
Kapitel 3

Anfragen auf räumlichen Objekten

Skript zur Vorlesung: Spatial, Temporal, and Multimedia Databases
Sommersemester 2010, 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
Bremscheibe?


- 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.



triangulierte Oberfläche



- 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 binären 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:



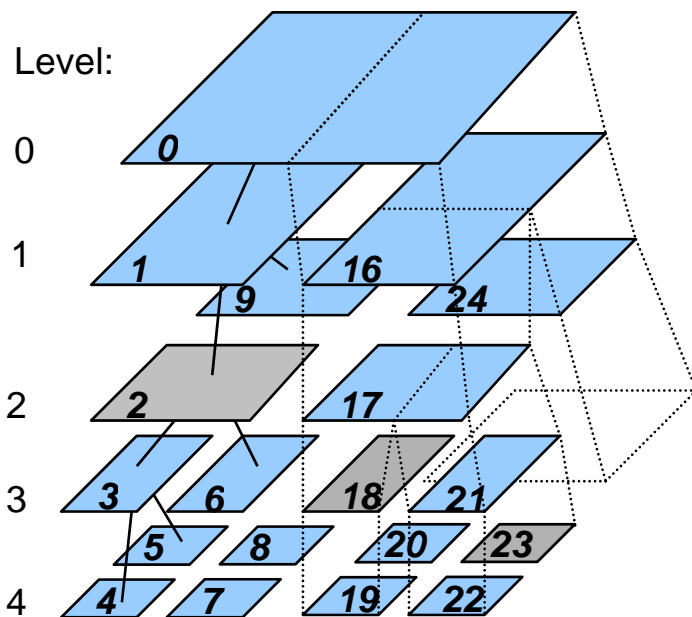


- Indexierung (Forts.)
 - Kodierung der Z-Werte => lineare Ordnung auf den Z-Werten

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

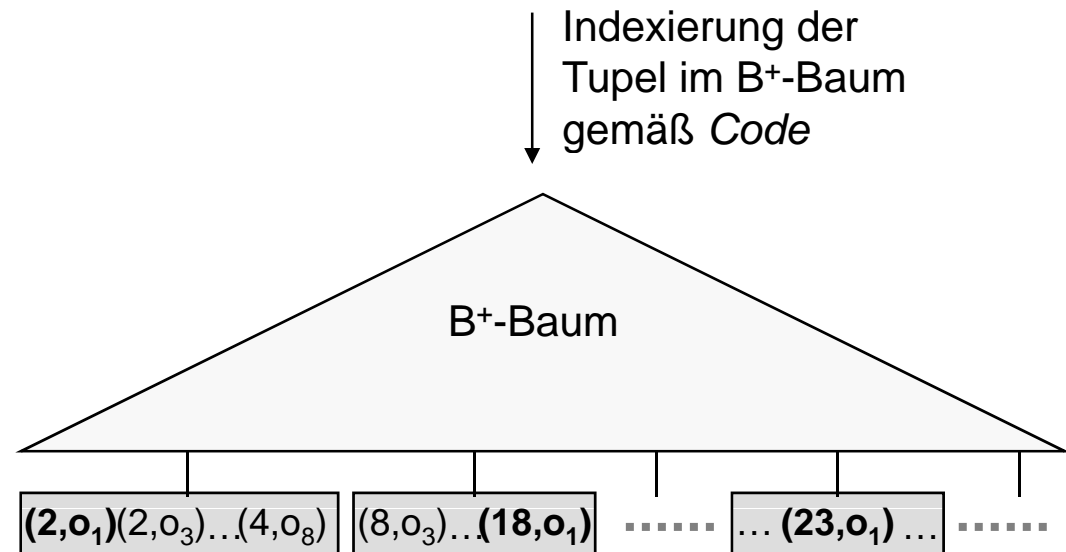
MaxLevel = maximaler Level für die rekursive Partitionierung
(s.o. Maxlevel = 6)




