# 2.6 Skylineanfrage

- Gegeben:

  Menge von Objekten mit positiven Attributwerten $a_i \in \Re^+$ ($1 \le i \le d$).

- Gesucht:

  Ergebnis enthält alle Objekte die von keinem anderen Objekt *dominiert* werden, d.h. kein anderes Objekt ist „besser“ bzgl. aller Attribute.

- Formal:

  Vektor $x=(x_1,..,x_d) \in \Re^d$ dominiert Vektor $y=(y_1,..,y_d) \in \Re^d$ wenn gilt:

  $dom(x,y) \Leftrightarrow (\forall\ 1 \le i \le d\ x_i \le y_i) \wedge (\exists\ 1 \le i \le d\ x_i < y_i)$

  SkyLine(*DB*) = $\{o \in DB \mid \forall p \in DB : \neg dom(p,o)\}$

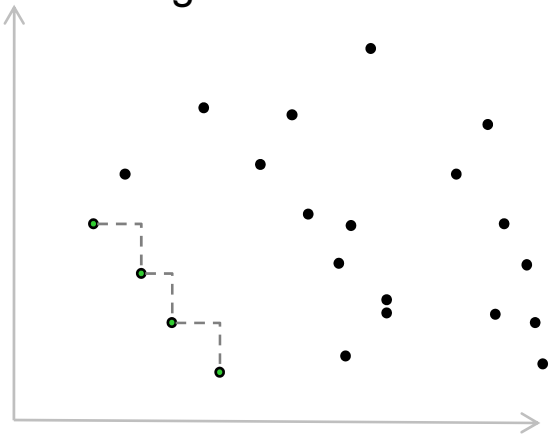

Skyline Anfrage

- Basisalgorithmus (sequential scan):

```
Skyline-SeqScan(DB)
    result = ∅;
    FOR i=1 TO n DO
        o = getObject(i);
        IF o not-dominated-by(any other object in DB)THEN
          result := result ∪ o;
    RETURN result;
```

zusätzlicher sequentieller scan über DB

- Skyline-Anfrage Varianten: [Papadias et al., ToDS 2005]

  zum Beispiel:

  » *Constrained Skyline*:

  Ausgabe aller Skyline-Objekte deren Attribute zusätzlich eine bestimmte Bedingung (z.B. Hotelkosten zwischen 50 und 80 Euro) erfüllen.

  » *Ranked Skyline*:

  Ausgabe der *k* ersten Skyline-Objekte, die bzgl. einer Präferenzfunktion (Kostenfunktion über alle Attribute) sortiert ausgegeben werden.

  » weitere Varianten:

  *Group-by Skyline*, *Dynamic Skyline*, *K-dominating Queries*, etc.

# 2.6.2 Indexbasierte Skyline-Anfrage

– Anforderungen:

- Gegeben:
  - Menge von d-dimensionalen Punkte (Objekte)
  - Indexierung mittels R-Baum

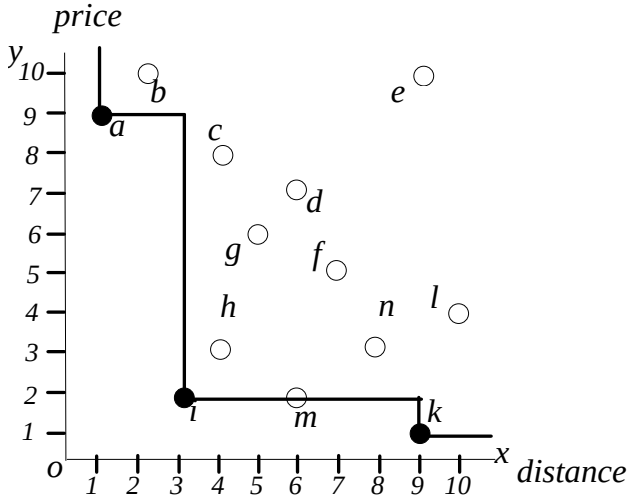


- Gesucht:
  - Alle Objekte, die von keinem anderen Objekt dominiert werden.
- Ziele:
  - Wenig Seitenzugriffe
  - Wenig Dominanzüberprüfungen (Objektvergleiche)
  - Möglichst früh erste Ergebnisse ausgeben

