– Mutual Pruning

Idee:

- Ausschluss von Seiten/Objekten mittels Distanzabschätzungen (ohne Vorberechnung, zur Laufzeit der Anfrage ermittelt)
- Für mindestens *k* Objekte ist die Distanz zu Objekt o mindestens so groß wie die Distanz zwischen Anfrageobjekt q und o

  => Objekt o $\notin$ RkNN(q)
- Distanzabschätzungen über Indexseitenregionen

Vorteile:

- Keine Vorberechnung notwendig

  → keine Update-Problematik mehr
- Parameter *k* zur Anfragezeit frei wählbar

– Mutual-Pruning Strategien

- Min/Max-Dist-Ansatz: Verwendung von Min/Max/MinMax-Dist

  [Achtert, Kröger, Kriegel, Renz, Züfle, EDBT, 2009]

  – Vorraussetzung: Indexseite speichert Anzahl der Objekte |e| in Seite e

Ausschluß von Seite e durch Seite e‘ (k≥1):

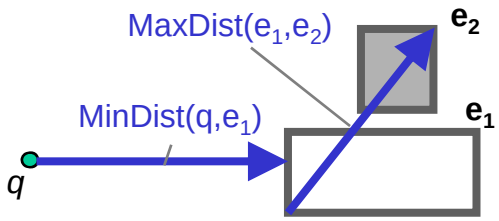

MaxDist(e_1,e_2) < MinDist(q,e_1)
⇒ e_1 kann keine RkNN(q)-Ergebnisse enthalten wenn $|e_2| \geq k$

Seite e schließt sich selbst aus (k≥1):

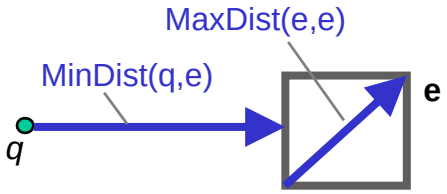

MaxDist(e,e) < MinDist(q,e)
⇒ e kann keine RkNN(q)-Ergebnisse enthalten wenn |e|-1 ≥ k

MinDist(e_1,e_2): Distanz zwischen den beiden voneinander am nächsten liegenden Punkten $p_1 \in e_1$ und $p_2 \in e_2$

MaxDist(e_1,e_2): Distanz zwischen den beiden voneinander entferntesten Punkten $p_1 \in e_1$ und $p_2 \in e_2$

  – Vorteile:
    - » Keine Vorberechnung mehr (keine Update-Problematik)
    - » Parameter k zur Anfragezeit frei wählbar
    - » Pruningkonzept auf allg. metrische Daten anwendbar

– Problem:
  » Abhängigkeiten zwischen Distanzen unberücksichtigt

Min/Max-Dist Pruning:

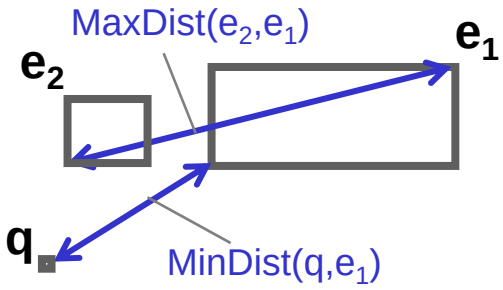

$MinDist(q,e_1) < MaxDist(e_2,e_1)$

„Optimales“ Pruning:

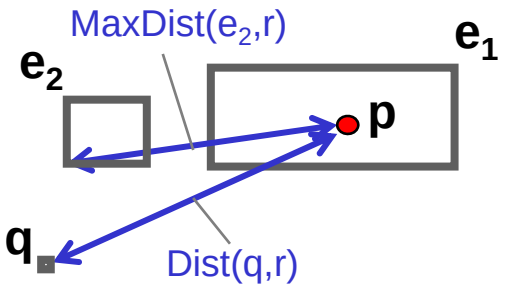

$\forall p \in e_1: Dist(q,r) > MaxDist(e_2,r)$

  » Die Distanz $MinDist(q,e_1)$ schätzt die Distanz dist(q,p) zwischen q und einem Objekt p in Seitenregion e_1 (untere Distanzabschätzung)
  » Die Distanz $MaxDist(e_2,e_1)$ schätzt die Distanz dist(o,p) zwischen einem Objekt o in Seitenregion e_2 und einem Objekt p in Seitenregion e_1 (obere Distanzabschätzung)
  » Beide Distanzen dist(q,p) und dist(o,p) hängen von der Lage des Objektes p in Region e_1 ab => dist(q,p) abhängig von dist(o,p)
  » Diese (Abhängigkeits-) Information geht bei der Verwendung von $MaxDist(e_2,e_1)$ und $MinDist(q,e_1)$ verloren

  → geringeres Pruningpotential

- Geometrische RNN-Suche (Filter/Verfeinerung)

  [Tao, Papadias, Lian. Int. Conf. Very Large Databases (VLDB), 2004]

  – Idee

    » Gegeben: Voronoi-Ebene zwischen q und beliebigen Punkt p

    » Liegt ein Punkt x auf der Seite von p dieser Voronoi-Ebene, kann q nicht NN von x sein und damit $x \notin RNN(q)$

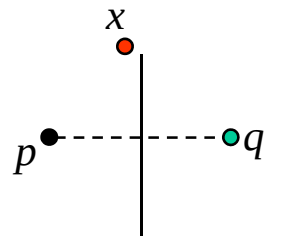

Voronoi-Ebene $E(p,q)$ zwischen p und q

    » Voronoi-Ebene $E(p,q)$: für alle Punkte $e \in E$ gilt: $dist(q,e) = dist(p,e)$

  – „Geometrisches“ Pruning ist optimal:

geometrisches Pruning:

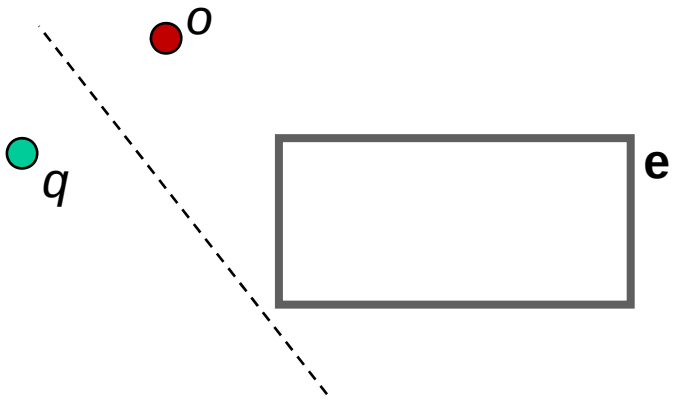

e hinter der Hyperebene
=> prune e

Min/Max-dist Pruning:

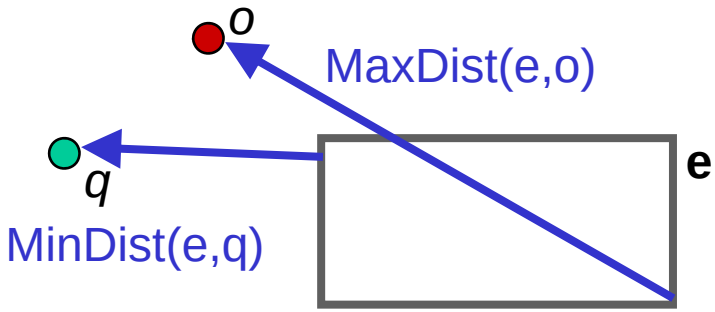

MaxDist(e,o) > MinDist(e,q)
=> prune e nicht!

- Algorithmus: Filter-Schritt (Skizze)
  - Berechne ein NN-Ranking der DB
  - Solange noch Objekte im Ranking sind:
    - » Rufe getNext() auf
    - » Wenn aktueller Punkt *p* nicht „hinter“ einer Voronoi-Ebene liegt, konstruiere neue Voronoi-Ebene *E*(*p*,*q*); *p* wird zur Kandidatenmenge hinzugefügt
    - » Punkte/Directoryseiten, die „hinter“ einer der Voronoi-Ebenen liegen (außer der eigenen), können aus dem Ranking/Kandidatenmenge gelöscht werden
  - Punkte, die die Ebenen bestimmen, müssen verfeinert werden, d.h. für diese Punkte muss jeweils eine NN-Anfrage berechnet werden
- Beispiel

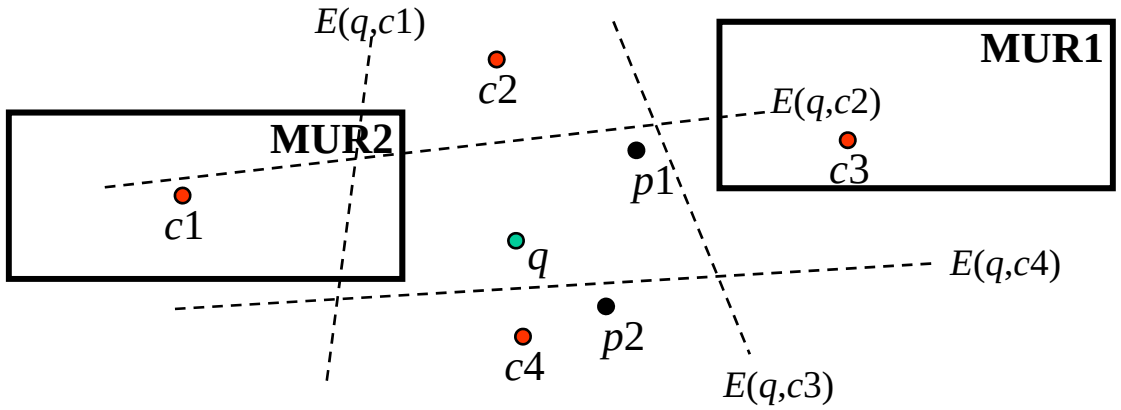

Bisherige Kandidaten:

{*c*1, *c*2, *c*3, *c*4}

Inhalt des Rankings (ungeordnet):

MUR1: nicht verfeinern
MUR2: verfeinern
*p*1: verfeinern
*p*2: nicht verfeinern

– Verfeinerung von *p*1
  » Streiche *c*2 und *c*3 aus Kandidatenliste (liegt nun hinter *E*(*q*,*p*1))
  » MUR2 muss weiterhin verfeinert werden

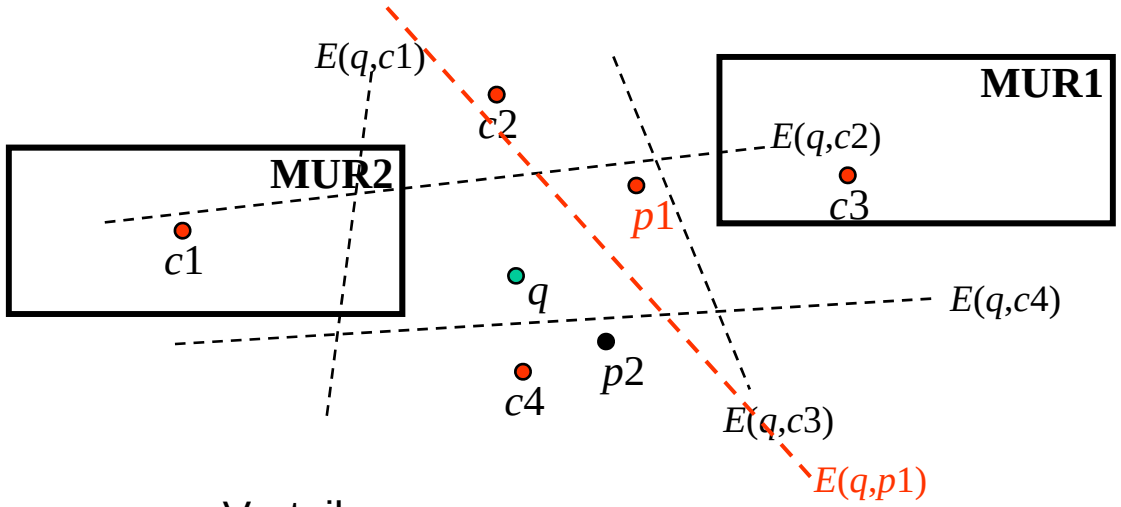

Bisherige Kandidaten:

