Non-Standard-Datenbanken und Data Mining

Prof. Dr. Ralf Möller

Universität zu Lübeck Institut für Informationssysteme

Tanya Braun und Felix Kuhr (Übungen)



Organisatorisches: Übungen

- **Start**: Freitag, 19. Oktober 2017
- **Zwei Übungen**: ab 19.10. Fr. 8.30-10 Uhr , IFIS, Geb. 64, Seminarraum Mathematik II, Banach (Anmeldung über Moodle notwendig)
 - Erste Ausgabe eines Übungsblattes am 18.10. ab 18 Uhr über Moodle
- Übungsaufgaben stehen jeweils nach der Vorlesung am Donnerstag ca. ab 18 Uhr über Moodle bereit
- Abgabe der Lösungen erfolgt bis Mittwoch 12 Uhr in der IFIS-Teeküche (jeweils in der Woche nach der Ausgabe, 1 Kasten pro Übungsgruppe)
 - Erste Abgabe am 24.10.
- Aufgaben können in einer 2-er Gruppe bearbeitet werden (also bitte Name(n), Matrikelnummer(n) und Übungsgruppennummer vermerken)
- In den Übungen am Freitag wird der Übungszettel besprochen, dessen Lösungen bis zum jeweils vorigen Mittwoch abgegeben wurde, und es werden auch Fragen zum jeweils neuen Übungszettel geklärt (ggf. mit Präsenzaufgaben als Hilfestellung)



Organisatorisches: Prüfung

- Die Eintragung in den Kurs und in eine Übungsgruppe ist Voraussetzung, um an dem Modul Non-Standard-Datenbanken teilnehmen zu können
- Am Ende des Semesters findet eine Klausur statt
- Voraussetzung zur Teilnahme an der Klausur sind mindestens 50% der gesamtmöglichen Punkte aller Übungszettel



Teilnehmerkreis und Voraussetzungen

Studiengänge

- Bachelor Medizinische Informatik
- Bachelor Medieninformatik
- Bachelor Informatik
- Bachelor Mathematik in Medizin und Lebenswissenschaften
- Master Informatik
- Master MML

Voraussetzungen (Bestehen der unten genannten Veranstaltungen ist keine Teilnahmebedingung für NDB-Klausur)

- Algorithmen und Datenstrukturen
- Lineare Algebra und Diskrete Strukturen
- Datenbanken
- Kontextfreie Grammatiken

Vorteilhaft

Einführung in die Logik





Merkmale von Standard-Datenbanken

- Datenmodell: relational ("Tabellen" und "Tupel")
- Annahmen:
 - Strukturen fix (Schemaänderung möglich, aber aufwendig)
 - Verwerfen d. A. führt zu semistrukturierten Datenbanken und zu Graphdatenbanken
 - Abstrakte Entitäten mit abstr. Assoziationen (Tupel in Relationen)
 - Verwerfen führt zu temporalen, sequenzorientierten, räumlichen, und multimodalen¹ Datenbanken
 - Daten persistent, Anfragen bzgl. Schnappschuss einmal beantwortet
 - Verwerfen führt zu stromorientierten Datenbanken
 - Daten enthalten feste Werte bzw. Referenzen
 - Verwerfen führt zu Datenbanken für unsichere und unvollständige Information



