Kapitel 14: Datenspeicherung, Indexstrukturen und Anfrageausführung

14.1 Wie Daten gespeichert werden

14.2 Wie auf Daten effizient zugegriffen wird (Indexstrukturen)

14.3 Wie Anfragen ausgeführt werden

Interne (idealisierte) Schichtenarchitektur eines DBS

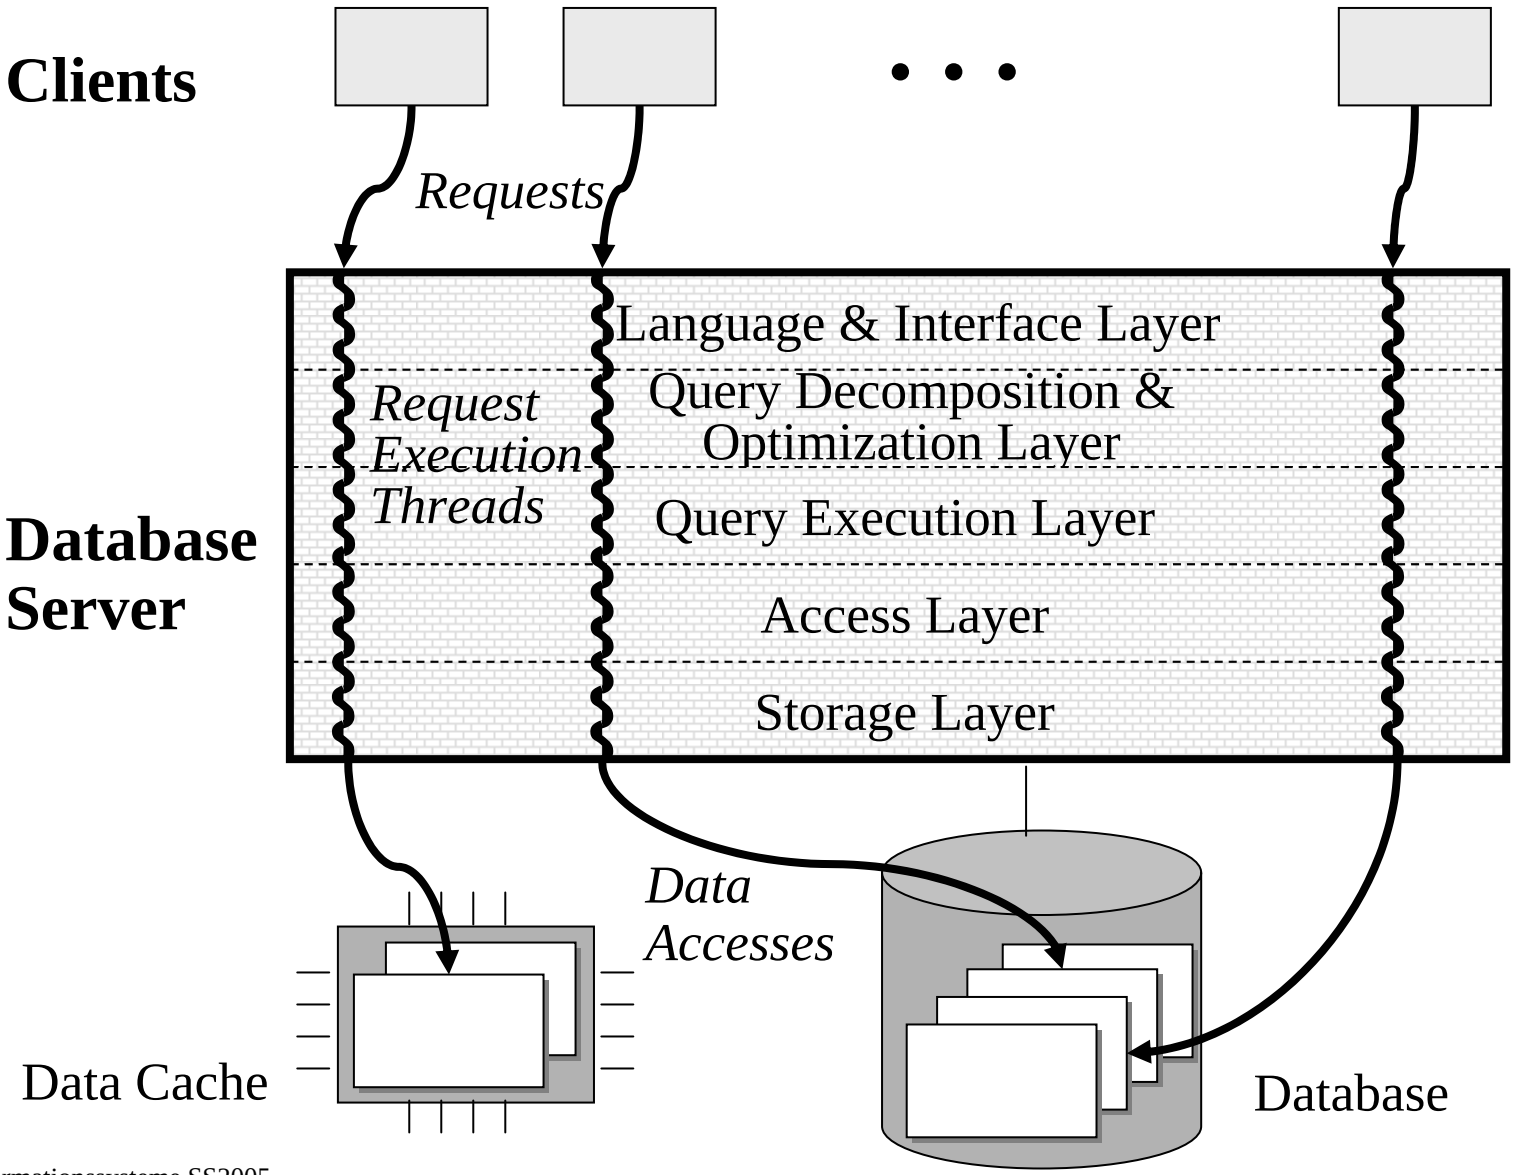

14.1 Wie Daten gespeichert werden

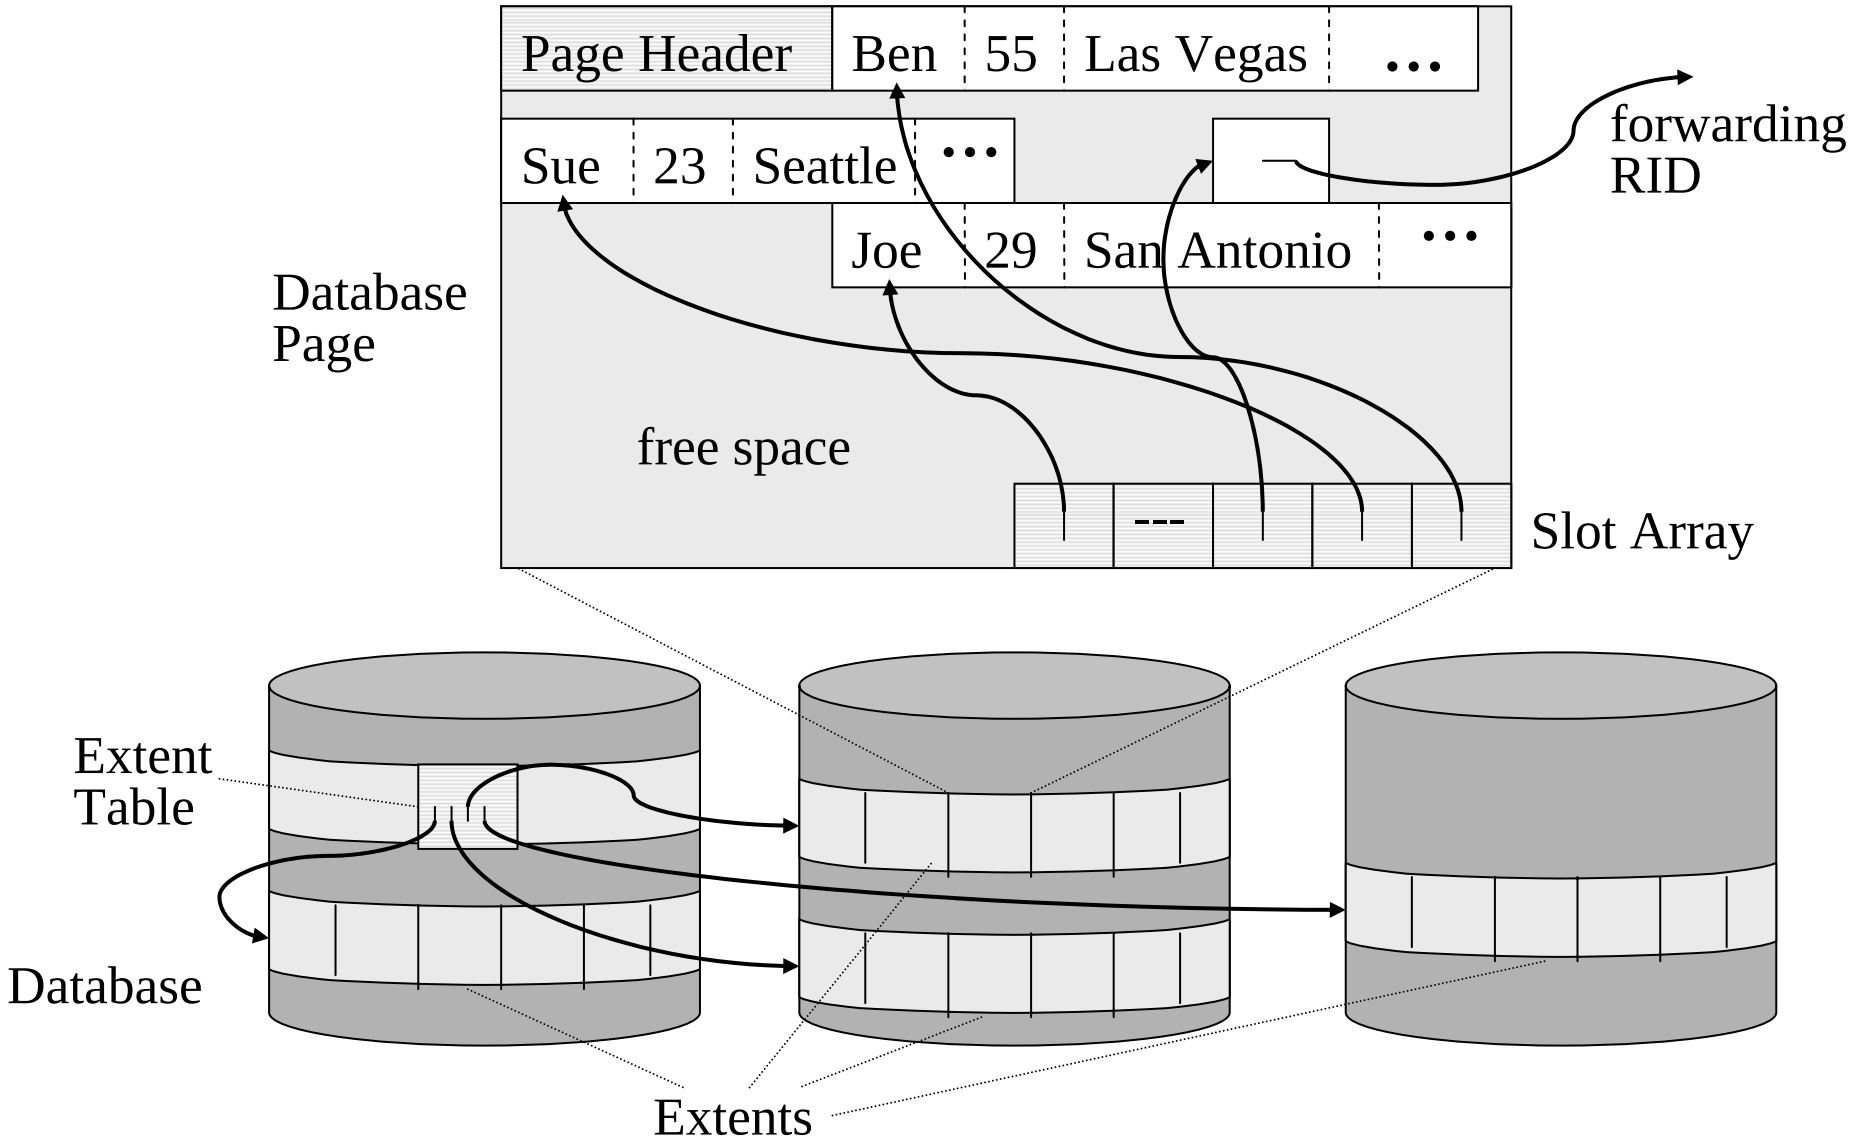

Charakteristika von Magnetplatten (~2001)

(z.B. Seagate Cheetah 18 mit Ultra-SCSI- oder Fibre-Channel-Schnittstelle)

Durchmesser	3.5 Zoll
Speicherkapazität	18.2 GBytes
Preis	ca. 4000 DM
Größe	ca. 14 x 10 x 4 cm
Gewicht	ca. 1.2 kg
Energieverbrauch	15 Watt
Zuverlässigkeit (MTTF)	800 000 Stunden (> 75 Jahre)
Anzahl Oberflächen	24
Anzahl Zylinder	6962
Spurkapazität	87 bis 128 KBytes
Rotationszeit	6 ms (10000 U/min)
Mittlere Armpositionierungszeit	5.7 ms
Minimale Armpositionierungszeit	0.6 ms
Übertragungsrate	14.5 bis 21.3 MBytes / s

Random I/O auf 1 Block a 4 KB	ca. 9 ms
Sequential I/O auf 30 Blöcke a 4 KB	ca. 12 ms

Charakteristika moderner Magnetplatten

(z.B. Seagate Cheetah 15K.4 mit Ultra-SCSI- oder Fibre-Channel-Schnittstelle)

Durchmesser	3.5 Zoll
Speicherkapazität	146,8 GBytes
Preis	ca. 1000 Euro
Größe	ca. 14 x 10 x 2.5 cm
Gewicht	ca. 0,8 kg
Energieverbrauch	17,5 Watt
Zuverlässigkeit (MTTF)	1.400.000 Stunden (160 Jahre)
Anzahl Oberflächen	8
Anzahl Zylinder	50.864
Spurkapazität	471 KBytes im Durchschnitt
Rotationszeit	4 ms (15.000 U/min)
Mittlere Armpositionierungszeit	3.5 ms
Minimale Armpositionierungszeit	0.2 ms
Übertragungsrate	58 bis 96 MBytes / s
Random I/O auf 1 Block a 4 KB	ca. 5,5 ms
Sequential I/O auf 30 Blöcke a 4 KB	ca. 7 ms

Leistungsparameter einer Magnetplatte

Z: #cylinders

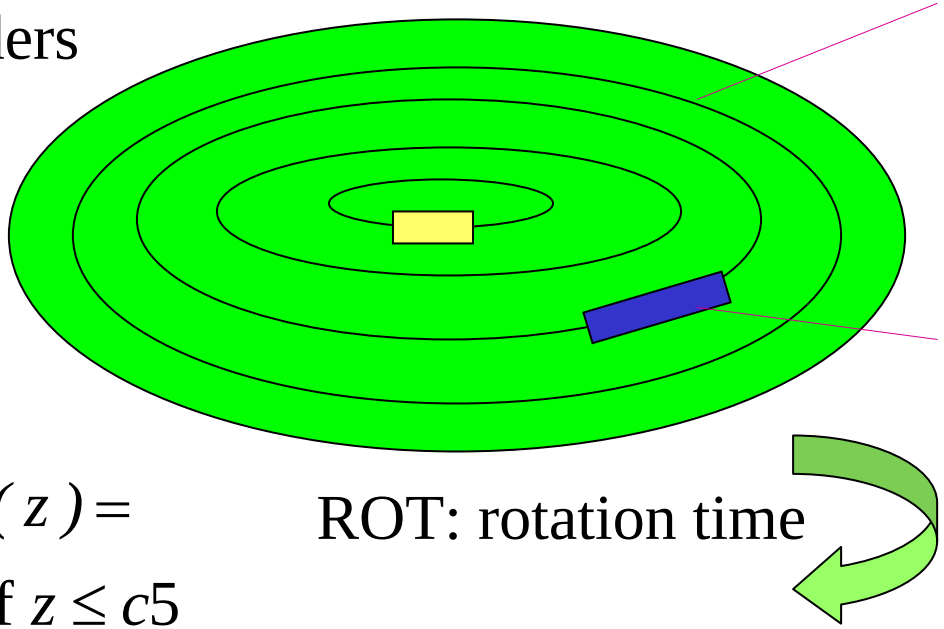

C_i: track capacity

$B_i = C_i / ROT$:
disk transfer rate

R: request size

$T_{seek} = tseek(z) =$

$$\begin{cases} c1\sqrt{z} + c2 & \text{if } z \le c5 \\ c3\,z + c4 & \text{otherwise} \end{cases}$$

