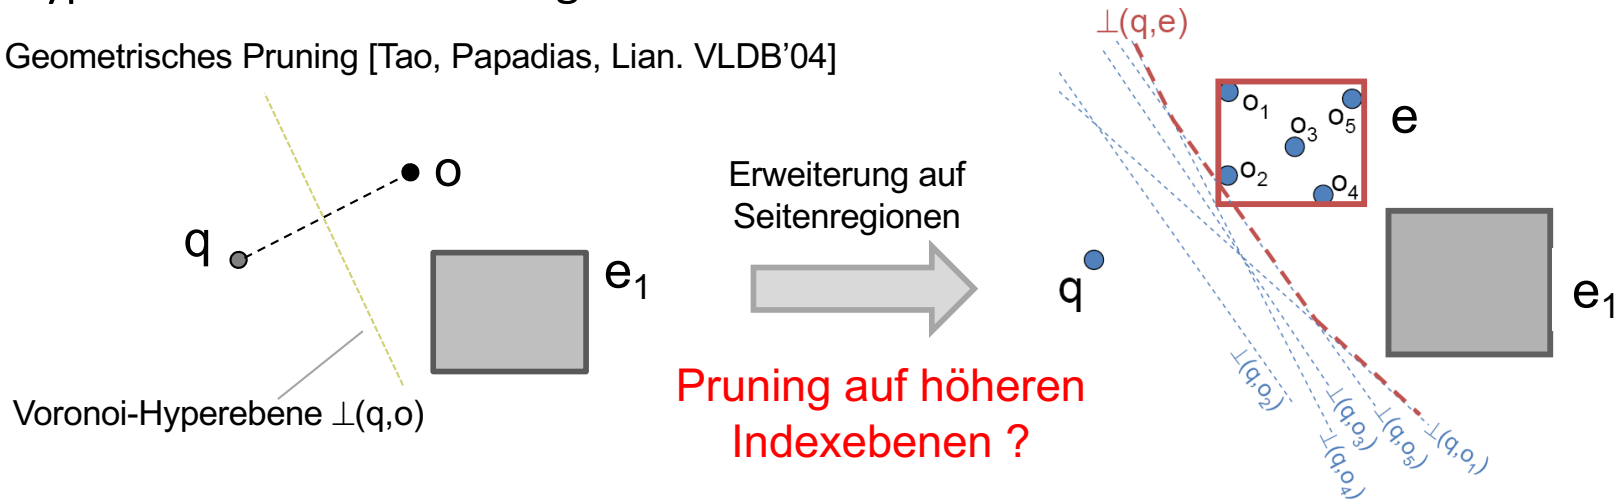


## 2.5 Reverse nächste Nachbarn Anfragen

- Erweiterung des geometrischen Pruning-Konzepts auf Basis von Voronoi-Hyperebenen auf Seitenregionen

Geometrisches Pruning [Tao, Papadias, Lian. VLDB'04]




- Frage: Effiziente Repräsentation von Voronoi-Hyperebenen zwischen einem Punkt und einer Seitenregion ?
- Idee: Konservative Approximation der Hyperebenen  
Eigenschaft:  $\forall p \in \perp(q,e): \text{dist}(q,p) = \text{MaxDist}(e,p)$

## 2.5 Reverse nächste Nachbarn Anfragen

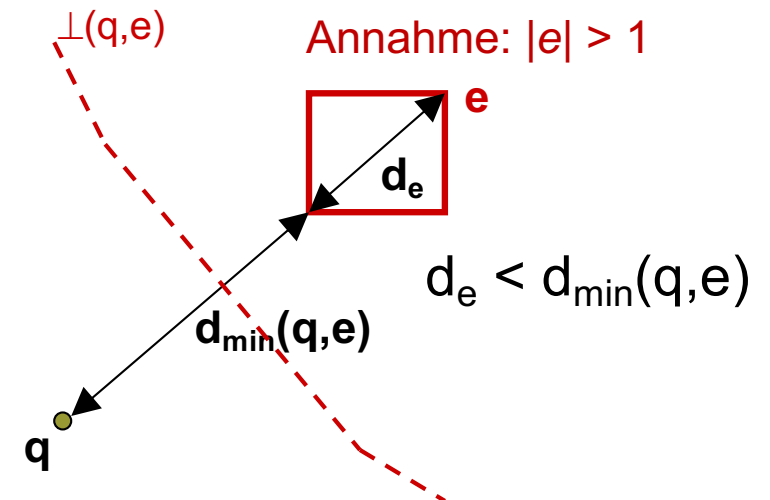
- Erweiterung der Geometrischen RNN-Suche (gilt nur für Vektordaten!!!)
  - [Kriegel, Kröger, Renz, Züfle: SSDBM, 2009]
  - Ziel: Pruning auf höheren Indexebenen
  - Definition von Hyper-Ebenen zwischen Anfragepunkt und Seitenregion  $e$
  - Bilde konservative Approximation  $\mathcal{H}$  aller Hyperebenen 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 ( $k=1$ ):



