
Non-Standard-Datenbanken und Data Mining

Multidimensionale Indizierung

Prof. Dr. Ralf Möller

Universität zu Lübeck

Institut für Informationssysteme



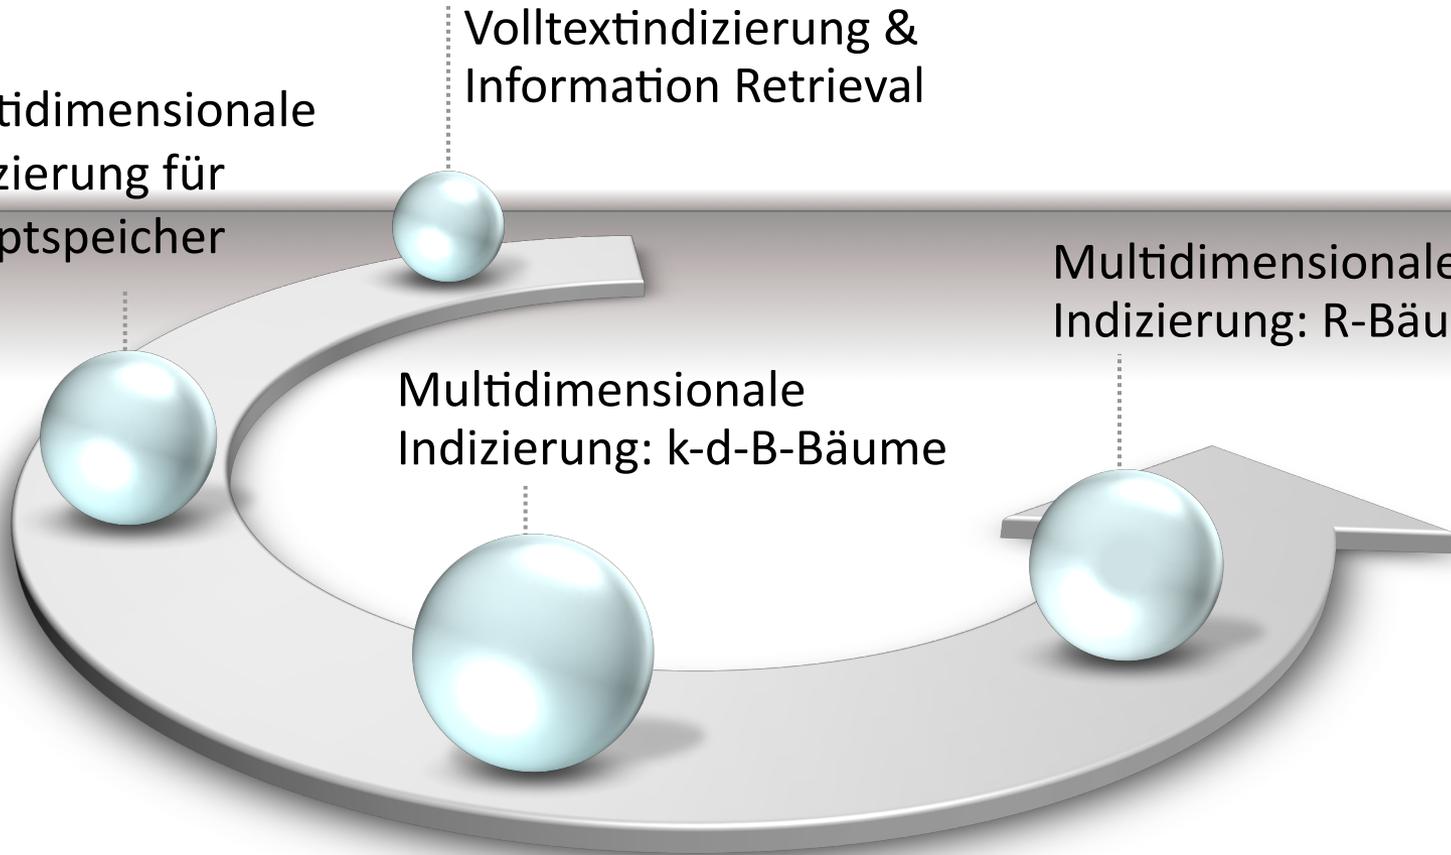
Übersicht

Multidimensionale
Indizierung für
Hauptspeicher

Volltextindizierung &
Information Retrieval

Multidimensionale
Indizierung: R-Bäume

Multidimensionale
Indizierung: k-d-B-Bäume



Wdhlg: Textindizierung, Information Retrieval

- **Annahme:** Falls zwei Sequenzen eine gute lokale Übereinstimmung haben, dann ist mit großer Wahrscheinlichkeit eine kleine **Teilzeichenkette** sogar identisch (**Seed**)

```
TTGACTCGATTATAGTCGCGGATATACTATCG
CCTATCACAAGAATATAGTCCCTGATCCAGC
```

```
TTGACTC GATTATAGTCGCGGAT ATACTATCG
CCTATCACA GAATATAGTCCCTGAT CCAGC
```

```
TTGACTC GATTATAGTCGCGGAT ATACTATCG
CCTATCACA GAATATAGTCCCTGAT CCAGC
```

BLAST: Basic Local Alignment Search Tool

Gegeben sei eine Anfragesequenz s und eine Sequenzdatenbank $D=\{d_j\}$

1. Berechne Teilsequenzen s_i von s der Länge q
 - Auch Q-Gramme genannt (wieviele?)
 - Füge evtl. Q-Gramme mit Änderungen hinzu, um die Anzahl der Passungen zu erhöhen (mit geringerer Bewertung)
2. Finde alle Vorkommen aller s_i in allen d_j (Seeds)
 - Lückenfreie Ausrichtung mit Bewertung
3. Erweitere Seeds nach links und rechts in s_i und d_j
 - Ergänzung des Bewertungsmaßes der initialen Treffer
 - Anwendung von dynamischer Programmierung für Variantenanalyse
 - Schwellwert t

Beispiel

$q=5, t=3$

$s=ACGTGATA$

$d=GATTGACGTGACTGCTAGTGATACTATAT$



$s_1=ACGTG$

$s_2=CGTGA$

$s_3=GTGAT$

$s_4=TGATA$

GATTG**ACGTG**ACTGCTAGTGATACTATAT

GATTGAC**CGTGA**CTGCTAGTGATACTATAT

GATTGACGTGACTGCTAG**TGATA**CTATAT

GATTGACGTGACT**GC**TAGTGATACTATAT



GATTGAC**CGTGA**CTGCAAGTGATACTATAT

ACGTGATA

5

ACGTGATA

5+1=6

ACGTGATA

6-1=5

...

...

PCA mit genetischen Daten

Genetic markers:

- genetically inherited traits which vary between individuals
- items of a nucleic or proteic sequence which vary between individuals

Technically:

- a marker is a variable with different states; one marker = one *locus* (pl. *loci*)
- states are called *alleles*
- one individual can possess several alleles for one locus

Single Nucleotide Polymorphism (SNP)

SNPs are nucleotides which vary in a set of aligned DNA sequences.

Example:

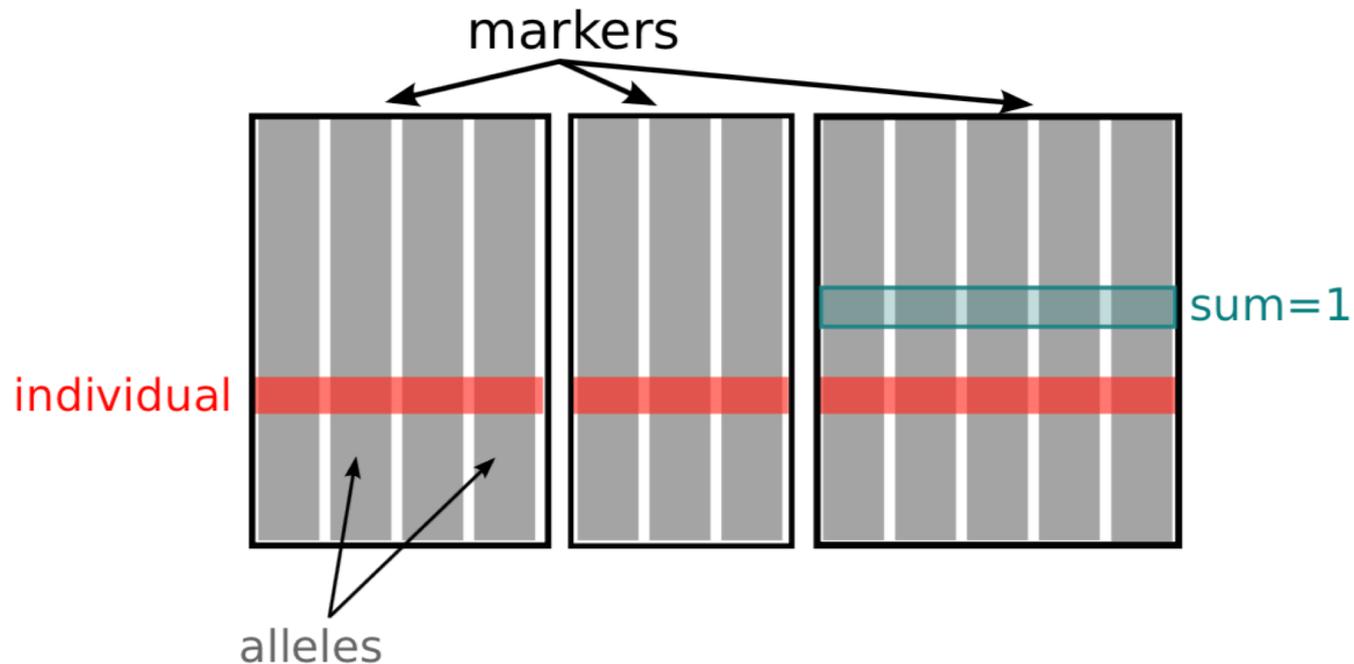
Individual 1: ATG**G**GTATC**T**G

Individual 2: ATG**C**GTATC**A**G

SNPs are often binary (two alleles), but analysed in large numbers (thousands).

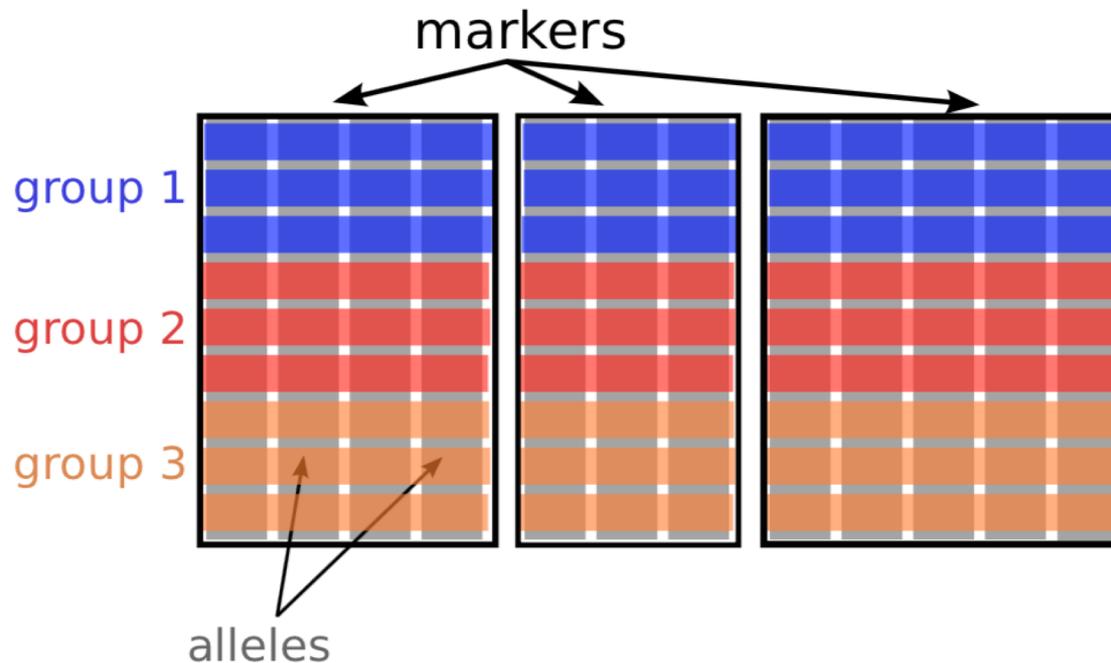
Daten (generelle Aspekte)

- in practice, genetic markers form tables of relative frequencies of alleles.
- data can be aggregated by groups



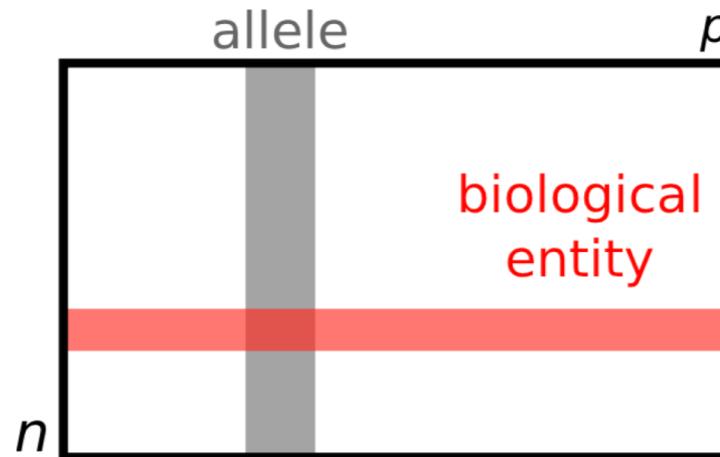
Daten (generelle Aspekte)

- in practice, genetic markers form tables of relative frequencies of alleles.
- data can be aggregated by groups



Daten (generelle Aspekte)

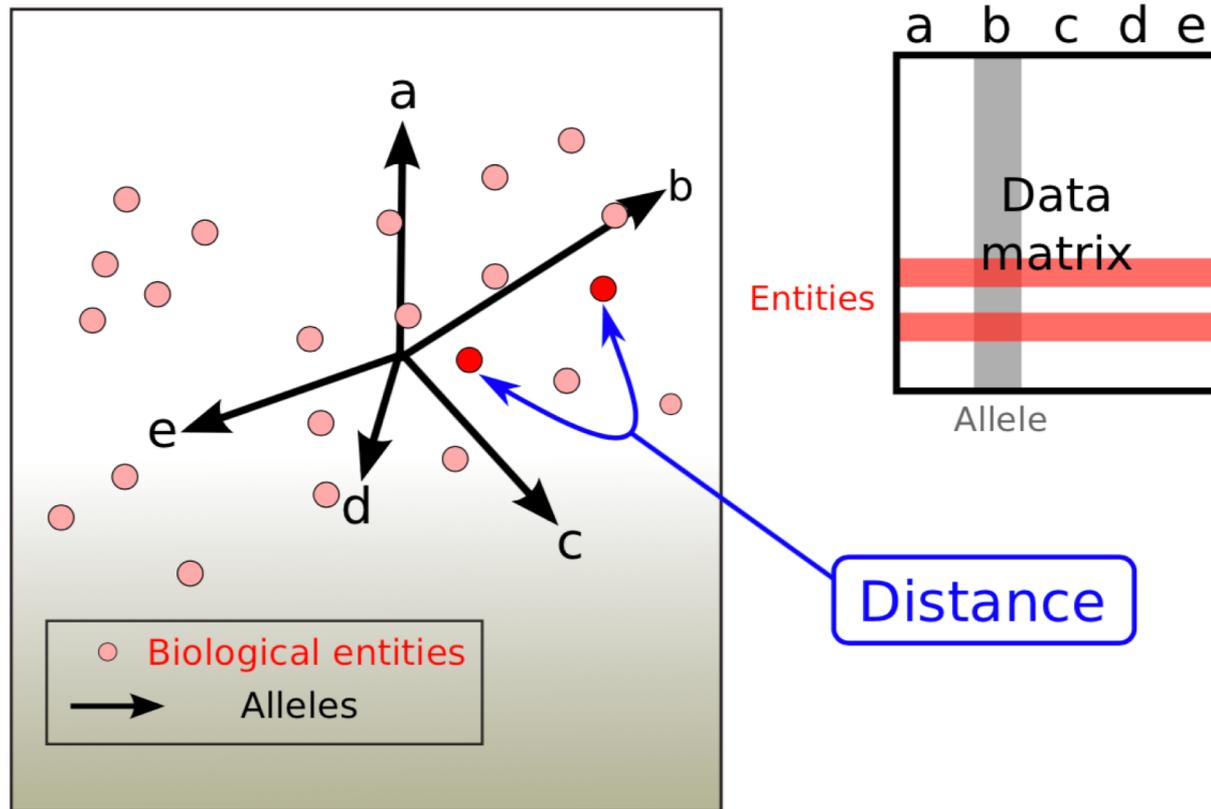
- in practice, genetic markers form tables of relative frequencies of alleles.
- data can be aggregated by groups



In general, we analyse allele frequencies of individuals or groups (*biological entities*).

