2.6 Bewertung von Methoden zur Ähnlichkeitssuche

- Fragestellung
  - Anfragebearbeitung in metrischen Räumen oder Vektorräumen
  - Gesucht: Feature-Transformation zur Umwandlung komplexer STMM-Objekten in metrische Objekte/Featurevektoren
  - Wie gut drückt die Feature-Transformation die Ähnlichkeit der realen Objekte aus, d.h. wie gut approximiert die Distanz im Feature-Raum die Distanz im Objektraum?
  - Bewertung von Methoden zur Ähnlichkeitssuche („Ähnlichkeitsmodelle“)
    - Testset von Objekten
    - Stelle für alle Objekte des Testsets Ähnlichkeitsanfragen (typischerweise *k*-NN-Queries)
    - Evaluiere das Ergebnis dieser Anfragen

– Objekte mit bekannten Kategorien

- Objekte sind in Kategorien eingeteilt und entsprechend markiert (z.B. „Schrauben“, „Nägel“, „Bolzen“, …), d.h. Ergebnis der Anfragen ist bekannt
- Übersicht

	erwünscht	**unerwünscht**
gefunden	richtig positive (rp)	falsch positive (fp)
nicht gefunden	falsch negative (fn)	richtig negative (rn)

- Recall (Sensitivität): Wie viele der erwünschten Objekte wurden gefunden?

$$\frac{rp}{rp+fn} = \frac{\text{gefundene erwünschte Objekte}}{\text{alle erwünschten Objekte}}$$

- Precision: Wie viele der gefundenen Objekte sind erwünscht?

$$\frac{rp}{rp+fp} = \frac{\text{gefundene erwünschte Objekte}}{\text{alle gefundenen Objekte}}$$

- Spezifität: WS, dass Test für unerwünschtes Obj. negativ verläuft

$$\frac{rn}{rn+fp} = \frac{\text{richtig negativ}}{\text{alle unerwünschten Objekte}}$$

– Objekte mit unbekannten Kategorien
  - Ergebnis der Anfragen ist unbekannt
  - Manuelle Evaluation weniger zufälligen *k*-NN-Queries
  - Problem: Qualität des Modells hängt ab von
    - einer geringen Anzahl von Query-Objekten
      - » Besser: möglichst alle Objekte der DB spielen eine Rolle bei der Evaluation
    - der Wahl dieser Query-Objekte
      - » Schlechtes Anfrageergebnis für gegebenes *q* bedingt nicht schlechtes Modell
      - » Gutes Anfrageergebnis für gegebenes *q* bedingt nicht gutes Modell

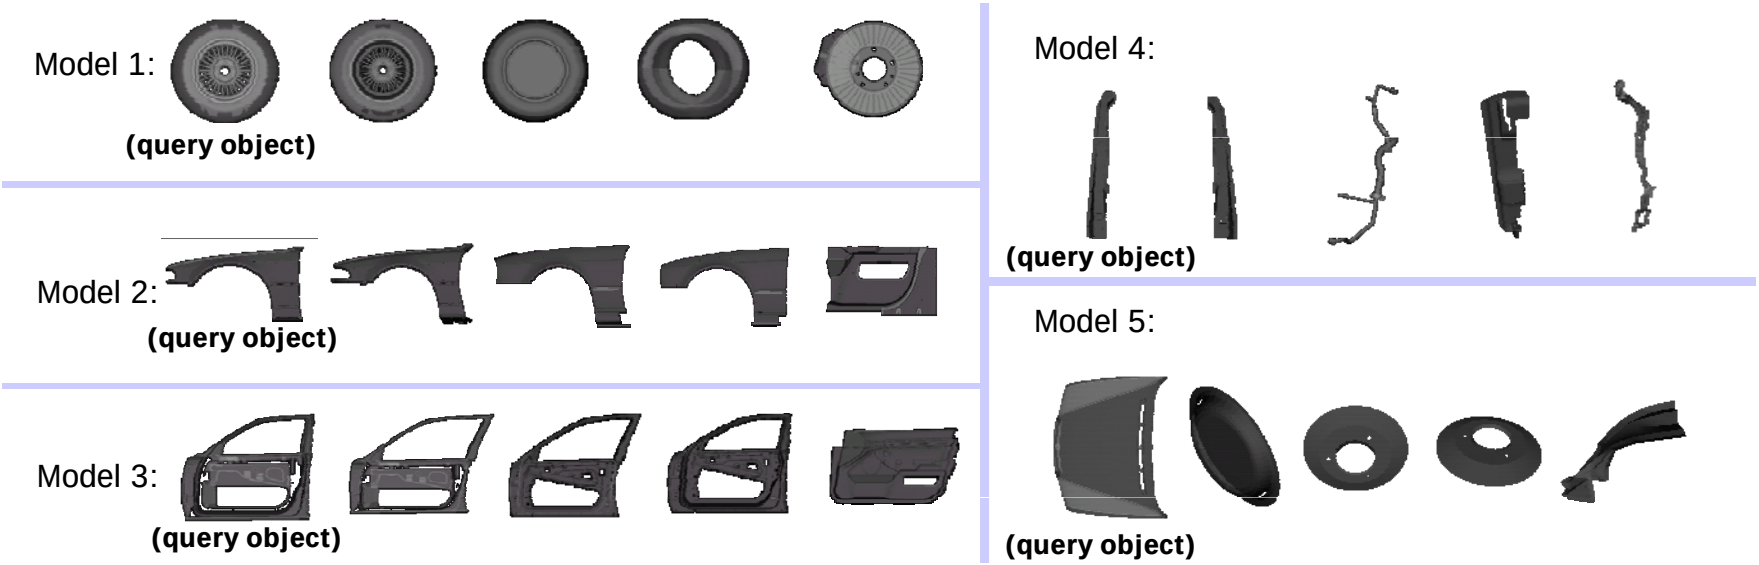

- BOSS (Browsing OPTICS-plots for Similarity Search)

  [Brecheisen, Kriegel, Kröger, Pfeifle. Proc. SIAM Int. Conf. Data Mining (SDM), 2004]

  – Idee: benutze Data Mining Methoden
  – Clustering
    » Fasse Objekte in Gruppen zusammen, sodass die Objekte in einer Gruppe (Cluster) ähnlich, Objekte aus verschiedenen Clustern unähnlich sind
    » Hierarchisches Clustering: erstelle eine Hierarchie von ähnlichen Objekten
  – Clustererkennung und Clusterrepräsentation
    » Erkenne automatisch geeignete Cluster in der Hierarchie
    » Stelle jeden Cluster durch einen geeigneten Repräsentanten dar
  – Evaluation/Retrieval
    » Hierarchie von Clusterrepräsentanten ist navigierbar
    » Evaluation der Cluster um Ähnlichkeitsmodell zu evaluieren
    » Ähnlichkeits-basierte Suche nach Objekten ohne konkretes Anfrageobjekt angeben zu müssen

