

---

## Kapitel 3

# Anfragen auf räumlichen Objekten

---

Skript zur Vorlesung: Spatial, Temporal, and Multimedia Databases  
Sommersemester 2012, LMU München

© 2007 Prof. Dr. Hans-Peter Kriegel, Dr. Peer Kröger, Dr. Peter Kunath, Dr. Matthias Renz, Arthur Zimek

---

## Übersicht

### 3.1 Schnitthanfragen räumlicher Objekte

- Raumpartitionierende Anfrage-Methoden
- Datenpartitionierende Anfrage-Methoden


### 3.2 Ähnlichkeitssuche in räumlichen Objekten

- Invarianten
- Räumliche Partitionierungen
- Räumliche Features

## 3.1 Schnitthanfragen räumlicher Objekte

### – Allgemeines

- Unter räumlichen Objekten verstehen wir Objekte mit räumlichem Bezug (Lage im Raum) und räumlicher Ausdehnung.
- Räumliche Objekte können neben den räumlichen Attributen auch nicht-räumliche Attribute enthalten, wie z.B. Objekt-ID, Bezeichnung, Farbe, Material, etc.
- Beispiele von räumlichen Objekten:




### – Anfragen auf räumlich ausgedehnten Objekten (GEO-Objekte, CAD-Objekte)




#### **Bereichsanfragen in GEO Datenbanken:**

Welche Strassen durchlaufen das ausgewählte Fenster?



#### **Räumliche Selektion:**



Welche Bauteile befinden sich in der angegebenen Anfragebox?




#### **Schnittanfragen:**

Welche Maschinenteile haben direkten Kontakt mit der vorderen rechten Bremsscheibe?


- Gegeben:  
Menge mit räumlich ausgedehnten Objekten
- Zu unterstützende Anfragen:



Punkt-Anfrage



Schnitt-Anfrage



Fenster-Anfrage


Gegeben ein Anfragepunkt  $P$ , ein Anfrageobjekt  $Q$ , bzw. ein Anfragerechteck  $R$  (2D)

- Punkt-Anfrage: Finde die Objekte, die  $P$  enthalten.
- Schnitt-Anfrage: Finde die Objekte, die  $Q$  schneiden.
- Fenster-Anfrage: Finde die Objekte, die  $R$  schneiden.

- Zu unterstützende Anfragen (Forts.)
  - Räumliche Verbund-Anfrage (Spatial Join)

Gegeben:

Zwei Mengen  $M = \{Obj_{M,1}, \dots, Obj_{M,m}\}$ ,  
 $N = \{Obj_{N,1}, Obj_{N,n}\}$  räumlich  
 ausgedehnter Objekte



Spatial Join:

Finde die Menge von Objekt-Paaren  
 $\{(Obj_1, Obj_2) \mid Obj_1 \in M, Obj_2 \in N \text{ und } Obj_1 \text{ schneidet } Obj_2\}$ .

Auch andere räumliche Prädikate möglich, z.B.


- » andere Topologien wie *enthalten-in*
- » Distanz-basierte Anfragen
- » etc.

## – Ziele:

- **Effektivität**
    - Verwaltung von (komplex strukturierten) geometrischen Objekten
    - räumliche Anfragebearbeitung
  - **Effizienz**
    - kurze Antwortzeiten für Anfragen
    - schnelles Einfügen, Ändern und Entfernen
  - **Skalierbarkeit**
    - Verwaltung sehr großer Datenmengen
    - Anbindung vieler Benutzer
- Reduzierung der Beschreibungskomplexität (d.h. einfachere Darstellung der Objekte)
- Verwendung geeigneter Zugriffsstrukturen
- Mehrstufige Anfragebearbeitung

## – Repräsentation Räumlicher Objekte

- Typischerweise sind räumlich ausgedehnte Objekte als geschlossener Kantenzug (2D) oder durch geschlossene triangulierte Oberflächen beschrieben.