Geometric Approach

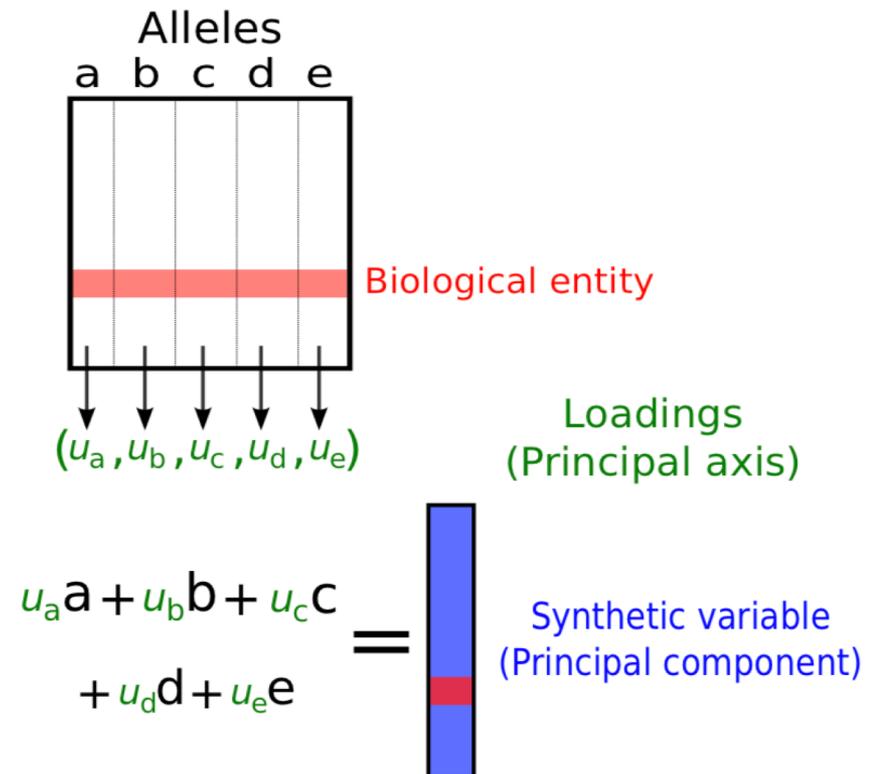
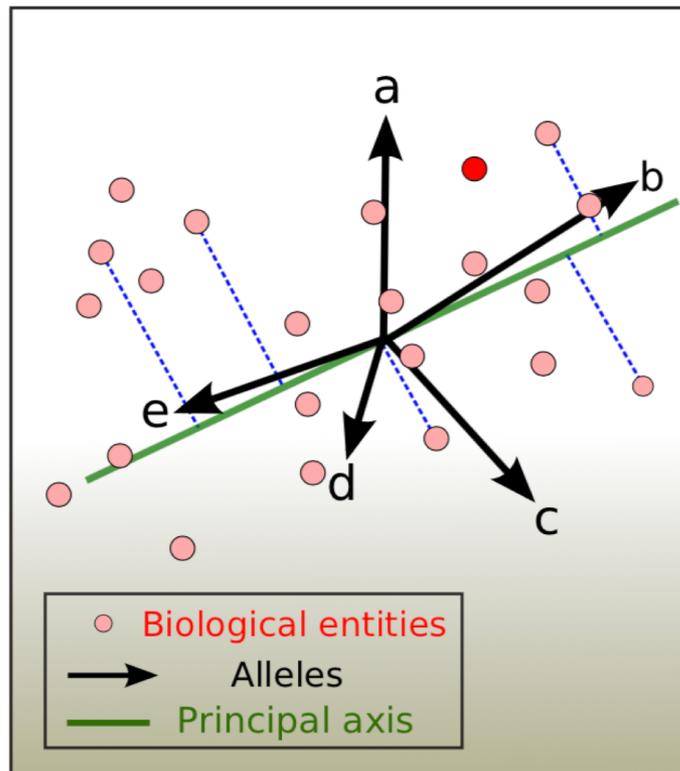
Data form a cloud of points in a multivariate space:



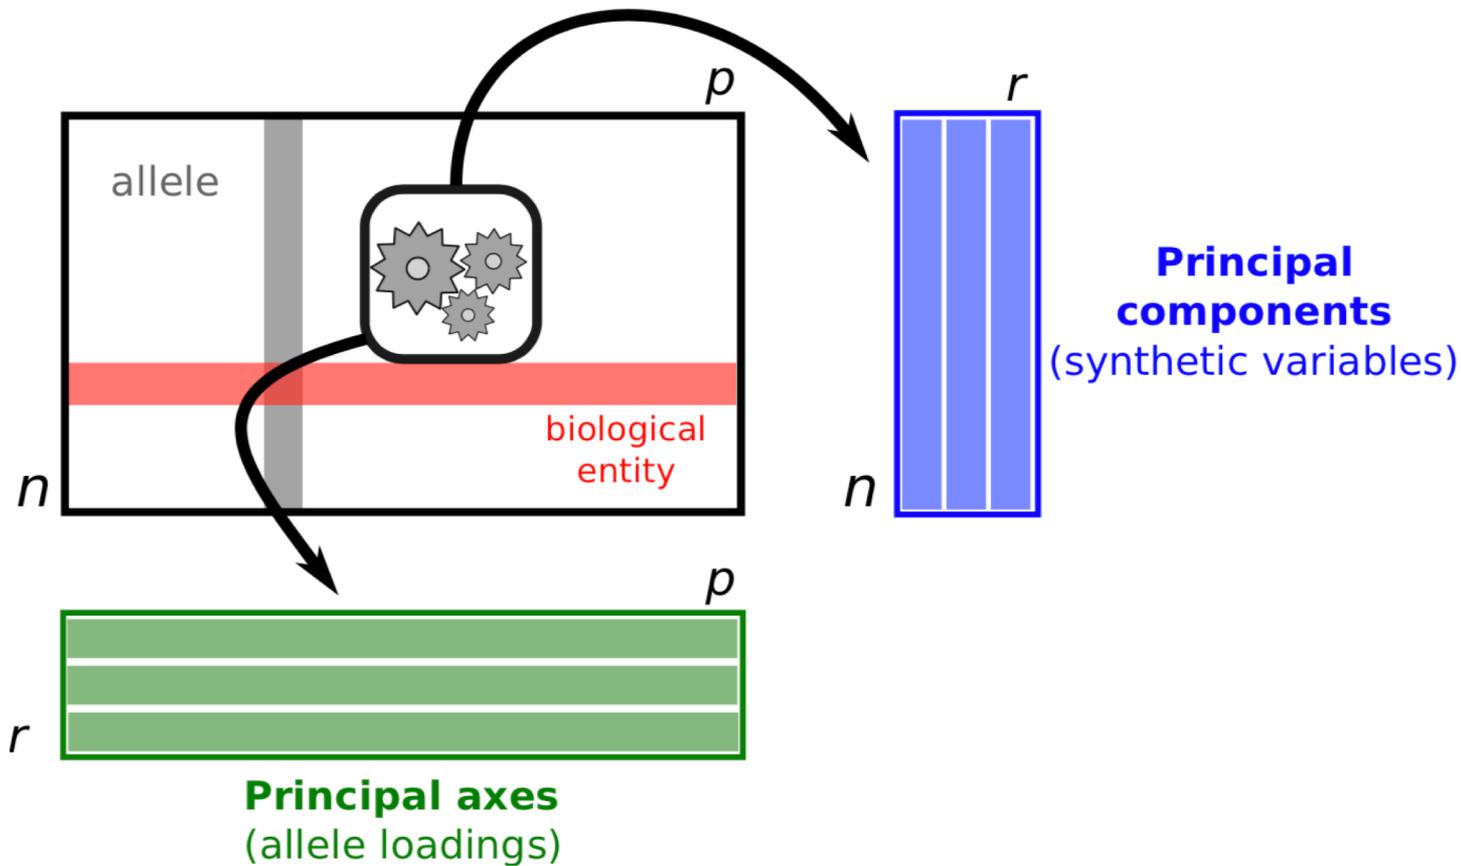
Principal component analysis of genetic data
 David Reich, Alkes L Price & Nick Patterson
 Nature Genetics volume 40, pages 491–492, 2008.

Multivariate Analyse

Finding the directions showing most information.



Ausgabe der Multivariaten Analyse



- principal components: summarize genetic diversity
- principal axes: allele contributions

Danksagung

Die nachfolgenden Präsentationen sind motiviert durch
Materialien einer Vorlesung von Jens Teubner
Insbesondere die Bilder habe ich übernommen
Ich bedanke mich für die Bereitstellung des Materials

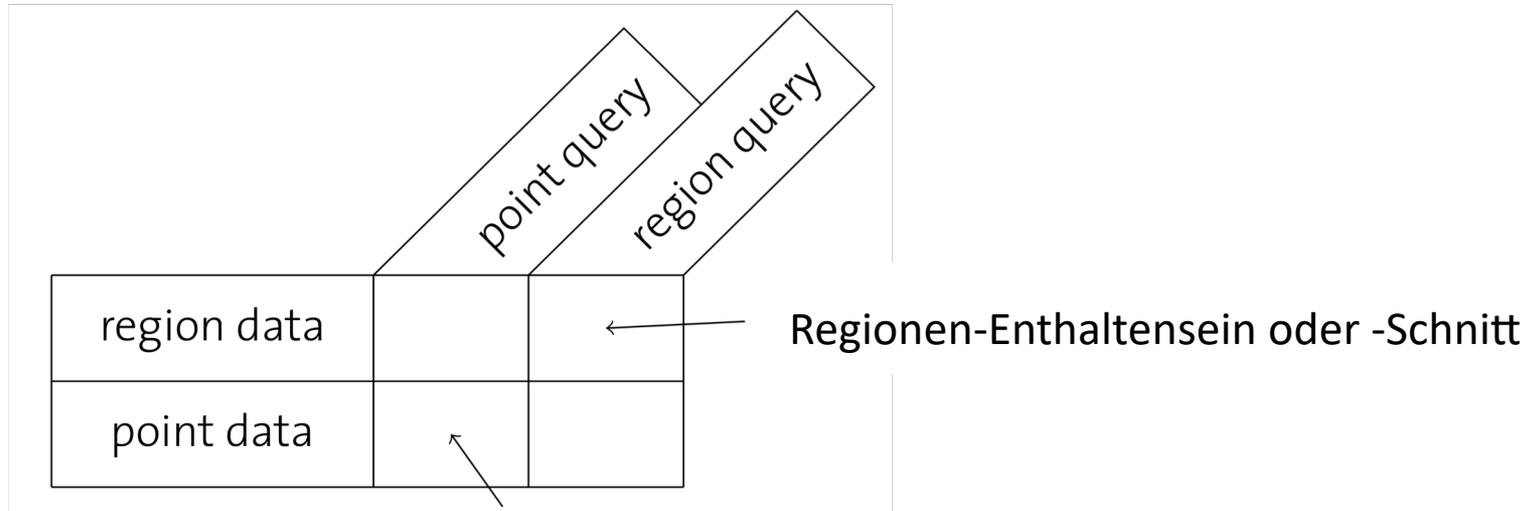
Indexe für mehr Dimensionen ...

```
SELECT *  
  FROM CUSTOMERS  
 WHERE ZIPCODE BETWEEN 8000 AND 8999  
        AND REVENUE BETWEEN 3500 AND 6000
```

- Anfrage beinhaltet Bereichsprädikat definiert über zwei Dimensionen, die nicht Primärschlüssel sind
- Typische Anwendungsfälle mit multidimensionalen Daten:
 - Online Analytical Processing (OLAP)
 - Geographische Informationssysteme
 - Information-Retrieval und Multimedia-Systeme (Dokumentsuche)

... weitere Herausforderungen

Anfragen und Daten können Punkte oder Regionen sein



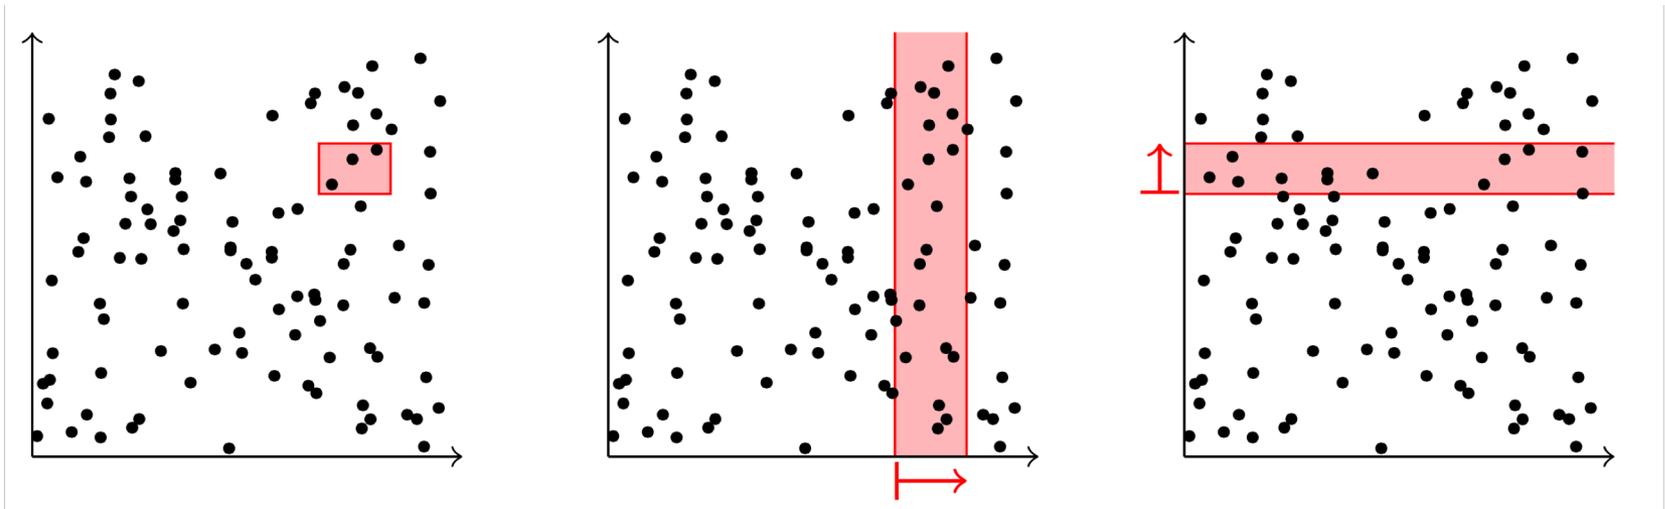
K-Nächste-Nachbarn-Suche (k-NN)

... und es gibt noch viele weitere interessante Anfragetypen für multidimensionale Daten

NB: Anfragen mit Gleichheit lassen sich in eindimensionale Anfragen zerlegen

Können wir nicht einfach B⁺-Bäume verwenden?