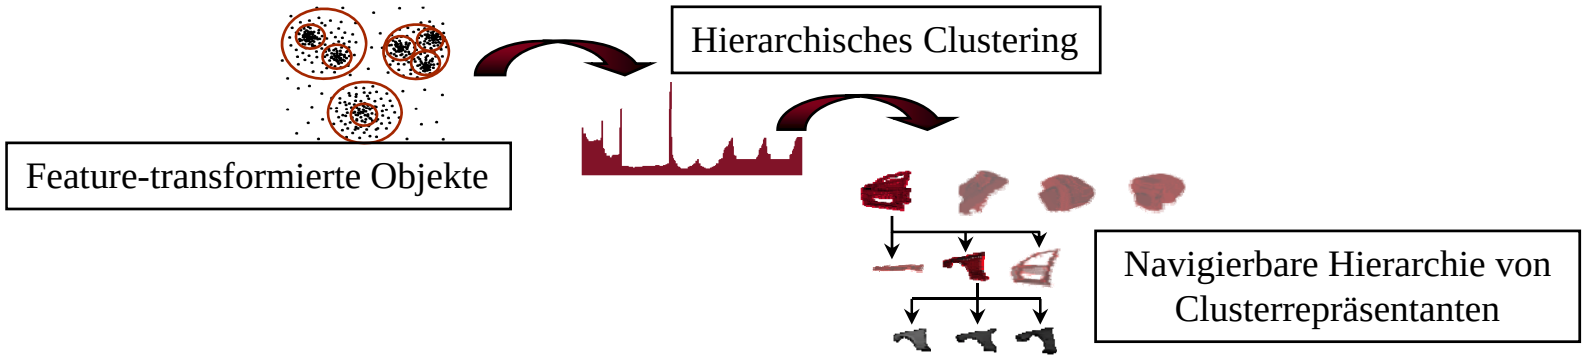

Kapitel 3
Anfragen auf räumlichen Objekten

Skript zur Vorlesung: Spatial, Temporal, and Multimedia Databases
Sommersemester 2013, LMU München

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

Übersicht

3.1 Schnittanfragen räumlicher Objekte

- Raumpartitionierende Anfrage-Methoden
- Datenpartitionierende Anfrage-Methoden

3.2 Ähnlichkeitssuche in räumlichen Objekten

- Invarianten
- Räumliche Partitionierungen
- Räumliche Features

3.1 Schnittanfragen 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:

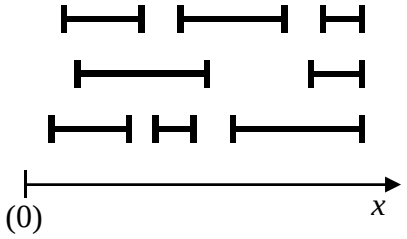

Zeitintervalle (1D)

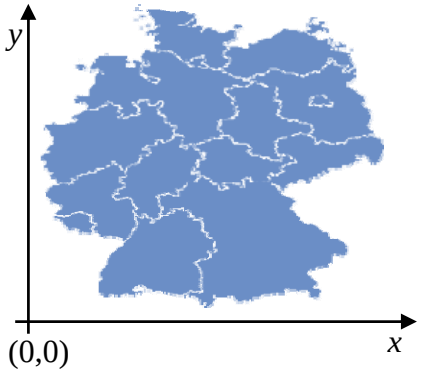

Stadtregionen, Landflächen (2D)

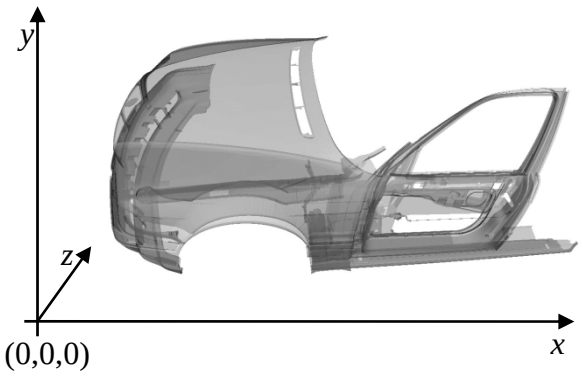

Flugzeugteile, Autoteile (3D)

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

Bereichsanfragen in GEO Datenbanken:
Welche Strassen durchlaufen das ausgewählte Fenster?

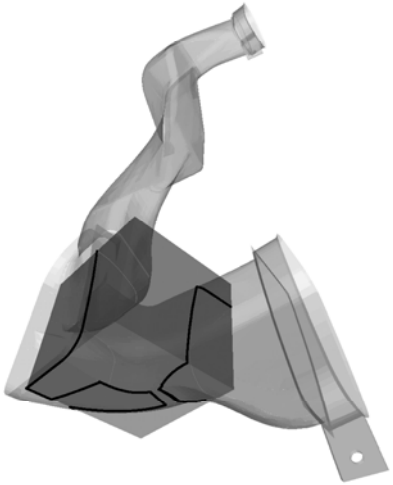

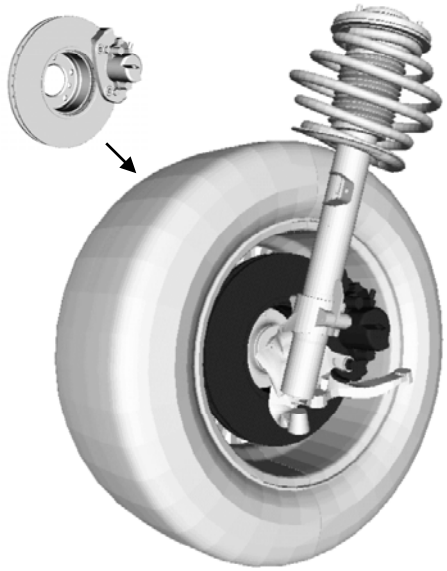

Schnittanfragen:
Welche Maschinenteile haben direkten Kontakt mit der vorderen rechten Bremsscheibe?

Räumliche Selektion:
Welche Bauteile befinden sich in der angegebenen Anfragebox?