- Für effiziente Anfragen werden in einem Filterschritt zunächst räumliche Approximationen der Objekte verwendet




- **Raumpartitionierende Verfahren**
  - Repräsentationen durch feste Raumpartitionsgrenzen definiert
- **Datenpartitionierende Verfahren**
  - Repräsentationen durch die räumliche Ausdehnung der Daten definiert

### 3.1.1 Raumpartitionierende Anfrage-Methoden

- Ausgangslage: Voxel-basierte Objektbeschreibung (Raster-Modell)

- Bei der Voxel-basierten Zerlegung wird ein Körper in eine Menge identischer Zellen (i.d.R. Würfel) zerlegt, die auf einem festen regelmäßigen Gitter angeordnet sind.

- Beispiel (3D):




- Beschreibung der Objekte (des Objektraums) durch drei-dimensionales ARRAY [...][...][...] OF BOOLEAN (oder seltener eine Liste belegter Zellen)
- Anwendungen:
  - » Computer Tomographie, Virtual Engineering (CAD), etc.

**Nachteil:**


genaue Approximation mit hohem Speicherplatzaufwand verbunden  
(Auflösung:  $n$  Voxel pro Dimension  $\rightarrow$  Speicherplatzaufwand =  $n^3$ )

- Octree-basierte Objektrepräsentation:

- Hierarchische Variante der Voxel-basierten Zerlegung
- Idee:
  - » hierarchische binäre Unterteilung in Quadranten/Oktanten;
  - » Darstellung durch größte Quadranten die vollständig gefüllt sind.



Voxel-basierte Zerlegung




Octree (Quadtree) Zerlegung

- Vorteil:
  - » große einheitliche Flächen/Volumen Anteile werden über wenig große Partitionen (Quadranten/Oktanten) repräsentiert.
  - » Randbereiche, die eine beliebig komplexe Struktur (Form) annehmen können, werden über viele kleine Partitionen repräsentiert, die eine exaktere Darstellung erlauben.

• Indexierung


- Quadtree-Zellen durch Z-Werte benennen:



Z-Werte bestehen aus

- » Bitfolge  $\langle b_1, b_2, \dots, b_n \rangle$  durch abwechselnd rechts/links und oben/unten partitionieren (links/unten  $\rightarrow 0$ , rechts/oben  $\rightarrow 1$ )
- » Level = Anzahl der Bits

rekursive Schritte für die generierung der Z-Werte:




• Indexierung (Forts.)

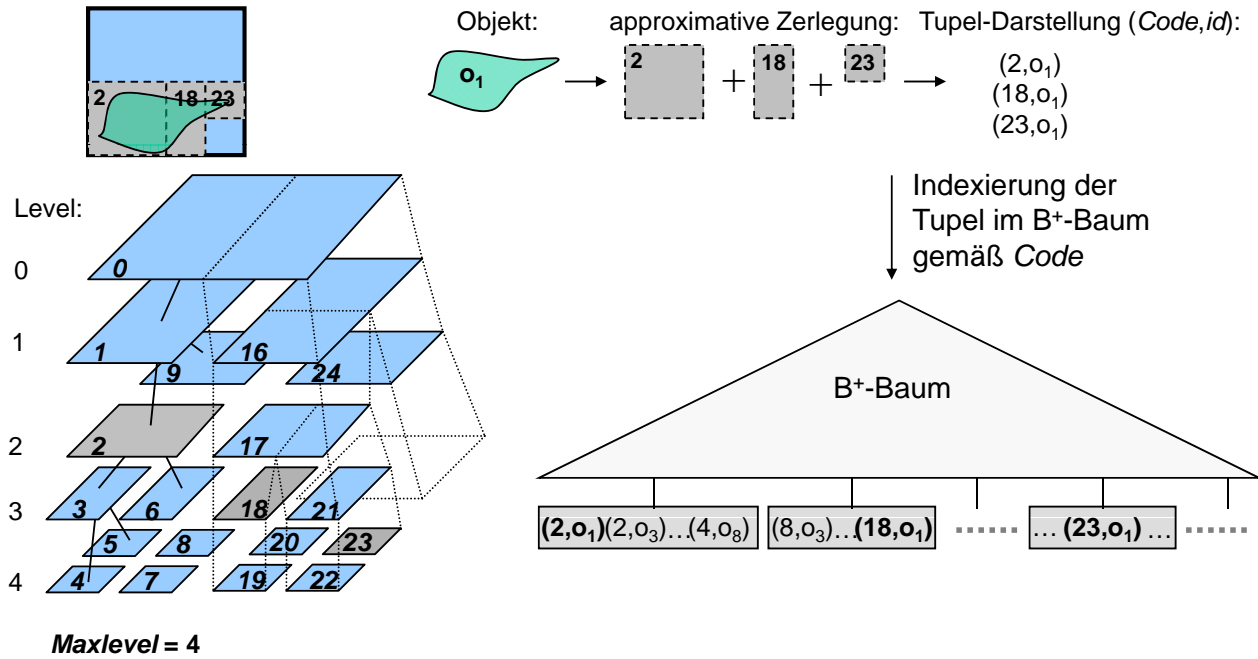
- Kodierung der Z-Werte => lineare Ordnung auf den Z-Werten