- Grundsätzlich viele unterschiedliche Ansätze
  - Hauptspeicher-basiert ←→Sekundärspeicher-basiert
  - Iterative Berechnung ←→ Nicht-Iterative Berechnung

  Skyline-Anfrage Varianten:
  - Mit explizitem Anfrageobjekt(en) (dynamische Skyline)
  - zusätzliche Bedingungen
  - andere Skylinevarianten: z.B: Top-k-Dominanz, etc.

- Bekannteste Ansätze die auf Sekundärspeicher beruhen:

  (Zusammenfassung aus [Papadias et al., ToDS 2005])
  - Divide-and-Conquer, Block-Nested Loop [Borzsonyi et al., 2001]
  - Sort First Skyline [Chomicki et al., 2003]
  - Bitmap, Index [Tan et al., 2001]
  - Nearest-Neighbor [Kossmann et al., 2002][Papadias et al., ToDS 2005]

    Eigenschaften:
    - » Sekundärspeicherbasiert
    - » Erfüllen alle drei Ziele:

      - wenig Seitenzugriffe und Dominanzüberprüfung mittels Index (R-Baum).
      - Erste Ergebnisse werden frühzeitig ausgegeben durch iterative Verarbeitung.

– Nächste-Nachbarn-Skyline (NNS) Algorithmus:

[Kossman et al., VLDB 2002]

Prinzip:

- Benutzt Nächste-Nachbarn-Suche zur (rekursiven) Partitionierung des Suchraums

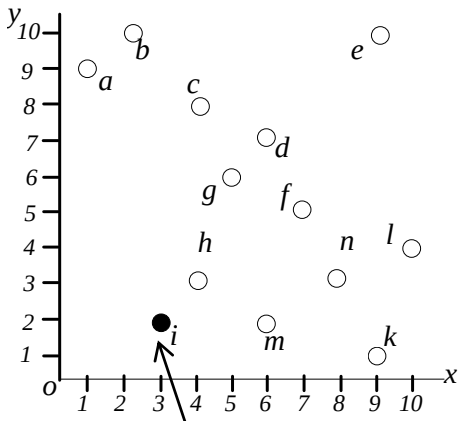


Nächster Nachbar
(des Koordinaten-Ursprungs)
→ erstes Skyline-Ergebnis

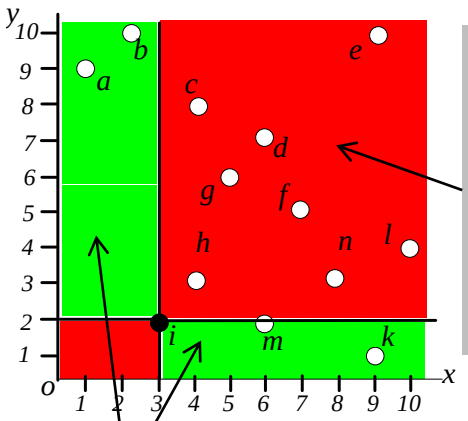


Raumpartitionen mit
weiteren Skyline-Kandidaten

Raumpartition mit Objekten die von Objekt i dominiert werden => Objekte gehören nicht zum Ergebnis (*true drops*).

- Nächste-Nachbar-Suche kann durch R-Baum Index beschleunigt werden (z.B. Alg.: k-NN-Index-HS).

- Nächste-Nachbar-Suche wird zur weiteren Partitionierung **in jeder** Kandidaten-Suchregion rekursiv fortgesetzt.

