


HOCHDIMENSIONALE DATEN

Leipzig, 03.07.2015

Paul Jähne

HOCHDIMENSIONALE DATEN

- ab wann? > 100 typisch
- Beispiele: Geoinformationssystem, CAD, Molekular-Biologie, Gen-Sequenzierung, psychologische Profile, Data-Mining
- Ähnlichkeitsanfragen werden auf Nachbarschaftsanfragen in Feature-Räumen abgebildet



HOCHDIMENSIONALE FEATURE-VEKTOREN

- Modell für wichtige Eigenschaften eines Objekts
- Vektor mit Zahlenwert für feste Anzahl an Dimension
- bilden Vektorraum
- orthogonale Dimensionen
- Reduktion auf lineare Algebra
- Beispiele: Farb-Histogramm, Fourier-Vektor

OPERATIONEN AUF FEATURE-VEKTOREN

- Nächste-Nachbarsuche (NN)
- k-Nächste-Nachbarsuche (kNN)
- Approximative Nächste-Nachbarsuche (aNN)
- Reverse-Nächste-Nachbarsuche (rNN)
- Bereichssuche
- Punktsuche
- Partial-Match-Suche
- Ähnlichkeitsverbund


METRIKEN FÜR ABSTÄNDE

Ähnlichkeit:


Unähnlichkeit:

,


[BBK01]



Manhattan (L_1)




Euclidean (L_2)



Maximum (L_∞)



weighted Eucl.



weighted Max.




Ellipsoid


INDEXSTRUKTUREN

- B-Baum ungenügend
 - nur nach einer Dimension indexiert
 - exakte Suche

R-BAUM

- Rectangle
- B-Baum mit mehreren Dimensionen
- Clusterbildung mit umschließenden Rechtecken
- jeder Elternknoten umfasst mindestens alle rechtecke der Kindknoten
- für effiziente Suche minimale Überlappung benötigt





R-BAUM EINFÜGEN

- Suche von Knoten mit geringstem Erweiterungsvolumen
- falls gleich, dann kleinerer Knoten
- Blatt gefunden, dann einfügen und Vaterknoten anpassen
- Überlauf
 - Zerlegung in zwei Knoten
 - Aufteilung mit geringster Volumensumme wählen

R-BAUM SUCHE


- löst Nächster-Nachbar-Problem
- RKV-Algorithmus
 - Branch and Bound
 - Tiefensuche
 - kein getNext möglich
- HS-Algorithmus
 - Breitensuche
 - getNext möglich
 - benötigt viel Speicher

R-BAUM-VARIANTEN


- hohe Dimensionalität ergibt viele Überlappungen
- seltener Teilbäume ausschließbar
- verschiedene Varianten, um dies zu verbessern:
 - R_+
 - Überlappungen verboten
 - neuer Einfügealgorithmus
 - dafür geringe Auslastung der Knoten → viele Knoten
 - R^*
 - X

X-BAUM

- eXtended
- hybrid aus Array und R-Baum
- R-Baum-Split kann schlechte Strukturen erzeugen
 - viele Überlappungen
 - besonders bei hochdimensionalen Daten
 - viele Pfade müssen untersucht werden
 - gute Split-Strategie: viele Leerknoten



a. Overlap (Uniformly Distributed Data)





b. Weighted Overlap (Real Data)

Figure 2: Overlap of R*-tree Directory Nodes depending on the Dimensionality

X-BAUM

- R*-Erweiterung
- sequentieller Durchlauf bei hoher Überlappung effizienter
- überlappungsfreie Splitstrategie mit Split-Historie
- zusätzliche Superknoten
 - dynamisch angelegt bei hoher Überlappung
 - umfassen beliebig viele Seiten
 - Suche innerhalb sequentiell




-  Superknoten
-  innerer Knoten
-  Blattknoten

X-BAUM

- Vorteile:

- größerer Fanout
- Scan von Superknoten eventuell schneller als Suche in R-Baum
- Punktsuche bis zu 450x schneller als R*-Baum
- NN-Suche bis zu 20x schneller als R*-Baum
- Einfügen 8x schneller als R*
- größere Knoten nur dort wo sie benötigt werden



ZUSAMMENFASSUNG

- hohe Dimensionalität vermeiden
- Modellierung mit Feature-Vektoren
- Anfragen häufig Nächste-Nachbar- oder Bereichssuche
- X-Bäume als Index gut geeignet

QUELLEN

Böhm, Brechtold, Keim: Searching in High-dimensional Spaces - Index Structures for Improving the Performance of Multimedia Databases, 2001

Böhm: Effiziente Indexstrukturen für hochdimensionale Datenräume, 1998

Brechtold, Keim, Kriegel: The X-tree: An Index Structure for High-Dimensional Data, 1996

Wikipedia: R-tree, <https://en.wikipedia.org/wiki/R-tree>, 2015

Schmitt: Multimedia-Datenbanken - 6 Effiziente Algorithmen und Datenstrukturen, http://www.witi.cs.uni-magdeburg.de/iti_db/lehre/mmdb/skripte/6.pdf, 2009