$$\text{Code}(\langle b_0, b_1, \dots, b_n \rangle) = \sum_{i=0..n} \begin{cases} 1 & \text{falls } b_i = 0 \\ 2^{(\text{MaxLevel}-i)} & \text{falls } b_i = 1 \end{cases}$$

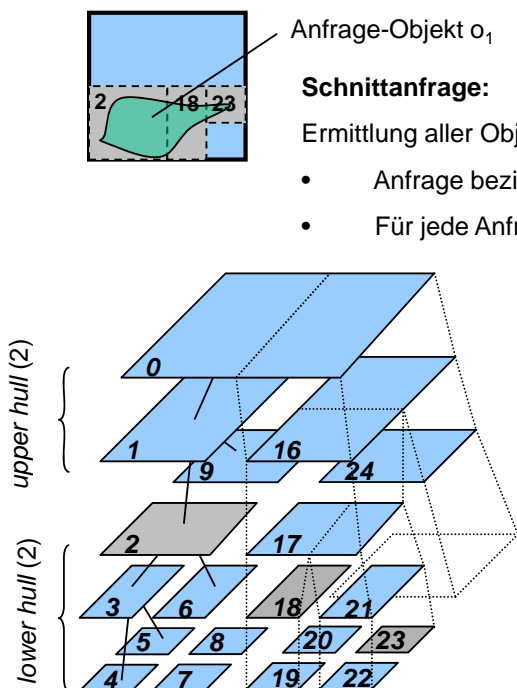
MaxLevel = maximaler Level für die rekursive Partitionierung (s.o. Maxlevel = 6)



• Verwaltung der Objekte im B+-Baum






• Schnitthanfrage




• Intervall-basierte Objektrepräsentation

- Idee: Einbettung in eindimensionalen Raum
  - » vollständige Zerlegung des Datenraums in gleichförmige disjunkte Zellen (Voxelisierung)
  - » Definition einer linearen Ordnung auf diesen Zellen (mittels raumfüllenden Kurven)
  - » Gruppierung direkt aufeinanderfolgender Zellen zu ein-dimensionalen Intervallen
- Vorteile:
  - » erlaubt auch nicht-rechteckige Repräsentationen
  - » einfache Verwaltung von Intervallen (über konventionelle (ein-dimensionale) Indexstrukturen wie den B+-Baum)
- Raumfüllende Kurven:
  - » Lexikographische Ordnung
  - » Hilbert-Kurve
  - » Z-Ordnung
- Z-Ordnung erhält die räumliche Nähe relativ gut
- Z-Ordnung ist effizient berechenbar



• Intervall-basierte Objektrepräsentation (Fortsetzung):

- Beispiel:




• Indexierung:

- Codierung von Intervallen
  - » lineare Ordnung entsprechend der Intervallgrenzen (Startpunkt / Endpunkt) [Bozkaya and Özsoyoglu: *Indexing Valid Time Intervals*. Int. Conf. on Database and Expert Systems Applications, 1998]
  - » indirekte Codierung der Intervalle, z.B. Relationaler Intervall-Baum [H.-P. Kriegel, M. Pötke, T. Seidl: *Managing Intervals Efficiently in Object-Relational Databases*, VLDB 2000]
- Verwaltung der Intervalle in einem B+-Baum




- Vergleich zur Quadtree-basierten Zerlegung:
  - Die Z-Ordnung-basierte Intervall-Zerlegung erzeugt signifikant weniger Redundanz als die Quadtree/Octree-basierte Zerlegung.

