

Inhaltsverzeichnis

I Grundlagen und klassische IR-Methoden	1
1 Einführende Beispiele	3
1.1 Literatursuche	5
1.2 Recherche in einer Literaturdatenbank	7
1.3 Faktendatenbanken und -retrieval	10
1.4 Hypertext-Informationssysteme	11
1.5 Expertensysteme	12
1.6 Management-Informationssysteme	13
1.7 Data Mining	14
1.8 Kategorisierung mit einem Data-Mining-System	15
1.9 Assoziative Regeln und der Warenkorb	17
1.10 Wissensgewinnung und Information Retrieval	18
2 Grundlagen	21
2.1 Informationsübertragung	21
2.1.1 Datenübertragung	21
2.1.2 Komplexere Übertragungsbeispiele	22
2.2 Dialoge	24
2.3 Information Retrieval	26
2.3.1 Daten, Wissen, Information	26
2.3.2 Struktur eines Information-Retrieval-Systems	28
2.3.3 Information Retrieval: Definition und Abgrenzung	29
3 Klassische Information-Retrieval-Verfahren	33
3.1 Boolesches Retrieval	33
3.1.1 Logik des booleschen Retrieval	34
3.1.2 Boolesches Retrieval für Textdokumente	34
3.1.3 Implementierung mit invertierten Listen	36
3.1.4 Erweiterungen	38
3.2 Zeichenketten, Wörter und Konzepte	39
3.2.1 Reduktion von Wörtern auf ihre Grundformen	40
3.2.2 Lexikografische Grundformenreduktion nach Kuhlen	42
3.2.3 Lexikonbasierte Morphologie-Analyse	44
3.2.4 Auflösen von Mehrdeutigkeiten	46
3.3 Klassifikationen	47

3.3.1	Internationale Dezimalklassifikation	50
3.3.2	Erweiterte Klassifikationssysteme	52
3.4	Thesauren	54
3.5	Semantische Netze	59
3.6	Das Vektorraummodell	61
3.6.1	Das Modell	62
3.6.2	Vektorraummodell und boolesches Retrieval	64
3.6.3	Gewichtungsmethoden	66
3.6.4	Globale Gewichtungseinflüsse	67
3.6.5	Lokale Gewichtungseinflüsse	70
3.6.6	Relevance Feedback	72
3.6.7	Ähnlichkeitsfunktionen	72
3.6.8	Das Retrieval-System SMART	80
3.7	Bewertung und Vergleich von IR-Systemen	83
3.7.1	Einflussfaktoren	84
3.7.2	Relevanz	85
3.7.3	Precision und Recall	86
3.7.4	Mittelwertbildungen	90
3.7.5	Testkollektionen	91
3.7.6	Die TREC-Experimente	94

II Wissensgewinnung mit Data-Mining-Methoden 101

4	Lernen	103
4.1	Lernen als Informationsverarbeitung	106
4.2	Automatisches Lernen aus Beispielen	108
4.2.1	Faktendatenbanken	108
5	Kategorisieren	111
5.1	Attribute und Kategorien	111
5.2	Trainings- und Testmenge	113
5.3	Lernparadigmen	114
5.4	Der ID3-Algorithmus	115
5.4.1	Formale Beschreibung des ID3-Algorithmus	116
5.4.2	Kategorisieren mit dem ID3-Algorithmus	119
5.5	Rahmenbedingungen für Lernalgorithmen	119
5.5.1	Konsistenz	119
5.5.2	Größe von Entscheidungsbäumen	120
5.5.3	Wertebereiche der Attribute	121
5.5.4	Bewertung von Kategorisierungsergebnissen	123
5.5.5	Inkonsistente Trainingsdaten	124
5.5.6	Unvollständige Beispiele	126
5.5.7	Größe und Repräsentativität der Trainingsmenge	127
5.5.8	Inkrementelles Lernen	128

5.5.9	Overfitting	129
5.5.10	Suchstrategien	129
5.6	Einfache Regelsysteme	131
5.6.1	Entscheidungslisten	133
5.6.2	Ripple-down-Regelmengen	134
5.6.3	Top-down- und Bottom-up-Methoden	135
5.7	Der AQ-Algorithmus	137
5.7.1	Generalisierungsoperationen	143
5.8	Regelsysteme mit zusammengesetzten Attributen	143
5.9	Multivariate Entscheidungsbäume	145
5.9.1	Attributauswahl	147
5.9.2	Sequenzielle Elimination und Auswahl	148
5.9.3	Verteilungsbasiertes Eliminationsverfahren	148
5.9.4	Das CART-Verfahren	149
5.9.5	Koeffizientenbestimmung	149
5.9.6	Evaluierung	151
6	Cluster und unscharfe Mengen	153
6.1	Cluster	153
6.2	Unscharfe Mengen	155
7	Assoziative Regeln	163
7.1	Warenkorbmodell	164
7.2	DBLearn/DBMiner	166
8	Ein komplexeres Beispiel	173
8.1	Problemstellung	173
8.2	Lösungsansätze	174
8.3	Verfahren	174
8.4	Durchführung und Bewertung	176
III	Erweiterte Retrieval-Ansätze	179
9	Das Vektorraummodell als Fuzzy-Set-Ansatz	181
9.1	Verallgemeinerte boolesche Verfahren	181
9.1.1	Das MMM-Modell	182
9.1.2	Das Paice-Modell	183
9.1.3	Das P-Norm-Modell	184
10	Der probabilistische Retrieval-Ansatz	185
10.1	Wahrscheinlichkeiten in endlichen Mengen	185
10.1.1	Beispiel: Würfel	186
10.2	Abschätzung des Retrieval-Status-Werts	188
10.3	Die Robertson-Sparck-Jones-Formel	192