- Gegeben:

  Menge mit räumlich ausgedehnten Objekten

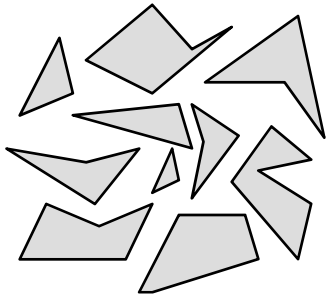

- Zu unterstützende Anfragen:

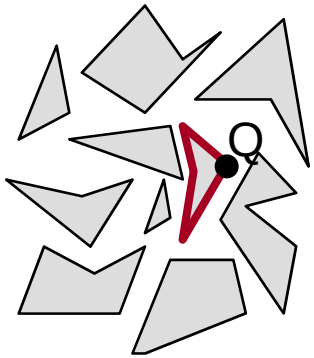

Punkt-Anfrage

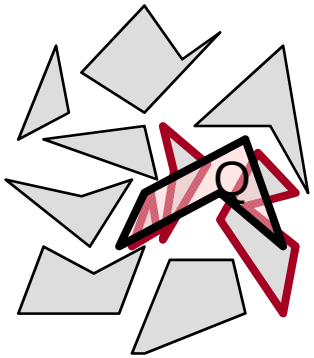

Schnitt-Anfrage

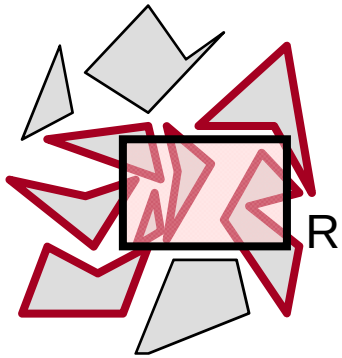

Fenster-Anfrage

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)

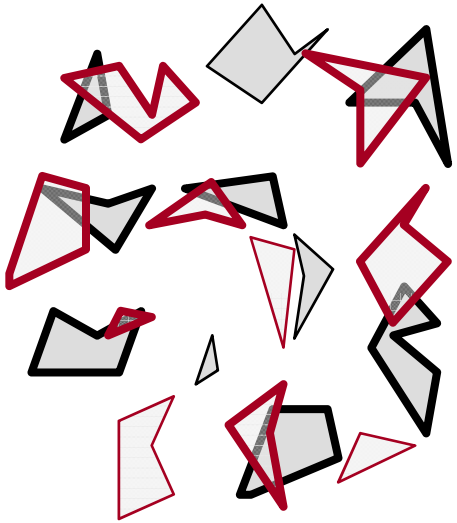

Gegeben:

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

Spatial Join:

Finde die Menge von Objekt-Paaren

$\{(Obj_1,Obj_2) \mid Obj_1 \in M, Obj_2 \in N$ und Obj_1 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.

Kantenzug 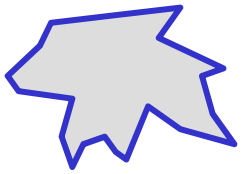

triangulierte Oberfläche

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

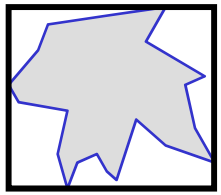

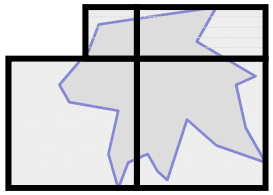

- Raumpartitionierende Verfahren
  - Repräsentationen durch feste Raumpartitionsgrenzen definiert
- Datenpartitionierende Verfahren
  - Repräsentationen durch die räumliche Ausdehnung der Daten definiert

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):

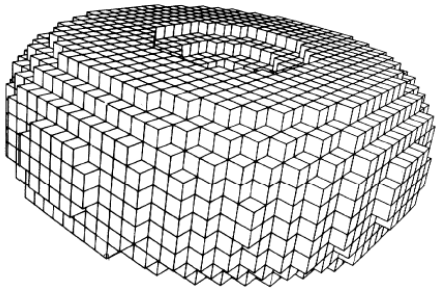

  - Beschreibung der Objekte (des Objektraums) durch drei-dimensionales ARRAY [...][...][...] OF BOOLEAN (oder seltener eine Liste belegter Zellen)
  - Anwendungen:
    - » Computer Tomographie, Virtual Engineering (CAD), etc.

Nachteil:

genaue Approximation mit hohem Speicherplatzaufwand verbunden (Auflösung: n Voxel pro Dimension ➔ 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.

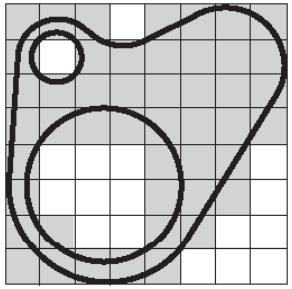

Voxel-basierte Zerlegung

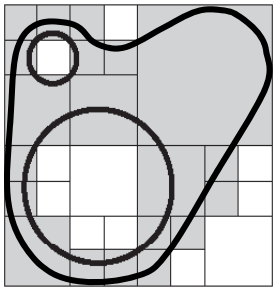

Octree (Quadtree) Zerlegung

  - 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:

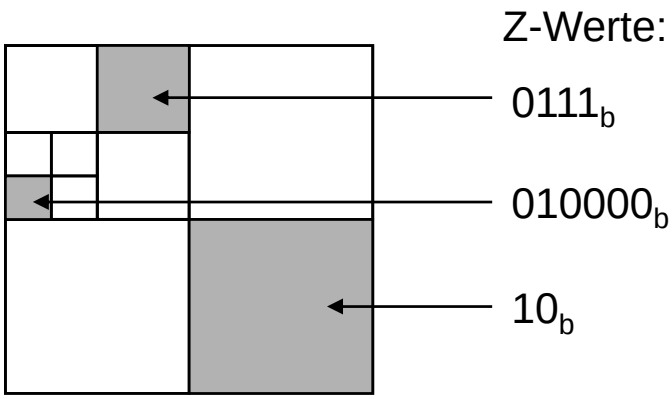

Z-Werte bestehen aus

» Bitfolge $<b_1,b_2,..,b_n>$ durch abwechselnd rechts/links und oben/unten partitionieren (links/unten → 0, rechts/oben → 1)

» Level = Anzahl der Bits

rekursive Schritte für die generierung der Z-Werte:

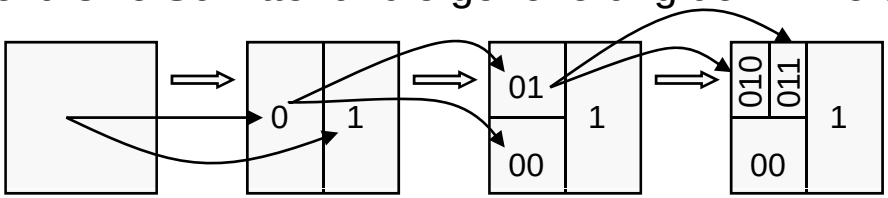

- Indexierung (Forts.)
  - Kodierung der Z-Werte => lineare Ordnung auf den Z-Werten