Beispiel:




Quadtree-basierte Zerlegung  
(60 Quadranten)



Z-Ordnungsbasierte Zerlegung  
(41 Intervalle)

- Beobachtung:
  - » Anzahl der Partitionen (Quadtree- oder Intervall-basiert) ist proportional zum Umfang (2d) bzw. zur Oberfläche (3d) des Objekts, da eine Raumunterteilung nur zur Randkodierung des Objekts nötig ist.
  - » je kleiner das Verhältnis von Oberfläche zu Volumen, desto höher die Redundanz.
  - » raumpartitionierende Verfahren für komplex strukturierte Objekte wie z.B. Kabelstränge, Leitungen nicht geeignet.


Beispiel für komplexes Objekt:  
Fahrwerk eines Autos



- Räumliche Anfrage:
  - Problem:
    - » (Anfrage-)Objekte zerfallen in viele Partitionen (Quadtree-basierte Zerlegung)



- » jede Partition des Anfrageobjektes führt zu mehreren Partitions-Schlüsseln, die angefragt werden müssen



Anfrage = Sequenz von Primärschlüssel

⇒ sehr viele (Einzel-)Anfragen notwendig ⇒ Anfrage sehr teuer

- Ziel: Reduktion der Anfragekosten durch
  - Vermeidung von Redundanz
    - » sammeln aller Anfragepartitionen und Löschen redundanter Partitionen bevor Anfrage startet
  - Geeigneten Indexdurchlauf
    - » geeignete Wahl zwischen Scan auf Blattebene und Index-basierter Suche


• **Kostenbasierte Suche:**

[Kriegel, Kunath, Pfeifle, Renz: Proc. Int. Conf. on Database Systems for Advanced Applications (DASFAA), 2004]

- Idee: optimale Nutzung des partiellen Scans im B<sup>+</sup>-Baum durch Bildung von Bereichsanfragen
- Gegeben: Anfragesequenz als Menge von Bereichsanfragen




- Prinzip: kostenoptimale Gruppierung von Bereichsanfragen



- **Kostenabschätzung:**
  - » I/O-Kosten für Suche im B<sup>+</sup>-Baum ~ Höhe des B<sup>+</sup>-Baum
  - » I/O-Kosten für Scan auf Blattebene: Abschätzung mittels Statistiken über die Verteilung der Daten auf Blattebene gemäß dem Suchschlüssel

- **Kostenbasierte Anfrage (Bildung der finalen Anfragesequenz):**
  - » konservative Approximation der Anfrage mit nur einem Anfragebereich  $I_0$
  - » rekursive Zerlegung von  $I_0$  mit dem Ziel die geschätzten Anfragekosten zu minimieren (Zerlege  $I_0$  in  $I_1$  und  $I_2$ , falls  $K(I_1) + K(I_2) < K(I_0)$ )




- » Zerlegungsheuristik: Zerteile approximierten Anfragebereich an der größten Lücke zwischen zwei Anfragebereichen
- » Zerlegungsalgorithmus:

```

Decompose(I0)
{
  zerlege I0 in I1 und I2 (z.B. durch Split an der größten Lücke)
  schätze Kosten: K(I0), K(I1), K(I2)
  if K(I0) > K(I1) + K(I2) then
    report {Decompose(I1) ∪ Decompose(I2)};
  else
    report I0;
}
    
```

### 3.1.2 Datenpartitionierende Anfrage-Methoden

- Grundlegende Idee:
  - direkte Verwaltung von räumlichen Objekten anstatt Verwaltung von Raumpartitionen
  - Problem: räumliche Objekte variieren stark in ihrer Größe (Größe = benötigter Speicherplatz), sind aber auf Seiten fester Größe abzuspeichern
  - Organisation von vereinfachten Räumlichen-Objekten (**Approximationen**), z.B. minimal umgebende Rechtecke (MUR)
  - Verweis auf die exakte Beschreibung (EB) der Räumlichen-Objekte




