– RNN-Baum [Korn, Muthukrishnan. ACM Int. Conf. Management of Data (SIGMOD), 2000]
  - RNN-Queries für Vektordaten
  - Berechne NN-Distanz für alle DB-Punkte
  - Speichere statt Punkte alle NN-Sphären der Punkte in R-Baum

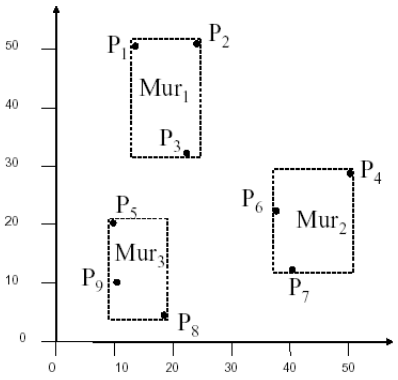

Normaler R-Baum

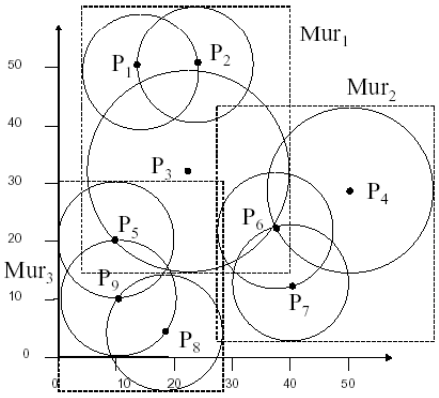

RNN-Baum

- Algorithmus zur NN-Suche
  – Datenseiten enthalten Kreise, d.h. Objekte der Form (Punkt, Radius)
    » Punkt = DB-Objekt (Mittelpunkt)
    » Radius = NN-Distanz(Punkt)

```
RNN-Tree-Search(pa, q,)          // pa = Diskadress z.B. der Wurzel des Indexes
    result = ∅;
    p := pa.loadPage();
    IF p.isDataPage() THEN
        FOR i=0 TO p.size() DO
            IF dist(q, p.getObject(i).Point) ≤ p.getObject(i).Radius THEN
                result := result ∪ getObject(i).Point;

    ELSE                         // p ist Directoryseite
        FOR i=0 TO p.size() DO
            IF MINDIST(q, p.getRegion(i)) = 0 THEN
                result := result ∪ RNN-Tree-Search(p.childPage(i), q);
    RETURN result;
```

- Vorteil
  - » Sehr gute Performanz (Pruning-Power) bei RNN-Anfragen
- Nachteile
  - » *k* muss fest vorgegeben sein
  - » Nur für Vektordaten
  - » Hohe Überlappungen der Seitenregionen im Directory führt zu schlechter Performanz bei normalen NN-Anfragen

    Lösung: speichere einen RNN-Baum und einen konventionellen R-Baum
  - » Schlechte Performanz bei Einfügungen und Löschungen

    Beispiel: *Einfügen* von *p*

„Normaler“ Index	Bestimme NN(*p*) und füge Kreis (*p*, NN-Distanz(*p*)) in Index ein
Zusätzlich für RNN-Baum	Bestimme RNN(*p*)
	Erneuere NN-Sphären aller $o \in$ RNN(*p*)
	Erneuere Seitenregionen (von *p* und allen *o*) betroffener Datenseiten
	Erneuere rekursiv Seitenregionen der Vaterseiten

- Varianten:
  - » Voronoi-Zellen statt NN-Sphären
  - » Andere Verfeinerungsreihenfolge (siehe NN-Algorithmen)

– RdNN-Baum [Yang, Lin. IEEE Int. Conf. Data Engineering (ICDE), 2001]

- Prinzip
  - – Idee des RNN-Baum, ABER
  - – Speichere die DB-Objekte statt NN-Sphären
  - – Speichere zu jedem Punkt in der DB seine NN-Distanz
    - » Zu jedem Punkt zusätzlich einen Wert abspeichern
    - » Zu jeder Seitenregion *s* zusätzlich noch den Wert

$$\max_{child \in s} child.getNNDist()$$

abspeichern (Maximum aller NN-Distanzen in den Kinderseiten)