{*c*1, *c*4, *p*1}

Inhalt des Rankings (ungeordnet):

MUR2: verfeinern

– Vorteil
  » *k* kann beliebig sein (Ausschlusskriterium: Objekt/Seite muss hinter *k* Ebenen liegen
  » Keine vorberechneten Distanzen, daher keine Update-Problematik und bessere Speicherkomplexität
– Nachteil
  » Nur für Vektordaten
  » Teurer Verfeinerungsschritt (eine NN-Anfrage pro Kandidat)
  » Teilweise komplexe Ebenenverwaltung

- Weitere Eigenschaft der Geometrischen RNN-Suche
  - Ausschluß (Pruning) von Punkten/Seiten nur aufgrund anderer Punkte
  - Ausschlußkriterium könnte auch vollständig auf Directory-Ebene angewandt werden, aber wie?
- Erweiterung des geometrischen Pruning-Konzepts auf Basis von Voronoi-Hyperebenen auf Seitenregionen

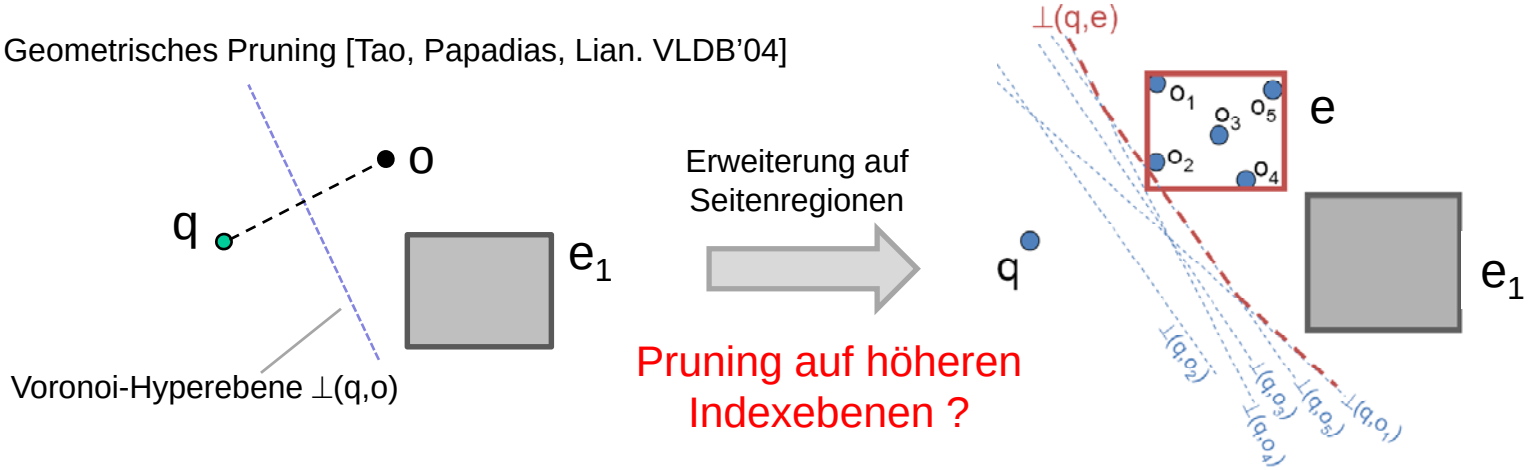

- Frage: Effiziente Repräsentation von Voronoi-Hyperebenen zwischen einem Punkt und einer Seitenregion ?
- Idee: Konservative Approximation der Hyperebenen

  Eigenschaft: $\forall p \in \perp(q,e)$: dist(q,p) = MaxDist(e,p)

- Erweiterung des Pruning der Geometrischen RNN-Suche auf höheren Indexebenen (gilt nur für Vektordaten!!!)

  [Kriegel, Kröger, Renz, Züfle: SSDBM, 2009]

  – Definition von Hyper-Ebenen zwischen Anfragepunkt und Seitenregion e
  – Bilde konservative Approximation $\mathcal{H}$ aller Hyperebenen bzgl. aller Punkte innerhalb der Seitenregion e
  – Anzahl der konservativ approximierten Hyperebenen kann zum Ausschluß von Seitenregionen (Self/Mutual Pruning) verwendet werden (insbesondere auch für RkNN-Suche mit k>1)

Seite e schließt Seite e‘ aus (k=1):

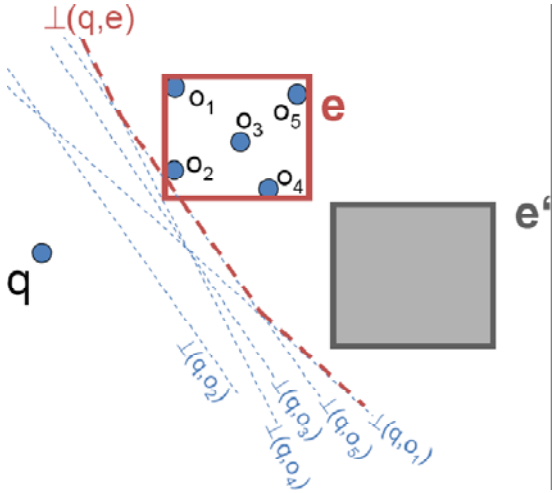

Seite e schließt sich selbst aus (k=1):

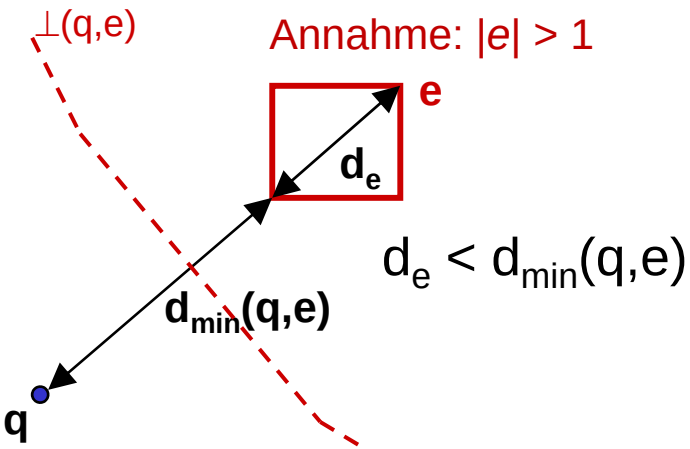

$\forall o \in e'$: $o \notin RNN(q)$, da $\exists o_i \in e$: e’ hinter Hyperebene $\perp(q,o_i)$