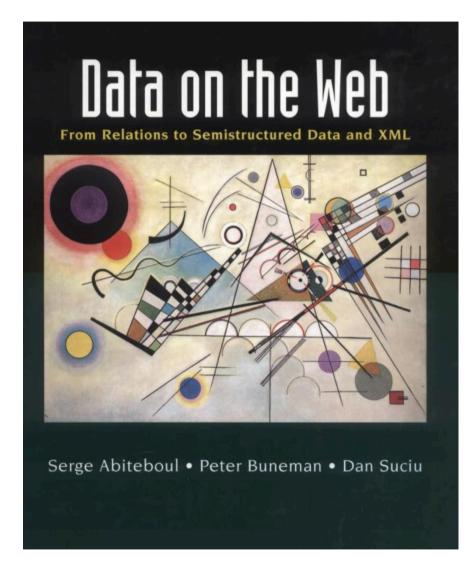
Non-Standard-Datenbanken

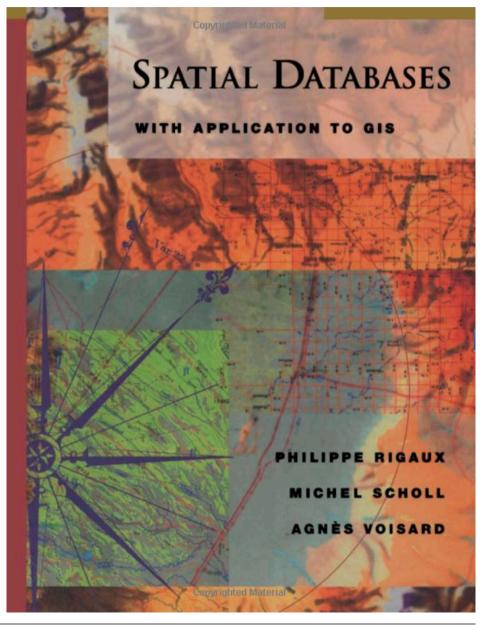


- Semistrukturierte Datenbanken (XML)
- Räumliche und multimodale Datenbanken
 - lineare und mehrdimensionale Strukturen
- Temporale Datenbanken
 - zeitlich beschränkte Gültigkeiten
- Datenbanken für **Datenströme** (Fensterkonzept)
- Bewertung von Antworten (Top-k-Anfragen)
- Probabilistische Datenbanken zur Repräsentation unsicherer Information
- Next Generation Databases, Graphdatenbanken