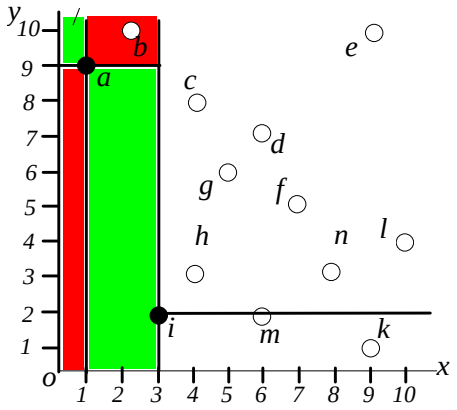


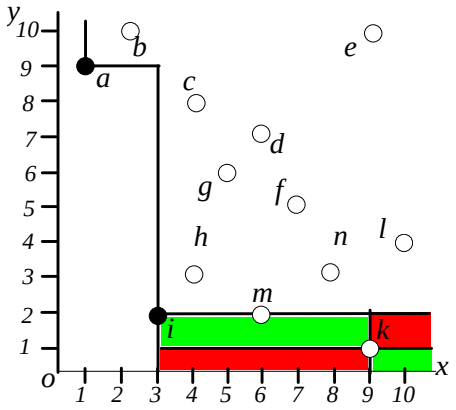


- Vorteile:
  - Verwendung von effizienten Methoden zur NN-Suche.
  - Erste (relevante) Resultate können schnell ausgegeben werden.
- Nachteile:
  - Im d-dimensionalen Raum führt jedes gefundene Skyline-Objekt (Punkt) zu d weiteren Fensteranfragen.
    → viele redundante Anfragen → Duplikateliminierung
    → viele (unnötige) Anfragen auf leeren Raum

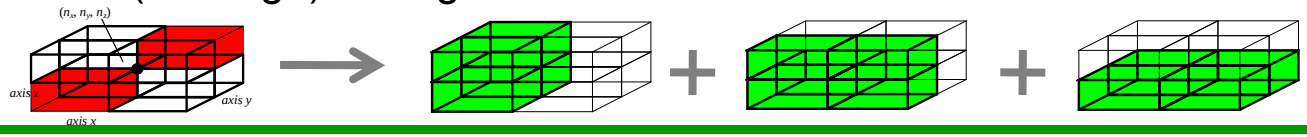

– Branch-and-Bound Skyline (BBS) Algorithm:

[Papadias et al., ToDS 2005]

Prinzip:

- Idee: Datenorientierte Suche statt Datenraumorientierte Suche
  - Vermeidung von Suche in “leeren” Datenraumpartitionen.
  - Kandidaten werden direkt über einen Index (R-Baum) ermittelt.
- Prioritäts-basierte Suche des nächsten Skyline-Objektes
  - Priorität entsprechend Manhattan-Distanz zum Koordinaten-Ursprung
  - Iterative Verfeinerung des Index (R-Baum) mittels Prioritätsliste (vgl. k-NN-Index-HS, Folie 63)

→ Verwendung eines Heaps aufsteigend sortiert über MINDIST(e,(0,0)), e := Seitenregion oder Objekt (Punkt)

→ Verwendung einer Liste mit bereits gefundenen Skylineobjekten zum Prunen von anderen Seitenregionen / Objekten

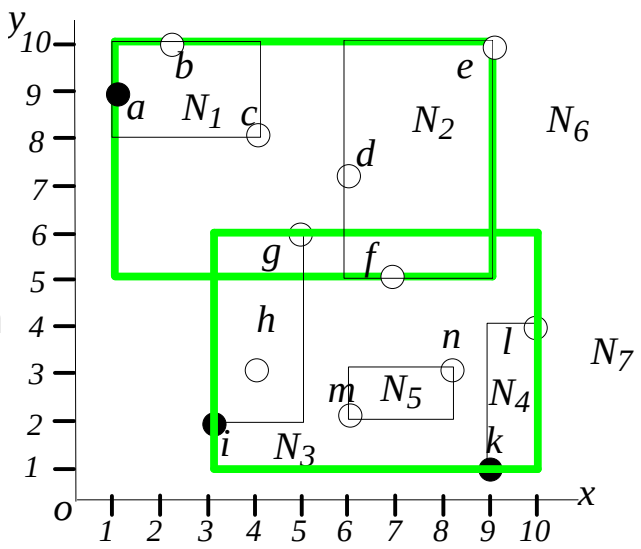

- Algorithmus:

Algorithm BBS (R-tree R)
S=Ø
Füge alle Einträge der Wurzel R in den Heap ein
Solange Heap nicht leer:
    entferne ersten Eintrag e
    wenn e von einem Punkt in S dominiert wird, verwerfe e
    sonst (e ist nicht dominiert)
        wenn e kein Datenpunkt ist
            für jedes Kind $e_i$ von e
                falls $e_i$ nicht von einem Punkt in S dominiert wird, füge $e_i$ in den Heap ein
        sonst (e ist ein Datenpunkt)
                füge e in S ein

- Vorteile:
  - Vorzeitige Ausgabe von ersten Resultaten
  - Keine unnötige Partitionierung des Datenraums → geeignet auch für Suchraumdimensionen > 3 (im Gegensatz zu NNS)
  - BBS ist optimal bzgl. der Seitenzugriffe im R-Baum (I/O-optimal)

- Experimenteller Vergleich: NNS ←→ BBS
  - Datensatz: 1 Mio. Objekte gleichmäßig verteilt

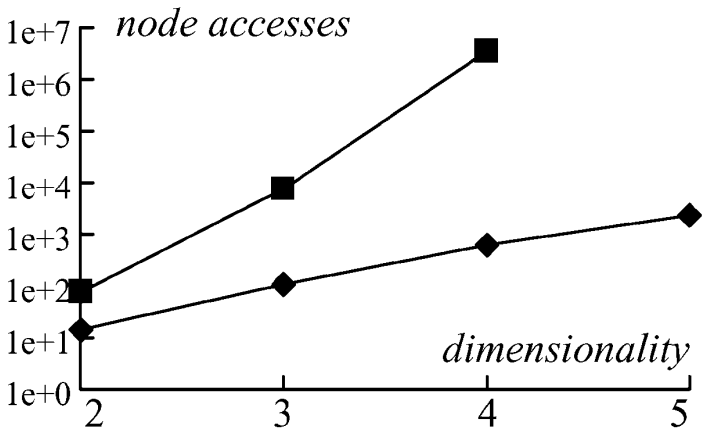


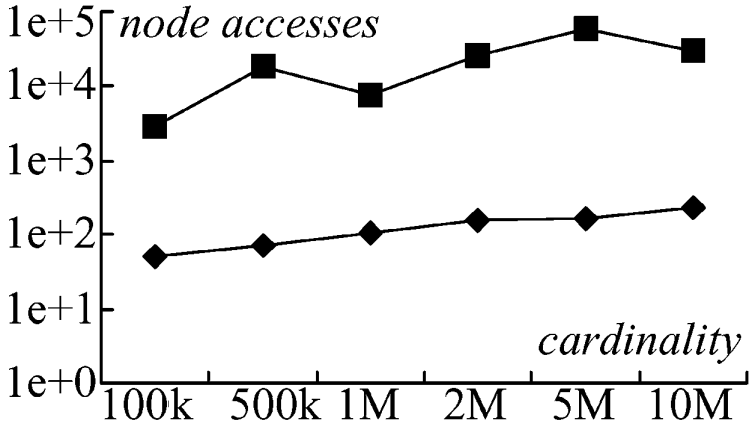


  - Fazit: BBS schlägt NNS bzgl. I/O-Kosten über mehrere Größenordnungen