- Berechnung der konservativen Approximation aller Hyperebenen zwischen Anfragepunkt q und Seitenregion e
  - Aufsplittung des Datenraums in 2^d Partitionen orientiert am Mittelpunkt der Seitenregion E (z.B. 4 Partitionen NW, NE, SE und SW in 2D Raum)
  - Für jede Partition P: Wähle Referenzpunkt $R \in e$, sodaß gilt:

    $$\forall p \in P, \forall e \in E: d(p,e) \leq d(p,R)$$

    Bemerkung: Referenzpunkt eindeutig durch die gewählte Partitionierung
  - Für jede Partition P bilde Hyperebene zwischen q und Referenzpunkt zu P

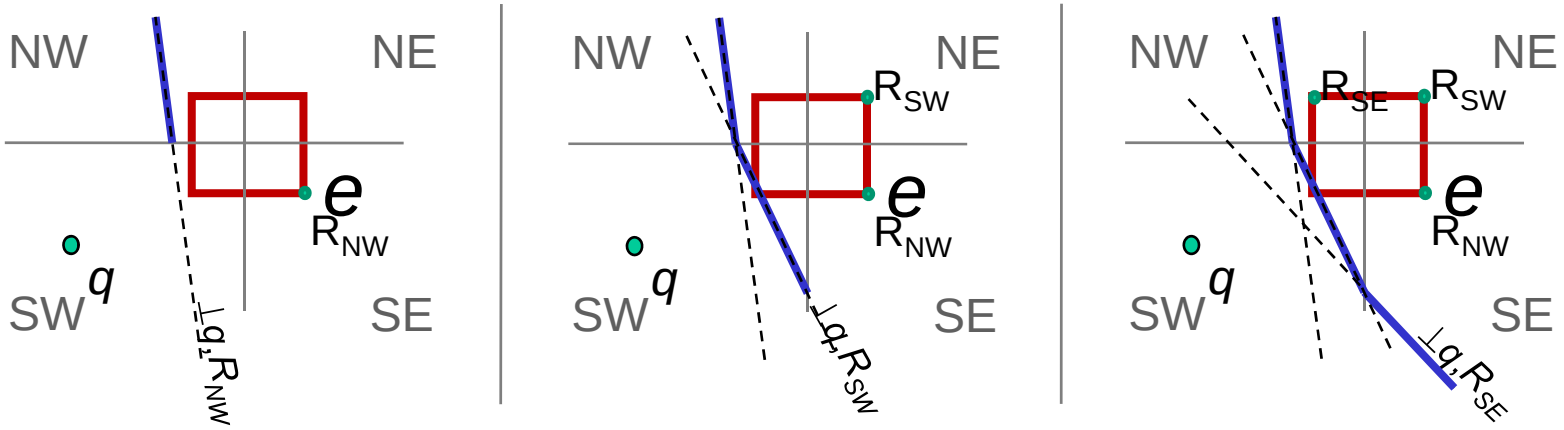

  - Die konservative Hyperebenen-Approximation wird aus 2^d-1 Hyperebenen gebildet

- Erweiterung der Geometrischen R*k*NN-Suche für k > 1
  - Verwende aR-Baum anstatt R-Baum, d.h. R-Baum mit zusätzlicher Angabe der Anzahl der Punkt-Objekte |e| die innerhalb einer Seitenregion e organisiert werden.
  - Menge der Punkt-Objekte auf die sich eine konservative Approximation $\mathcal{H}$ bezieht ist zur Anfragezeit bekannt.

    => Anzahl N der Objekte, die näher an einem Objekt o bzw. einer Seitenregion e‘ sind als der Anfragepunkt q lässt sich einfach ermitteln
  - Prune Seitenregion e‘ (bzw. e‘ bei self pruning) falls N > k (bzw. N-1 > k)

Seite e schließt Seite e‘ aus (k>1):

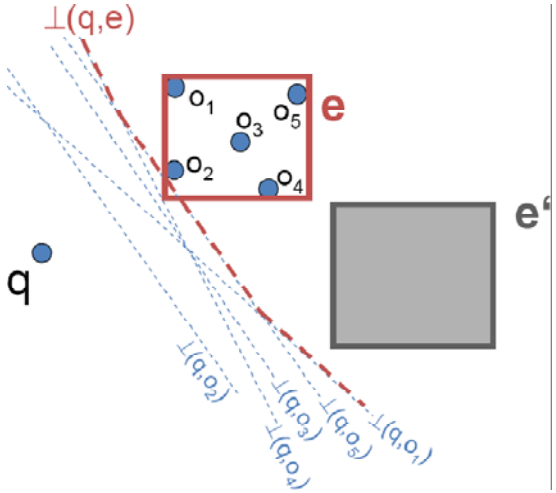

∀o∈e’: $o \notin$ R*k*NN(q), where $k \leq |e|$

Seite e schließt sich selbst aus (k>1):

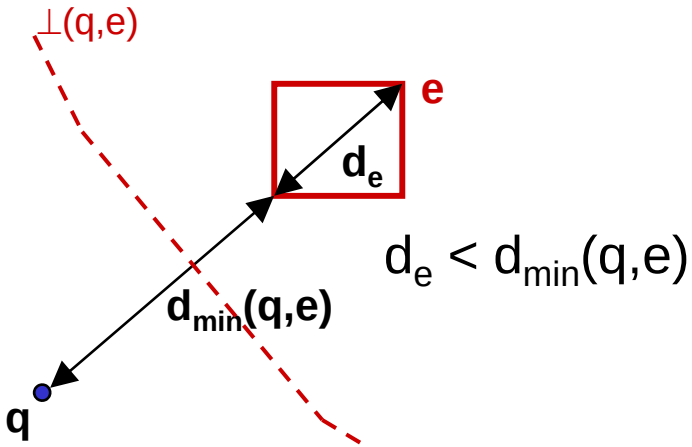

∀o∈e: o $\notin$ R*k*NN(q), where $k \leq |e\text{-}1|$

- Beispiel:

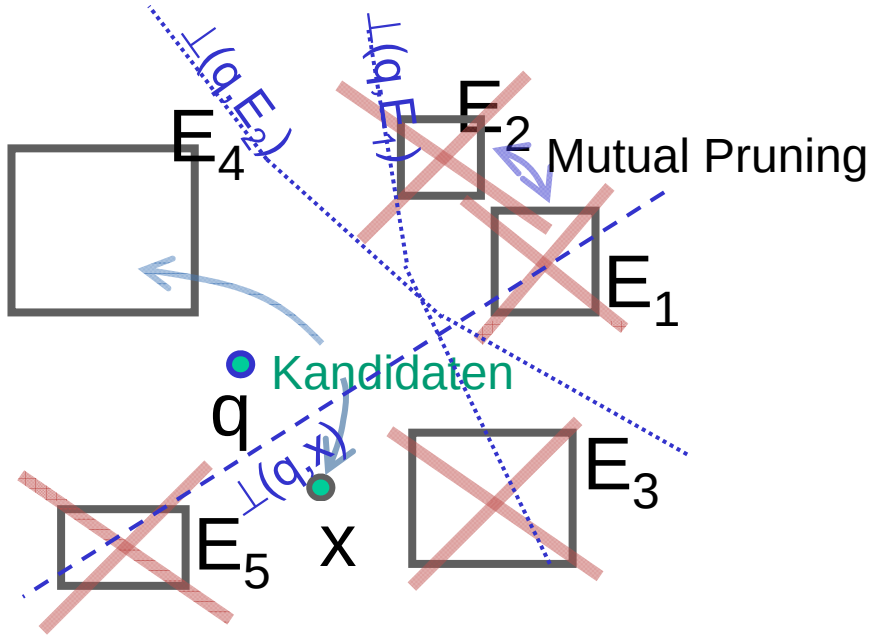

- Bemerkung zum „Optimalen“ Pruning:
  - Die Suche mittels Mutual-Pruning ohne Vorberechnung ist weniger selektiv als mit vorberechneten NN-Distanzen

    ==> schlechteres Pruning-Verhalten als bei (reinen) Self-Pruning-Methoden

- Eigenschaften der Geometrischen R*k*NN-Suche
  - Vorteile:
    - » Vollständige Flexibilität bzgl. *k*
    - » Keine Zusätzliche Kosten für Änderungen im Index (Update-Kosten)
    - » Pruning-Filter selektiver als bei Min/Max-Dist-Ansatz
  - Nachteile:
    - » 2^d Hyperebenen pro Seitenregion müssen materialisiert werden => Overhead der Ebenenverwaltung (schlechte Performanz in höher-dimensionalen Räumen)
    - » Test ob Seitenregion geprunt werden kann ist teuer (2^d Ebenen-Pruning-Tests)
- Fazit:
  - Min/Max-Dist-Ansatz hat geringeres Pruningpotential als Geometrisches Pruning
  - Geometrisches Pruning eignet sich nur für niedrig-dimensionale Räume
- Gewünscht:
  - Verfahren mit „optimalen“ Pruningpotential, das auch für hoch-dimensionale Räume effizient funktioniert

  → Welche Beziehung gilt zwischen dem Min/Max-Dist-Basierten Ansatz und dem Geometrischen Pruning Ansatz?

– Generelle Problemstellung:

Gegeben:

Drei Punktobjekt-Approximationen A, B und R gegeben als achsenparellele Rechtecke

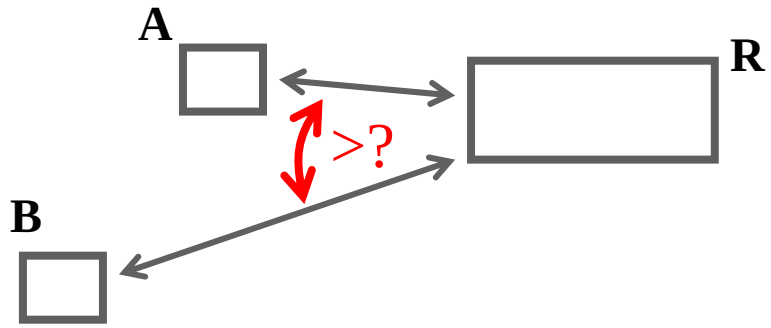

Frage:

Wie kann man effizient bestimmen ob die Objekte in R näher an den Objekten in A oder näher an den Objekten in B liegen

→ Nachbarschafts-Entscheidungskriterium [SIGMOD 10]