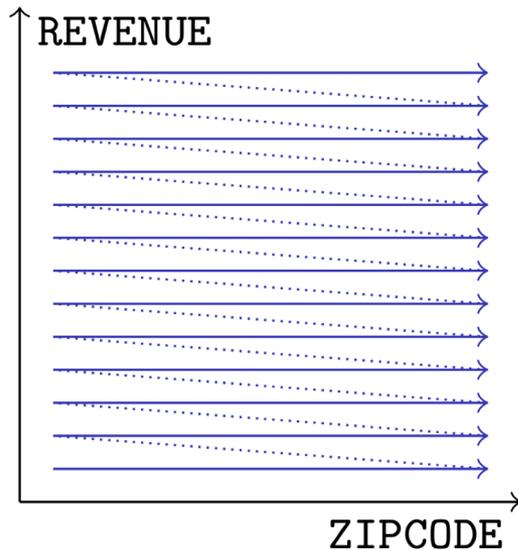
Vielleicht zwei B⁺-Bäume für ZIPCODE und REVENUE?



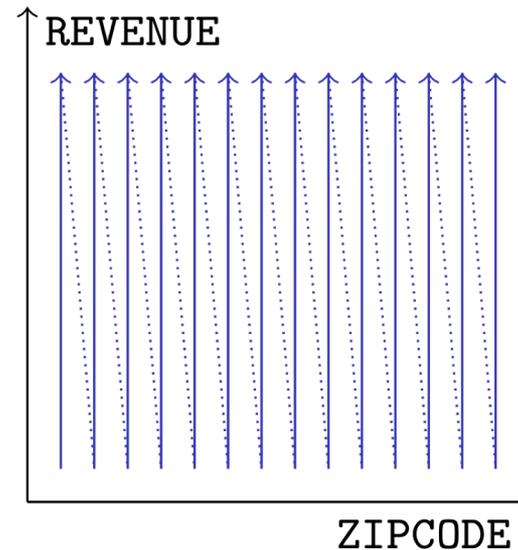
Man kann **pro Dimension** nur über **einen** Index laufen und hat viele **falsche Treffer**

Einige Datenbanken (z.B. DB2) bieten Konjunktion über Indexeinträge als Nicht-Standard-Erweiterung

Oder zusammengesetzte Schlüssel?



$\langle \text{REVENUE, ZIPCODE} \rangle$ index



$\langle \text{ZIPCODE, REVENUE} \rangle$ index

Gleiche Situation!

Indizes über zusammengesetzte Schlüssel sind **nicht symmetrisch**.

Das Hauptattribut dominiert die Organisation des B⁺-Baums

Immerhin kann man ggf. auf dem Index arbeiten und irrelevante Einträge eliminieren

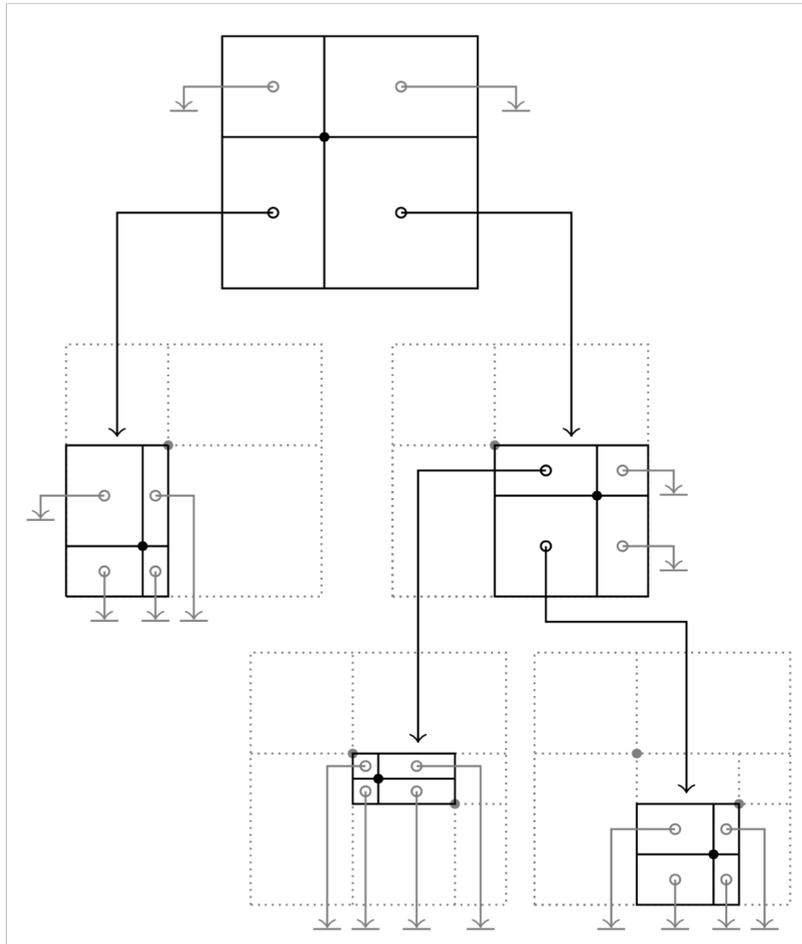
Multidimensionale Indexstrukturen

- B⁺-Bäume unterstützen nur **eindimensionale** Anfragen¹
- Wir suchen multidimensionale Indexstrukturen mit folgenden Eigenschaften
 - Symmetrie in allen Dimensionen
 - Raumorientierte Gruppierung von Daten
 - Dynamisch in Bezug auf Schreiboperationen
 - Unterstützung von häufigen Anfragen
- Erst Hauptspeicherdatenstrukturen,
dann Erweiterungen für Sekundärspeicherbetrieb

¹ Am Ende betrachten wir mit UB-Bäumen noch eine elegante Kodierung, die auch bei B-Bäumen mehrdimensionale Anfragen recht gut unterstützt

„Binärer“ Suchbaum

Für k Dimensionen wird aus dem Binärbaum ein 2^k -ärer Baum



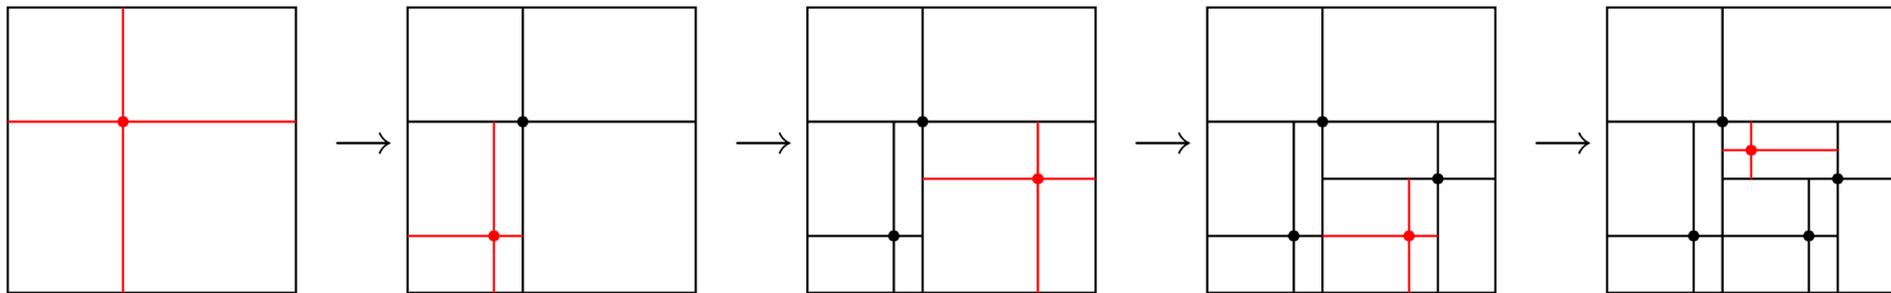
- Jeder Datenpunkt **partitioniert** den Datenraum in 2^k **disjunkte** Regionen
- In einem Knoten zeigt jede Region auf einen neuen Knoten (zur Partitionierung) oder auf einen speziellen **Nullzeiger**
- Eine solche Datenstruktur heißt **Punkt-Quad-Baum**

Einfügen in einen Punkt-Quad-Baum

Einfügen eines Punktes q_{new} in einen Quad-Baum funktioniert wie das Einfügen in einen Binärbaum

1. **Traversiere** den Baum, so als suche man nach q_{new} bis eine Partition P mit einem **Nullzeiger** erreicht ist
2. Erzeuge **neuen Knoten** n' , der die Region P aufspannt und durch q_{new} partitioniert wird (mit **Null** für alle Subpartitionen)
3. Lasse P auf n' zeigen

Leider bleibt der Baum **nicht immer balanciert**



Bereichsanfragen

Um eine Bereichsanfrage² zu evaluieren, müssen ggf. mehrere Regionen verfolgt werden

```
1 Function: r_search ( $Q$ ,  $node$ )
2 if data point in  $node$  is in  $Q$  then
3   append data point to result ;
4 foreach partition  $P$  in  $node$  that intersects with  $Q$  do
5    $node' \leftarrow$  node pointed to by  $P$  ;
6   r_search ( $Q$ ,  $node'$ ) ;
```

```
1 Function: regionsearch ( $Q$ )
2 return r_search ( $Q$ ,  $root$ ) ;
```

² Wir betrachten rechteckige Regionen, bei allgemeinen Regionen sind Umschließungsboxen zu bilden und die Antworten nachzuarbeiten

Punkt-Quad-Bäume – Diskussion

Punkt-Quad-Bäume

- ✓ sind **symmetrisch** in Bezug auf alle Dimensionen
- ✓ und unterstützen **Punkt-** und **Regionen-**Anfragen

Aber

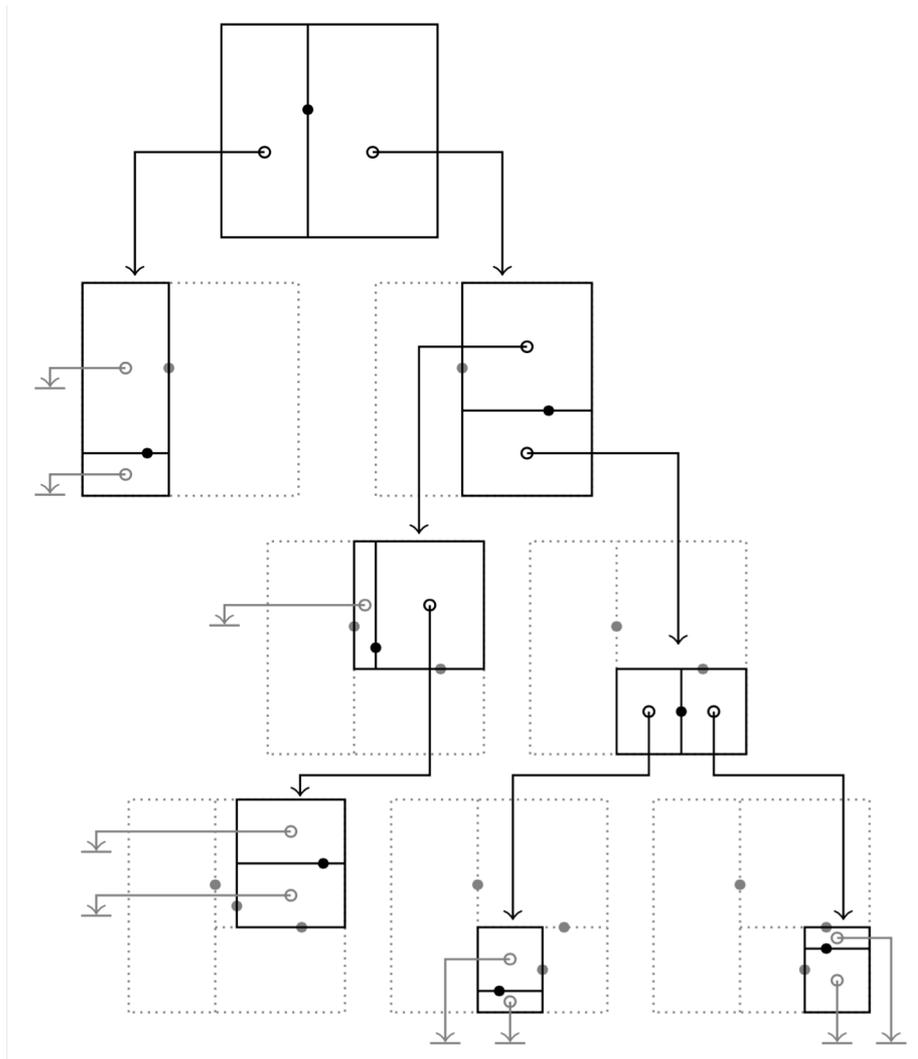
- die Form hängt von der **Einfügereihenfolge** ab
(im **schlimmsten** Fall entsteht eine **verkettete Liste**)
- **Nullzeiger** sind speicher**ineffizient** (ins. bei großem k)

Und

- nur **Punktdaten** können gespeichert werden

NB: Punkt-Quad-Bäume sind für Hauptspeicher gedacht

k -d-Bäume



- Indiziere k -dimensionale Daten, aber halte den Baum binär
- Verwende für jede Baumebene / eine andere Dimension d_i als Diskriminator zur Partitionierung
 - Schema: Round-Robin
- Man erhält einen **k -d-Baum**

J.L. Bentley, Multidimensional Binary Search Trees Used for Associative Searching. *Comm. ACM*, vol. 18, no. 9, Sept. 1975.