11 Logikbasierte Modelle des Information Retrieval	195
11.1 Imaging	197
11.2 Bayessche Inferenznetze	200
11.3 Abduktive Anfrageoptimierung	205
12 Erfolgreiche TREC-Systeme	207
12.1 Die TREC-3-Ergebnisse von SMART	208
12.2 Die TREC-4-Ergebnisse von SMART	210
12.3 Ein Spreading-Activation-Modell	215
12.4 INQUERY in TREC-4	217
12.5 Das Okapi-System	219
12.6 Spezialaufgaben (TREC Tracks)	221
13 Korpusbasierte Verfahren	223
13.1 Der assoziative Ansatz im IR	223
13.2 Kookurrenzverfahren	226
13.2.1 Ein Machine-Learning-Ansatz	226
13.2.2 Term-Term-Matrizen	227
13.2.3 Anwendung im IR	228
13.2.4 Häufigkeit der Terme	228
13.2.5 Expansion von Termen oder Anfragen	231
13.2.6 Größe der Dokumentensammlung	231
13.2.7 Eine Untersuchung zur Bestimmung von Suchterminen	231
13.2.8 Komplexere Kookurrenzverfahren	232
13.3 Anwendung im mehrsprachigen Retrieval	233
13.4 Deskriptoren bestimmen	235
13.5 Latent Semantic Indexing	239
13.6 Gewichtungsmethoden Lernen	239
13.7 Social oder Collaborative Filtering	241
IV Information Retrieval und das Web	245
14 Explizit strukturierte Dokumente	247
14.1 Standard Generalized Markup Language (SGML)	248
14.1.1 SGML-Elemente	248
14.1.2 Elementattribute	250
14.1.3 SGML-Entities	252
14.2 HTML	253
14.3 XML	254
14.3.1 Verweise: XPointer und XLink	255
14.3.2 XML Schema	255
14.3.3 XPath, XQuery	256
14.4 Suche nach und in XML-Dokumenten	258
14.4.1 Anwendungen von XML bei der Suche	258
14.4.2 Indexierungsmethoden	259

14.4.3	Modelle für die Suche in XML-Dokumenten	261
14.4.4	Ein Vektorraummodell für strukturierte Anfragen an Sammlungen von XML-Dokumenten	262
14.4.5	Suche bei unterschiedlichen DTDs	265
15	Metadaten	267
15.1	Dublin-Core-Metadaten	268
15.2	Hierarchisch strukturierte Metadaten	272
15.3	PICS	275
15.4	RDF und das Semantische Web	276
15.4.1	Resource Description Framework	276
15.4.2	Pläne für ein Semantisches Web	281
16	Suche im World Wide Web	285
16.1	Das Web als Dokumentensammlung	285
16.1.1	Medienarten	286
16.1.2	Sprache	287
16.1.3	Länge und Granularität	287
16.1.4	Dynamik und Alter von Web-Seiten	288
16.1.5	Anbieter und ihre Ziele	289
16.1.6	Zielgruppen	290
16.1.7	Inhalte	291
16.1.8	Spamming	291
16.2	Suchmechanismen der Web-Protokolle	292
16.3	Hierarchische Verzeichnisse oder Web Directories	295
16.3.1	Klassifikation des Open Directory Project	296
16.4	Web-Suchmaschinen	299
16.4.1	Web-Roboter, Crawler oder Spider	300
16.4.2	Ranking-Strategien	302
16.4.3	Ranking nach externen Daten	303
16.4.4	Metasuchdienste	306
16.5	Spezialisierte und verteilte Sammlungen	308
16.5.1	Der Z39.50-Standard	309
16.5.2	Beispiele verteilter Sammlungen	310
16.5.3	Peer-to-Peer-Netze	313
16.6	Digitale Bibliotheken	316
16.6.1	Inhalte einer digitalen Bibliothek	318
16.6.2	Dienste	319
16.6.3	Archivierung	320
Literaturverzeichnis		323
Index		333