#### – Arten von Approximationen

- **Konservative Approximationen**
  - enthalten das zu approximierende Objekt vollständig
  - dienen insbesondere zur Bestimmung von Fehltreffern
  - Beispiel:  $\neg(a.kons\_appr \cap b.kons\_appr) \Rightarrow \neg(a \cap b)$
- **Progressive Approximationen**
  - sind vollständig im zu approximierenden Objekt enthalten
  - dienen insbesondere zur Bestimmung von Treffern
  - Beispiel:  $(a.prog\_appr \cap b.prog\_appr) \Rightarrow (a \cap b)$

## – Konservative Approximationen

- Vergleich verschiedener konservativer Approximationen (2D)



Approximation:	Kreis	MUR	Ellipse	gedrehtes MUR	4-Eck	5-Eck	Konvexe Hülle
Güte:	215%	193%	168%	162%	144%	133%	123%
# Parameter:	3	4	5	5	8	10	O(n)


(Güte = durchschnittliche Flächen der Approximationen in Prozent zur exakten Objektfläche (=100%). Gemittelt über verschiedene Landkartendatensätze.)

Quelle: Brinkhoff T., Kriegel H.-P., Schneider R.: 'Comparison of Approximations of Complex Objects used for Approximation-based Query Processing in Spatial Database Systems', Proc. 9th Int. Conf. on Data Engineering, 1993)


→ 5-Eck: guter Kompromiss zwischen Genauigkeit und Speicherplatzbedarf

## – Progressive Approximationen


- Berechnung schwierig (insbesondere für maximale progressive Approximationen)



Kreis  
(42%)




Rechteck  
(45%)




Rechteck + Strecken

## – Strukturelle Zerlegung

- Prinzip:
  - Zerlegung der Objekte in mehrere einfache Basiskomponenten
- Vorteile:
  - Vereinfachung der algorithmischen Komplexität von Anfragen und Operationen (z.B. Flächenberechnung, etc.)
  - Lokalität von Anfragen und Operationen kann ausgenutzt werden (Unterstützung von partiellen Objekt-Zugriff)
  - => effiziente Anfragebearbeitung (bei selektiven Anfragen)
- Zerlegungsvarianten:



konvexe Zerlegung



Dreiecks-Zerlegung




Zerlegung in Trapeze

- Zerlegung eines Polygons in (achsenparallele) Trapeze (Asano+Asano 1983)




- Berechnung durch Plane-Sweep-Algorithmus:  $O(n \log n)$  für  $n$  Eckpunkte

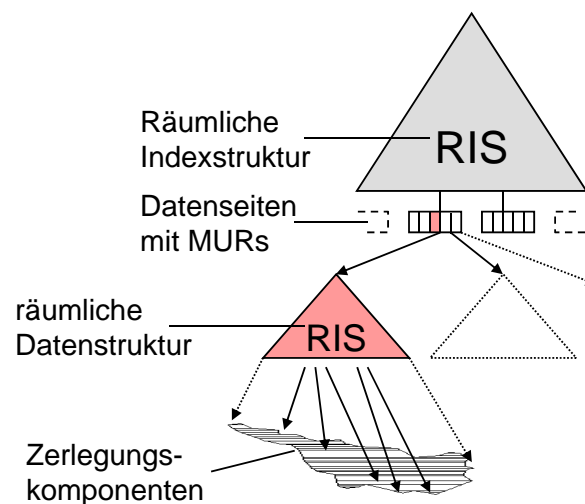


- Speicherplatzaufwand
  - » Anzahl der Komponenten =  $n$  bei  $n$  Eckpunkten
  - » Aber: Vervielfachung des Speicherplatzes da nun Trapeze statt Punkten verwaltet, d.h. abgespeichert werden

- Beobachtung
  - Operationen auf Zerlegungskomponenten sind einfach
  - Aber: Anzahl der Zerlegungskomponenten =  $O(n)$
  - Kein Gewinn, falls alle Komponenten getestet werden
  - Einsatz von Datenstrukturen zur Auswahl "relevanter" Komponenten
  - Einsatz von räumlichen Indexstrukturen (RIS)
- 1. Ansatz
  - Eine RIS verwaltet Zerlegungskomponenten aller Objekte
  - Redundanz bei der Anfragebearbeitung (betrifft insbesondere größere Window Queries)