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

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

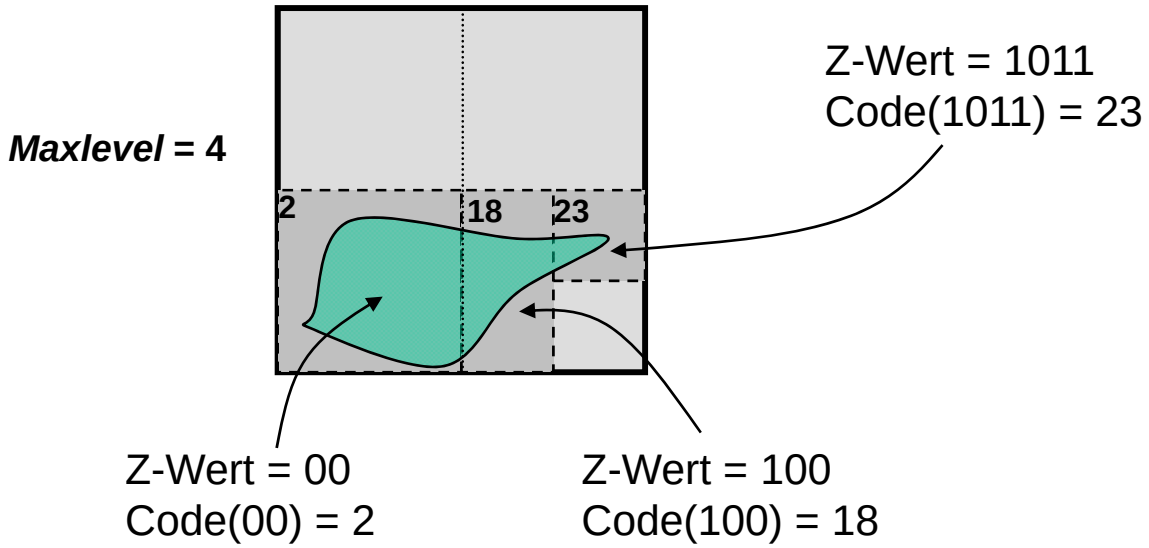

- Verwaltung der Objekte im B⁺-Baum

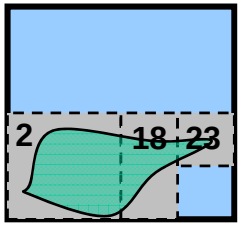

Objekt: approximative Zerlegung: Tupel-Darstellung (*Code*,*id*):

$(2,o_1)$
$(18,o_1)$
$(23,o_1)$

Indexierung der Tupel im B⁺-Baum gemäß *Code*

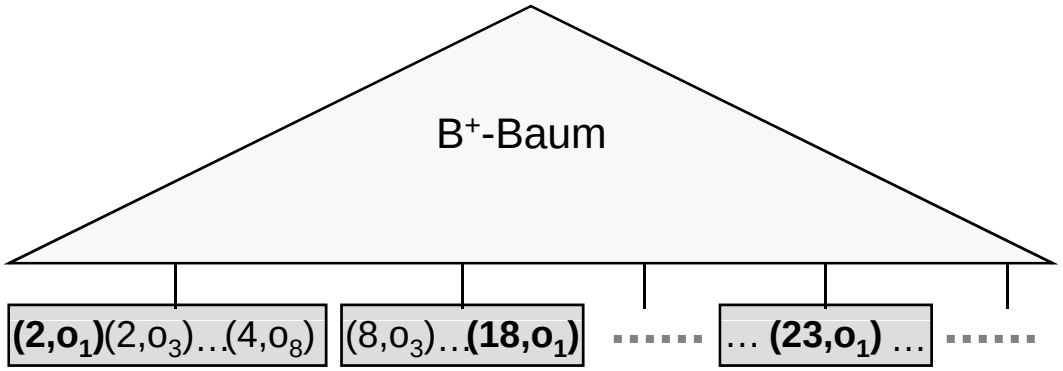

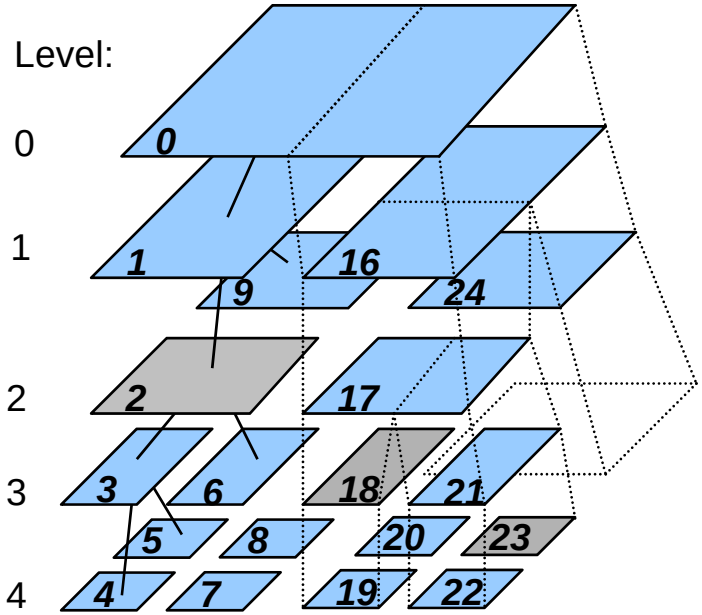

***Maxlevel* = 4**

- Schnittanfrage

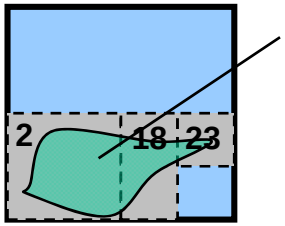

Anfrage-Objekt o_1

Schnittanfrage:

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.

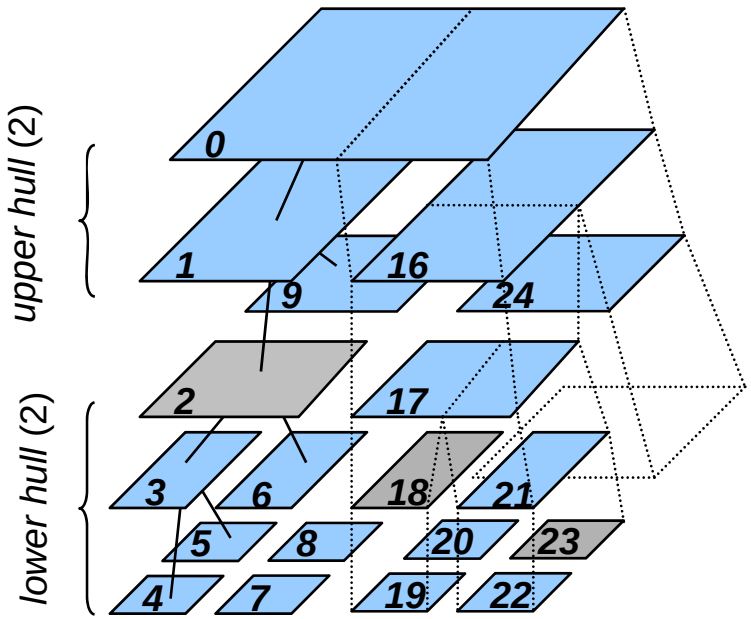

1) Ermittlung aller Partitionen P_j die P_i schneiden
   - ***upper hull*** = Partitionen P_j die P_i überdecken