k-d-Bäume

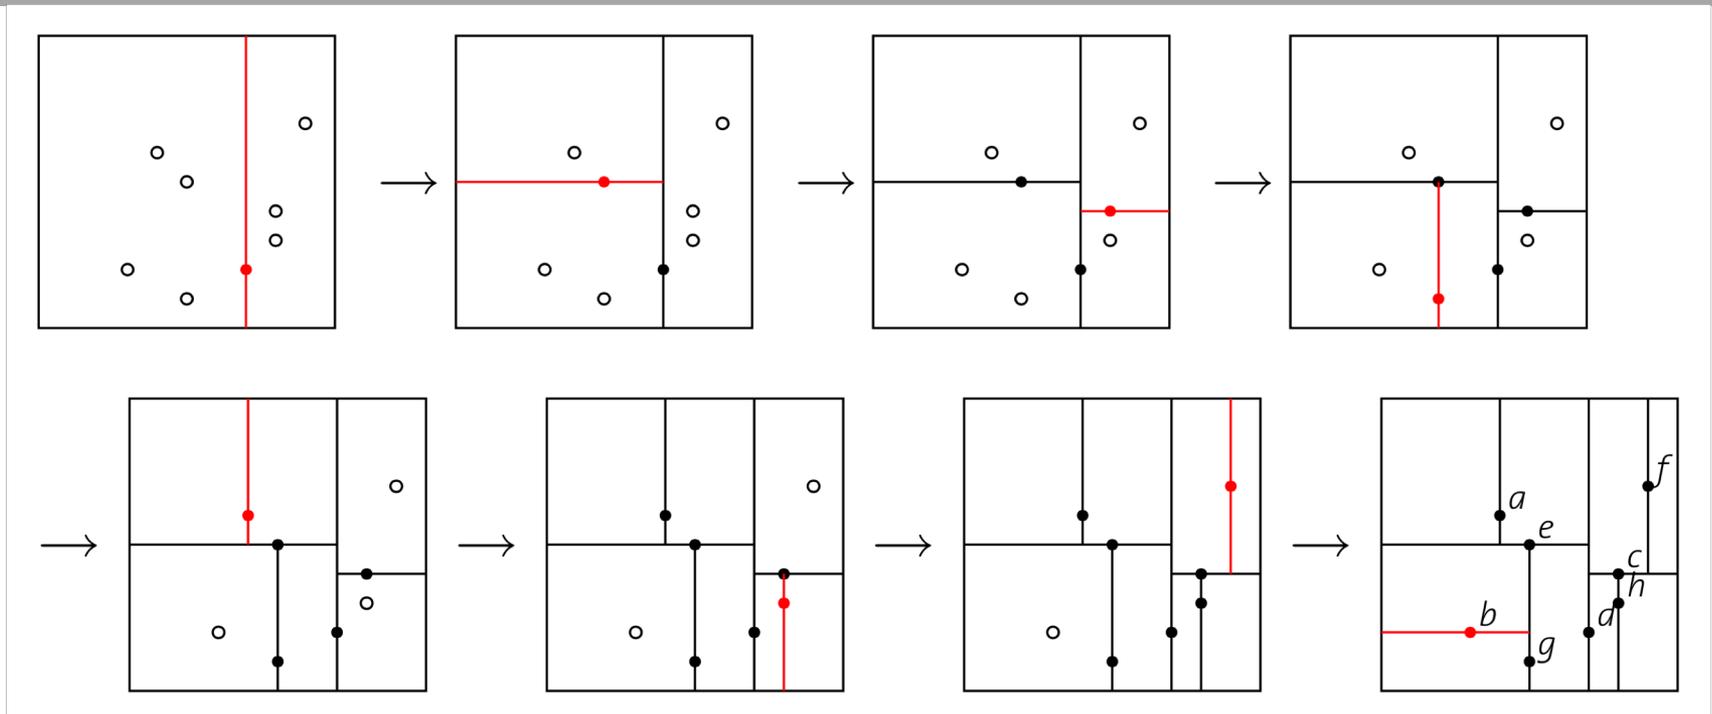
k-d-Bäume übernehmen die positiven Eigenschaften von Punkt-Quad-Bäumen, sind aber **speichereffizienter**

Für eine gegebene Punktmenge kann ein **balancierter** k-d-Baum konstruiert werden³

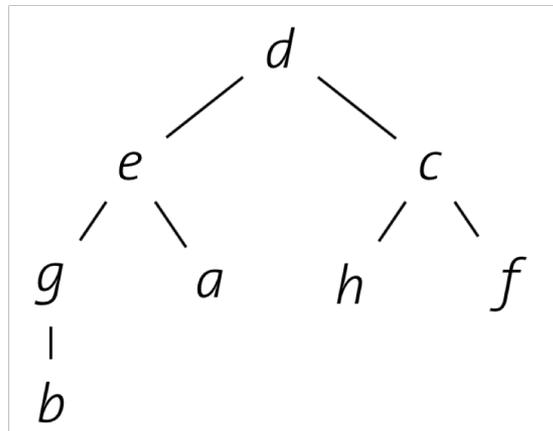
```
1 Function: kdtree (pointset, level)
2 if pointset is empty then
3   return null ;
4 else
5    $p \leftarrow$  median from pointset (along  $d_{level}$ ) ;
6    $points_{left} \leftarrow \{v \in pointset \text{ where } v_{d_{level}} < p_{d_{level}}\}$ ;
7    $points_{right} \leftarrow \{v \in pointset \text{ where } v_{d_{level}} \geq p_{d_{level}}\}$ ;
8    $n \leftarrow$  new k-d tree node, with data point  $p$  ;
9    $n.left \leftarrow$  kdtree ( $points_{left}$ , level + 1) ;
10   $n.right \leftarrow$  kdtree ( $points_{right}$ , level + 1) ;
11  return n ;
```

³ v_i : Koordinate i von Punkt v

Balancierte k -d-Baum-Konstruktion



Ergebnis



Non-Standard-Datenbanken

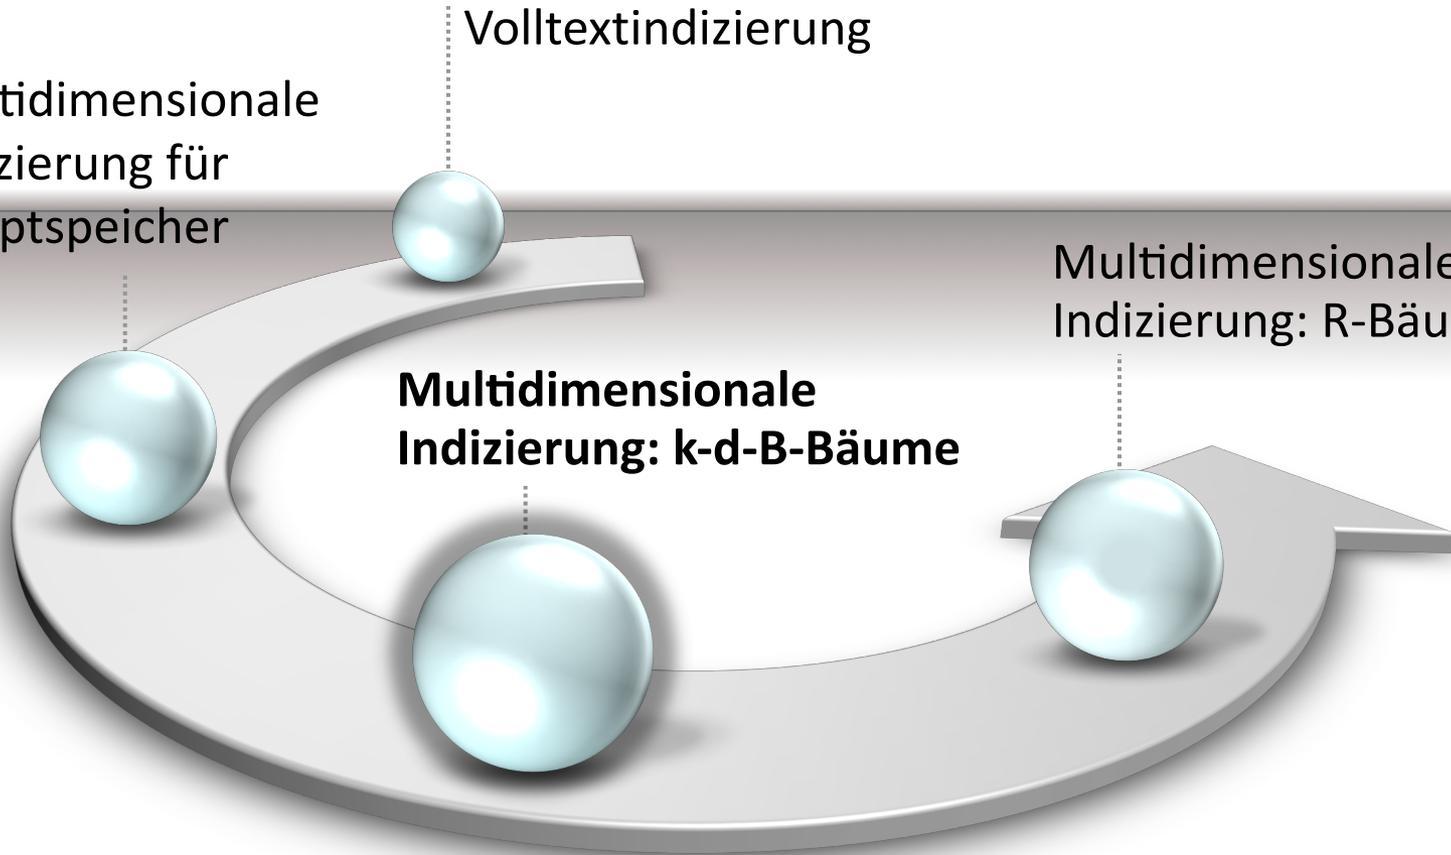
Multidimensionale Indizierung

Multidimensionale
Indizierung für
Hauptspeicher

Volltextindizierung

Multidimensionale
Indizierung: R-Bäume

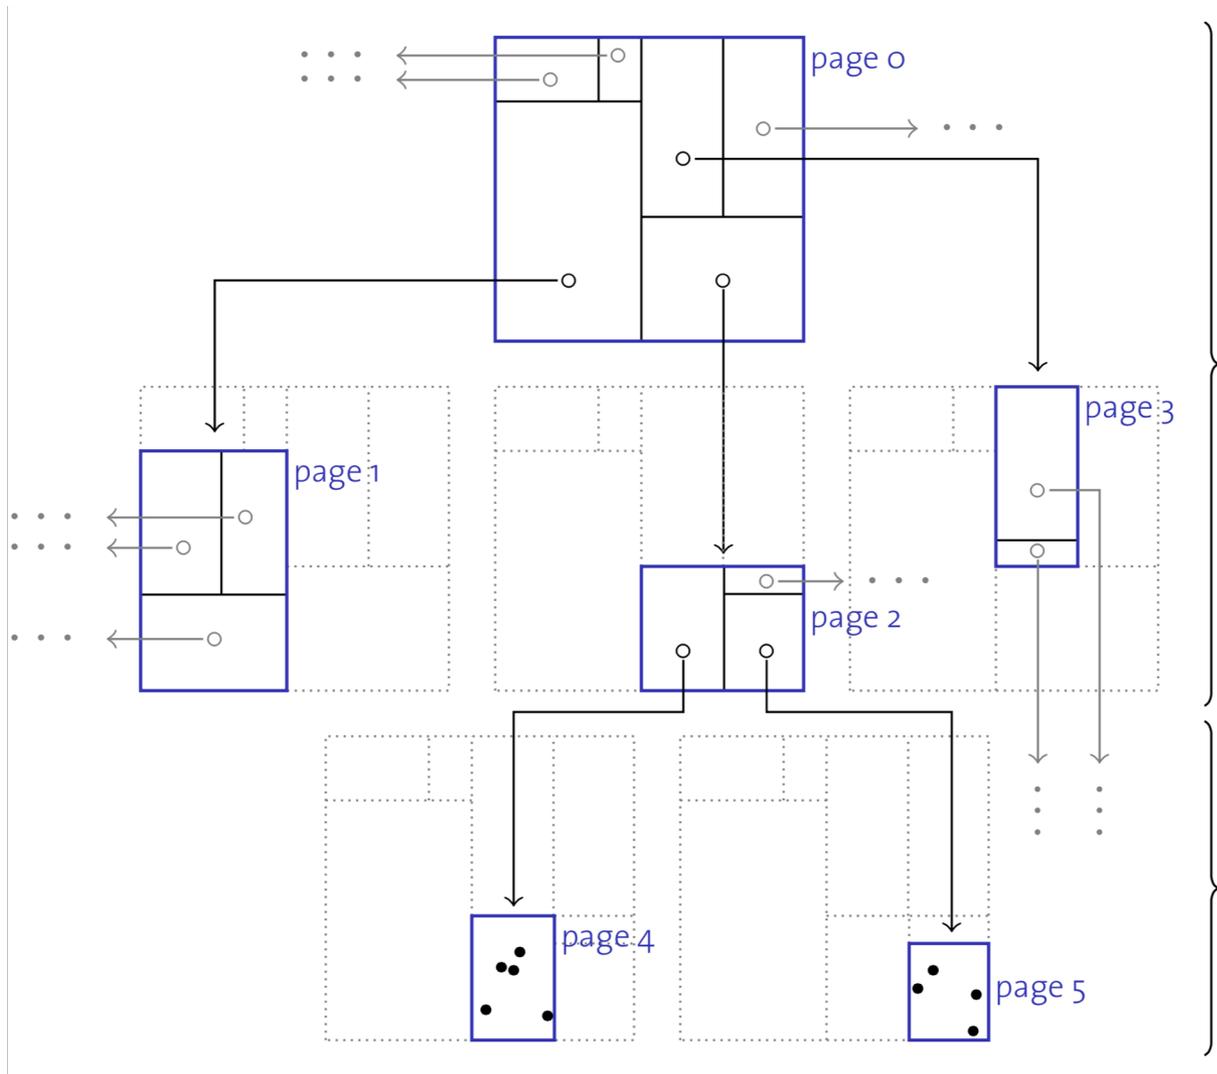
Multidimensionale
Indizierung: k-d-B-Bäume



k-d-B-Bäume

- k-d-Bäume auf Sekundärspeichern
- Verwendung von Seiten als organisatorische Einheiten
 - Jeder Knoten in einem k-d-B-Baum füllt eine Seite
- k-d-Baum-Layout für jede Seite

k-d-B-Bäume: Zentrale Idee



Regionenseiten

- enthalten Einträge $\langle \text{region, pageID} \rangle$
- keine **Nullzeiger**
- bilden **balancierten** Baum
- alle Regionen **disjunkt** und **rechteckig**

Punktseiten

- enthalten Einträge $\langle \text{point, rid} \rangle$
- \rightarrow Blattknoten B^+ -Baum

Operationen auf k -d-B-Bäumen

- **Suche** in einem k -d-B-Baum läuft wie folgt:
 - Auf jeder Seite bestimme die Region R_i , die Anfragepunkt q enthält (oder sich mit der Anfrageregion Q schneidet)
 - Für jedes solche R_i bestimme die Seite und wende Suche rekursiv an
 - Auf Punktseiten hole jeden Punkt p_i , der auf Anfrage passt, und gebe ihn zurück

Operationen auf k -d-B-Bäumen

- Beim **Einfügen** wird der Baum **balanciert** wie beim **B⁺-Baum**
 - Füge Eintrag $\langle \text{region}, \text{pageID} \rangle$ ($\langle \text{point}, \text{rid} \rangle$) in eine Regionenseite (Punktseite) ein, sofern **genügend Platz** vorhanden
 - **Sonst: Splitte** Seite auf