arm seek time

ROT: rotation time

T_{rot}
rotational delay

$T_{trans} = R / B_i$
transfer time

Charakteristika von Speicherhierarchien

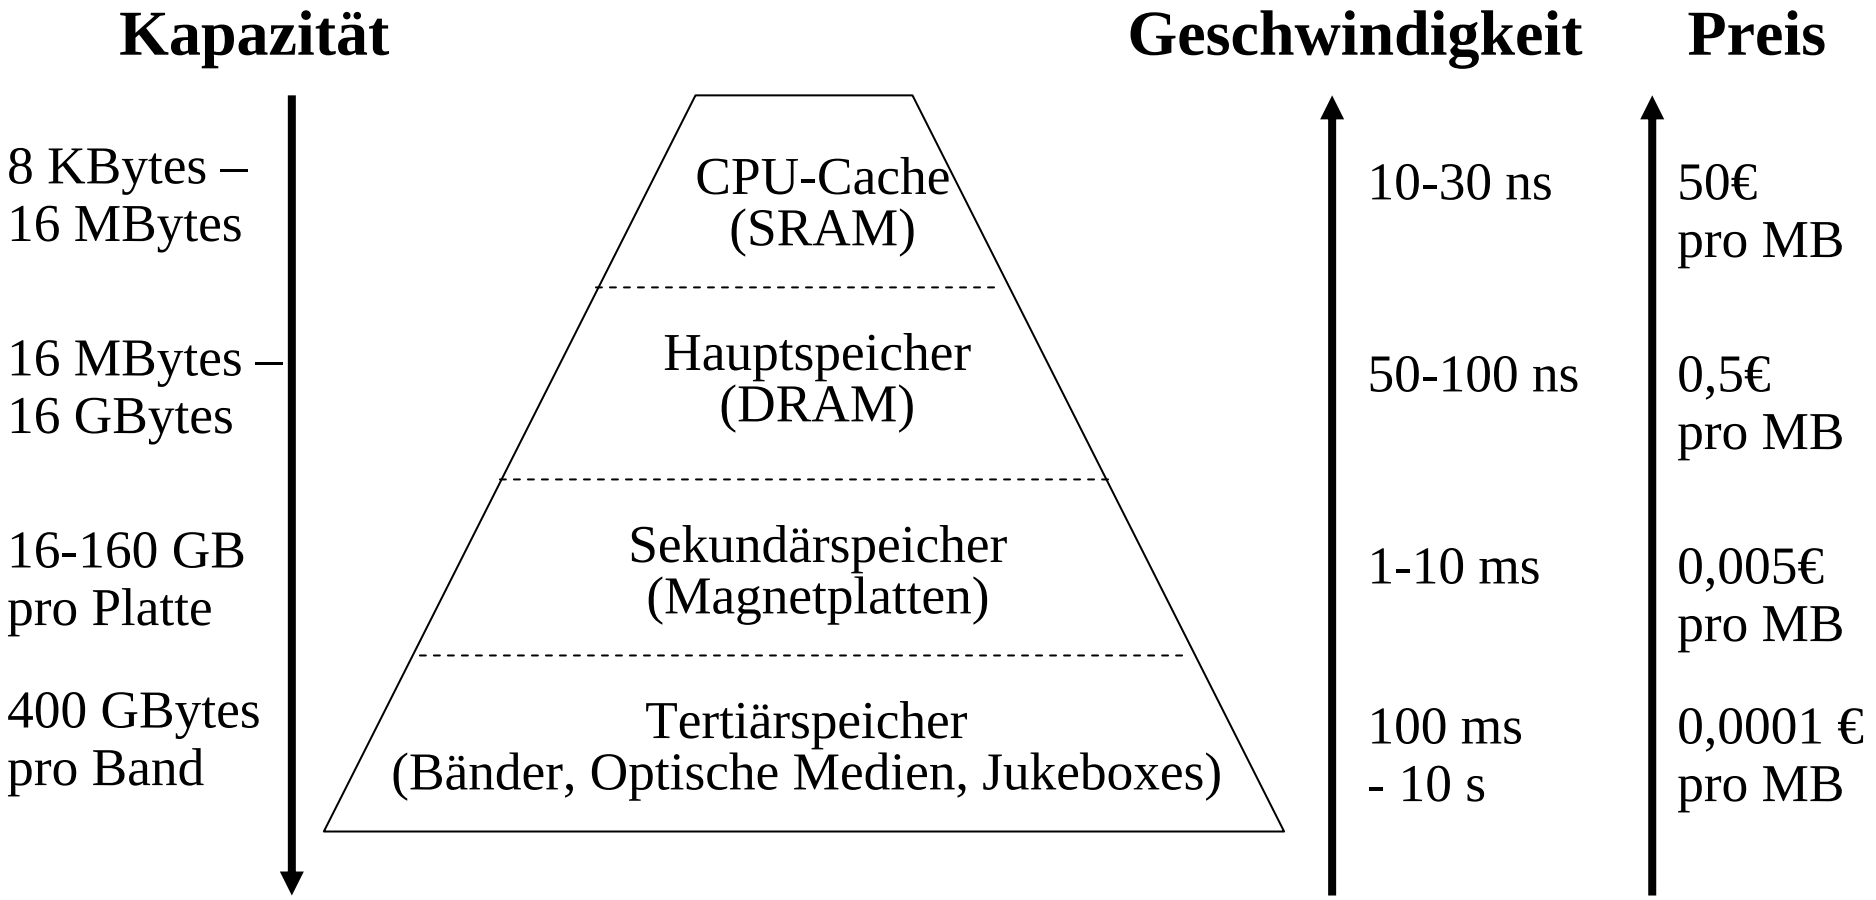

14.2 Wie auf Daten effizient zugegriffen wird (Indexstrukturen)

CREATE [UNIQUE] INDEX index-name
ON table (column, {, column ...})

zur Beschleunigung von:

- *Exact-Match-Selektionen*: A1=wert1 $\wedge$ A2=wert2 $\wedge$ ... $\wedge$ Ak=wertk
  (z.B. City = 'Miami' oder City = 'Paris' $\wedge$ State = 'Texas')
- *Bereichs-Selektionen*: u1 $\leq$ A1 $\leq$ o1 $\wedge$ ... $\wedge$ uk $\leq$ Ak $\leq$ ok
  (z.B. 21 $\leq$ Age $\leq$ 30 oder 21 $\leq$ Age $\leq$ 30 $\wedge$ Salary $\geq$ 100 000)
- *Präfix-Match-Selektionen*:
  u1 $\leq$ A1 $\leq$ o1 $\wedge$ u2 $\leq$ A2 $\leq$ o2 $\wedge$ ... $\wedge$ uj $\leq$ Aj $\leq$ oj (mit j < k)
  (z.B. 21 $\leq$ Age $\leq$ 30 bei einem Index über Age, Salary).

Welche Indexstrukturen für welche Attributkombinationen?

$\rightarrow$ Problem des physischen Datenbankentwurfs
für DBA oder „Index Wizard“ !

Binäre Suchbäume (für Hauptspeicher)

Schlüssel (mit den ihnen zugeordneten Daten)
bilden die Knoten eines binären Baums
mit der Invariante:

für jeden Knoten t mit Schlüssel t.key und alle Knoten l im linken Teilbaum von t, t.left, und alle Knoten r im rechten Teilbaum von t gilt: $l.key \leq t.key \leq r.key$

Suchen eines Schlüssels k:

Traversieren des Pfades von der Wurzel bis zu k bzw. einem Blatt

Einfügen eines Schlüssels k:

Suchen von k und Anfügen eines neuen Blatts

Löschen eines Schlüssel k:

Ersetzen von k durch das „rechteste“ Blatt links von k

Worst-Case-Suchzeit für n Schlüssel: O(n)
bei geeigneten Rebalancierungsalgorithmen
(AVL-Bäume, Rot-Schwarz-Bäume, usw.): O(log n)

Beispiel für einen binären Suchbaum

London, Paris, Madrid, Kopenhagen, Lissabon, Zürich, Frankfurt, Wien, Amsterdam, Florenz

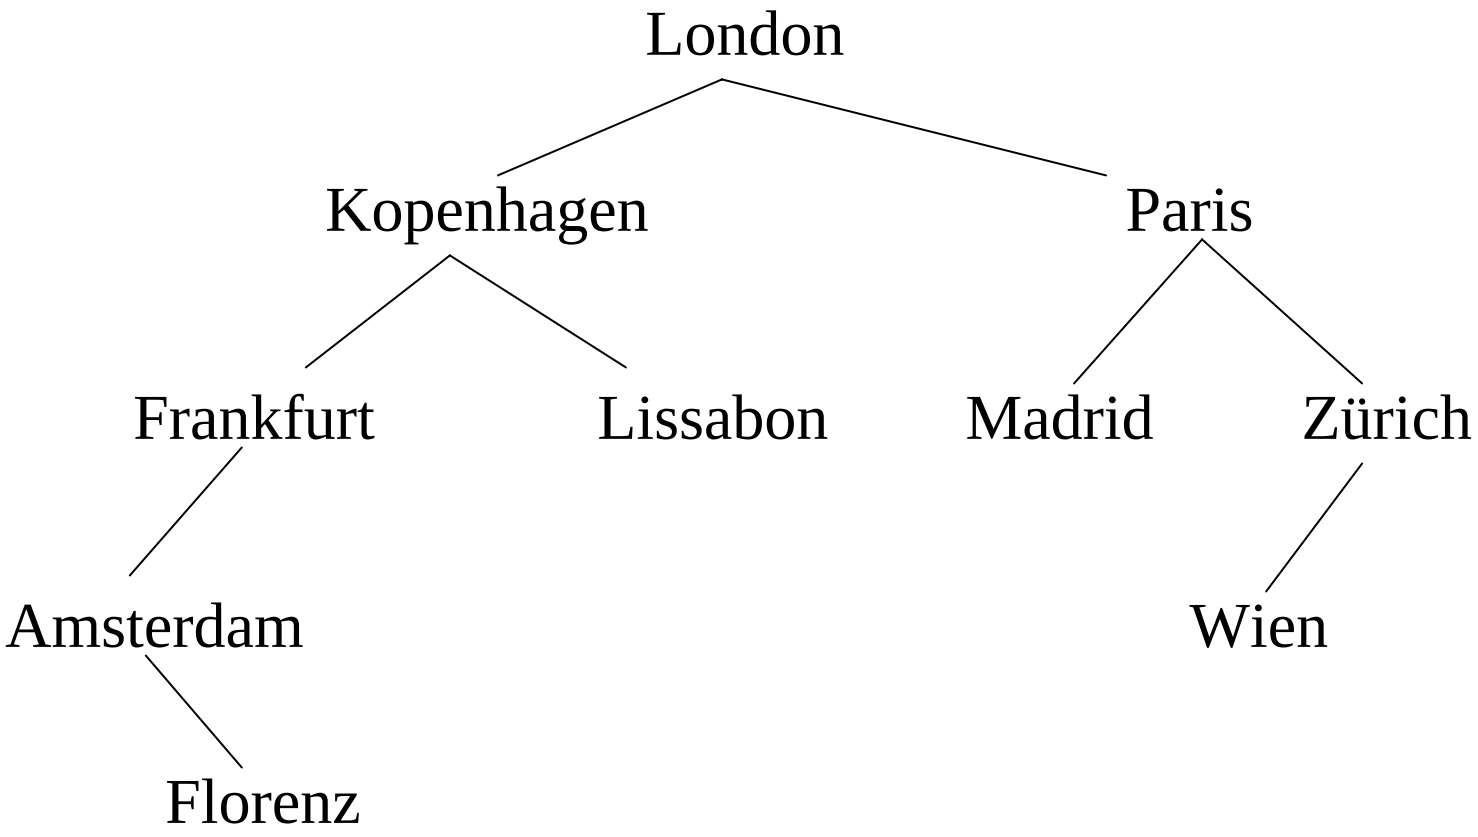

B*-Bäume: Seitenstrukturierte Mehrwegbäume

- Hohler Mehrwegebaum mit hohem Fanout ($\Rightarrow$ kleiner Tiefe)
- Knoten = Seite auf Platte
- Knoteninhalt:
  - (Sohnzeiger, Schlüssel)-Paare in inneren Knoten
  - Schlüssel (mit weiteren Daten) in Blättern
- perfekt balanciert: alle Blätter haben dieselbe Distanz zur Wurzel
- Sucheffizienz $O(\log_k n/C)$ Seitenzugriffe (Platten-I/Os)
  bei n Schlüsseln, Seitenkapazität C und Fanout k
  pro Baumniveau: bestimme kleinsten Schlüssel $\geq$ q und
  suche weiter im Teilbaum links von q
- Kosten einer Einfüge- oder Löschoperation $O(\log_k n/C)$
- mittlere Speicherplatzauslastung bei zufälligem Einfügen: $\ln 2 \approx 0.69$