     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

Lexikographische Ordnung

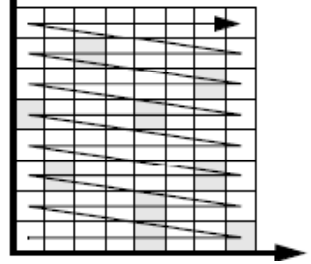

56	57	58	59	60	61	62	63
48	49	50	51	52	53	54	55
40	41	42	43	44	45	46	47
32	33	34	35	36	37	38	39
24	25	26	27	28	29	30	31
16	17	18	19	20	21	22	23
8	9	10	11	12	13	14	15
0	1	2	3	4	5	6	7

Hilbert-Kurve

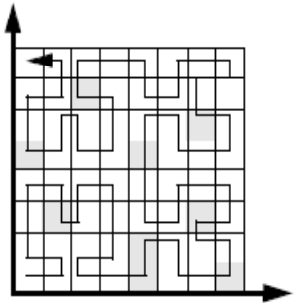

63	62	49	48	47	44	43	42
60	61	50	51	46	45	40	41
59	56	55	52	33	34	39	38
58	57	54	53	32	35	36	37
5	6	9	10	31	28	27	26
4	7	8	11	30	29	24	25
3	2	13	12	17	18	23	22
0	1	14	15	16	19	20	21

Z-Ordnung

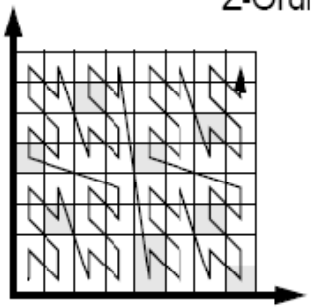

21	23	29	31	53	55	61	63
20	22	28	30	52	54	60	62
17	19	25	27	49	51	57	59
16	18	24	26	48	50	56	58
5	7	13	15	37	39	45	47
4	6	12	14	36	38	44	46
1	3	9	11	33	35	41	43
0	2	8	10	32	34	40	42

- Intervall-basierte Objektrepräsentation (Fortsetzung):
  - Beispiel:

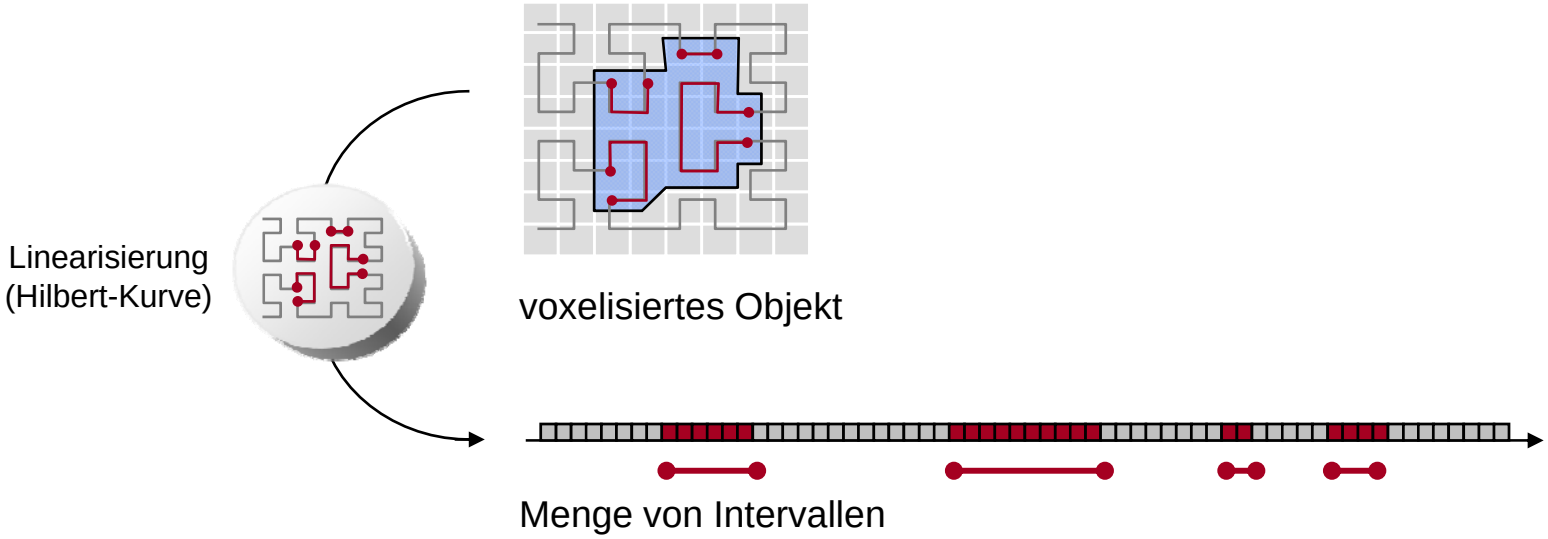

- Indexierung:
  - Codierung von Intervallen
    - » lineare Ordnung entsprechend der Intervallgrenzen (Startpunkt / Endpunkt)
      [Bozkaya and Özsoyoglu: *Indexing Valid Time Intervals*. Int. Conf. on Database and Expert Systems Applications, 1998]
    - » indirekte Codierung der Intervalle, z.B. 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 Rendundanz als die Quadtree/Octree-basierte Zerlegung.

Beispiel:

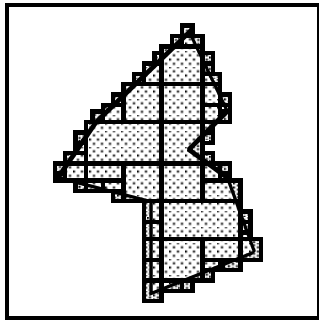

Quadtree-basierte Zerlegung
(60 Quadranten)

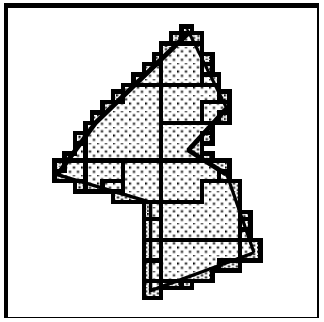

Z-Ordnungs-basierte Zerlegung
(41 Intervalle)

  - 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

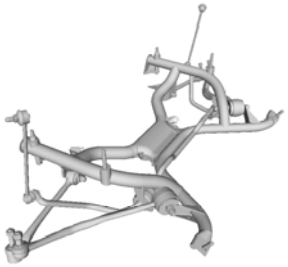

- Räumliche Anfrage:
  - Problem:
    - » (Anfrage-)Objekte zerfallen in viele Partitionen (Quadtree-basierte Zerlegung)