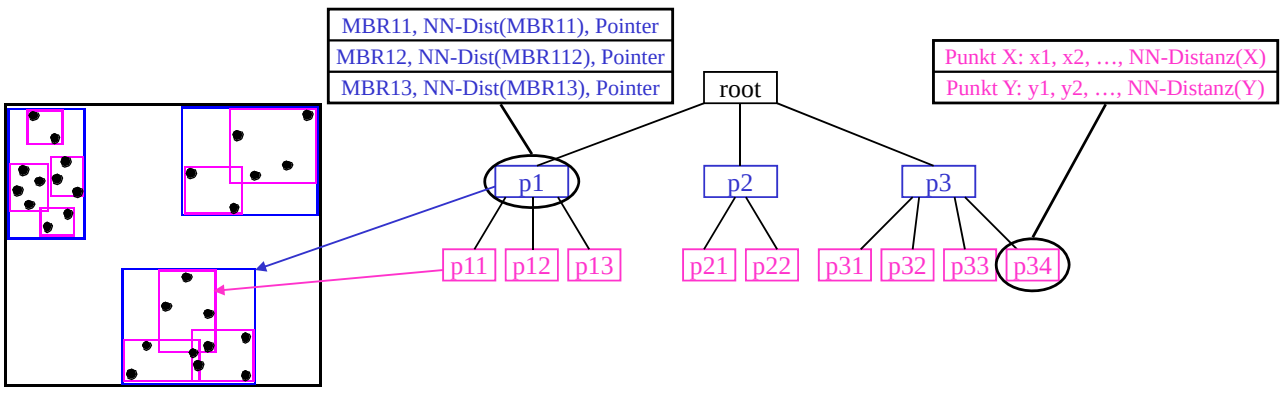

– Ausschluss von Directory-Seiten, wenn MINDIST(q,Seitenregion) größer ist, als die aggregierte NN-Distanz der Seitenregion

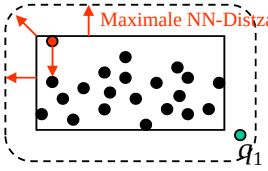

Query q_2: Seite kann ausgeschlossen werden; kein Punkt der Seite kann q_2 als NN haben

Query q_1: Seite kann nicht ausgeschlossen werden

- Algorithmus zur RNN-Suche

```
RdNN-Tree-Search(pa, q)          // pa = Diskadress z.B. der Wurzel des Indexes
  result = ∅;
  p := pa.loadPage();
  IF p.isDataPage() THEN
    FOR i=0 TO p.size() DO
      IF dist(q, p.getObject(i)) ≤ p.getNNDist(i) THEN
        result := result ∪ getObject(i);

  ELSE                           // p ist Directoryseite
    FOR i=0 TO p.size() DO
      IF MINDIST(q, p.getRegion(i)) ≤ p.getNNDist(i) THEN
        result := result ∪ RdNN-Tree-Search(p.childPage(i), q);
  RETURN result;
```


– Auch hier wieder alle möglichen anderen algorithmischen Lösungen zur NN-Suche anwendbar (Prioritätssuche, etc.)

– Vorteil
  » Sehr gute Selektivität, damit gute Performanz bei Anfragen
  » Seitenüberlappung wie bei „normalem“ R-Baum, daher kein extra Index für NN-/RQ-Anfragen nötig

– Nachteil
  » *k* muss fest vorgegeben sein
  » Nur für Vektordaten
  » Weiterhin schlechte Performanz bei Einfügungen und Löschungen

– MRkNNCoP-Baum

[Achtert, Böhm, Kröger, Kunath, Pryakhin, Renz. ACM Int. Conf. Management of Data (SIGMOD), 2006]