B*-Baum-Beispiel

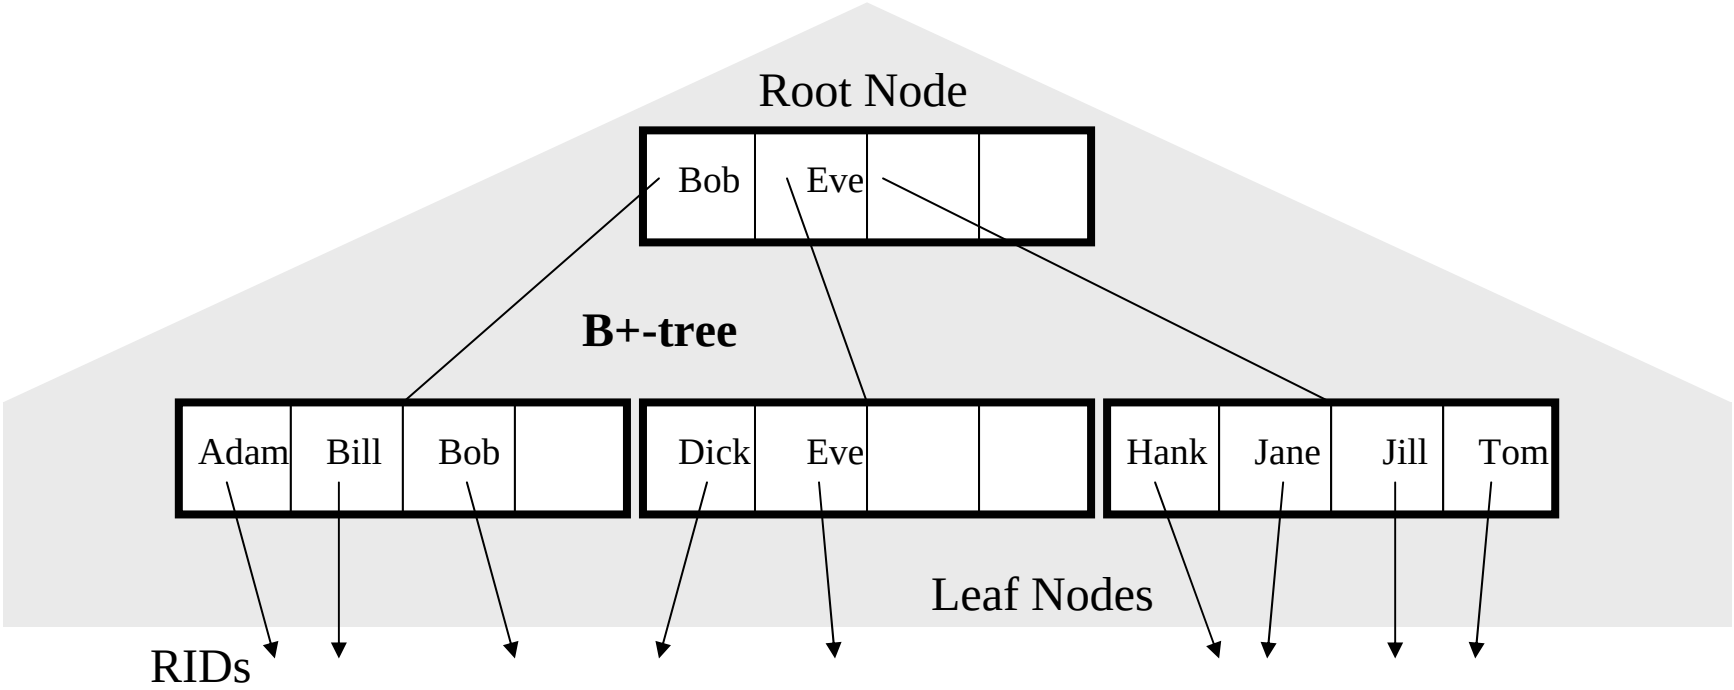

B*-Baum-Beispiel (2)

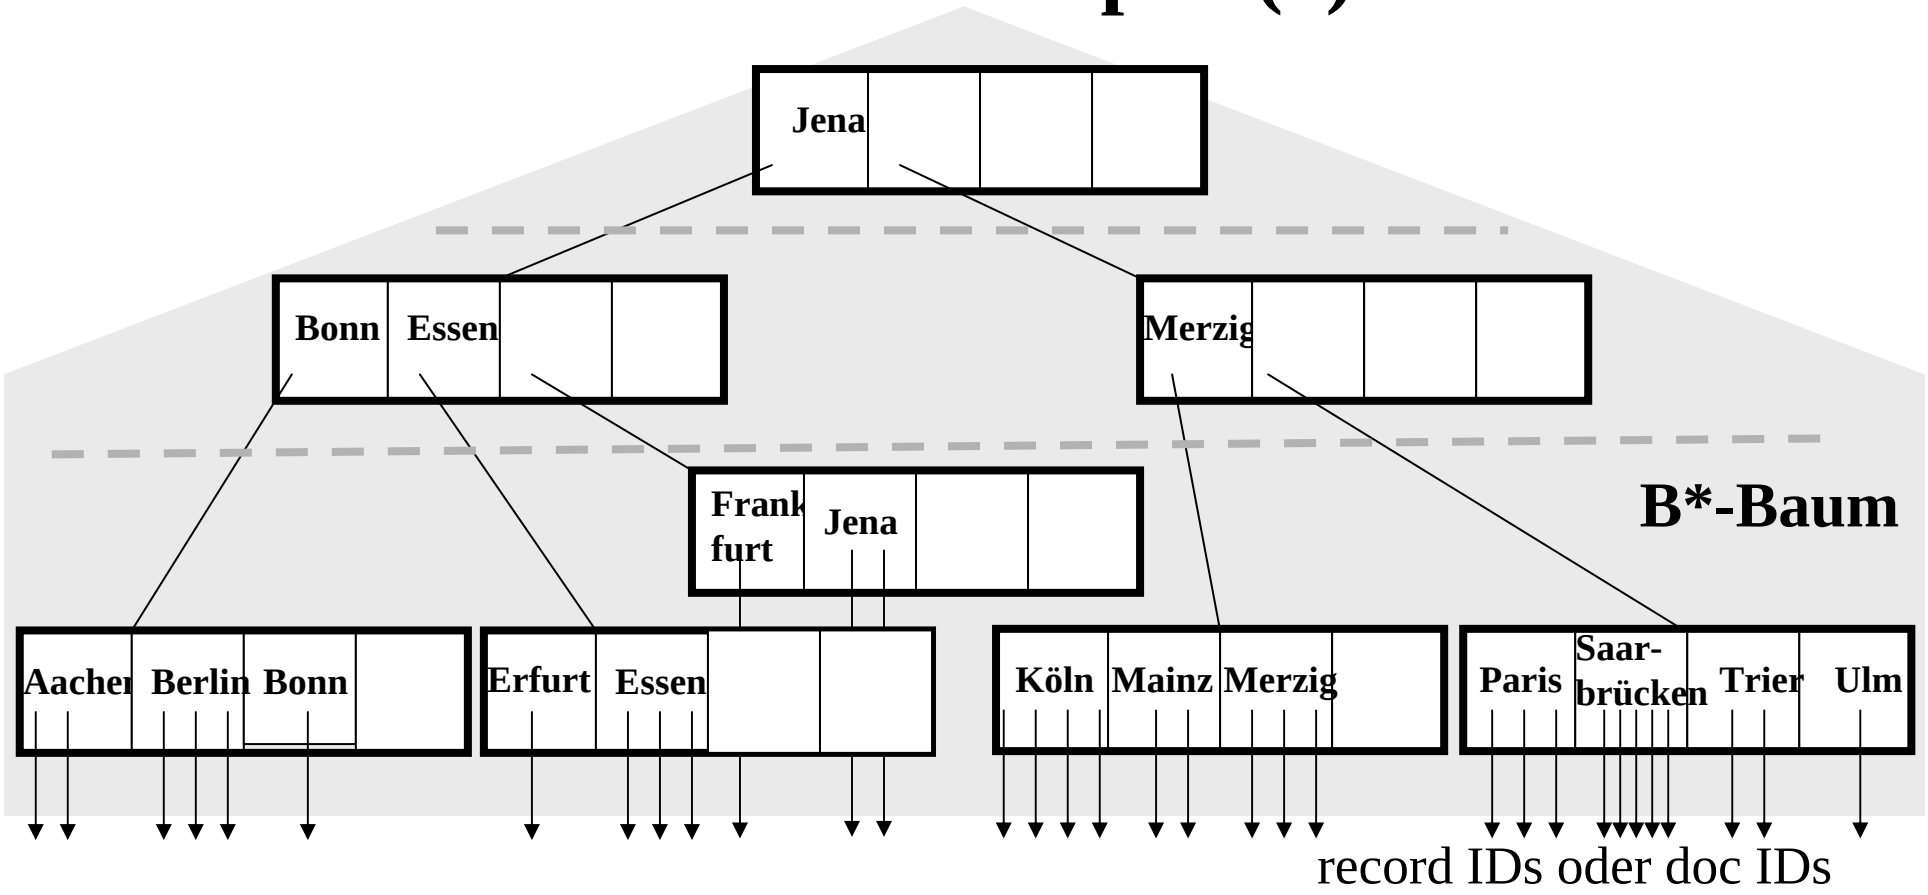

B*-Baum-Definition

Ein Mehrwegbaum heißt B*-Baum der Ordnung (m, m*), wenn gilt:

- Jeder Nichtblattknoten außer der Wurzel enthält mindestens m ≥1 und höchstens 2m Schlüssel (Wegweiser).
- Ein Nichtblattknoten mit k Schlüssel x_1, ..., x_k hat genau k+1 Söhne t_1, ..., t_{k+1}, so dass
  - für alle Schlüssel s im Teilbaum t_i ($2 \le i \le k$) gilt $x_{i-1} < s \le x_i$ und
  - für alle Schlüssel s im Teilbaum t_1 gilt $s \le x_1$ und
  - für alle Schlüssel im Teilbaum t_{k+1} gilt xk < s.
- Alle Blätter haben dasselbe Niveau (Distanz von der Wurzel)
- Jedes Blatt enthält mindestens m* ≥1 und höchstens 2m* Schlüssel.