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

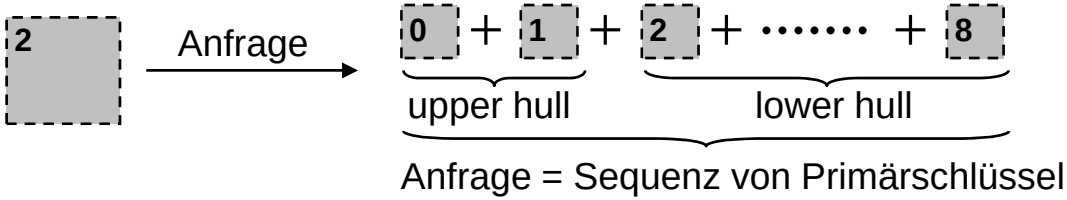

  ⇒ sehr viele (Einzel-)Anfragen notwendig => Anfrage sehr teuer

- Ziel: Reduktion der Anfragekosten durch
  - Vermeidung von Redundanz
    - » sammeln aller Anfagepartitionen 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

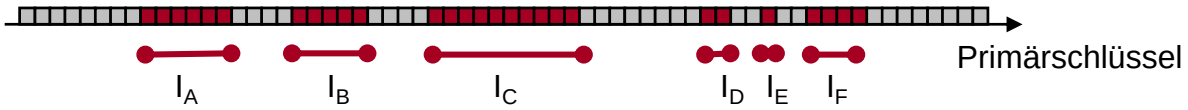

  – Prinzip: kostenoptimale Gruppierung von Bereichsanfragen

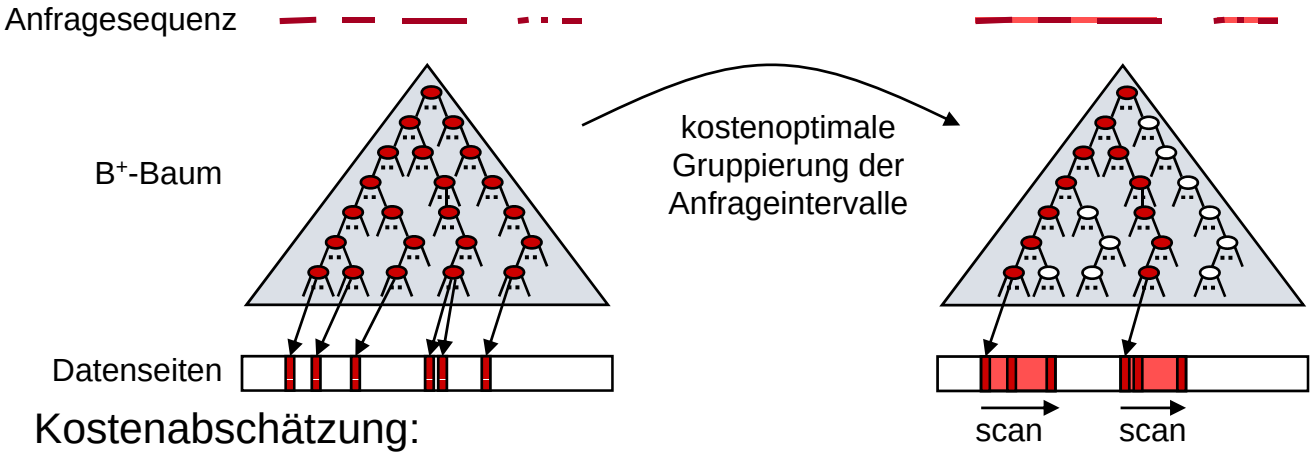

  – Kostenabschätzung:

    » 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 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 $K(I_1) + K(I_2) < K(I_0)$)

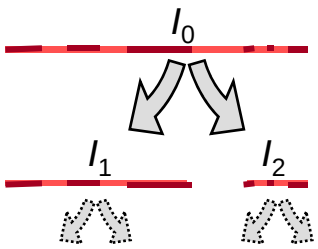

  - » Zerlegungsheuristik: Zerteile approximierten Anfragebereich an der größten Lücke zwischen zwei Anfragebereichen
  - » Zerlegungsalgorithmus:

Decompose(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)∪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

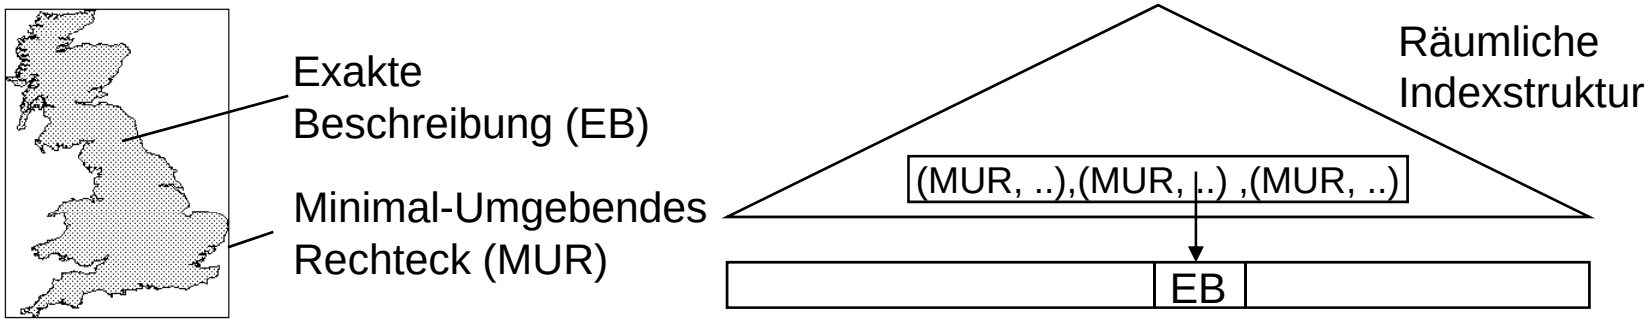

- Arten von Approximationen
  - Konservative Approximationen
    - enthalten das zu approximierende Objekt vollständig
    - dienen insbesondere zur Bestimmung von Fehltreffern

      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)

