingsdokumente

- Klassen unterschiedlich gut durch Beispieldokumente abgedeckt
- Für etliche Klassen existiert wenig bis kein Beispielmateriale
- Maschinelle Lernmodelle (in der Basiskonfiguration) verlangen gleichmäßige Klassenstärken

Deutsche Trainingsdokumente pro DDC-Sachgruppe



Englische Trainingsdokumente pro DDC-Sachgruppe




Probleme: Heterogene Dokumente

Dokumentlängen in Wörtern:


Englische Abstracts	Deutsche Abstracts
Minimale Länge: 59	Minimale Länge: 40
Maximale Länge: 10979	Maximale Länge: 8493
Durchschnittliche Länge: 271.34	Durchschnittliche Länge: 279.49
Standardabweichung: 204.34	Standardabweichung: 200.72

Probleme: Zu allgemeine Klassifizierung der Trainingsdaten in die X00-Klassen

F-Wert mit Klasse „500“: 0.85



F-Wert ohne Klasse „500“: 0.88



Lösungsansätze: Vergrößerung des Trainingskorpus

- Die Zahl der Trainingsdokumente steigt durch die regelmäßige Aktualisierung der BASE-Datenbasis aus den Repositorien
- Regelmäßiges Neu-Training des Klassifikators mit der aktuellen Datenbasis

Lösungsansätze: Korpusvergrößerung durch Nutzerfeedback

schließen

DDC Korrekturvorschlag

Bitte wählen Sie die korrekte DDC-Klasse für dieses Dokument in drei Schritten aus:

0 Informatik, Informationswissenschaft, allgemeine Werke

02 Bibliotheks- und Informationswissenschaften

Unterklasse wählen

Hinweis: Ihr Vorschlag hilft uns bei der Verbesserung der automatischen Klassifikation. Eine direkte Übernahme in die BASE-Ergebnisse findet nicht statt.

Senden

- Wird jedoch noch wenig genutzt

Fazit

- Automatische Dokumentenklassifikation im Bibliotheksbereich erstmalig praxistauglich
- Verfahren haben dennoch noch Schwächen, an Verbesserung wird gearbeitet
- Qualität der Beispielskorpora entscheidend für den Erfolg

Vielen Dank für Ihre Aufmerksamkeit!

Dr. Monika Lösse
Deutsche Nationalbibliothek
Deutscher Platz 1
D-04103 Leipzig
+49-341-2271-582
M.Loesse@dnb.de

Mathias Lösch
Universitätsbibliothek Bielefeld
Universitätsstr. 25
D-33615 Bielefeld
+49 521-106-2546
Mathias.Loesch@uni-bielefeld.de