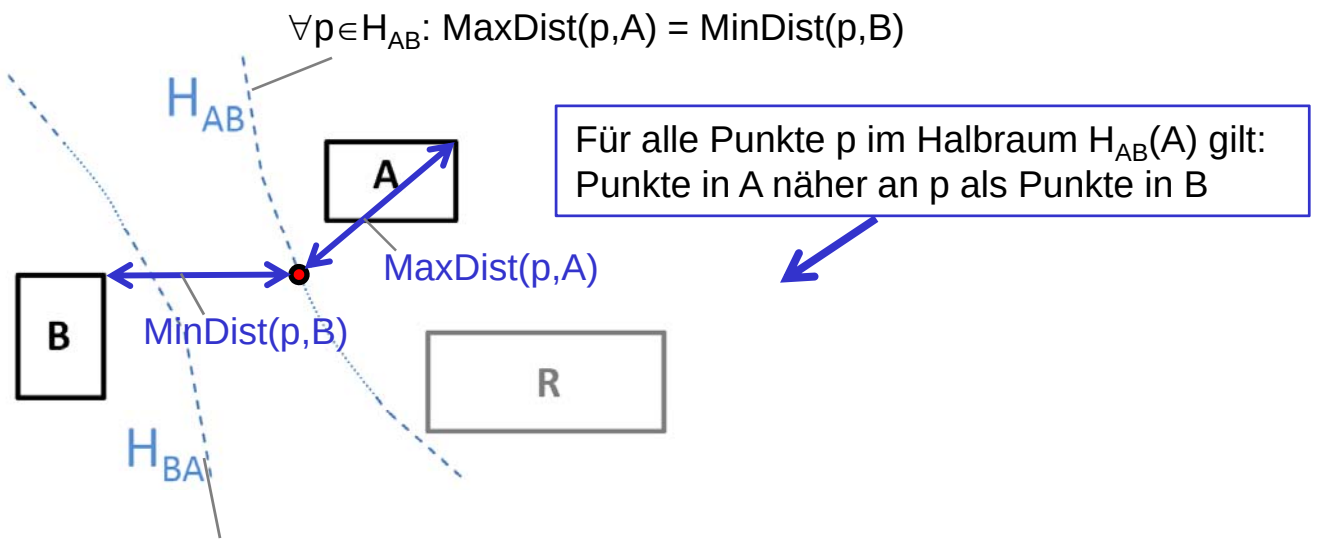

- Beobachtung:
  - Halbraum $H_{AB}(A)$ in der A liegt ist konvex

  → alle Eckpunkte von R liegen in $H_{AB}(A)$ => R liegt vollständig in $H_{AB}(A)$

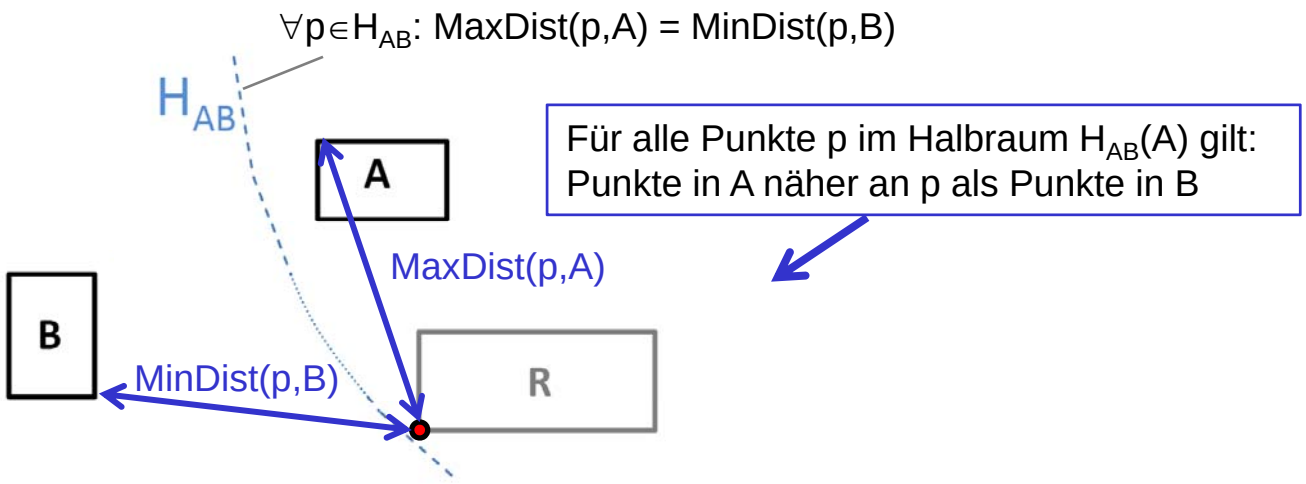

- Beobachtung:
  - Halbraum $H_{AB}(A)$ in der A liegt ist konvex
  - → alle Eckpunkte von R liegen in $H_{AB}(A)$ => R liegt vollständig in $H_{AB}(A)$
- Idee:
  - Finde Eckpunkt p von R bei dem MaxDist(p,A)-MinDist(p,B) den größten Wert hat
  - Falls dieser Wert kleiner 0 (d.h. p in $H_{AB}(A)$)
  - → Alle Ecken von R in $H_{AB}(A)$ => Region R vollständig in $H_{AB}(A)$

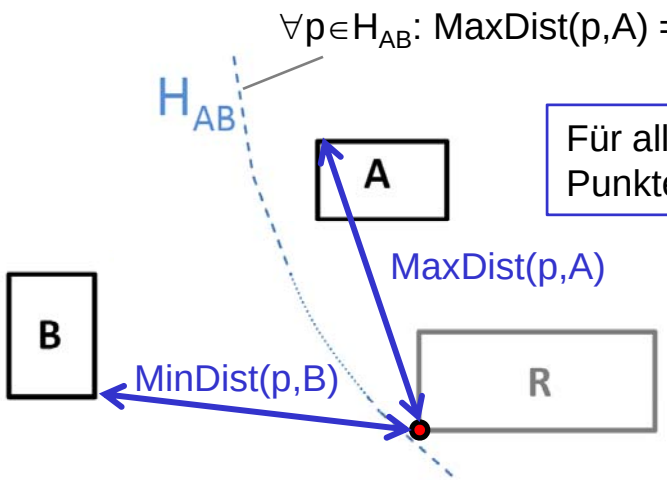

Für alle Punkte p im Halbraum $H_{AB}(A)$ gilt:
Punkte in A näher an p als Punkte in B

Nachbarschafts-Entscheidungskriterium:
Objekte in R näher an A falls

$$\sum_{i=1}^{d} \max_{r_i \in \{R_i^{min}, R_i^{max}\}} (MaxDist(A_i, r_i)^2 - MinDist(B_i, r_i)^2) < 0$$

- Beobachtung:
  - Halbraum $H_{AB}(A)$ in der A liegt ist konvex
  - → alle Eckpunkte von R liegen in $H_{AB}(A)$ => R liegt vollständig in $H_{AB}(A)$
- Idee:
  - Finde Eckpunkt p von R bei dem MaxDist(p,A)-MinDist(p,B) den größten Wert hat
  - Falls dieser Wert kleiner 0 (d.h. p in $H_{AB}(A)$)
  - → Alle Ecken von R in $H_{AB}(A)$ => Region R vollständig in $H_{AB}(A)$

- Herleitung
  - Idee: Umformung der Distanzrelation:

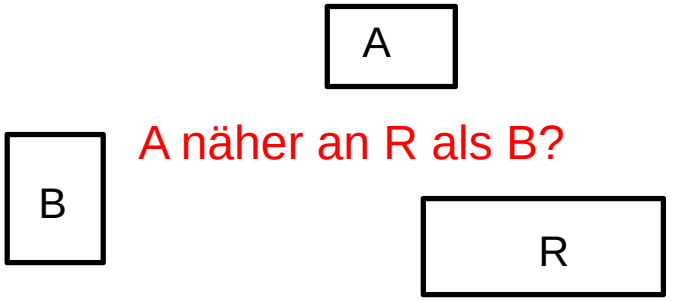

$$\forall a \in A, b \in B, r \in R : dist(a,r) < dist(b,r)$$

$$\Leftrightarrow \forall r \in R : MaxDist(A,r) < MinDist(B,r)$$ ← konservative Distanzabschätzung zu A und B

$$\Leftrightarrow \forall r \in R : \sqrt[p]{\sum_{i=1}^{d} MaxDist(A_i, r_i)^p} < \sqrt[p]{\sum_{i=1}^{d} MinDist(B_i, r_i)^p}$$

$$\Leftrightarrow \forall r \in R : \sum_{i=1}^{d} MaxDist(A_i, r_i)^p - \sum_{i=1}^{d} MinDist(B_i, r_i)^p < 0$$

$$\Leftrightarrow \max_{r \in R} \left(\sum_{i=1}^{d} (MaxDist(A_i, r_i)^p - MinDist(B_i, r_i)^p) \right) < 0$$

$$\Leftrightarrow \sum_{i=1}^{d} \max_{r_i \in R_i} (MaxDist(A_i, r_i)^p - MinDist(B_i, r_i)^p) < 0$$

$$\Leftrightarrow \sum_{i=1}^{d} \max_{r_i \in \{R_i^{min}, R_i^{max}\}} (MaxDist(A_i, r_i)^p - MinDist(B_i, r_i)^p) < 0$$

Reduzierung des Problems auf die einzelnen Dimensionen

Reduzierung des Problems auf Extremwerte in R_i (pro Dimension nur 2 Werte)

  - Vorteil: Berechnungskomplexität O(d) (d = Dimensionalität)

=> geeignet auch für höherdimensionale Räume

- Experimenteller Vergleich: Min/Max-Dist vs. Optimales Pruning:

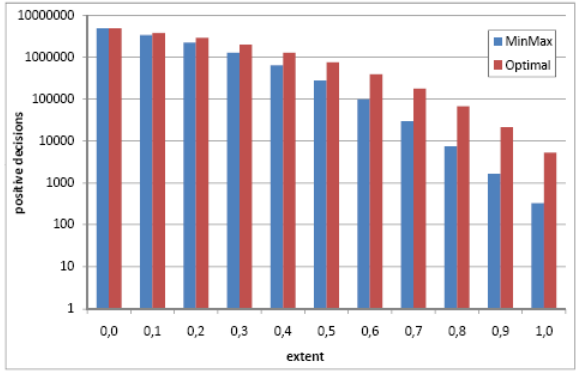

a) Anzahl der erkannten Ereignisse: Objekte in R näher an A als an B
Datensatz (synthetisch): 10 Mil. Triple (A,B,R) von Rechtecken (gleichverteilt im Raum $[0,1]^2$)

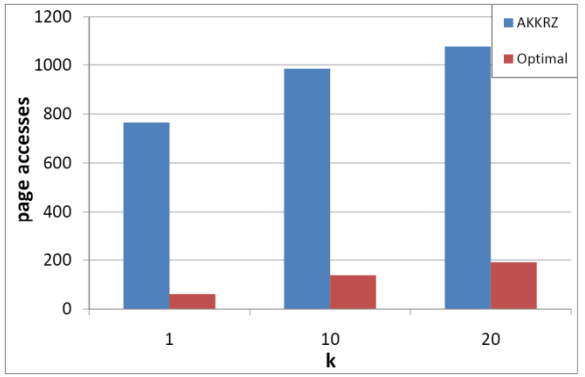

b) Anzahl der Seitenzugriffe für RkNN-Anfragen mit Index
Datensatz (synthetisch): 100K Punktobjekte (5D, gleichverteilt)

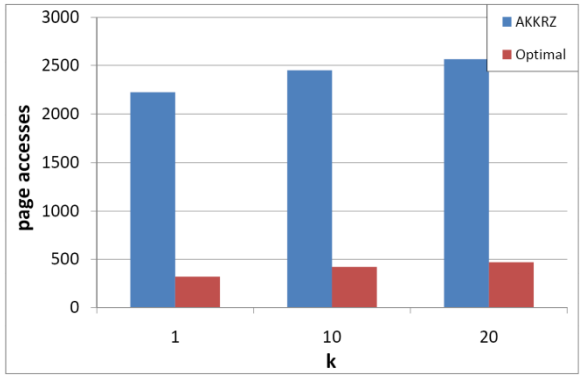

c) Anzahl der Seitenzugriffe für RkNN-Anfragen mit Index (I/O-Kosten)
Datensatz (real): 581K Punktobjekte (10D)

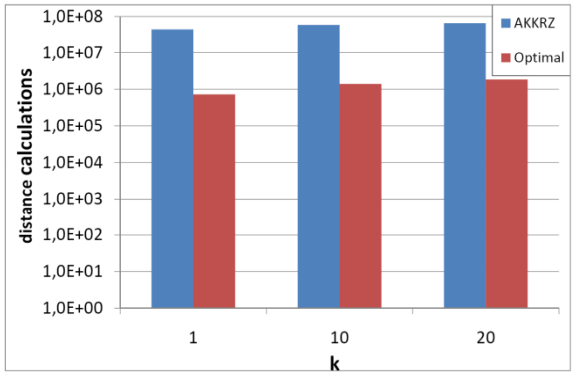

d) Anzahl der Distanzberechnungen für RkNN-Anfragen mit Index (CPU-Kosten), Datensatz (real): 581K Punktobjekte (10D)

– Weiterer Anwendungsbereiche des Nachbarschaftskriteriums:

Im Prinzip lässt sich das Nachbarschaftskriterium überall dort einsetzen wo Objekte durch achsenparallele Rechtecke approximiert sind und Nachbarschaftsbeziehungen relevant sind

Beispiele:

Spatial Index:

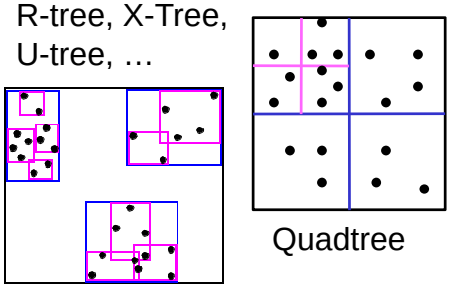

Anfragen:
- kNN, RkNN
- continuous kNN (RkNN)
- probabilistic kNN (RkNN)
- inverse ranking
- group Nearest Neighbor
- clustering
- usw.