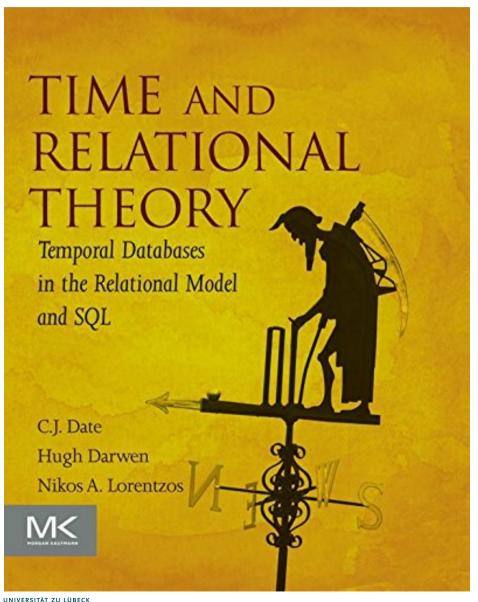


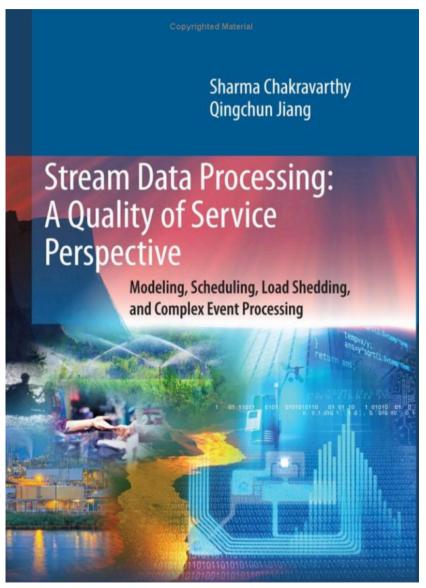
1999 2001











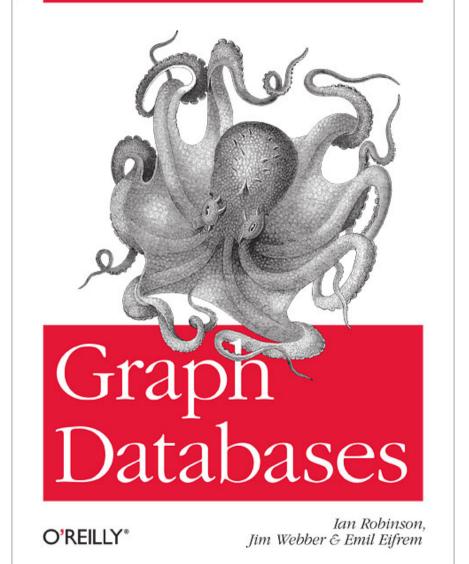
2011 2016



Probabilistic Databases

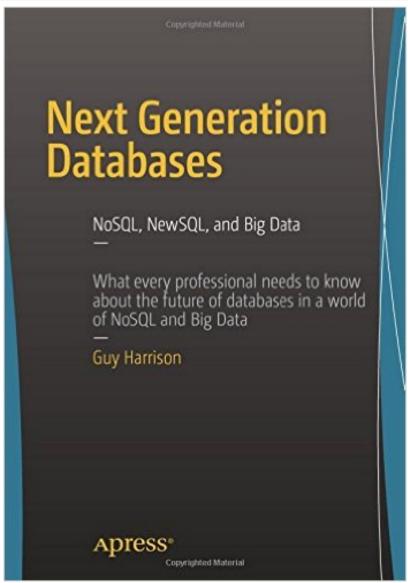
Dan Suciu Dan Olteanu Christopher Ré Christoph Koch