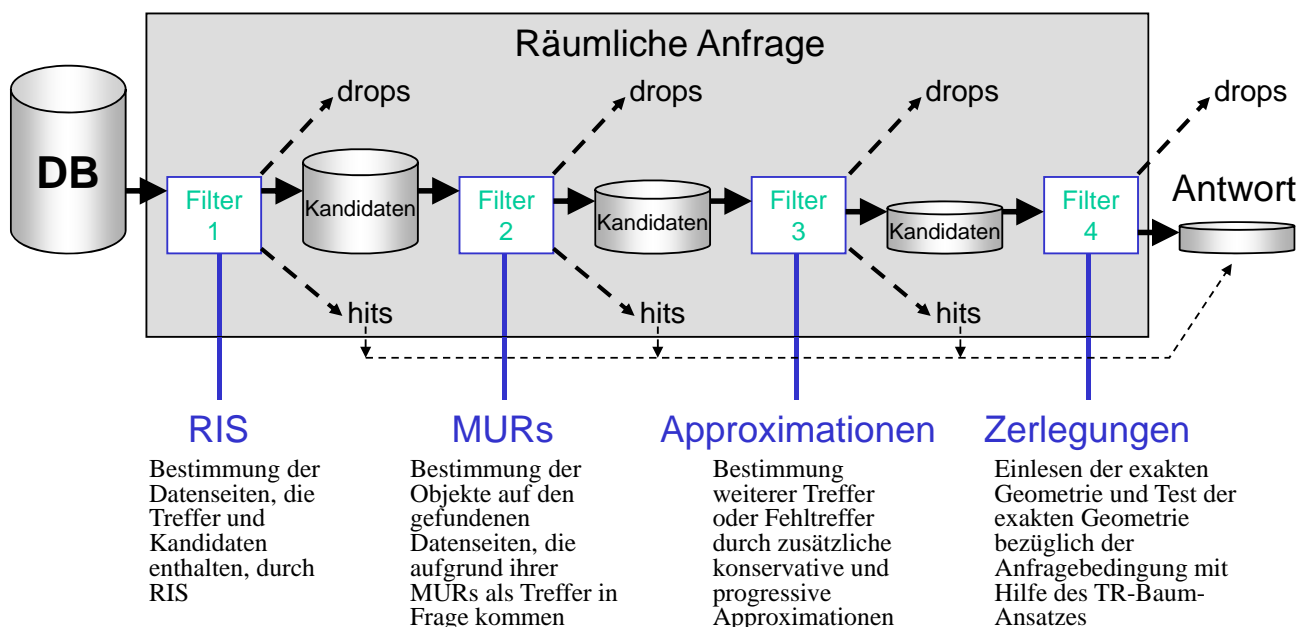


- 2. Ansatz
  - Eine RIS verwaltet die Objektapproximationen (MUR) aller Objekte
  - Für jedes Objekt verwaltet eine separate räumliche Datenstruktur die Zerlegungskomponenten dieses Objektes
  - Wenn die exakte Objektgeometrie untersucht werden muss, werden die Zerlegungskomponenten einschließlich der zugehörigen räumlichen Datenstruktur vom Sekundärspeicher in den Hauptspeicher eingelesen



- TR-Ansatz (Ausprägung des 2. Ansatzes)
  - Verwende R-Baum zur Verwaltung der Zerlegungskomponenten
- ➔ Anpassung des R-Baums an die neuen Anforderungen (TR-Baum):
  - TR-Baum soll für den Hauptspeicher ausgelegt werden
    - » möglichst kleine Knotengröße
  - TR-Baum soll möglichst schnell in den Hauptspeicher eingelesen werden
    - » kompakte Speicherung auf dem Plattenspeicher
    - » kein dynamischer Aufbau, keine Adressneuberechnungen
  - TR-Baum sollte möglichst kompakt gespeichert sein
- Eigenschaften des TR-Baums
  - sehr schnelle Bearbeitung geometrischer Operationen (z.B. Punkt-In-Polygon-Test)
  - erheblich höherer Speicherplatzbedarf
  - (und damit höhere Übertragungskosten beim Einlesen der exakten Geometrie)

## – Mehrstufige Anfragebearbeitung für räumliche Objekte



- GEMINI: Prototyp-System, das diese Anfragebearbeitung realisiert