Aufsplittung einer Punktseite

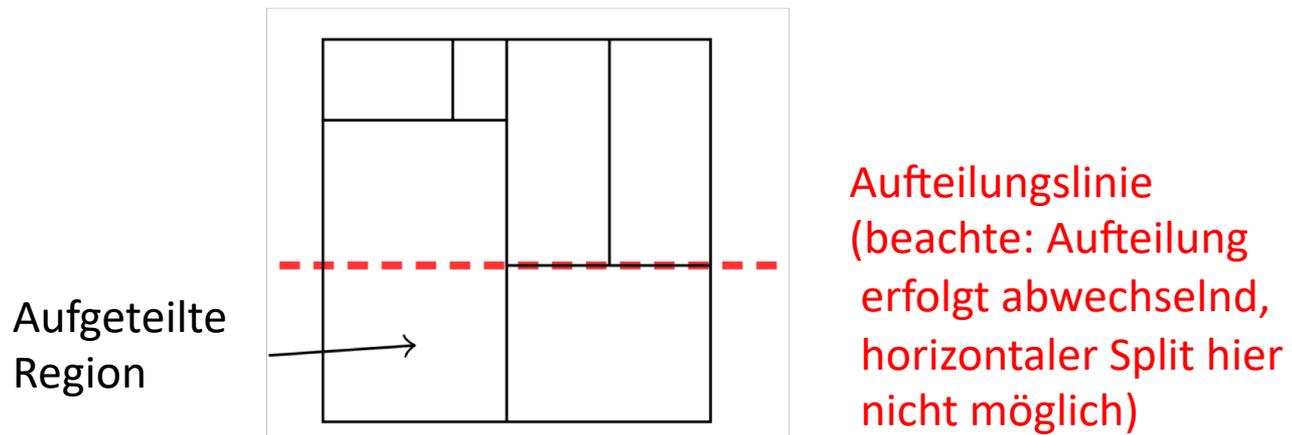
Aufteilung einer Seite p

1. **Wähle Dimension i** und eine i -Koordinate x_i entlang derer die Aufteilung erfolgen soll, so dass die Teilung zwei nicht übervolle Seiten erzeugt
2. **Schiebe** Datenpunkte entsprechend auf neue Seiten p_{links} oder p_{rechts} sofern $p_i < x_i$ oder $p_i \geq x_i$
3. **Ersetze** $\langle region, p \rangle$ auf der **Elternseite** durch $\langle linke-region, p_{links} \rangle$ und $\langle rechte-region, p_{rechts} \rangle$

Der 3. Schritt kann zu einem **Überlauf** der Elternseite führen und damit zu einem **Aufspalten** einer **Regionenseite**

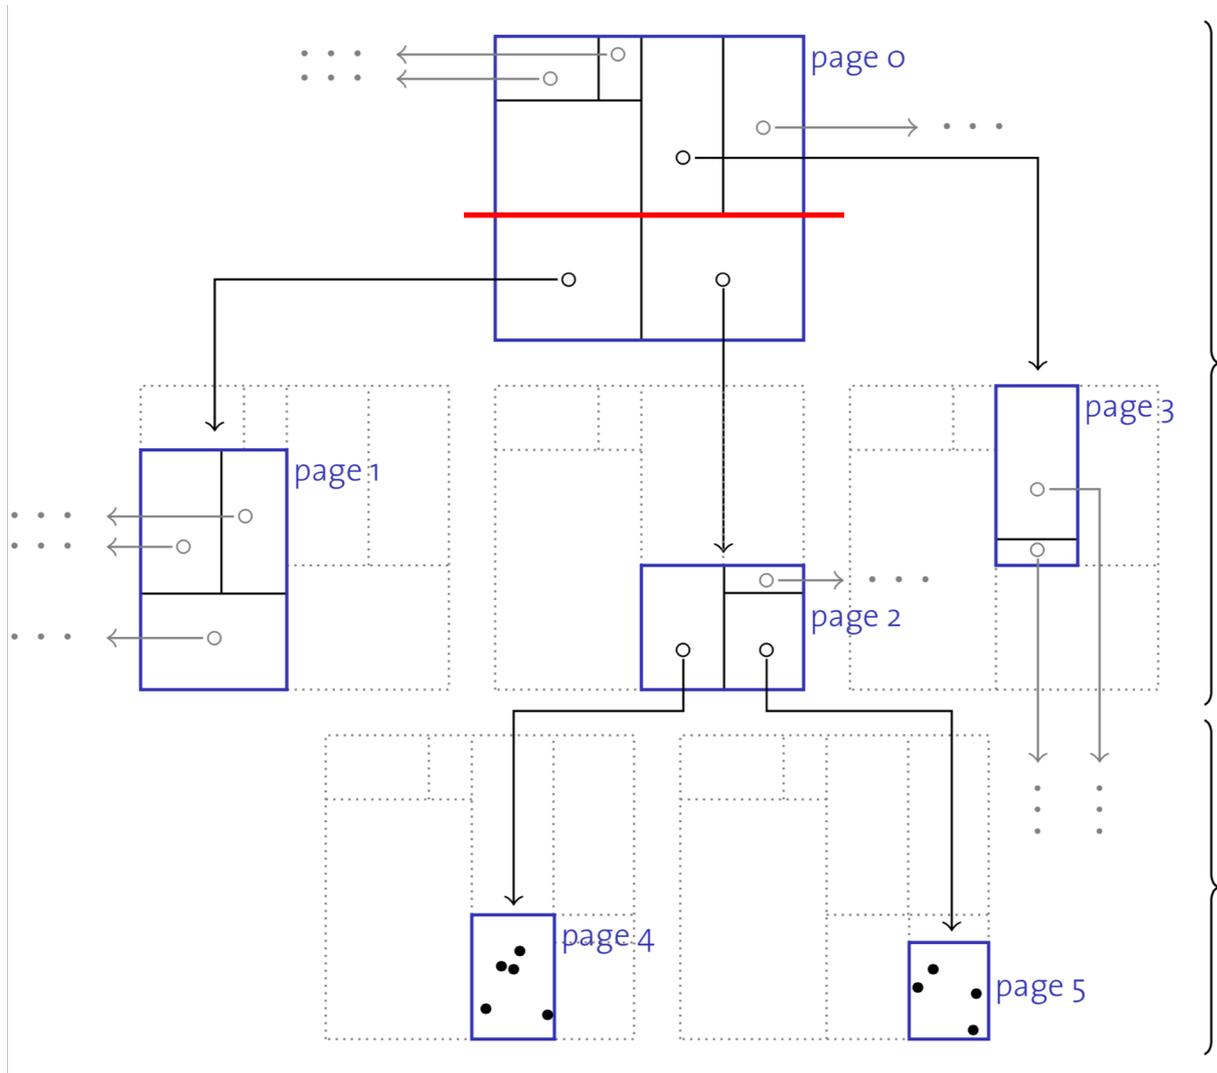
Aufspaltung einer Regionenseite

- Aufspaltung einer **Punktseite** und Verschiebung der Datenpunkte ist recht **einfach**
- Im Falle einer **Aufspaltung** können einige **Regionen auf beiden** Seite der Aufteilungslinie liegen



- Diese Regionen müssen **aufgeteilt** werden
- Mögliche Folge: **Rekursives Aufteilen nach unten**

Beispiel noch einmal



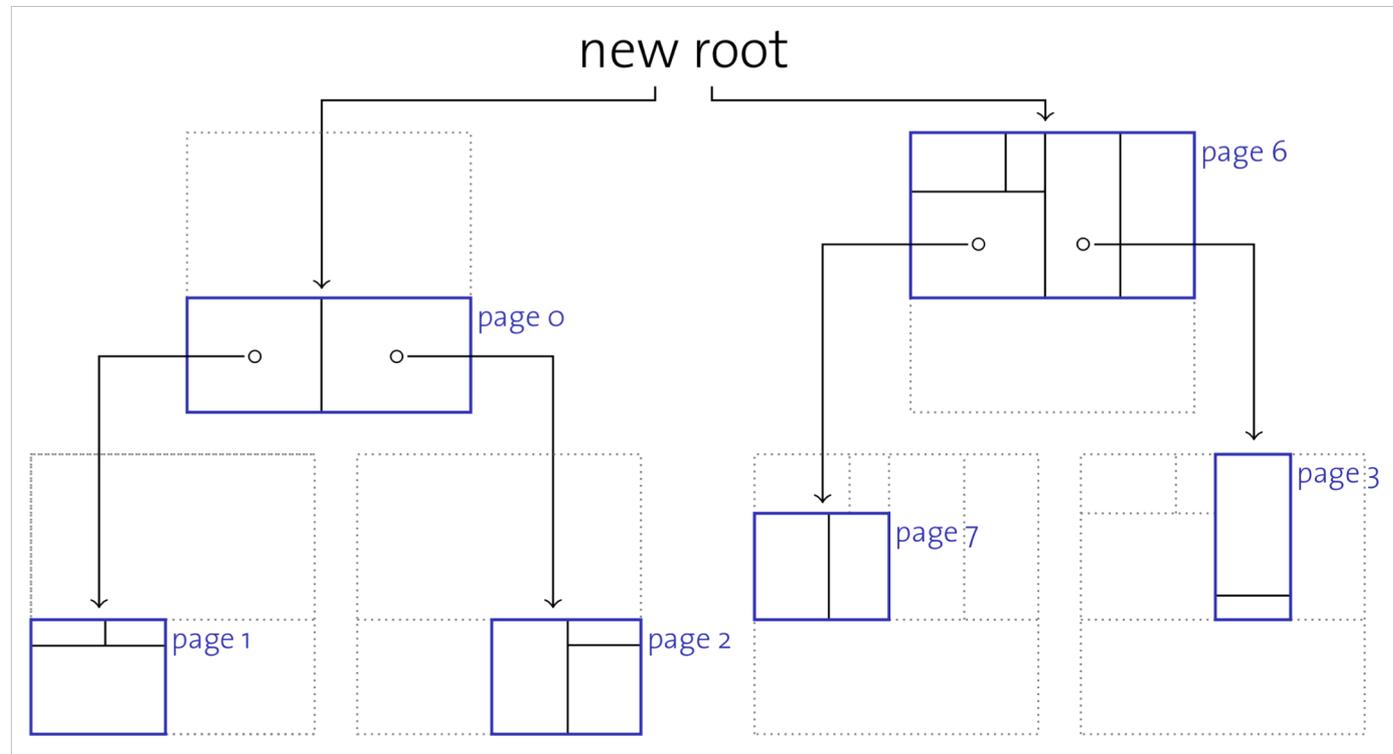
Regionenseiten

- enthalten Einträge $\langle \text{region, pageID} \rangle$
- **keine Nullzeiger**
- bilden **balancierten Baum**
- alle Regionen **disjunkt** und **rechteckig**

Punktseiten

- enthalten Einträge $\langle \text{point, rid} \rangle$
- \rightarrow Blattknoten B⁺-Baum

Beispiel: Aufspaltung von Seite 0



Wurzelseite 0 → Seiten 0 und 6 (neue Wurzel erzeugen)

Regionenseite 1 → Seiten 1 und 7

(Punktseiten nicht gezeigt)

k-d-B-Bäume – Diskussion

- ✓ **Symmetrie** in Bezug auf alle Dimensionen
- ✓ **Räumliche** Gruppierung von Daten in **seitenorientierter** Weise
- ✓ **Dynamisch** in Bezug auf **Schreib**operationen
- ✓ Unterstützung von **Punkt** und **Regionen**anfragen

Aber:

- **Keine Regionendaten**
- **Löschoperationen nicht** (dynamisch) **unterstützt**

Datenraum wird partitioniert, so dass

- jede Region **rechteckig** ist und
- sich Regionen **nicht überlappen**

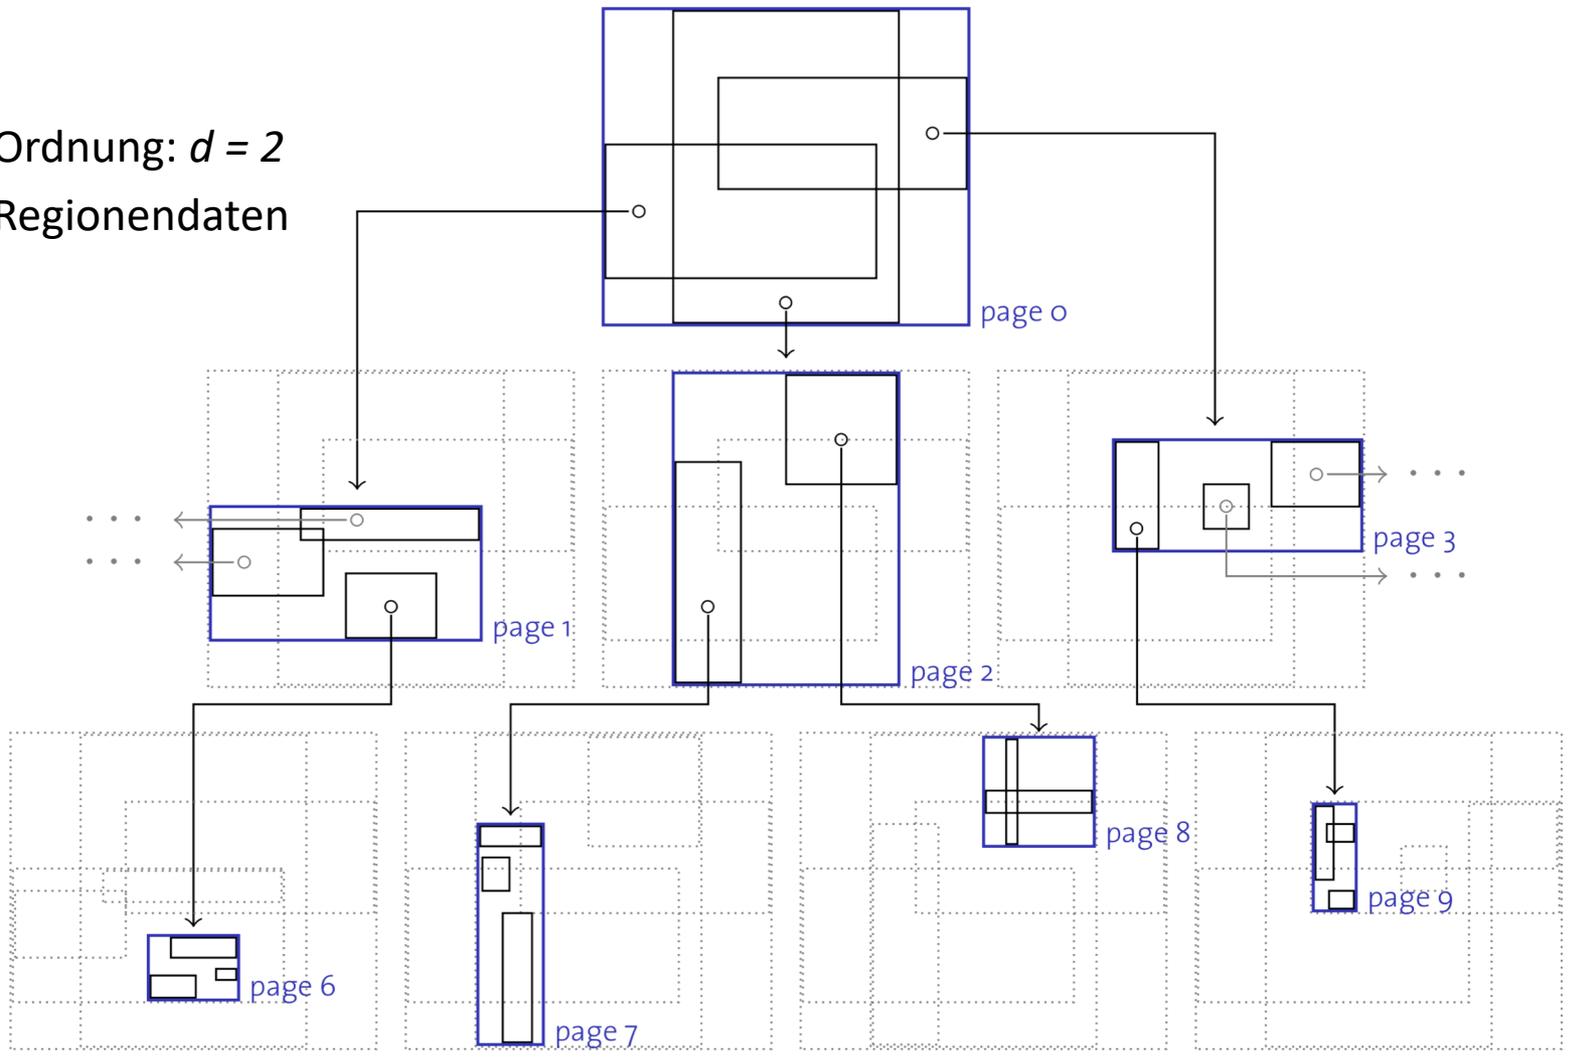
R-Bäume für Regionen als Daten

Regionen können sich in dieser Struktur überlappen

- Innere Knoten enthalten $\langle \text{region, pageID} \rangle$ Einträge, Blattknoten enthalten Einträge der Form $\langle \text{region, rid} \rangle$, wobei region das **minimale Umgebungsrechteck** der Datenelemente, die über den Zeigern erreichbar sind
 - Jeder Knoten enthält zwischen d und $2d$ Elemente (\rightarrow B⁺-Baum). Die Wurzel kann weniger als d Elemente enthalten, sofern weniger als d Elemente im Baum sind.
 - **Einfüge-** und **Löschalgorithmen** halten den R-Baum **balanciert**
- Es können sowohl **Punkte** als auch **Regionen gespeichert** werden