• Verwaltung der Objekte im B⁺-Baum



Maxlevel = 4



• Schnitthanfrage

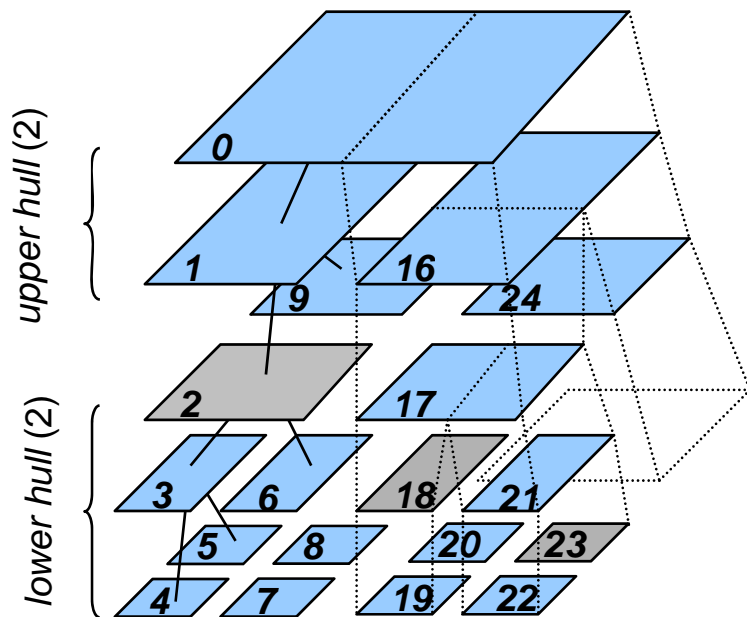


Anfrage-Objekt o_1

Schnitthanfrage:

Ermittlung aller Objekte $o \in DB$ die von o_1 geschnitten werden:

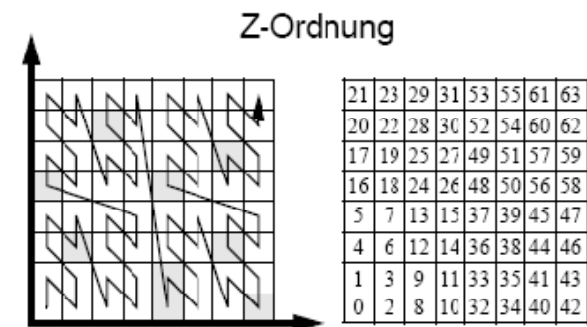
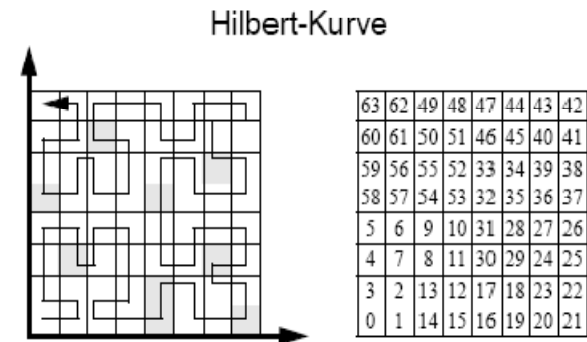

- Anfrage bezieht sich auf die 3 Partitionen: 2, 18 und 23
- Für jede Anfragepartition P_i : Ermittlung aller Objekte, die P_i schneiden, d.h.




- 1) Ermittlung aller Partitionen P_j die P_i schneiden
 - **upper hull** = Partitionen P_j die P_i überdecken
z.B.: $P_i = 2 \rightarrow upper\ hull = \{0, 1\}$
 - **lower hull** = Partitionen P_j die von P_i überdeckt werden
z.B.: $P_i = 2 \rightarrow lower\ hull = \{2, 3, 4, 5, 6, 7, 8\}$
- 2) Anfrage im B+-Baum gemäß aller $P_j = upper\ hull + lower\ hull$
(kann durch Bereichsanfragen im B+-Baum effizient unterstützt werden)

- 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⁺-Baum durch Bildung von Bereichsanfragen
- Gegeben: Anfragesequenz als Menge von Bereichsanfragen




- Prinzip: kostenoptimale Gruppierung von Bereichsanfragen



- **Kostenabschätzung:**

- » I/O-Kosten für Suche im B⁺-Baum ~ Höhe des B⁺-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 Abfragesequenz):
 - » konservative Approximation der Anfrage mit nur einem Anfragebereich I_0
 - » rekursive Zerlegung von I_0 mit dem Ziel die geschätzten Abfragekosten 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(I_0)

```
{  zerlege  $I_0$  in  $I_1$  und  $I_2$  (z.B. durch Split an der größten Lücke)
  schätze Kosten:  $K(I_0)$ ,  $K(I_1)$ ,  $K(I_2)$ 
  if  $K(I_0) > K(I_1) + K(I_2)$  then
    report {Decompose( $I_1$ ) $\cup$ Decompose( $I_2$ )};
  else
    report  $I_0$ ;
}
```