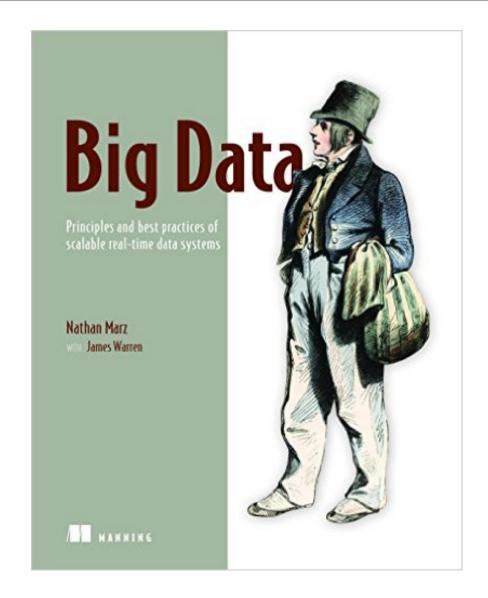
SYNTHESIS LECTURES ON DATA MANAGEMENT



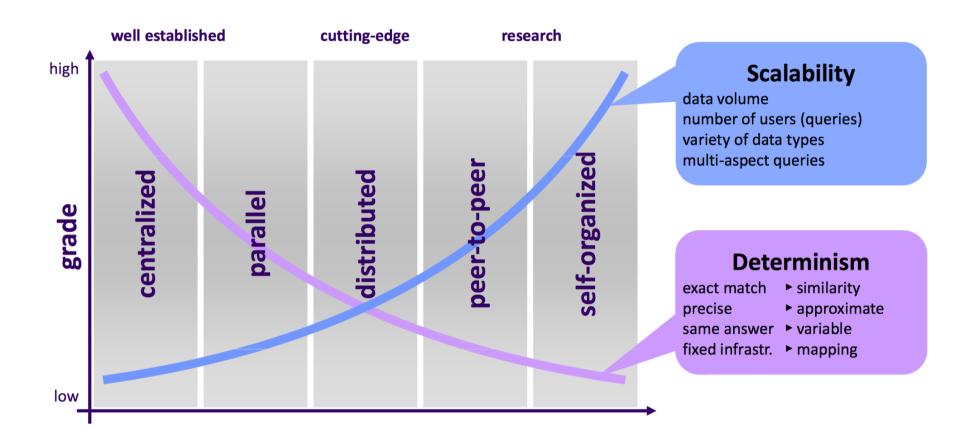


2015 2015





Datenhaltungstypen und Anfragebeantwortung





Anfragesprachen für Datenbanken

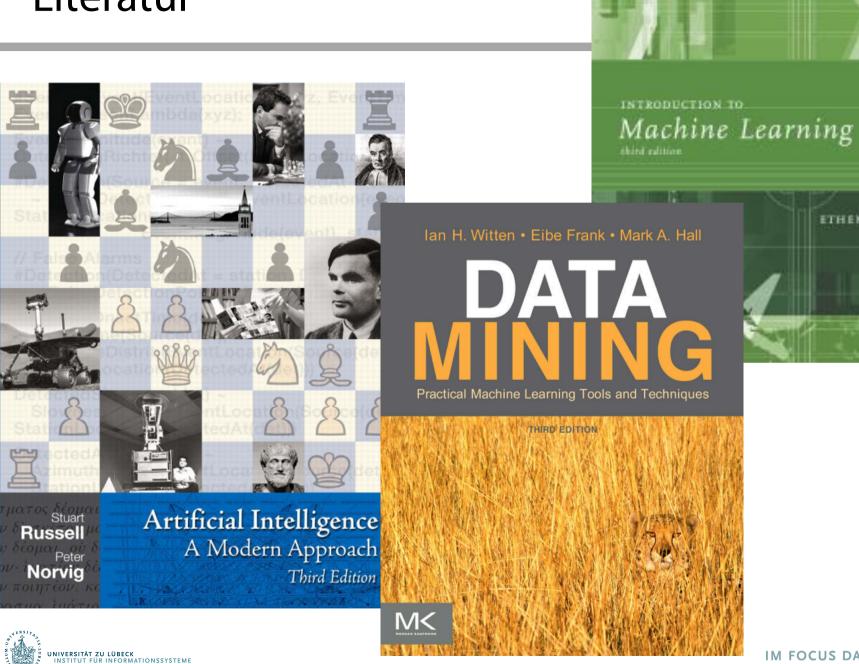
- Semantik und Ausdrucksstärke
 - Was braucht man in der Anwendung?
- Ausdrucksstärke vs. Skalierbarkeit
 - Betrachtung der Komplexität des Anfragebeantwortungsproblems für eine gegebene Anfragesprache
 - Datenkomplexität
 - Wie wirkt sich eine Verdopplung des Datenbestandes bei fixer Anfrage auf die Worst-Case-Laufzeit der besten Anfragebeantwortungsalgorithmen aus?
 - Kombinierte Komplexität
 - Laufzeit bezogen auf Anfragelänge und Daten (relevant aber selten betrachtet, da Anfragelänge klein)

Data Mining

- Gewinnung von
 Entscheidungsfunktionen (Klassifikation) oder
 Berechnungsfunktionen (Regression) aus Daten
 - Statische Daten
 - Über der Zeit eintreffende Daten (Stream Data Mining)
 - Daten mit Gültigkeitsinformation (Historical Data Mining)
- Extraktion von relationalen Beschreibungen aus Texten bzw. Vektordaten (z.B. Bildern)
- Umgang mit unsicheren und unvollständigen Daten

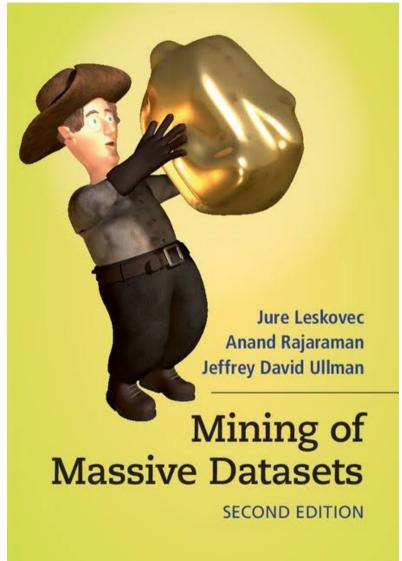


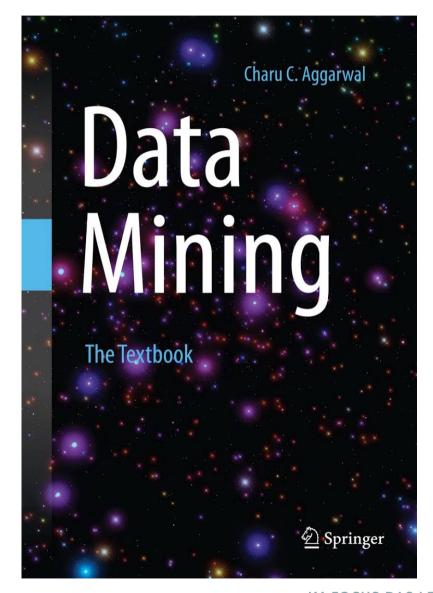
Literatur



ETHEM ALPAYDIN

Literatur





Literatur