R-Baum: Beispiel

- Ordnung: $d = 2$
- Regionendaten

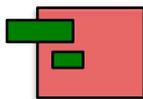
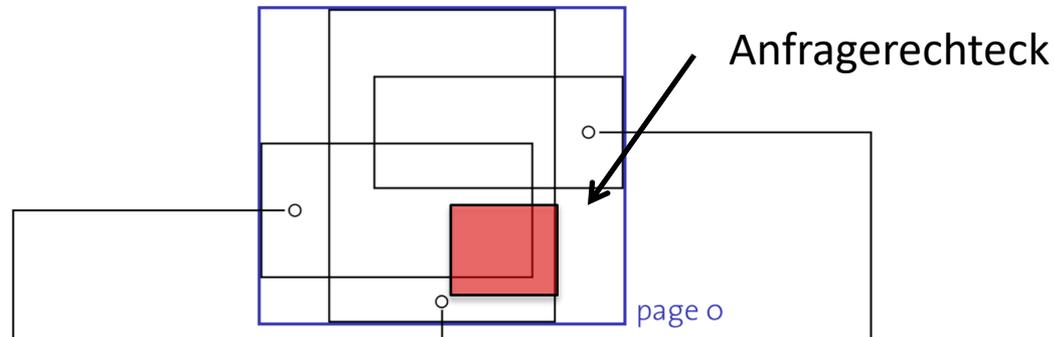


Innere Knoten

Blattknoten

R-Baum: Regionenabfrage (Schnitt)

- Ordnung: $d = 2$
- Regionendaten



Innere Knoten

Blattknoten

R-Baum: Suchen und Einfügen

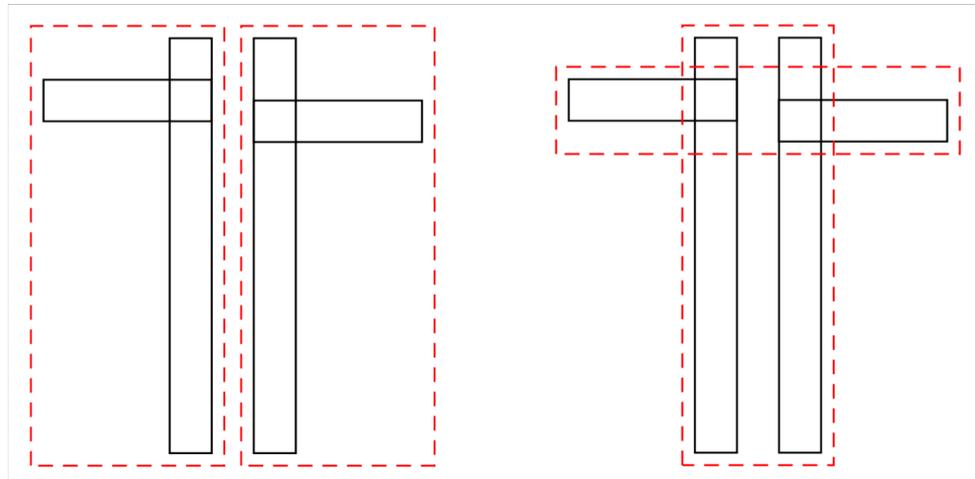
Während der **Suche** müssen ggf. mehrere Kinder betrachtet werden (gilt für Punkt- **und** Regionenanfragen)

Einfügen erfolgt wie in einem B^+ -Baum

1. **Wähle** richtigen Blattknoten n für die Einfügung
(versuche entstehende neue Rechtecke zu minimieren)
2. Falls n **voll** ist, **spalte** ihn auf (wir haben n und n') und verteile alte Einträge auf n und n'
 - Aufspaltungen können nach oben propagieren und erreichen ggf. die Wurzel
3. Nach dem Einfügung müssen Regionen im Vorgängerknoten angepasst werden (Umgebungsrechtecke)

Aufspaltung von Knoten im R-Baum

Mehrere Möglichkeiten



Schlechte Aufspaltung

Gute Aufspaltung

Heuristik: Minimiere überdeckte Fläche

Bestimmung der besten Aufteilung i.a. zu kombinatorisch

Das originale Guttman-Papier stellt Approximation vor

- Verbessert in Nachfolgebapieren (R^* -Baum, ...)

Löschoperationen

R-Baum-**Invarianten** bei jeder Operation **beibehalten**

1. Falls ein Knoten n zu leer wird (weniger als d Einträge nach einer Löschoperation) wird der Knoten gelöscht
2. Und die Einträge werden auf andere Knoten verteilt

Der erste Schritt kann zur Löschung des Elternknoten führen

- Löschen ist eine aufwendige Operation in R-Bäumen

Non-Standard-Datenbanken

Multidimensionale Indizierung

Multidimensionale
Indizierung für
Hauptspeicher

Volltextindizierung

Nächste-Nachbarn-
Anfragen

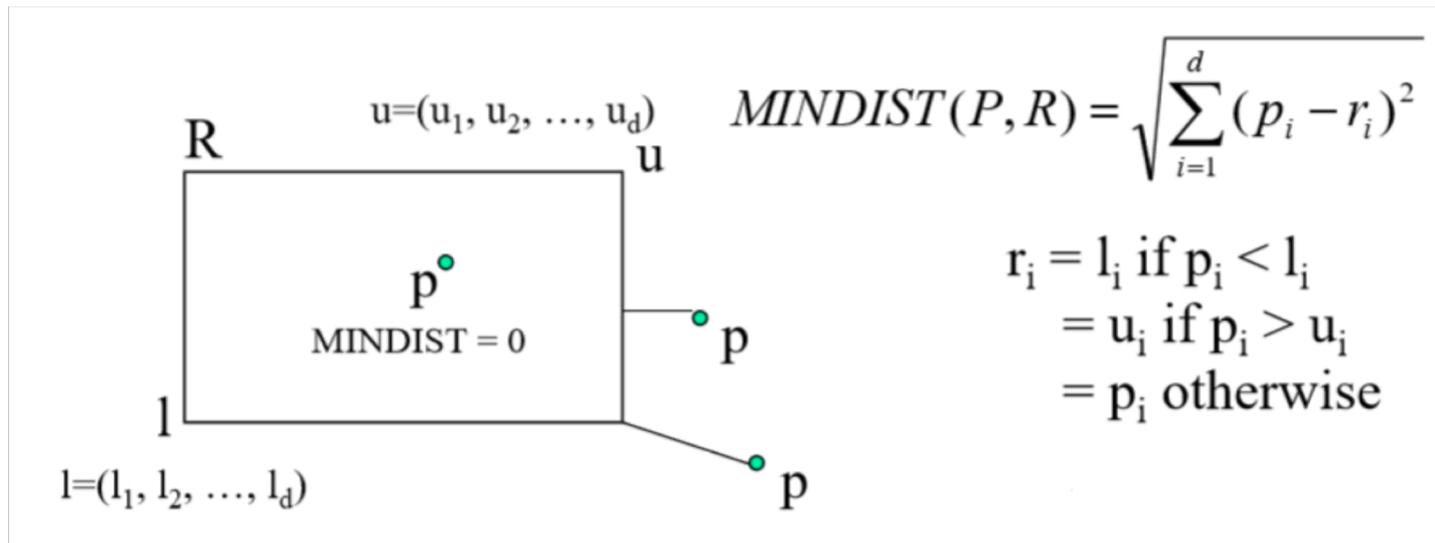
Multidimensionale
Indizierung: k-d-B- und R-
Bäume

K-Nächste-Nachbarn-Anfragen

- Sei M eine (Grund-)Menge,
- $q \notin M$ ein Anfragepunkt,
- $k \in \mathbb{N}$ die gewünschte Anzahl gesuchter nächster Nachbarn von q und d eine Abstandsfunktion
- und $|M| \geq k$,
- dann ist die Menge $NN(k, q, M)$ der k nächsten Nachbarn von q definiert
 - als diejenige Teilmenge $S \subseteq M$, mit $|S| = k$
 - so dass es keine Menge $S' \subseteq M$ mit $S \cap S' = \emptyset$ gibt,
 - so dass ein $p \in S$ und $p' \in S'$ existiert und $d(q, p) > d(q, p')$

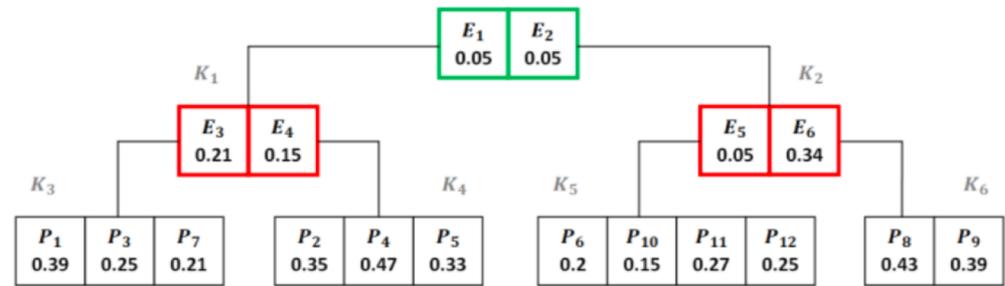
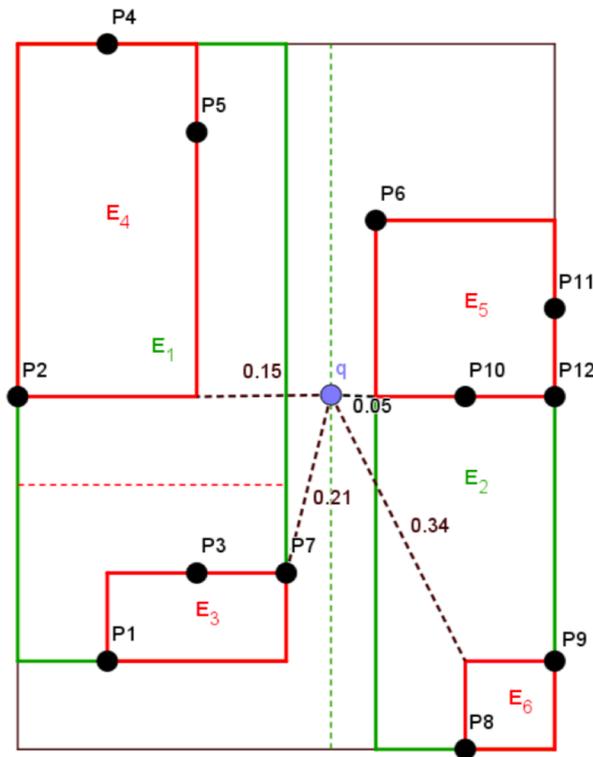
MINDIST

- Nehmen wir an, wir haben einen Punkt p und ein Rechteck R definiert durch zwei Punkte l und u , dann seien die Funktionen $MINDIST(p, R)$ wie folgt definiert:

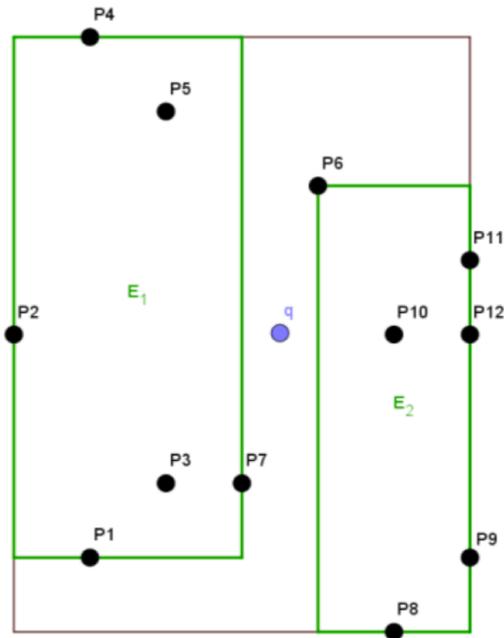


Branch-and-Bound-Ranking-Search mit R-Baum

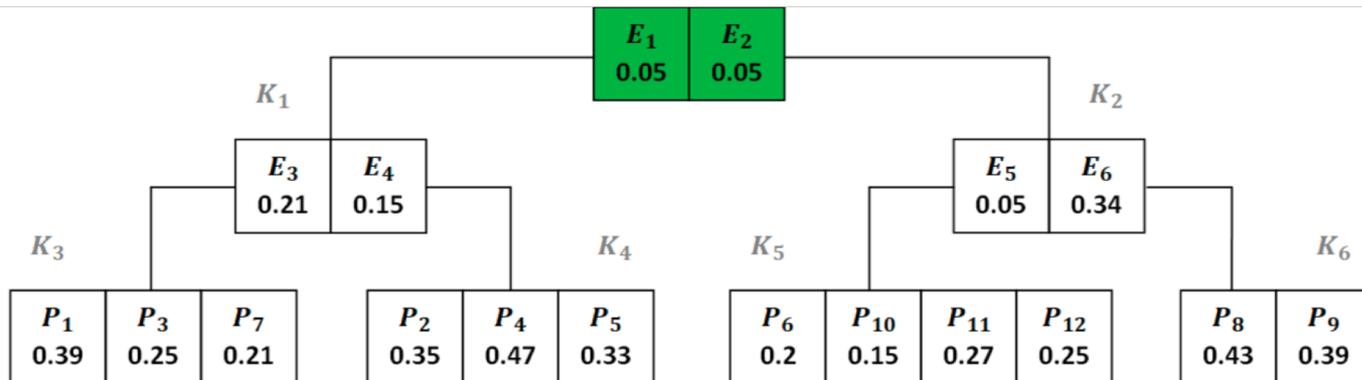
ID	1	2	3	4	5	6	7	8	9	10	11	12
Attribut 1	0,2	0,1	0,3	0,2	0,3	0,5	0,4	0,6	0,7	0,6	0,7	0,7
Attribut 2	0,2	0,5	0,3	0,9	0,8	0,7	0,3	0,1	0,2	0,5	0,6	0,5
Abstand	0,39	0,35	0,25	0,47	0,33	0,2	0,21	0,43	0,39	0,15	0,27	0,25