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

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




## 2.5 Reverse nächste Nachbarn Anfragen

- Berechnung der konservativen Approximation aller Hyperebenen zwischen Anfragepunkt  $q$  und Seitenregion  $e$ 
  - Aufspaltung 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

## 2.5 Reverse nächste Nachbarn Anfragen

- Erweiterung der Geometrischen RkNN-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 ( $k > 1$ ):      Seite  $e$  schließt sich selbst aus ( $k > 1$ ):

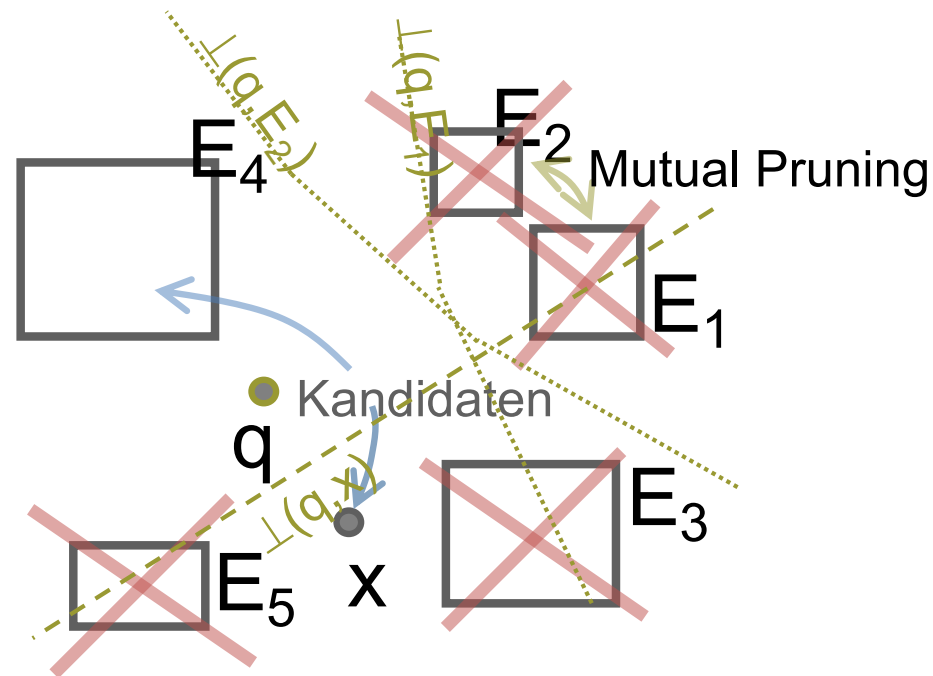


$\forall o \in e': o \notin RkNN(q), \text{ where } k \leq |e|$

$\forall o \in e: o \notin RkNN(q), \text{ where } k \leq |e|-1$

## 2.5 Reverse nächste Nachbarn Anfragen

- 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

## 2.5 Reverse nächste Nachbarn Anfragen


- Eigenschaften der Geometrischen RkNN-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<sup>d</sup> Hyperebenen pro Seitenregion müssen materialisiert werden => Overhead der Ebenenverwaltung (schlechte Performanz in höher-dimensionalen Räumen)
    - Test ob Seitenregion geprunt werden kann ist teuer (2<sup>d</sup> 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?

## 2.5 Reverse nächste Nachbarn Anfragen

### □ Generelle Problemstellung:

Gegeben:

Drei Punktobjekt-Approximationen A, B und R gegeben als achsenparallele 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]