Achtung: Implementierungen verwenden **variabel lange Schlüssel** und eine Knotenkapazität in Bytes statt Konstanten 2m und 2m*

Sonderfall m=m*=1: **2-3-Bäume** als Hauptspeicherdatenstruktur

Pseudocode für B*-Baum-Suche

Suchen von Schlüssel s in B*-Baum mit Wurzel t:

```
  t habe k Schlüssel x1, ..., xk und k+1 Söhne t1, ..., t(k+1)
  (letzteres sofern t kein Blatt ist)
  Bestimme den kleinsten Schlüssel xi, so daß s ≤ xi
  if s = xi (für ein i ≤ k) und t ist ein Blatt
  then Schlüssel gefunden
  else
      if t ist kein Blatt then
          if s ≤ xi (für ein i ≤ k)
          then suche s im Teilbaum ti
          else suche s im Teilbaum t(k+1) fi
      else Schlüssel s ist nicht vorhanden fi
   fi
```

B*-Baum-Suche (1)

Query
q: Mainz

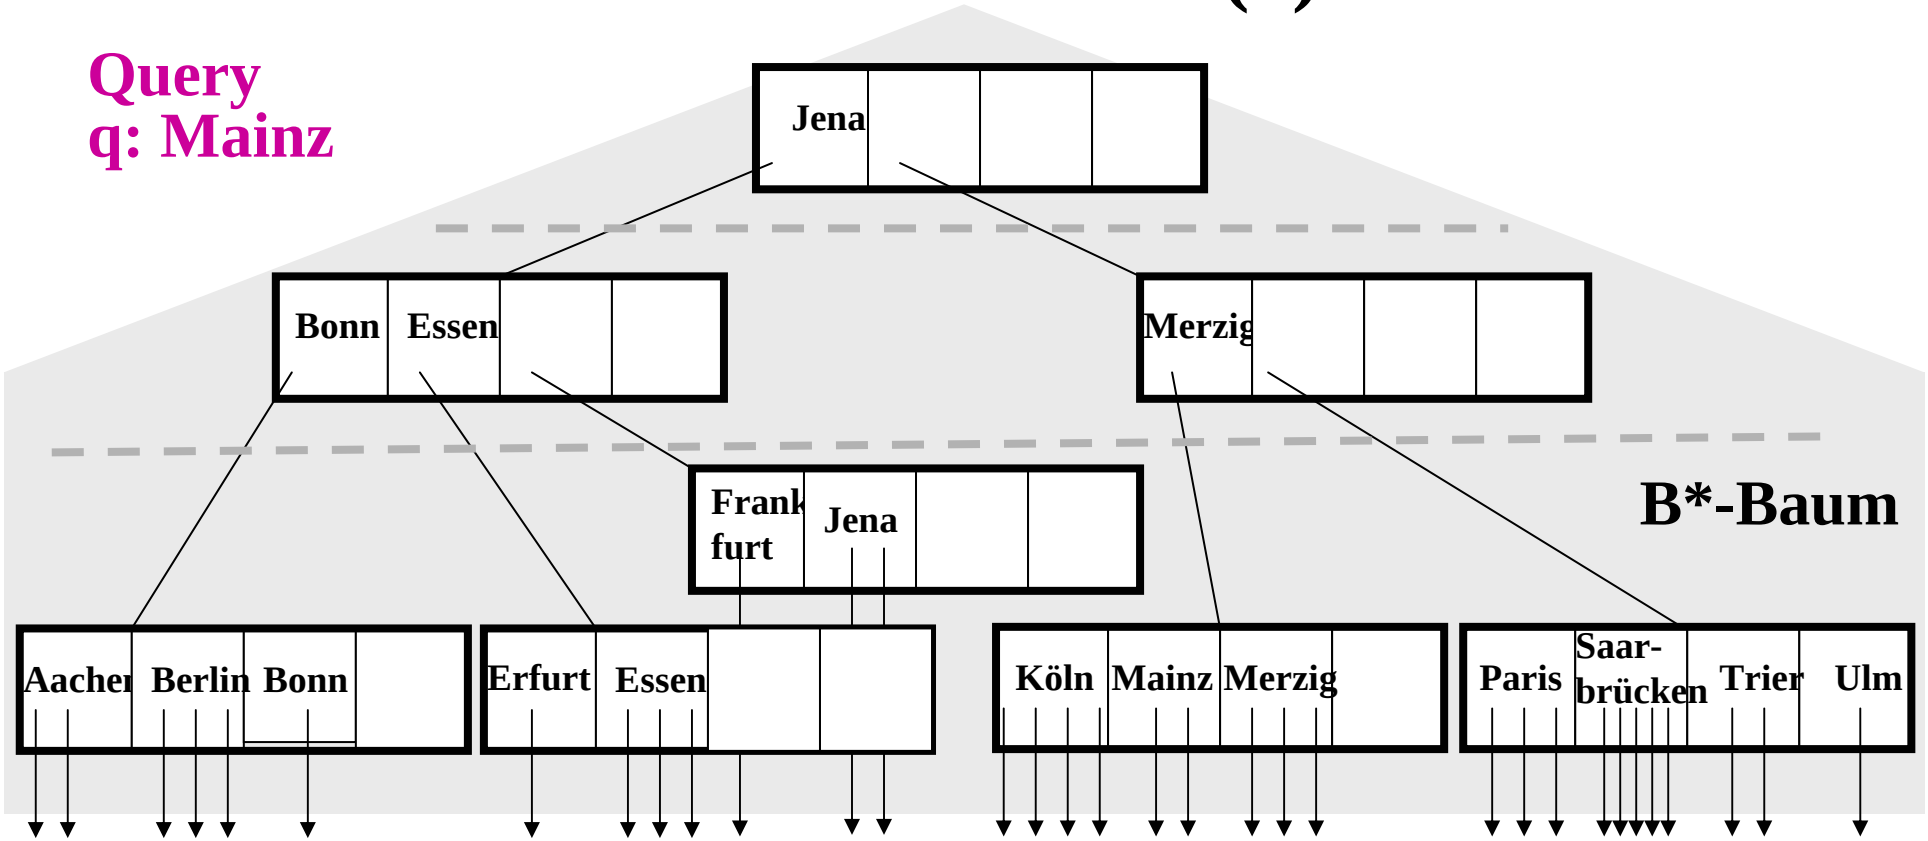

B*-Baum-Suche (2)