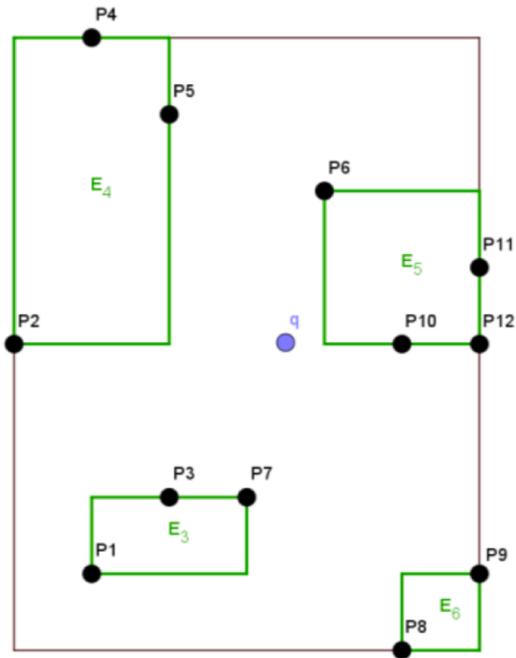


G. Hjaltason and H. Samet, "Distance Browsing in Spatial Databases," ACM TODS, 24(2), pp. 265- 318, Juni 1999

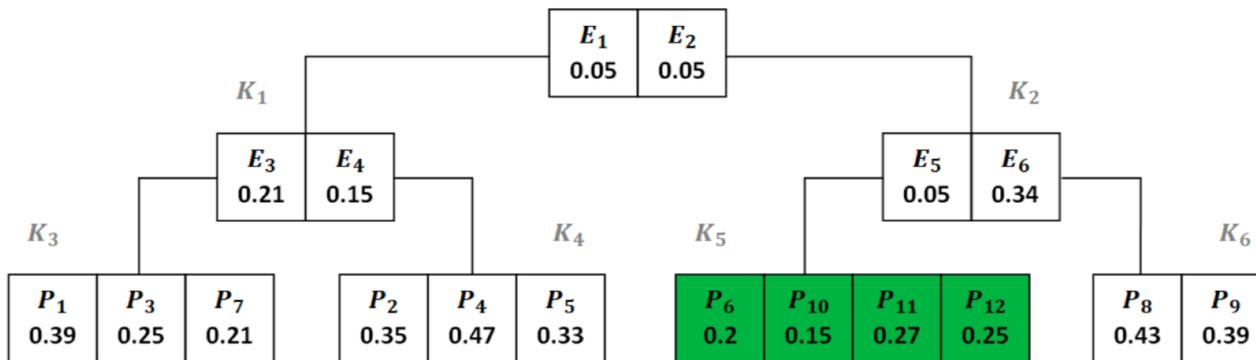


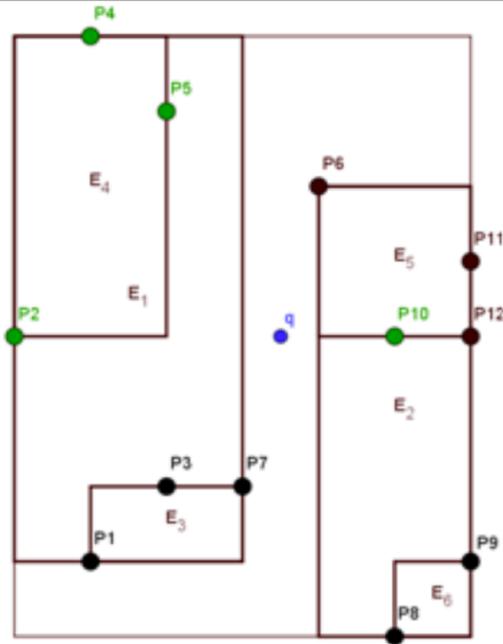
Aktion	Warteschlange	Ergebnis
Lade Wurzel	$(E_1, 0.05), (E_2, 0.05)$	\emptyset



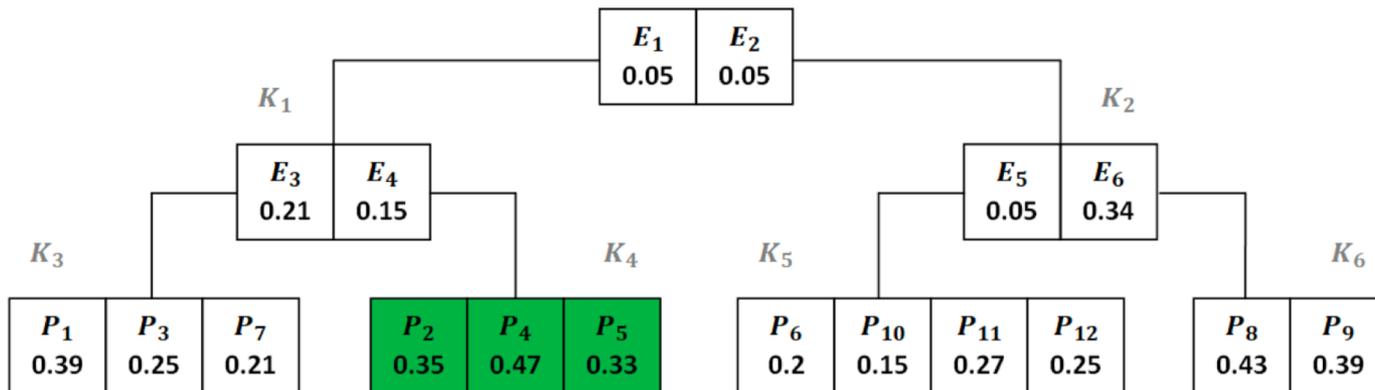


Aktion	Warteschlange	Ergebnis
Lade Wurzel	$(E_1, 0.05), (E_2, 0.05)$	\emptyset
Folge E_1 und E_2	$(E_5, 0.05), (E_4, 0.15), (E_3, 0.21), (E_6, 0.34)$	\emptyset





Aktion	Warteschlange	Ergebnis
Lade Wurzel	$(E_1, 0.05), (E_2, 0.05)$	\emptyset
Folge E_1 und E_2	$(E_5, 0.05), (E_4, 0.15), (E_3, 0.21), (E_6, 0.34)$	\emptyset
Folge E_5	$(E_4, 0.15), (P_{10}, 0.15), (P_6, 0.2), (E_3, 0.21), (P_{12}, 0.25), (P_{11}, 0.27), (E_6, 0.34)$	\emptyset
Folge E_4	$(P_{10}, 0.15), (P_6, 0.2), (E_3, 0.21), (P_{12}, 0.25), (P_{11}, 0.27), (P_5, 0.33), (P_2, 0.35), (E_6, 0.34), (P_4, 0.47)$	$\{P_{10}\}$



Branch-and-Bound-Ranked-Search (BRS)

```
algorithm BRS (rt, k, type, score, f, filter)
  // rt is an R-tree on the dataset, k denotes the number of data points to return
  // type can be either min or max, score computes a score for an rtree entry (MBR) based on f
  // f is a point scoring function, filter is a filter for the data points (where clause)
  let pq = build_priority_queue(type, {})
    result = {}
    n = 0
    object
  for e ∈ root(rt) do
    insert((e, score(mbr(e), f)), pq)
  while n < k and not empty?(pq) do
    object := delete_next(pq)
    if point?(object) then
      result := result ∪ {object}
      n := n + 1
    else
      if leaf?(object) then
        for p ∈ filter(points(mbr(object))) do
          insert((p, f(p)), pq)
      else
        for e ∈ children(object) do
          insert((e, score(mbr(e), f)), pq)
  return result
```

```
BRS(data-rtree, 3, 'min', MINDIST, f, identity)
```