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



– Konservative (redundanzfreie) Approximationen

- enthalten das zu approximierende Objekt vollständig
- dienen insbesondere zur Bestimmung von Fehltreffern
(Beispiel: $\neg(a.kons_appr \cap b.kons_appr) \Rightarrow \neg(a \cap b)$)
- Vergleich verschiedener konservativer Approximationen
(redundanzfreie Approximationen)




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%) [BKS 93])


→ 5-Eck: guter Kompromiss zwischen Genauigkeit und Speicherplatzbedarf

– Progressive Approximationen


- sind vollständig im zu approximierenden Objekt enthalten
- dienen insbesondere zur Bestimmung von Treffern
(Beispiel: $(a.\text{prog_appr} \cap b.\text{prog_appr}) \Rightarrow (a \cap b)$)
- Berechnung schwierig (insbesondere für maximale progressive Approximationen)



Kreis
(42%)




Rechteck
(45%)




Rechteck + Strecken

– Strukturelle Zerlegung (redundante Approximation)

- 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

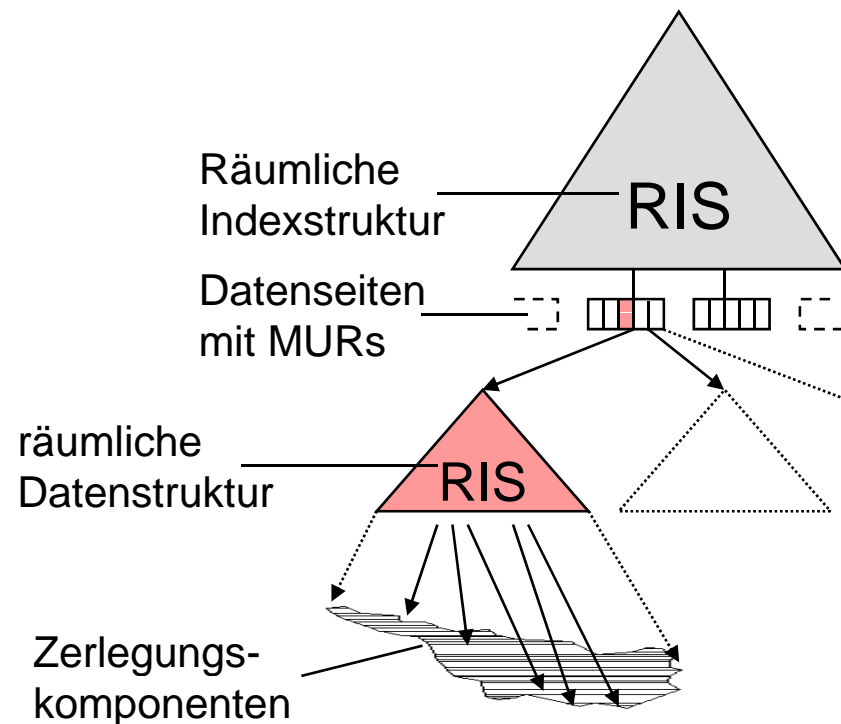


- Speicherplatzaufwand
 - » Anzahl der Komponenten = n bei n Eckpunkten
 - » Aber: Vervielfachung des Speicherplatzes da nun Trapeze statt Punkten verwaltet, d.h. abgespeichert werden