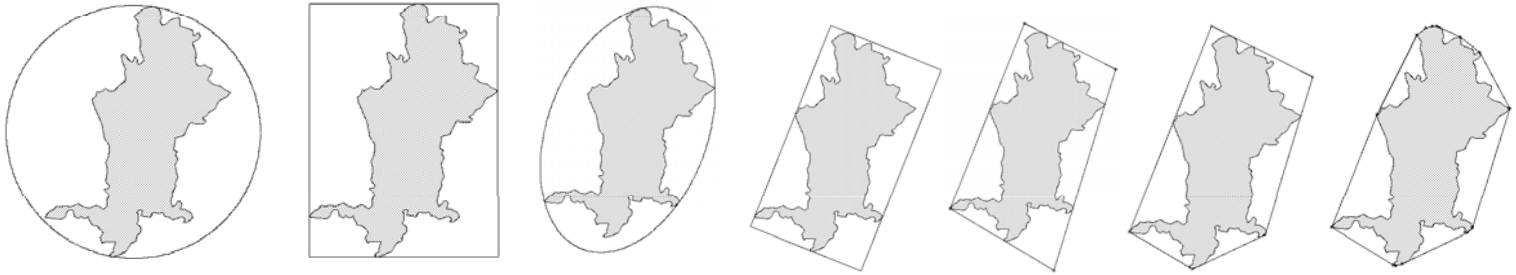

Approximation:	Kreis	MUR	Ellipse	gedrehtes MUR	4-Eck	5-Eck	Konvexe Hülle
Güte:	215%	193%	168%	162%	144%	133%	123%
# Parameter:	3	4	5	5	8	10	O(n)

(Güte = durchschnittliche Flächen der Approximationen in Prozent zur exakten Objektfläche (=100%). Gemitteltes Ergebnis 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)

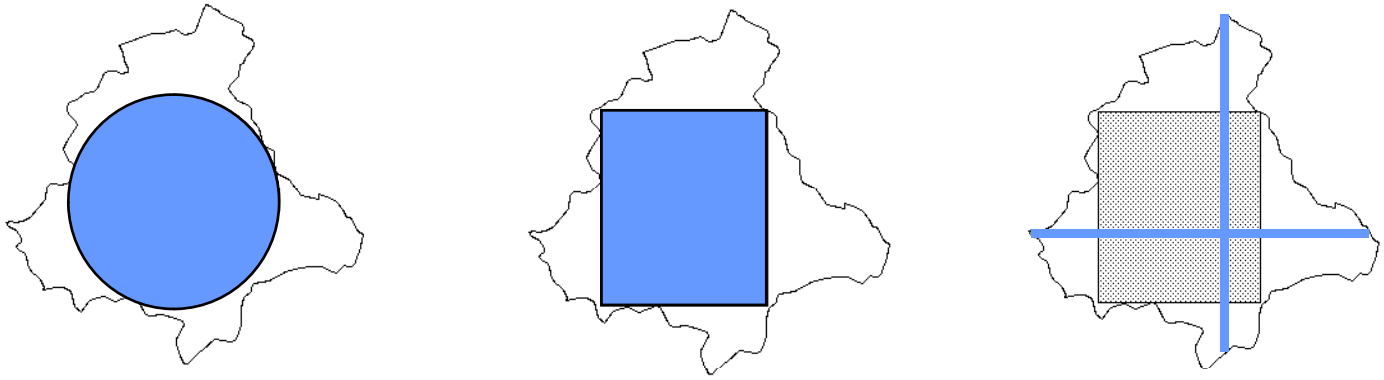

Kreis (42%) | Rechteck (45%) | Rechteck + Strecken

– 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:

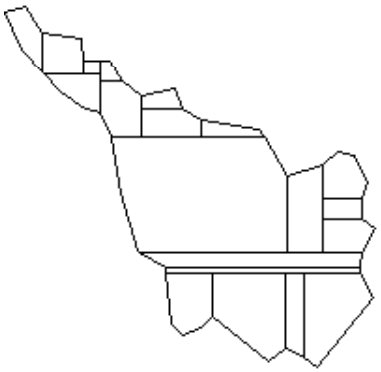

konvexe Zerlegung

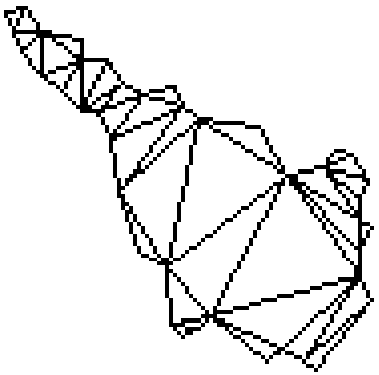

Dreiecks-Zerlegung

Zerlegung in Trapeze

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

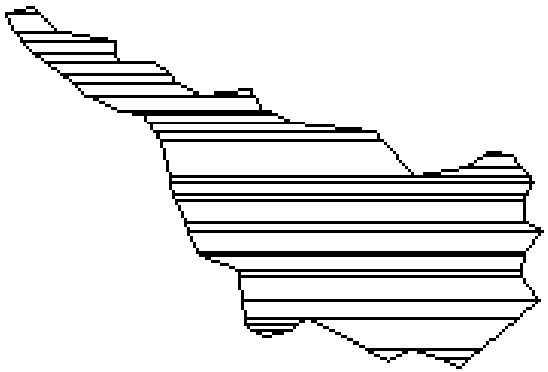

  - Berechnung durch Plane-Sweep-Algorithmus: O(*n* log *n*) für *n* Eckpunkte

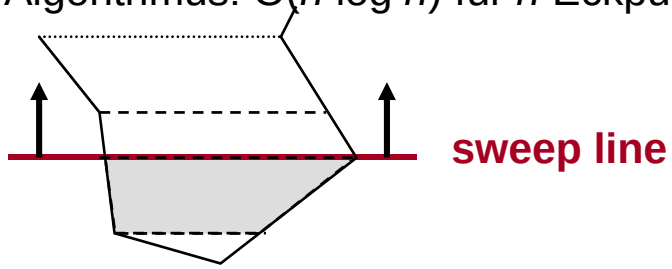

  - Speicherplatzaufwand
    - » Anzahl der Komponenten = *n* bei *n* Eckpunkten
    - » Aber: Vervielfachung des Speicherplatzes da nun Trapeze statt Punkten verwaltet, d.h. abgespeichert werden

- 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)

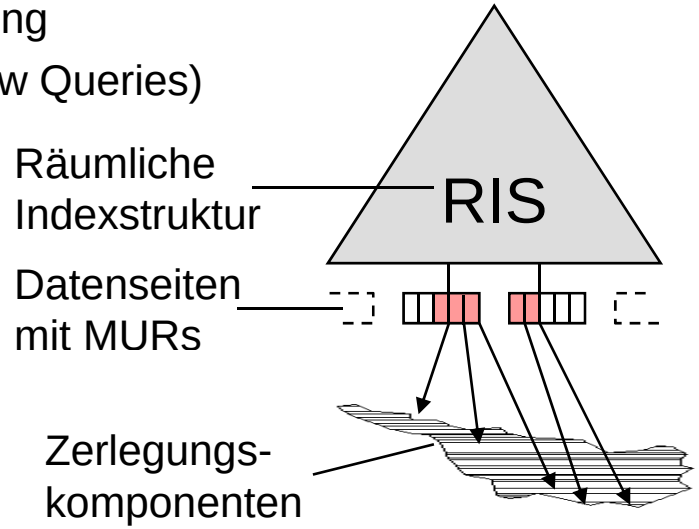

- 2. Ansatz
  - Eine RIS verwaltet die Objektapproximationen (MUR) aller Objekte
  - Für jedes Objekt verwaltet eine separate räumliche Datenstruktur die Zerlegungskomponenten dieses Objektes
  - Wenn die exakte Objektgeometrie untersucht werden muss, werden die Zerlegungskomponenten einschließlich der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