- Vergleich bisheriger Verfahren
  - RNN-Tree/RdNN-Tree: Vorberechnung der NN-Distanz
    - » Wert für *k* ist fix und vorher bekannt
    - » Update-Problematik
    - » Dafür: erweiterbar auf metrische Daten (z.B. M-Tree)
  - Geometrische Suche
    - » Nur für Vektordaten
    - » Teurer Verfeinerungsschritt, schlechtere Selektivität
    - » Dafür: beliebiges *k*, keine Update-Problematik
- Idee:
  - Benutze die gute Selektivität der vorberechneten NN-Distanzen
  - Berechne für mehrere (am besten alle) Werte für *k* die *k*-NN-Distanzen vor
  - Problem: Speicherung aller Distanzen zu aufwendig
    - » Pro Objekt alle *k*-NN-Distanzen => Index wäre sehr hoch => hohe Kosten
  - Lösung: Approximiere die *k*-NN-Distanzen
    - » Approximation sollte untere Schranke (LB) der *k*-NN-Distanz sein => true drops, wir können Objekte (Seiten) frühzeitig ausschließen
    - » Zusätzliche Approximation als obere Schranke (UB) => true hits

- Bewertung von Objekt *o* (analog: Seiten) mit UB- und LB-Approximationen
  - $dist(o,q) \leq LB_{k\text{-NN-Dist}}(o)$
    => *o* true hit, d.h. $o \in RNN(q, k)$
    - » Beispiel: $q = q_1$
  - $dist(o,q) \geq UB_{k\text{-NN-Dist}}(o)$
    => *o* true drop, d.h. $o \notin RNN(q, k)$
    - » Beispiel: $q = q_2$
  - $UB_{k\text{-NN-Dist}}(o) \leq dist(o,q) \leq LB_{k\text{-NN-Dist}}(o)$
    => *o* Kandidat
    - » Beispiel: $q = q_2$

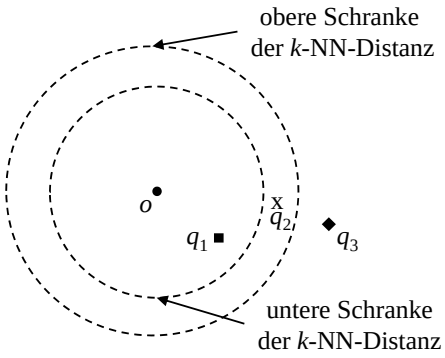

- Gegeben: für jedes Objekt *o* eine Sequenz der *k*-NN-Distanzen, <1-NN-Dist(*o*), 2-NN-Dist(*o*), …, k_{max}-NN-Dist(*o*)> für ein hinreichend großes k_{max}
- Frage: wie kann ich UB- und LB-Approximation dieser *k*-NN-Distanzen berechnen und kompakt speichern?

- Lösung aus der Theorie der Selbstähnlichkeit
  - Potentzgesetz gilt für Verhältnis zwischen
    - » dem Radius einer Hyperkugel
    - » der Anzahl an Objekten innerhalb der Hyperkugel

$$encl(\varepsilon) \propto \varepsilon^{d_f}$$

wobei *encl*(ε) = #Objekte innerhalb der Kugel
d_f = „Fraktale Dimension“

  - Übertragung auf k-NN-Sphäre:
    - » ε = *k*-NN-Distanz
    - » *encl*(ε) = *k*
  - Im log-log-Raum: $\log(k-\mathrm{NN}-\mathrm{Dist}(o)) \propto \frac{\log(k)}{d_f}$

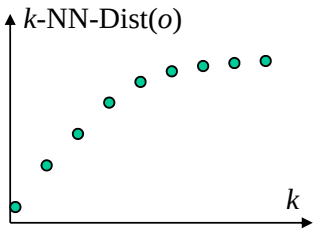

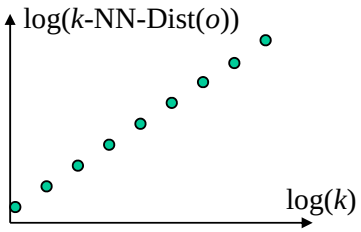

  - In der Realität verhalten sich die Distanzen nicht wie perfekte Linien im log-log-Raum
  - Trotzdem: im log-log-Raum können die *k*-NN-Distanzen mit einer Linie approximiert werden
  - Das ist erheblich billiger als alle *k*-NN-Distanzen zu speichern, oder andere Funktionen höherer Ordnung zu verwenden, um die Distanzen im normalen *k* / *k*-NN-Dist – Raum zu approximieren