- 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

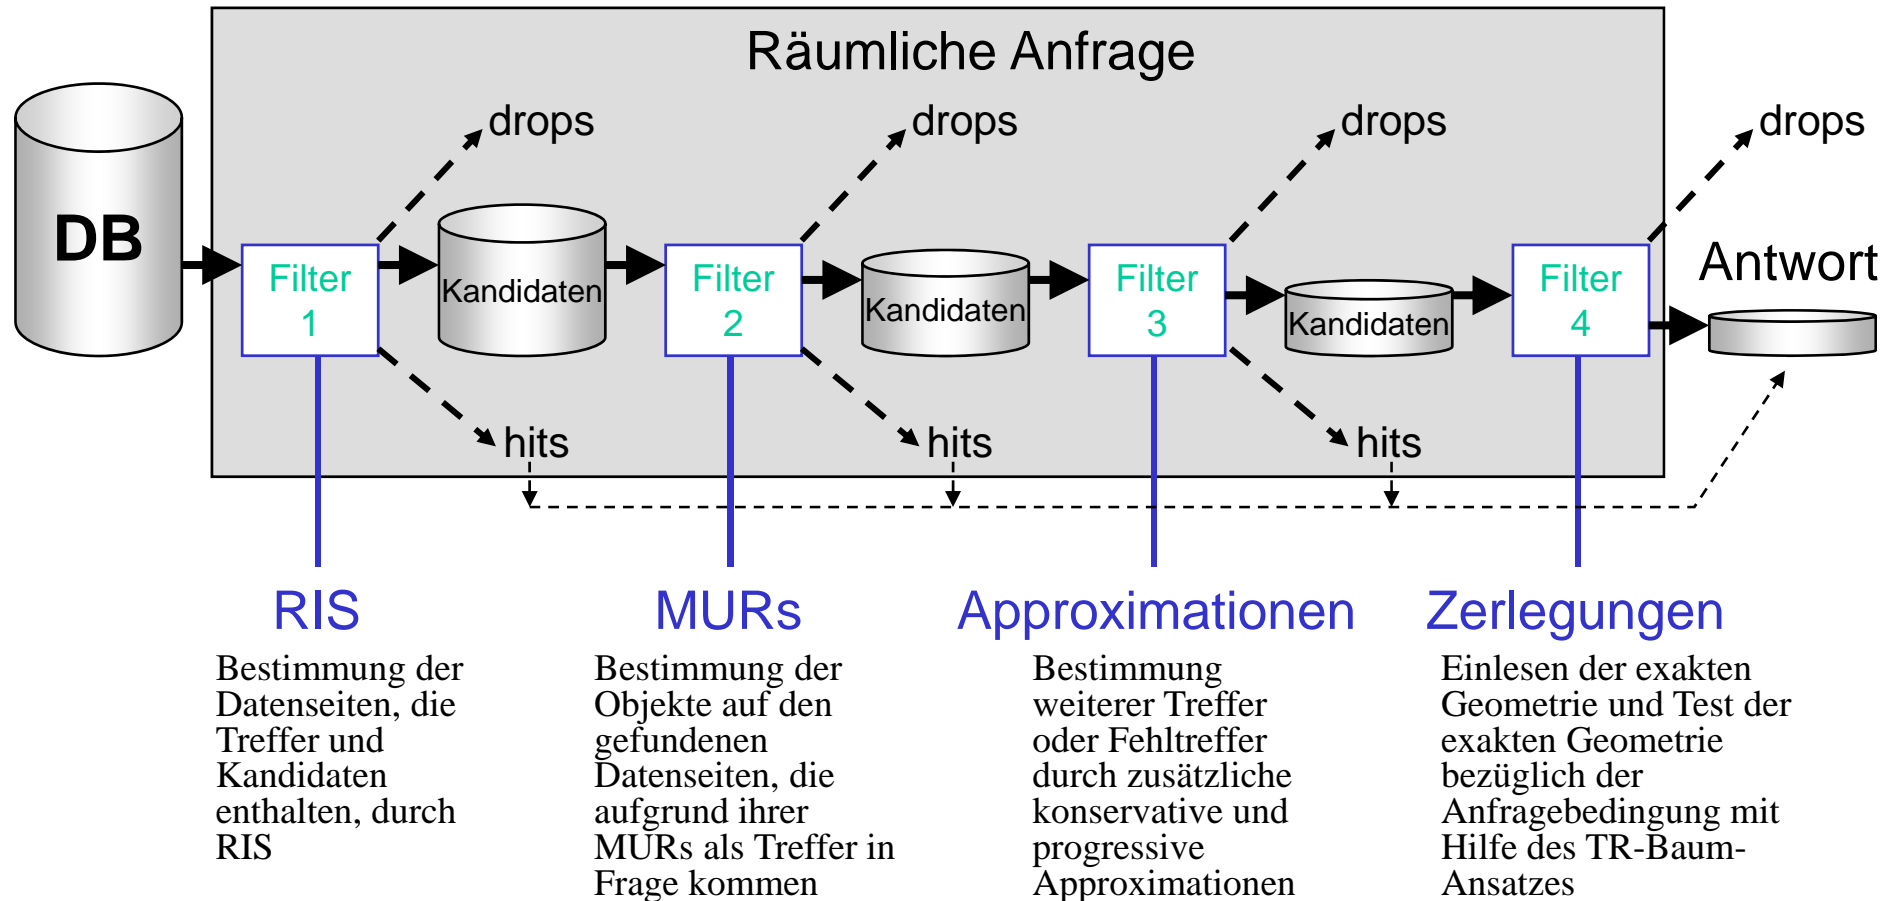


- TR-Ansatz (Ausprägung des 2. Ansatzes)
 - Verwende R-Baum zur Verwaltung der Zerlegungskomponenten

- ➔ 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



- **GENESYS: Prototyp-System, das diese Anfragebearbeitung realisiert**