Non-Standard-Datenbanken

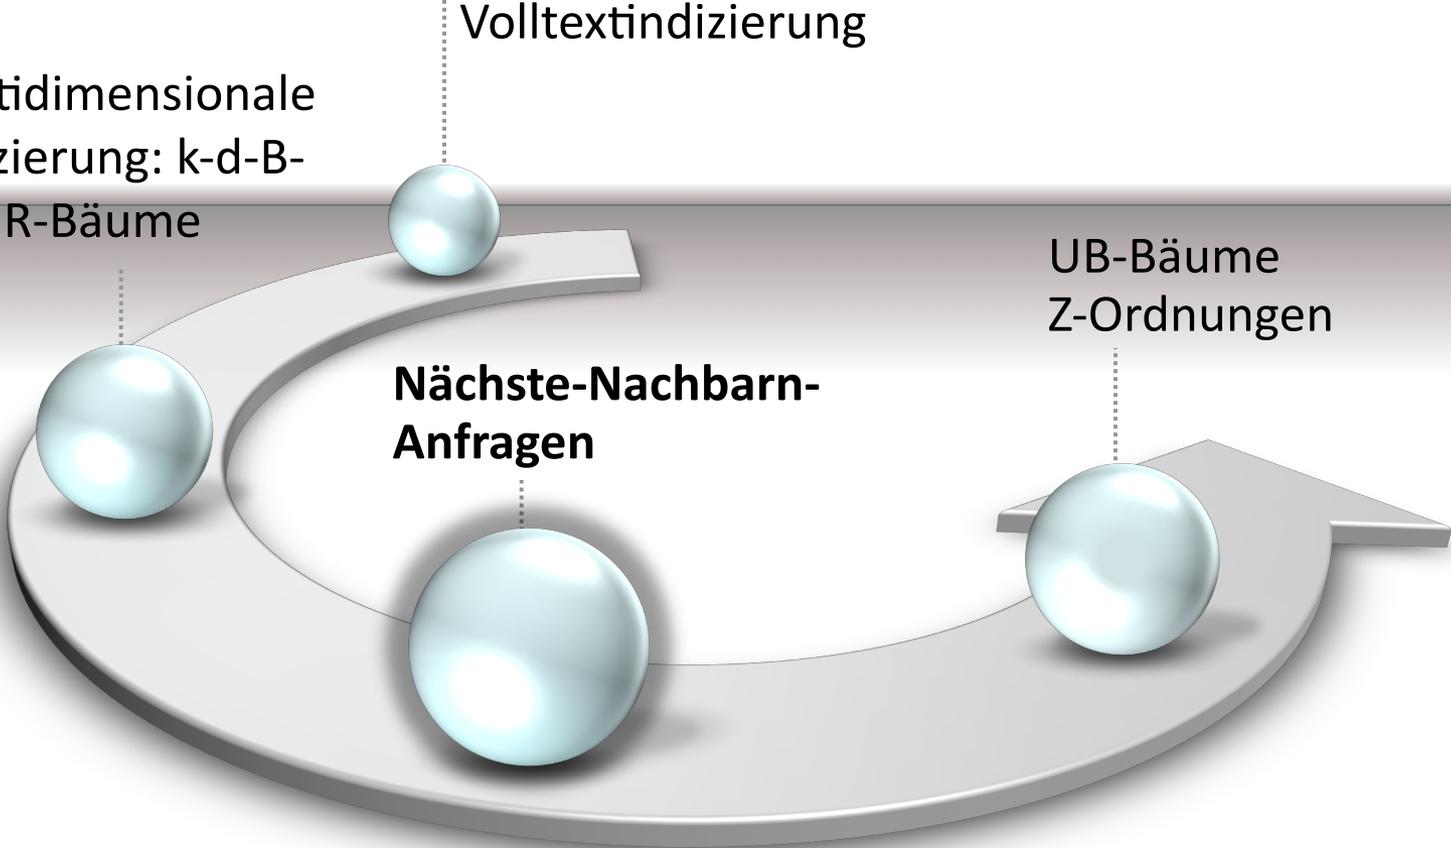
Multidimensionale Indizierung

Multidimensionale Indizierung: k-d-B- und R-Bäume

Volltextindizierung

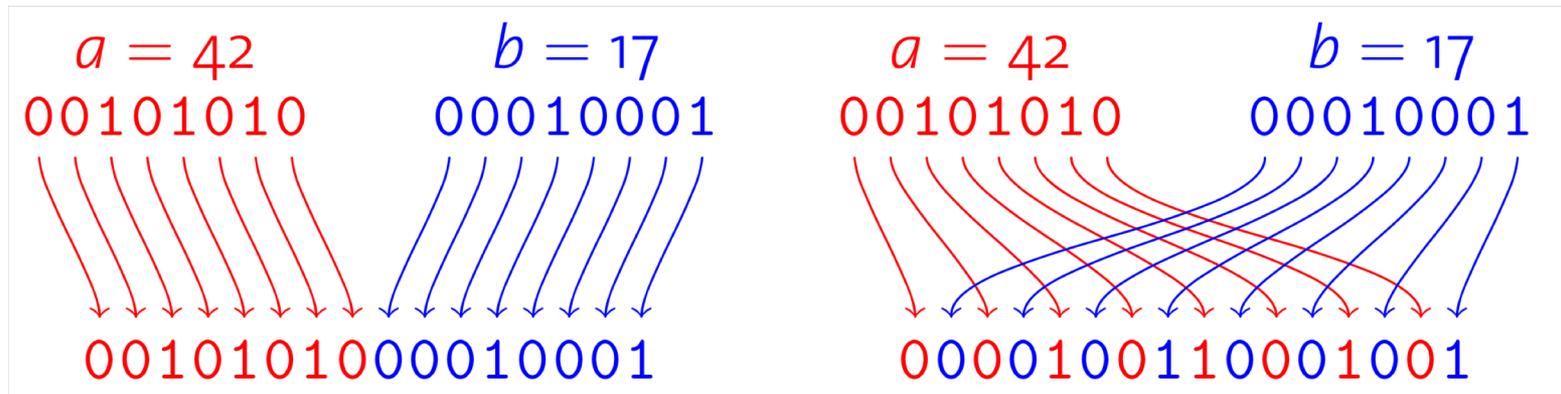
UB-Bäume
Z-Ordnungen

Nächste-Nachbarn-Anfragen



Bit-Verschränkung

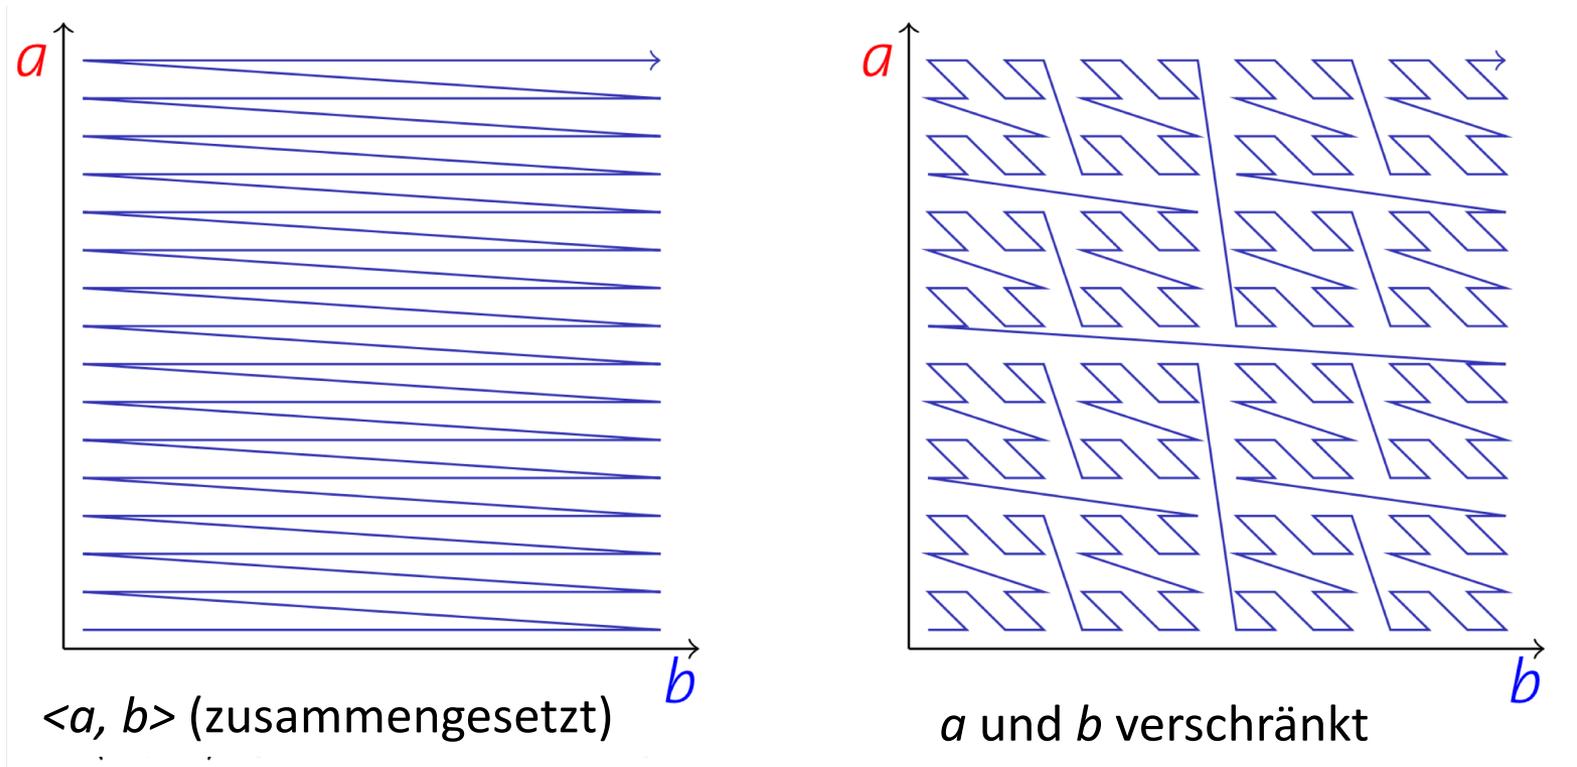
- Zusammengesetzte Schlüssel $\langle a, b \rangle$ wegen Asymmetrie nicht direkt hilfreich für den effizienten Zugriff
- Was passiert, wenn die Bits von a und b verschränkt werden (und damit „symmetrischer“)?



$\langle a, b \rangle$ (zusammengesetzt)

a und b verschränkt

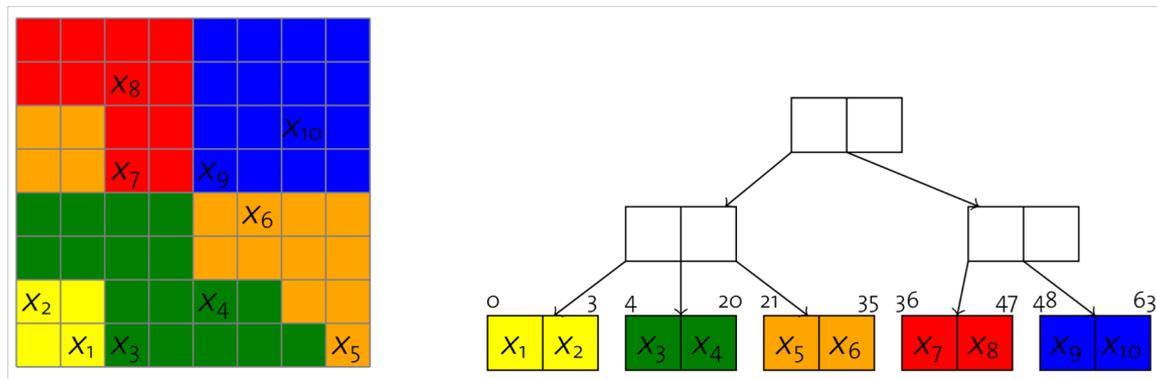
Z-Ordnung



- Beide Ansätze **linearisieren** die Koordinaten im Wertebereich nach einer festgelegten Ordnung
- Bitverschränkung erzeugt die **Z-Ordnung**
- Durch die Z-Ordnung erfolgt **räumliche Gruppierung**

B⁺-Bäume über Z-Ordnungen

- Verwendung eines **B⁺-Baumes** um Z-Kodes des multidimensionalen Raums zu indizieren
- Blatt im B⁺-Baum beschreibt **Intervall** im **Z-Raum**
- Jedes dieser Intervalle beschreibt eine **Region** im multidimensionalen Datenraum



- Um alle Datenpunkte für eine Anfrage Q zu finden, sollen nur solche Blattseiten betrachtet werden, die Regionen enthalten, die sich mit Q **schneiden**

UB-Baum-Bereichsanfragen

Nach jeder verarbeiteten Seite erfolgt Index-Rescan um neue Seite zu finden, die sich mit Anfragerechteck Q schneidet

1 **Function:** $ub_range(Q)$

2 $cur \leftarrow z(Q_{\text{bottom, left}})$;

3 **while** true **do**

 // search B⁺-tree page containing cur

4 $page \leftarrow \text{search}(cur)$;

5 **foreach** data point p on $page$ **do**

6 **if** p is in Q **then**

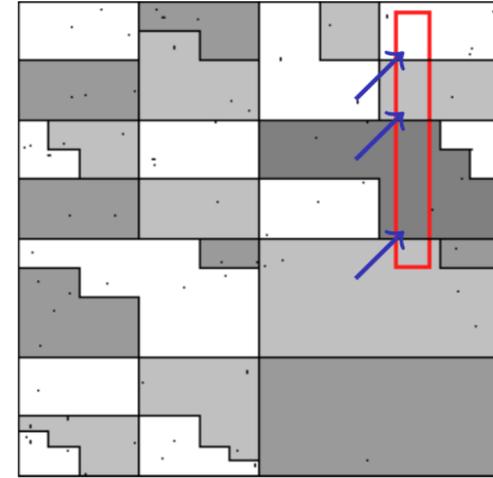
7 **append** p to result ;

8 **if** region in $page$ reaches beyond $Q_{\text{top, right}}$ **then**

9 **break** ;

 // compute next Z-address using Q and data on current page

10 $cur \leftarrow \text{get_next_z_address}(Q, page)$;



Non-Standard-Datenbanken

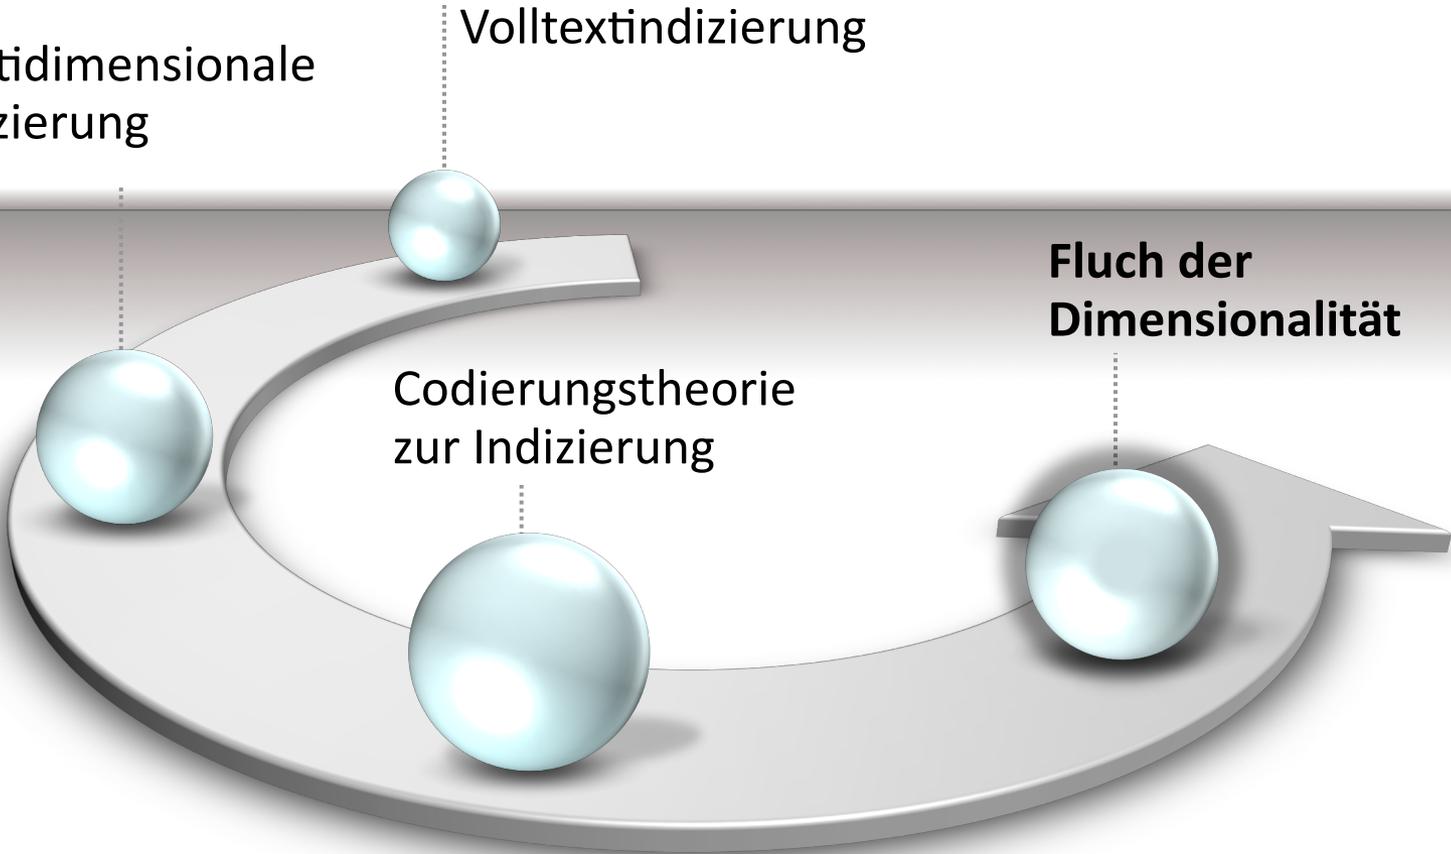
Von der Volltextsuche zur multidimensionalen Indizierung

Multidimensionale
Indizierung

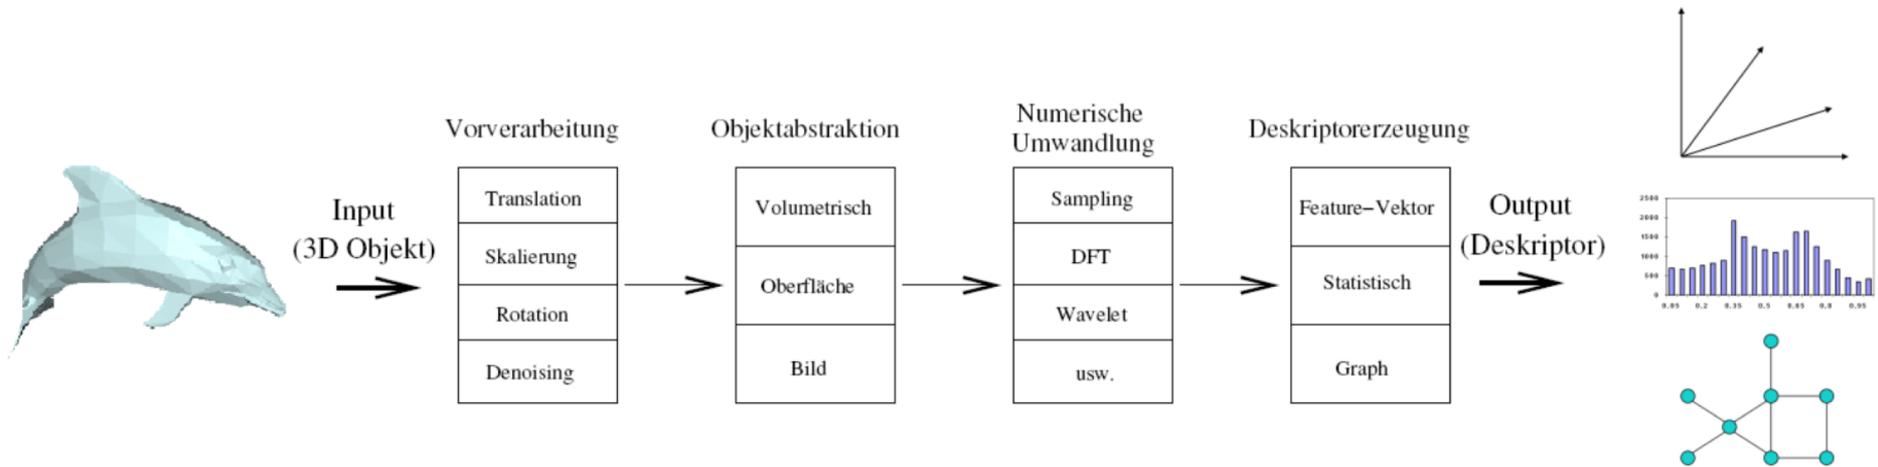
Volltextindizierung

Fluch der
Dimensionalität

Codierungstheorie
zur Indizierung



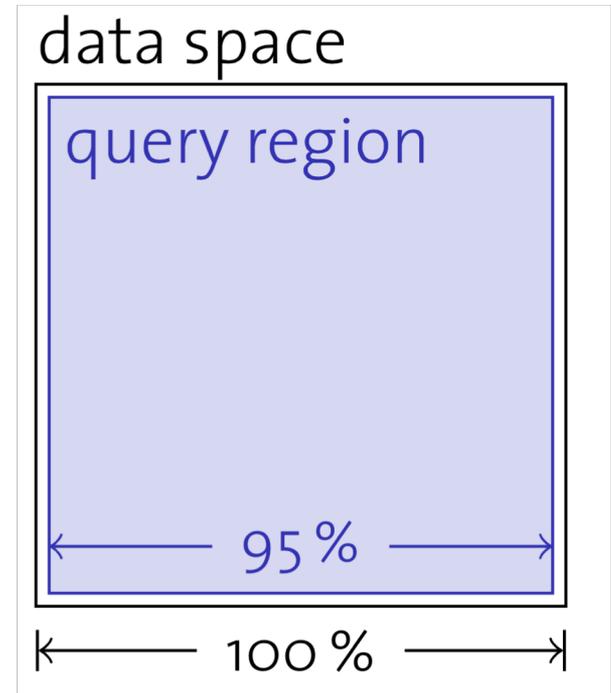
Anwendungen: Multimedia-Datenbanken



- Inhaltsbasierte Suche
- Viele Merkmalsvektoren
- Hochdimensionale Räume

Fluch der Dimensionalität

- **Für große Werte von k** sind die diskutierten Techniken **wenig effektiv**
 - Für $k=100$ ergeben sich $2^{100} \approx 10^{30}$ Partitionen pro Knoten in einem Punkt-Quad-Baum
 - Selbst bei Milliarden von Datenpunkten sind fast alle Partitionen leer
 - Betrachten wir eine sehr große Region („Würfel“) mit einer Abdeckung von 95% der Region in jeder Dimension



Für $k = 100$ ergibt sich eine Wahrscheinlichkeit von $0.95^{100} \approx 0,59\%$, dass ein Punkt in dieser Region liegt

Multidimensionale Indizierung: Überblick