- LB- und UB-Approximationen
  - UB-Approximation ist eine Linie im log-log-Space, sodass

$$\forall k \le k_{\max} : k-\mathrm{NN}-\mathrm{Dist}(o) \le \mathrm{UB}_{k-\mathrm{NN}-\mathrm{Dist}}(o)$$

  - LB-Approximation ist eine Linie im log-log-Space, sodass

$$\forall k \le k_{\max} : k-\mathrm{NN}-\mathrm{Dist}(o) \ge \mathrm{LB}_{k-\mathrm{NN}-\mathrm{Dist}}(o)$$

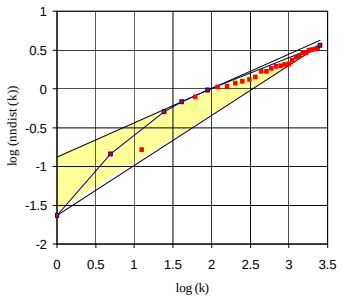

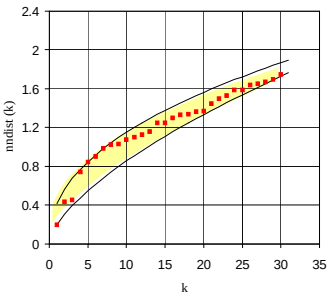

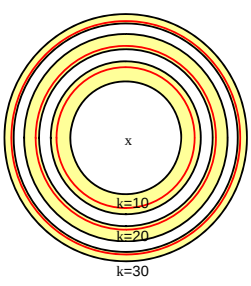

- Jedem Objekt wird zugeordnet
  - Eine LB-Approximation der *k*-NN-Distanzen
  - Eine UB-Approximation der *k*-NN-Distanzen
- Jeder Seite im Index wird zugeordnet
  - Eine LB-Approximation der LB-Approximationen der Kindseiten
  - UB-Approximation wird nicht gespeichert, da zu wenig selektiv

- Vorteil:
  - Beliebiges *k*
  - Für allgemein metrische Daten (M-Tree) oder Vektordaten (z.B. X-Tree)
  - Durch UB- und LB-Approximationen höhere Filterselektivität als Geometrisches Verfahren => weniger Kandidaten die verfeinert werden müssen

- Nachteil
  - Updateproblematik
  - k_{max} muss bekannt sein (ABER i.d.R. kein Problem)
  - Teure Verfeinerung nötig (ABER i.d.R. deutlich weniger Kandidaten)

- ***Filter***-Algorithmus für allgemein metrische Daten (M-tree)

Knoten Node = (RoutingObj, CovRadius)
MINDIST(*q*,Node) = max{dist(*q*,Node.RoutingObj) – CovRadius, 0}

```
MRkNNCoP-Tree-Search(DB, q)      // DB als MRkNNCoP-Tree organisiert
    result = ∅;
    candidates = ∅;
    queue = LIST OF (dist:Real, obj:Object) ORDERED BY dist ASCENDING;
    queue = [(0.0, DB.root)];
    WHILE NOT queue.isEmpty() DO
        p = queue.first().Object;
        IF p.isDataPage() THEN
            FOR i=0 TO p.size() DO
                IF dist(q, p.getObject(i)) ≤ LB_k-NN-Dist(p.getObject(i)) THEN
                    result := result ∪ getObject(i);
                ELSE IF dist(q, p.getObject(i)) ≤ UB_k-NN-Dist(p.getObject(i)) THEN
                    candidates := candidates ∪ getObject(i);

        ELSE                    // p ist Directoryseite
            FOR i=0 TO p.size() DO
                IF MINDIST(q, p.getRegion(i)) ≤ UB_k-NN-Dist(p.getRegion(i)) THEN
                    queue.insert((MINDIST(q, p.getRegion(i)), p.childPage(i)));
```