Spatio-Temporal Data:

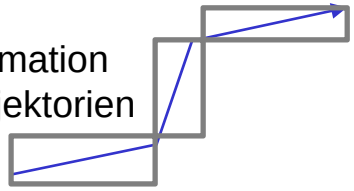

Unsichere Daten:

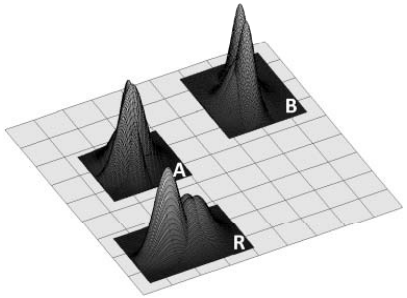

– Zusammenfassung

	Verfahren	Vorteile	Nachteile
self-pruning	**RNN-Tree**	Sehr gute Performanz, da keine Verfeinerung nötig	*k* fix; nur für Vektordaten; Updateproblematik; wenig selektiv bei normalen NN-Queries
self-pruning	**RdNN-Tree**	Sehr gute Performanz, da keine Verfeinerung nötig; auf allgemein metrische Daten erweiterbar	*k* fix; Updateproblematik
self-pruning	**MRkNNCoP-Tree**	variables *k (mit Einschränkung)*; für allgemein metrische Daten	Verfeinerung nötig, Updateproblematik
mutual-pruning	**Min/Max-Dist-basierte RkNN Suche**	variables *k*; geringe Kosten, für metrische Daten, erlaubt Pruning auf Directory-Ebene	schlechtere Filterselektivität
mutual-pruning	**Geometrische (Voronoi-basierte) RkNN Suche**	variables *k*;	Nur für Vektordaten; Verfeinerung nötig
mutual-pruning	**Erweiterte geometrische RkNN Suche**	variables *k*; erlaubt Pruning auf Directory-Ebene; optimale Filterselektivität	Nur für Vektordaten; teure Verwaltung der Hyperebenen
mutual-pruning	**optimal-pruning-basierte RkNN Suche**	variables *k,* geringe Kosten erlaubt Pruning auf Directory-Ebene; optimale Filterselektivität;	Nur für Vektordaten;

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

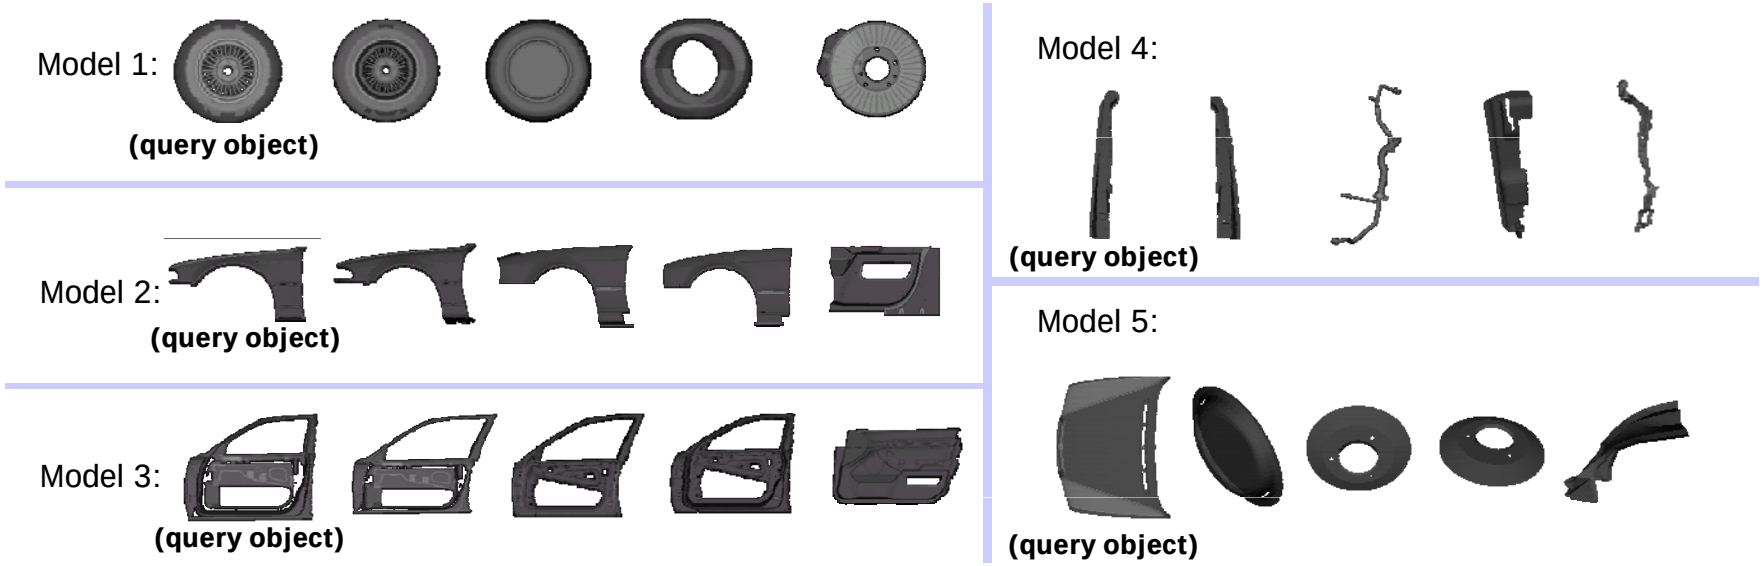

- BOSS (Browsing OPTICS-plots for Similarity Search)

  [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