Query
q: Gießen

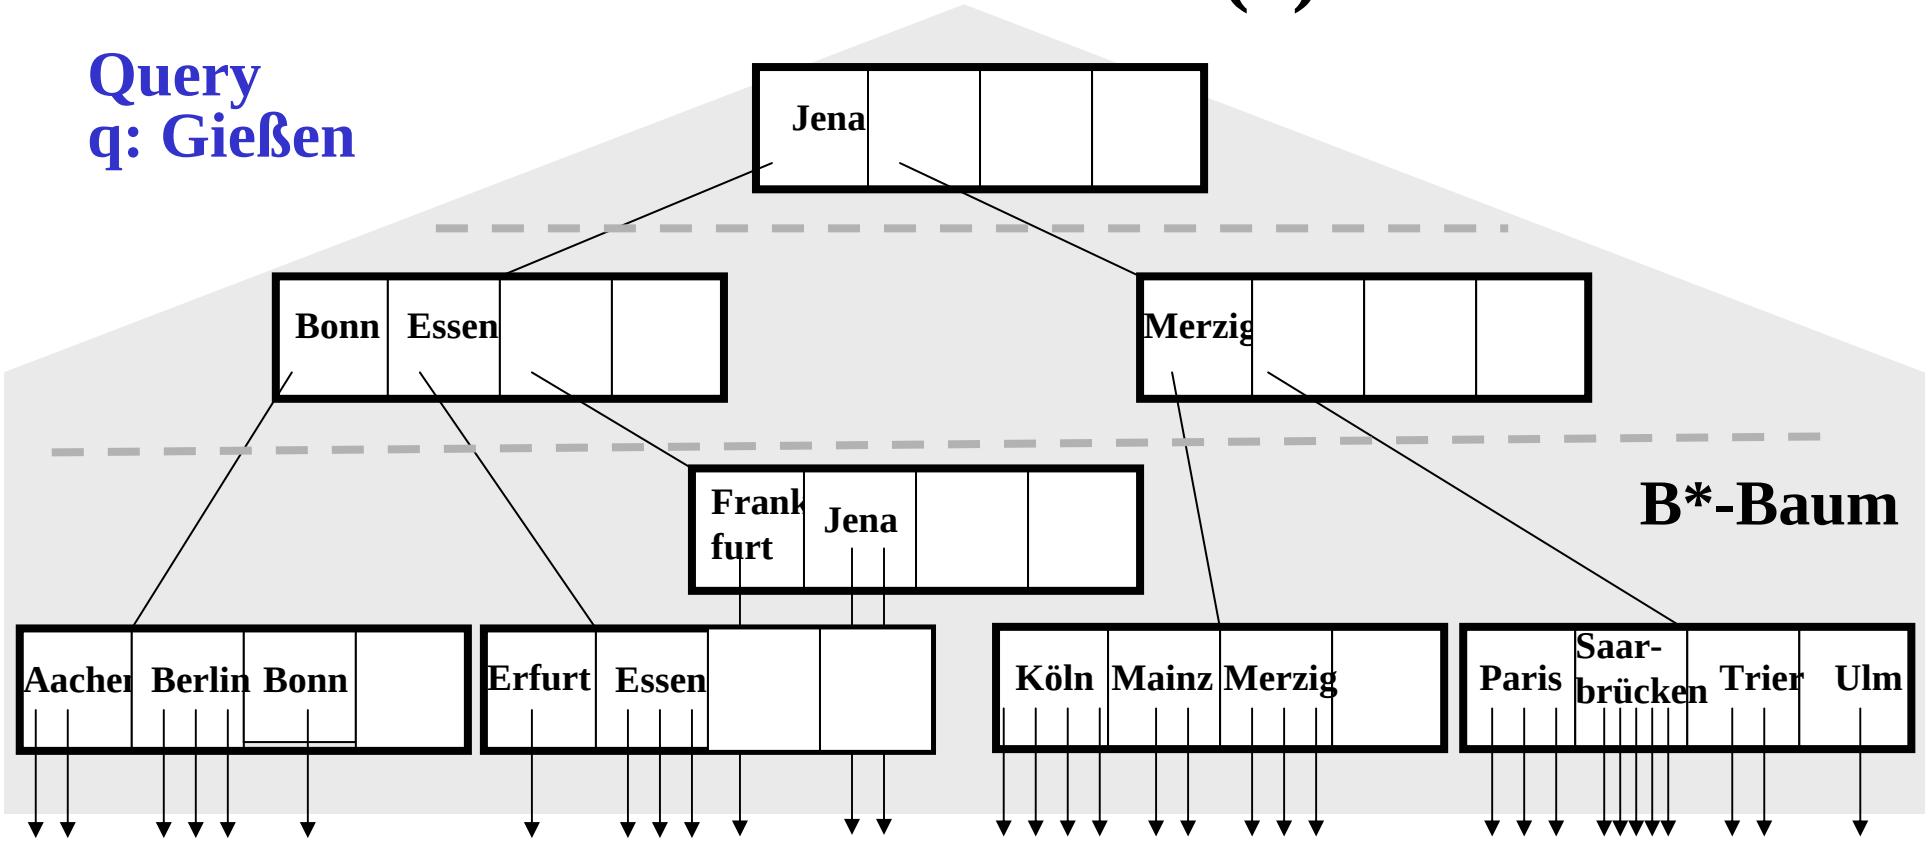

Pseudocode für Einfügen in B*-Baum (Grow&Post)

```
Suche nach einzufügendem Schlüssel e
if e ist noch nicht vorhanden then
  Sei t das Blatt, bei dem die Suche erfolglos geendet hat
  repeat
    if t hat weniger als 2m* bzw. 2m Schlüssel (d.h. ist nicht voll)
    then füge e in t ein
    else /* Knoten-Split */
      Bestimme Median s der 2m* +1 bzw. 2m+1 Schlüssel inkl. e
      Erzeuge Bruderknoten t‘ /* Grow-Phase */
      if t ist Blattknoten then
         Speichere Schlüssel ≤ s in t und Schlüssel > s in t‘
      else Speichere Schlüssel < s (mit Sohnzeigern) in t und
                          Schlüssel > s (mit Sohnzeigern) in t‘ fi
      if t ist Wurzel /* Post-Phase */
      then Erzeuge neue Wurzel r mit Schlüssel s und Zeigern auf t und t‘
      else Betrachte Vater von t als neues t und s (mit Zeiger auf t‘) als e fi
    fi
  until kein Knoten-Split mehr erfolgt
fi
```