– Mutual-Pruning Strategien

- 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 $x \notin RNN(q)$

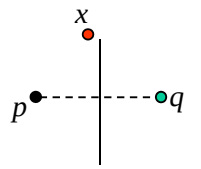

Voronoi-Ebene $E(p,q)$ zwischen p und q

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

- 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

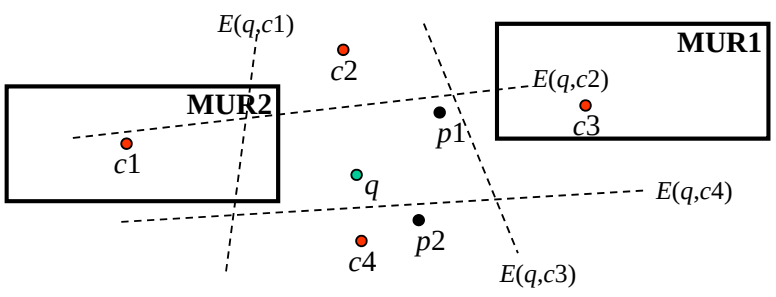

Bisherige Kandidaten:

{$c1$, $c2$, $c3$, $c4$}

Inhalt des Rankings (ungeordnet):

MUR1: nicht verfeinern
MUR2: verfeinern
$p1$: verfeinern
$p2$: nicht verfeinern

– Verfeinerung von $p1$
  » Streiche $c2$ und $c3$ aus Kandidatenliste (liegt nun hinter $E(q,p1)$)
  » MUR2 muss weiterhin verfeinert werden

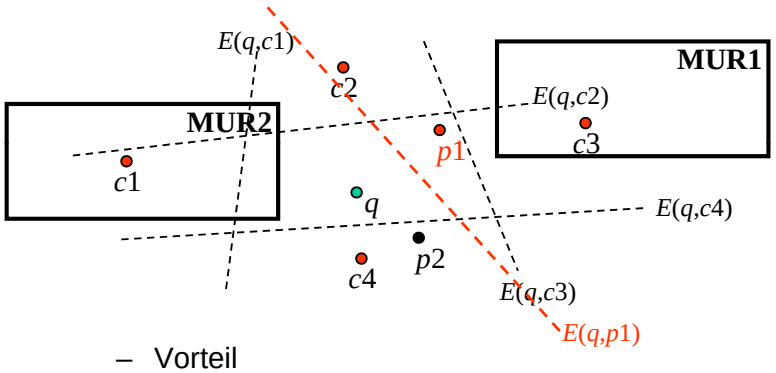

Bisherige Kandidaten:
{$c1$, $c4$, $p1$}

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?

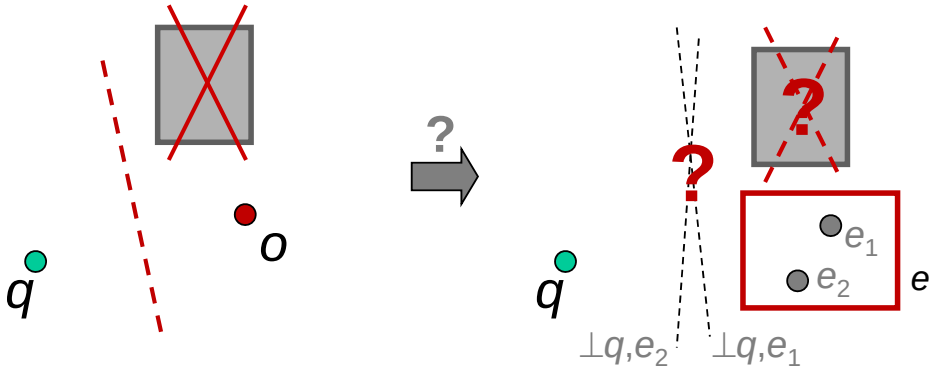

- Idee: Kombination beider Pruning-Strategien
  – Verwendung des Pruningkonzepts der geometrischen RNN-Suche für Mutual-Pruning und Self-Pruning (ohne Vorberechnung)
  – Erweitere Mutual-Pruning-Ansatz für höhere Indexebenen
  – Erweiterung auf metrische Daten