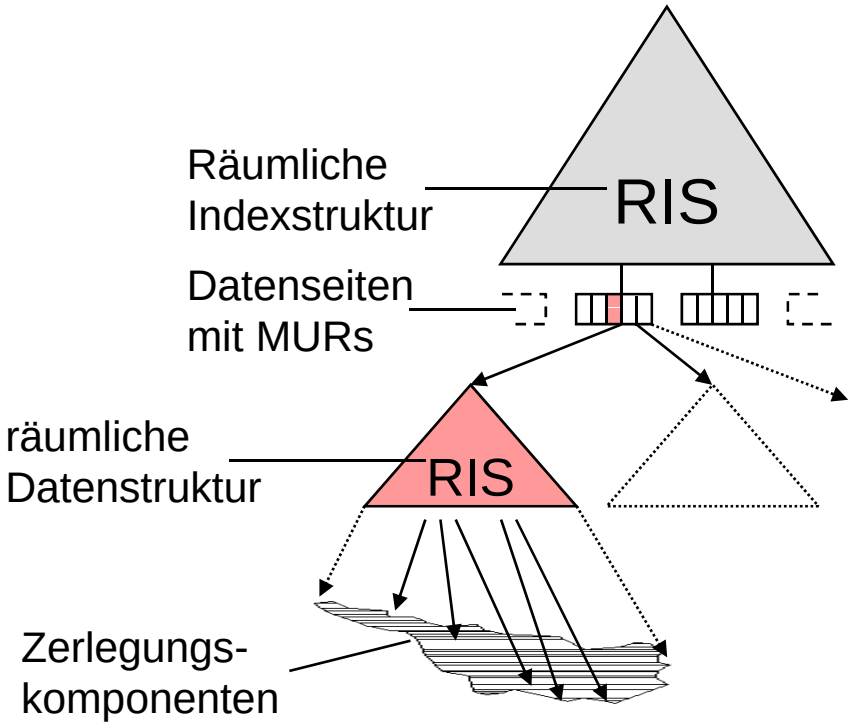

- TR-Ansatz (Ausprägung des 2. Ansatzes)
  - Verwende R-Baum zur Verwaltung der Zerlegungskomponenten

➔ 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

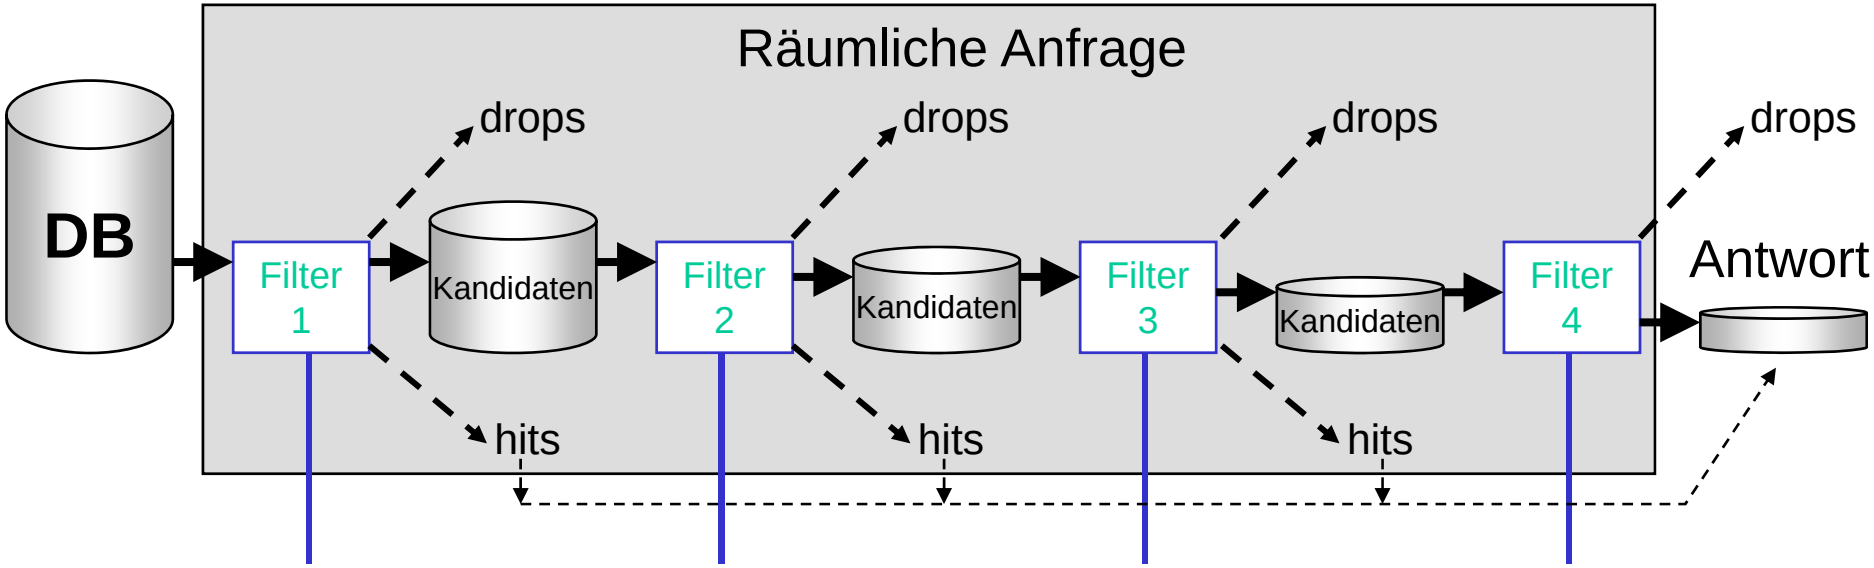

RIS

Bestimmung der Datenseiten, die Treffer und Kandidaten enthalten, durch RIS

MURs

Bestimmung der Objekte auf den gefundenen Datenseiten, die aufgrund ihrer MURs als Treffer in Frage kommen

Approximationen

Bestimmung weiterer Treffer oder Fehltreffer durch zusätzliche konservative und progressive Approximationen

Zerlegungen

Einlesen der exakten Geometrie und Test der exakten Geometrie bezüglich der Anfragebedingung mit Hilfe des TR-Baum-Ansatzes

- GEMINI: Prototyp-System, das diese Anfragebearbeitung realisiert