Beispiel: Einfügen in B*-Baum

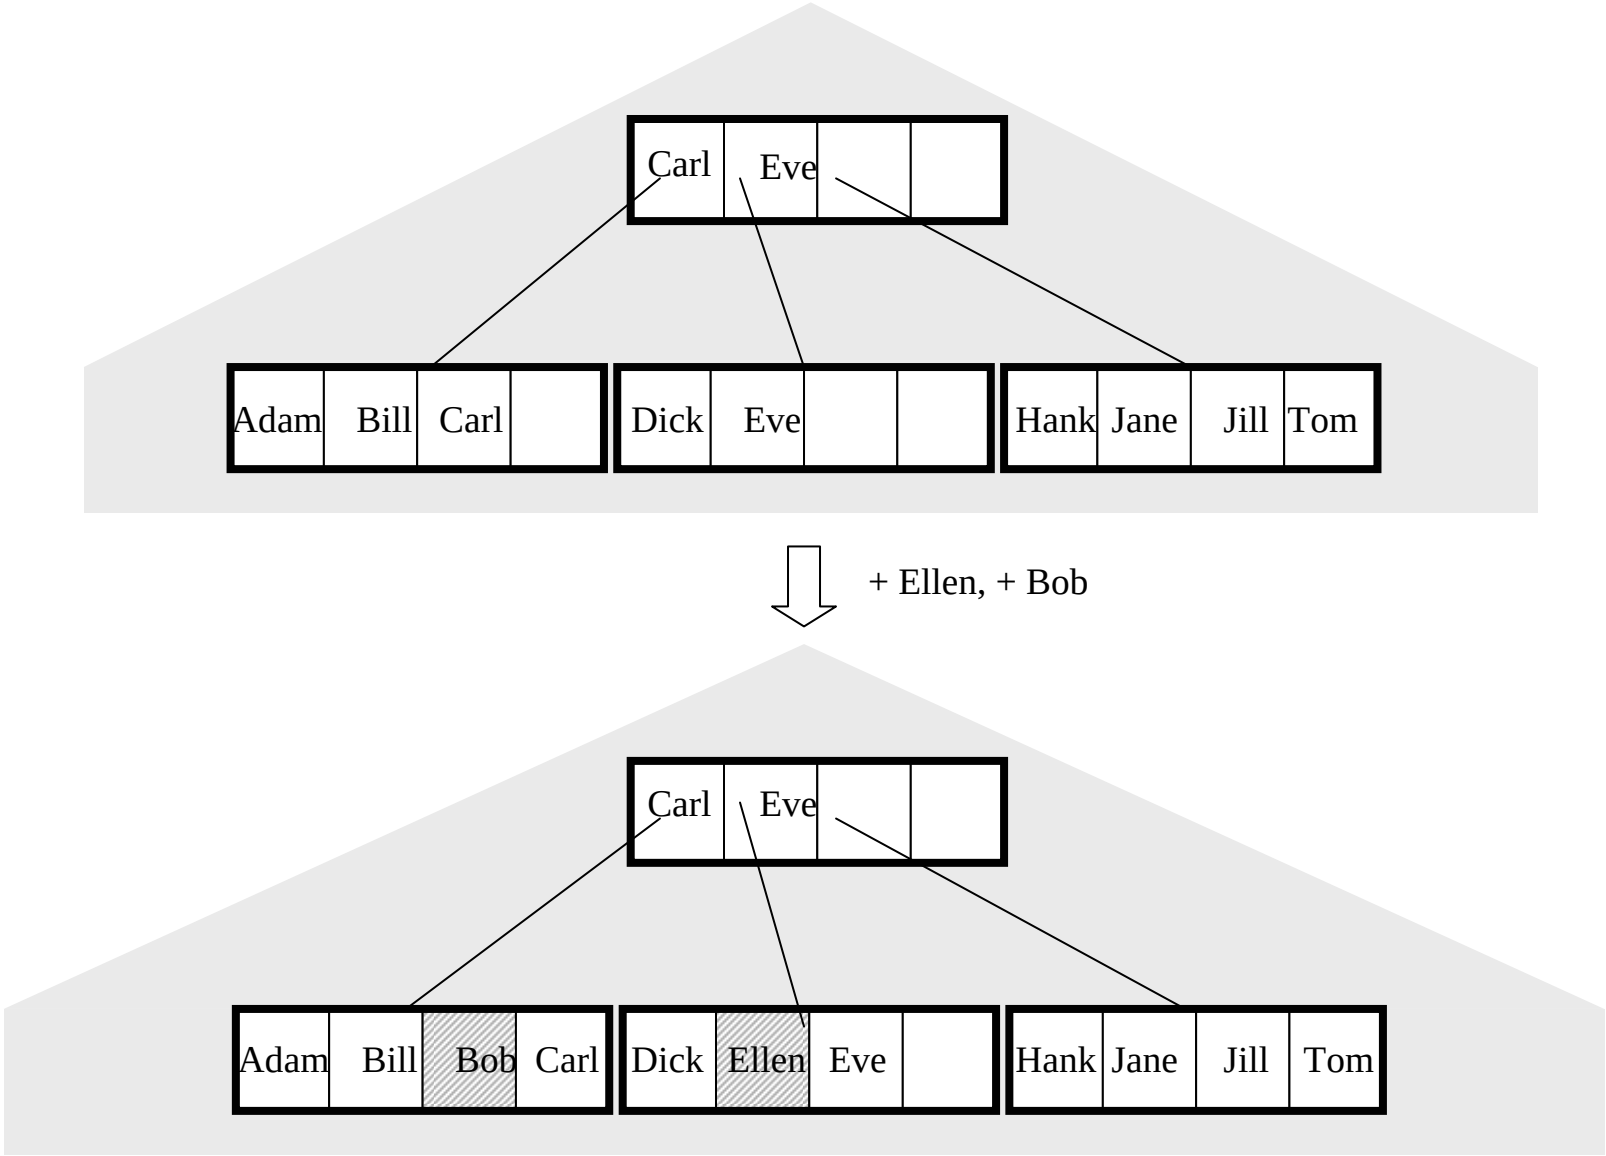

Beispiel: Einfügen in B*-Baum mit Blatt-Split

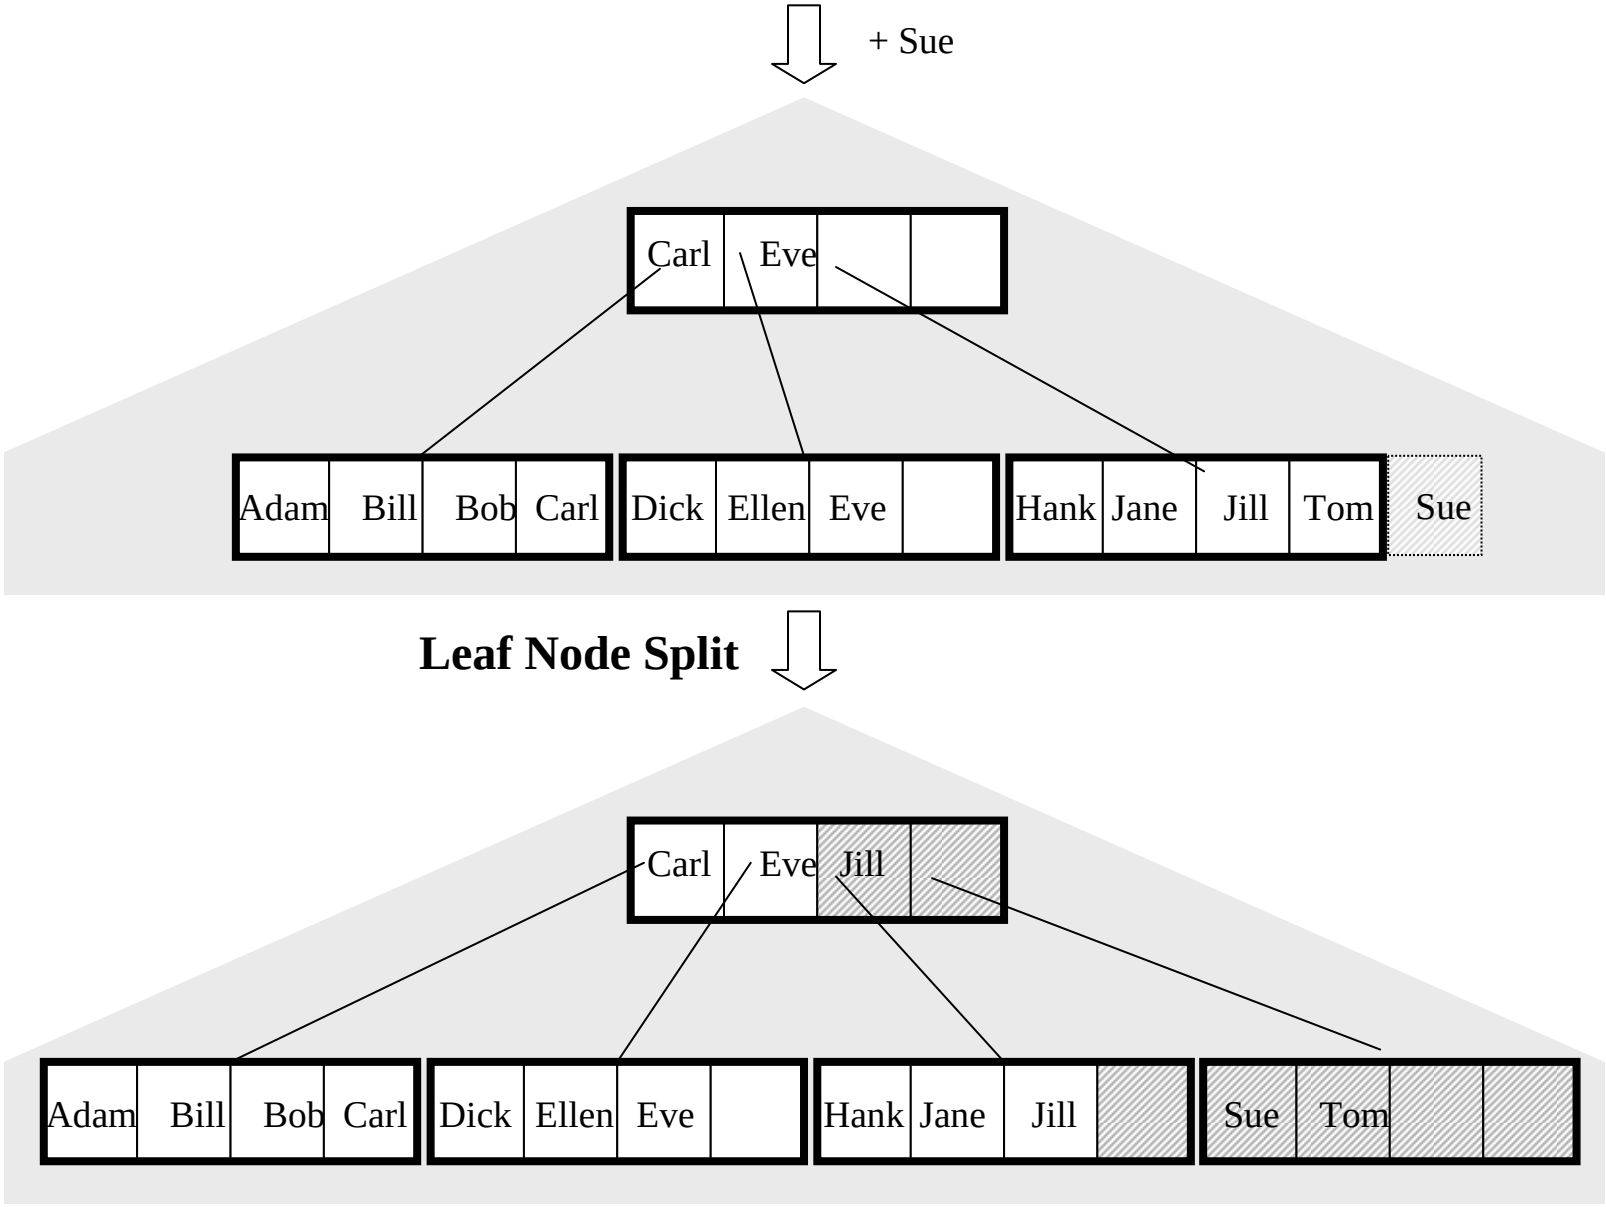

Beispiel: Einfügen in B*-Baum mit Wurzel-Split

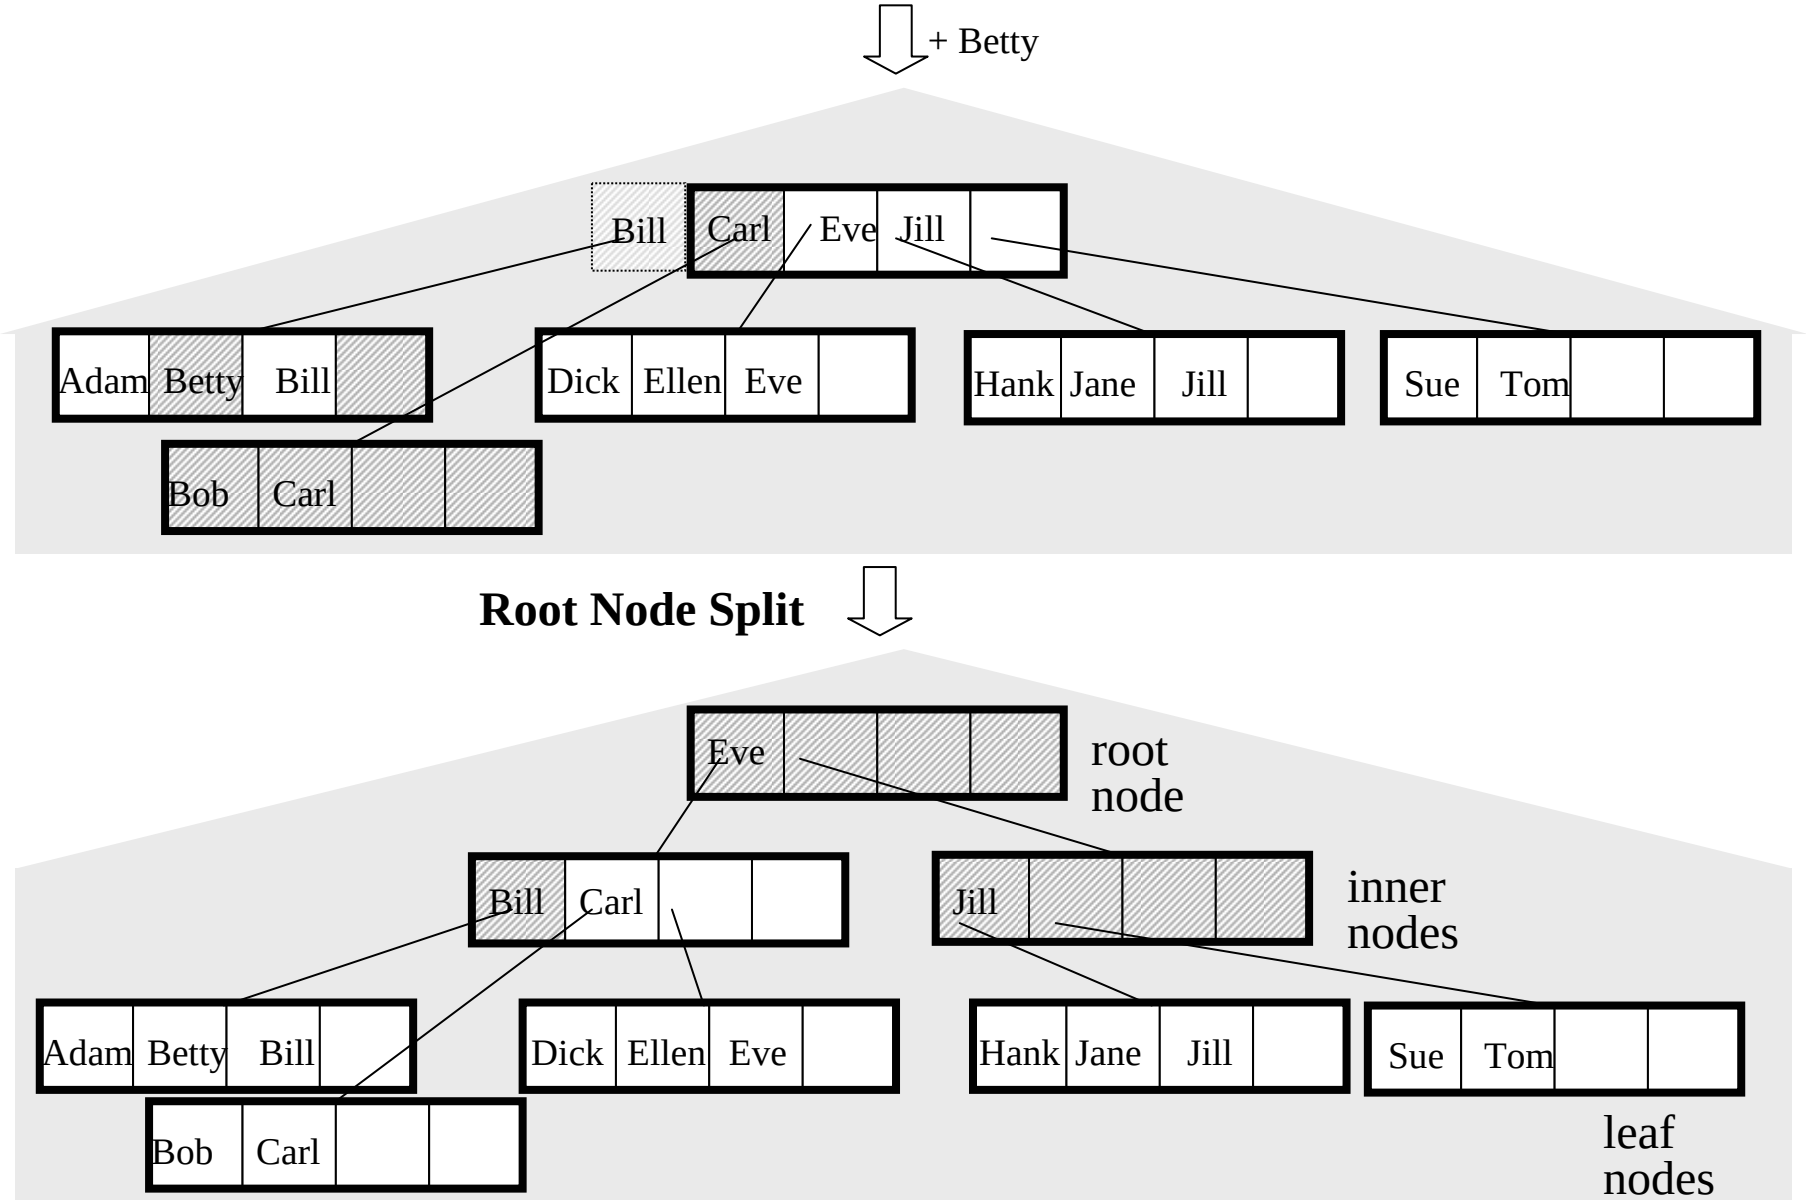

Präfix-B*-Bäume für Strings als Schlüssel

Schlüssel in inneren Knoten sind nur **Wegweiser (Router)** zur Partitionierung des Schlüsselraums.
Statt xi = max{s: s ist ein Schlüssel im Teilbaum ti} genügt ein (kürzerer) Wegweiser xi‘ mit si ≤ xi‘< s(i+1) für alle si in ti und alle s(i+1) in t(i+1).
Eine Wahl wäre xi‘ = kürzester String mit der o.a. Eigenschaft.
→ höherer Fanout, potentiell kleinere Baumhöhe