- Min/Max-Dist-Ansatz: Verwendung von Min/Max/MinMax-Dist
  [Achtert, Kröger, Kriegel, Renz, Züfle, EDBT, 2009]
  - Verwendung des Pruningkonzepts der geometrischen RNN-Suche für Mutual-Pruning und Self-Pruning (ohne Vorberechnung)
  - Erweitere Mutual-Pruning-Ansatz für höhere Indexebenen

mutual pruning (k=1):

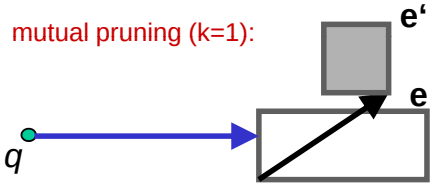

MinMaxDist(e,e‘)<MinDist(q,e)
=> prune e

self pruning (k=1):

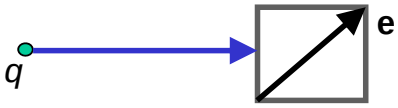

MinMaxDist(e,e)=MaxDist(e,e)<MinDist(q,e)
=> prune e (falls |e| > 1)

mutual pruning (k≥1):

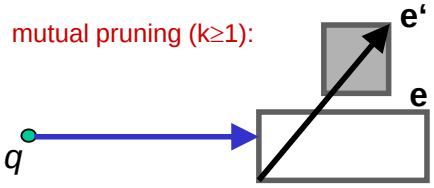

MaxDist(e,e‘)<MinDist(q,e)
=> prune e (falls |e‘|>k)

self pruning (k≥1):

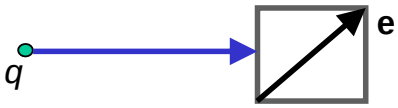

MaxDist(e,e)<MinDist(q,e)
=> prune e (falls |e|-1>k)

- Vorteile:
  - Beibehaltung des Pruningkonzepts der geometrischen RNN-Suche, d.h. keine Vorberechnung von Distanzen
  - Mutual-Pruning und Self-Pruning auch für höhere Index-Level
  - Kann auch auf metrische Daten angewendet werden
- Nachteil:
  - Pruningfilter ist weniger selektiv als bei der geometrischen RNN-Suche

geometrisches Pruning:

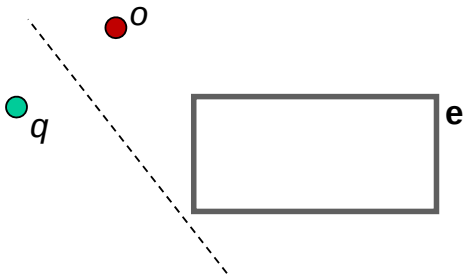

e hinter der Hyperebene
=> prune e

Min/Max-dist Pruning:

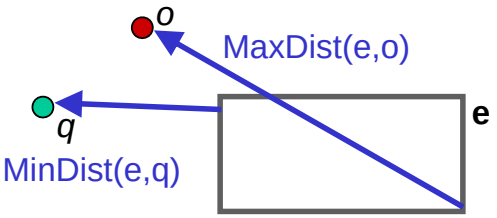

MaxDist(e,o) > MinDist(e,q)
=> prune e nicht!

- 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)

Mutual Pruning (k=1):

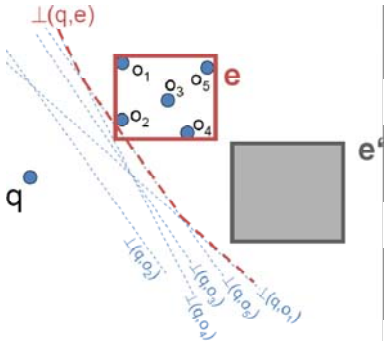

Self Pruning (k=1):

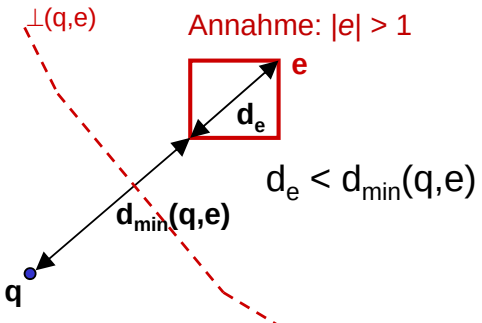

$\forall o \in e'$: $o \notin RNN(q)$, da $\exists o_i \in e$: e' hinter Hyperebene $\perp(q,o_i)$

- 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

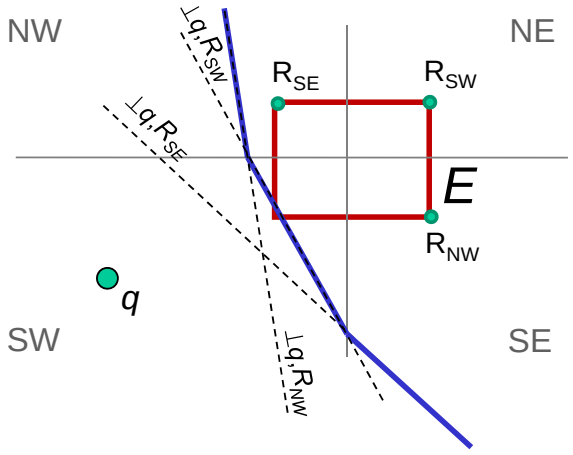

=> Die konservative Approximation wird aus 2^d-1 Hyperebenen gebildet

- 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)

Mutual Pruning (k>1):

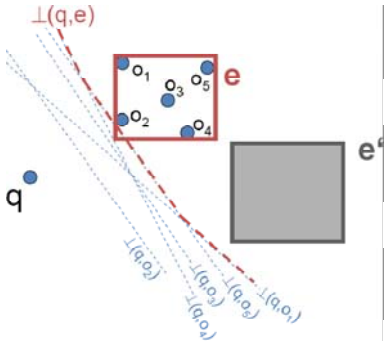

∀o∈e’: $o \notin$ R*k*NN(q), where $k \leq |e|$

Self Pruning (k>1):

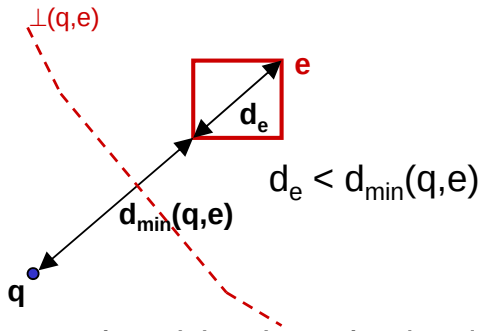

∀o∈e: o $\notin$ R*k*NN(q), where $k \leq |e\text{-}1|$

- 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)
- Optimales Pruning: [Emrich, Kriegel, Kröger, Renz, Züfle: SIGMOD 2010]
  - Idee: Mischung zwischen Min/Max-Dist Pruning und Geometrisches Pruning

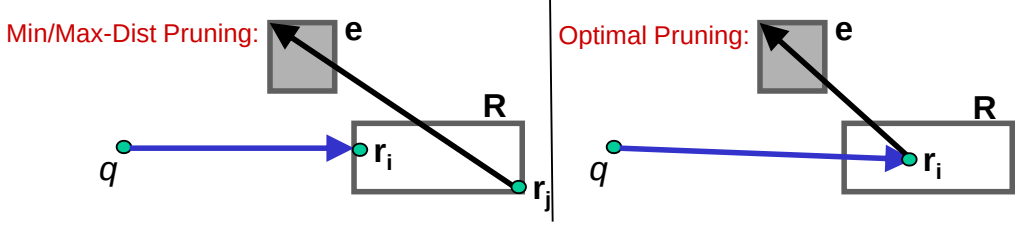

  - Optimal Pruning: Prune R wenn $\forall r_i \in R$: $d(q,r_i) > MaxDist(r_i,e)$

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

- Beispiel:

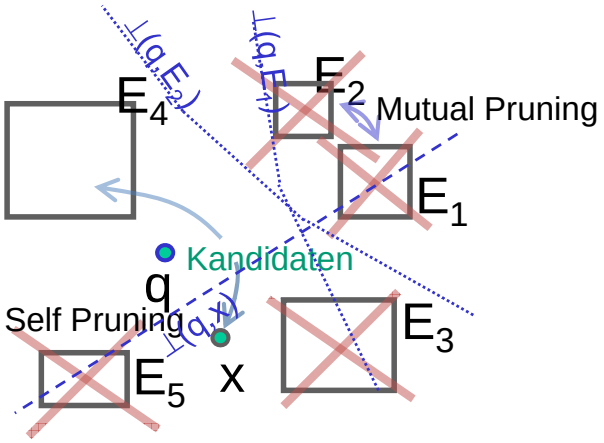

- Eigenschaften des „Optimalen Prunings“:
  - Vorteile:
    - » Vollständige Flexibilität bzgl. *k*
    - » Keine Zusätzliche Kosten für Änderungen im Index (Update-Kosten)
    - » Pruning-test (fast) genauso günstig wie normale Min/Max-Dist-Berechnung
    - » Pruning-Filter-Selektivität entspricht dem geometrischen Pruning mittels Hyperebenen
  - Nachteil:
    - » Die Suche mittels Self-Pruning ohne Vorberechnung ist weniger selektiv
      ==> schlechteres Pruning-Verhalten als bei (reinen) Self-Pruning-Methoden

– 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	**Geometrische (Voronoi-basierte) RkNN Suche**	variables *k*;	Nur für Vektordaten; Verfeinerung nötig
self+ mutual-pruning	**Min/Max-Dist-basierte RkNN Suche**	variables *k*; geringe Kosten, für metrische Daten, erlaubt Pruning auf Directory-Ebene	schlechtere Filterselektivität
self+ mutual-pruning	**Erweiterte geometrische RkNN Suche**	variables *k*; erlaubt Pruning auf Directory-Ebene; optimale Filterselektivität	Nur für Vektordaten; teure Verwaltung der Hyperebenen
self+ 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

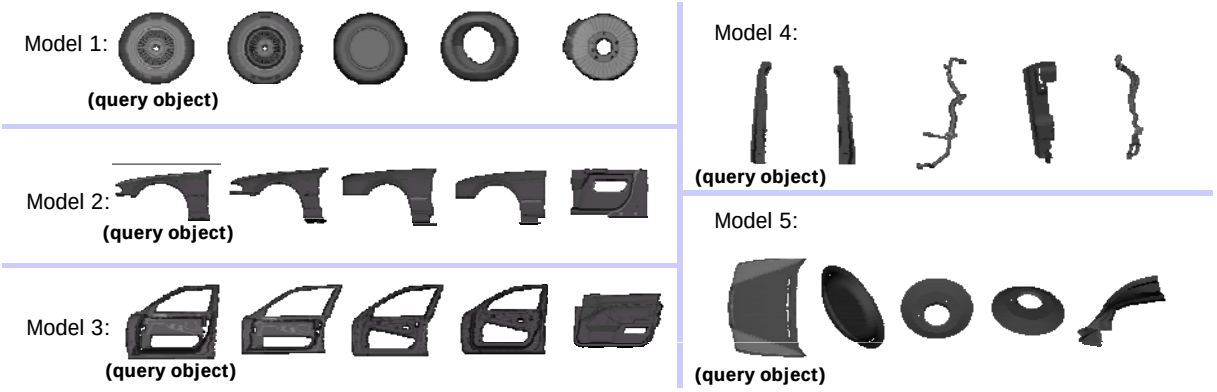

- BOSS (Browsing OPTICS-plots for Similarity Search)
  [Brecheisen, Kriegel, Kröger, Pfeifle. Proc. SIAM Int. Conf. Data Mining (SDM), 2004]
  – Idee: benutze Data Mining Methoden
  – Clustering
    » Fasse Objekte in Gruppen zusammen, sodass die Objekte in einer Gruppe (Cluster) ähnlich, Objekte aus 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