Beispiel:

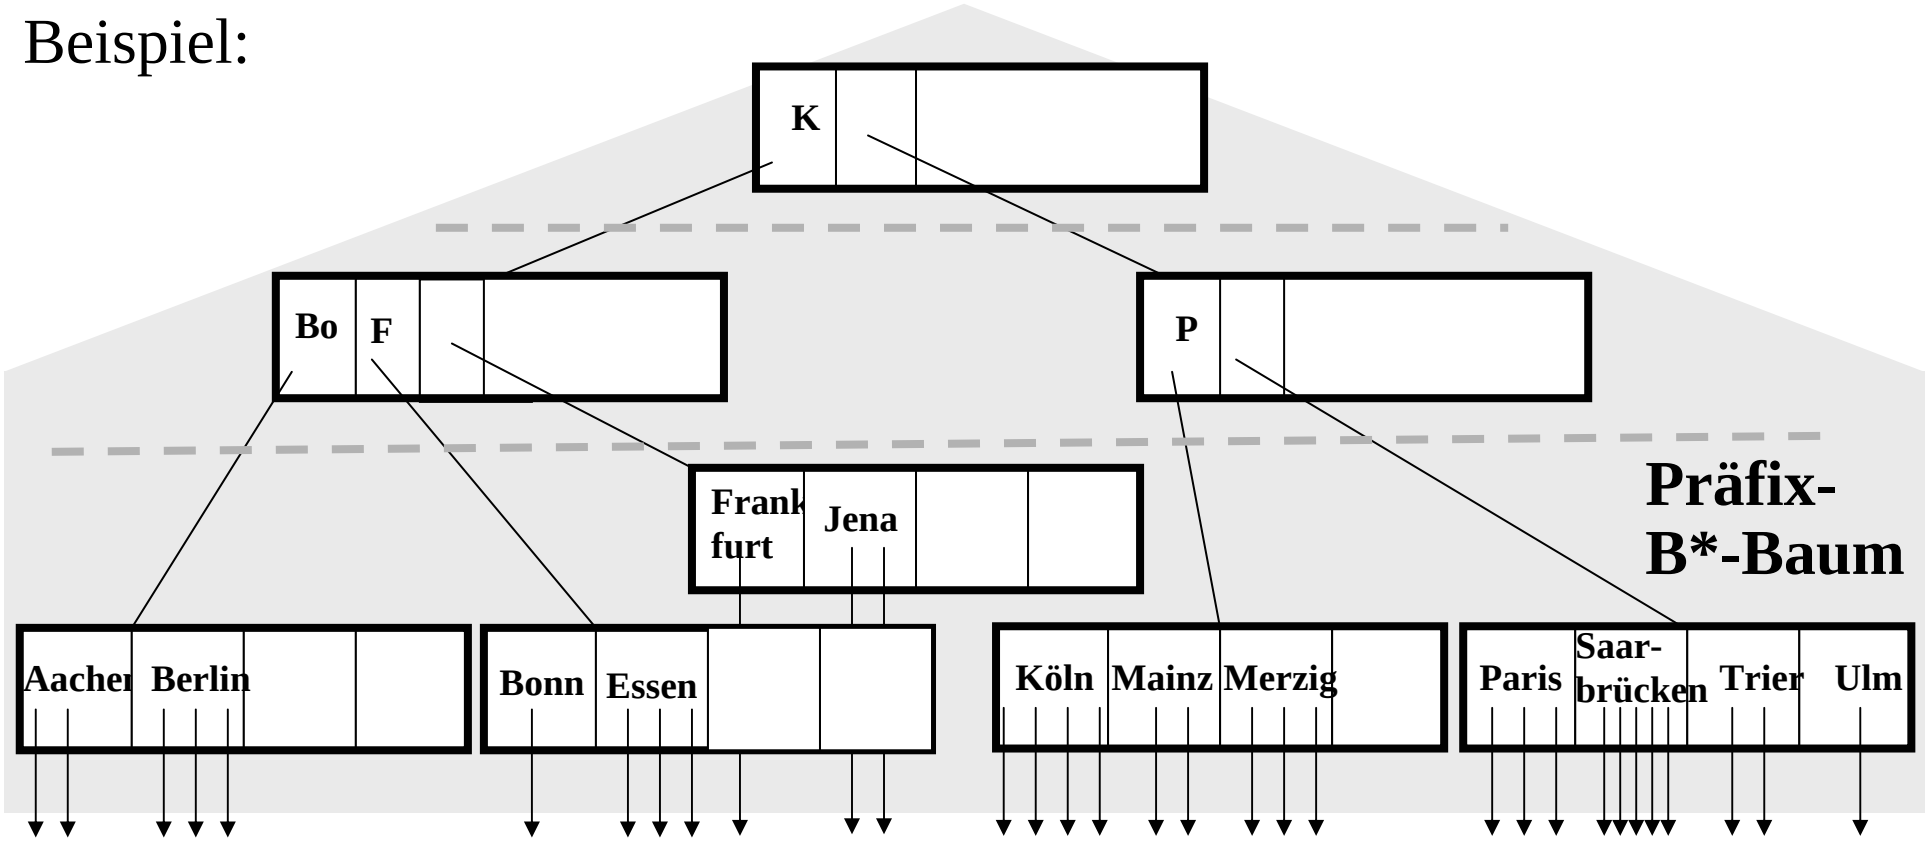

14.3 Wie Anfragen ausgeführt werden

Interne Repräsentation einer Anfrage bzw. eines Ausführungsplans als Operatorbaum mit algebraischen Operatoren der Art:

- Table-Scan
- RID-Zugriff
- Index-Scan
- Sortieren
- Durchschnitt, Vereinigung, Differenz
- Filter (Selektion)
- Projektion für Mengen
- Projektion für Multimengen
- usw.

Ausführungspläne (Operatorbäume): Beispiel 1

```
Select Name, City, Zipcode, Street
From Person
Where Age < 30
And City = "Austin"
```

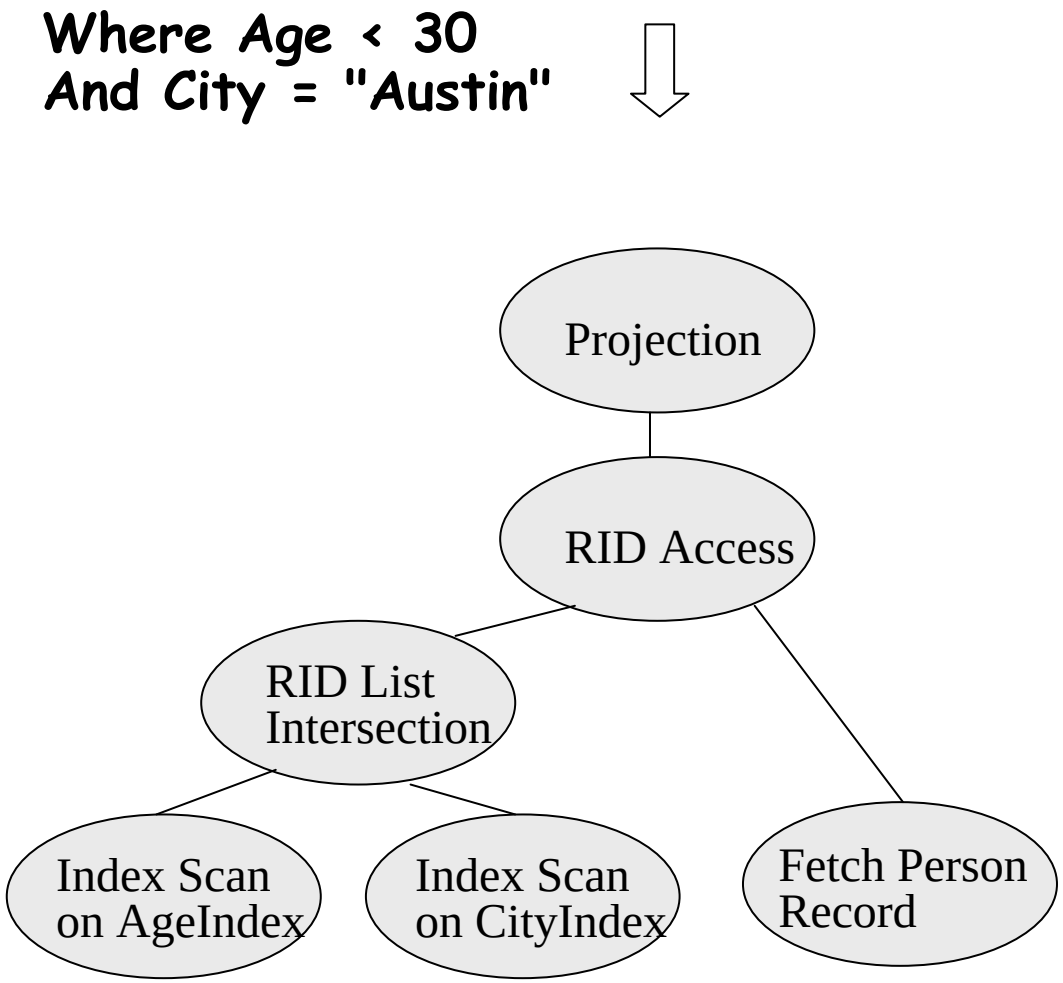

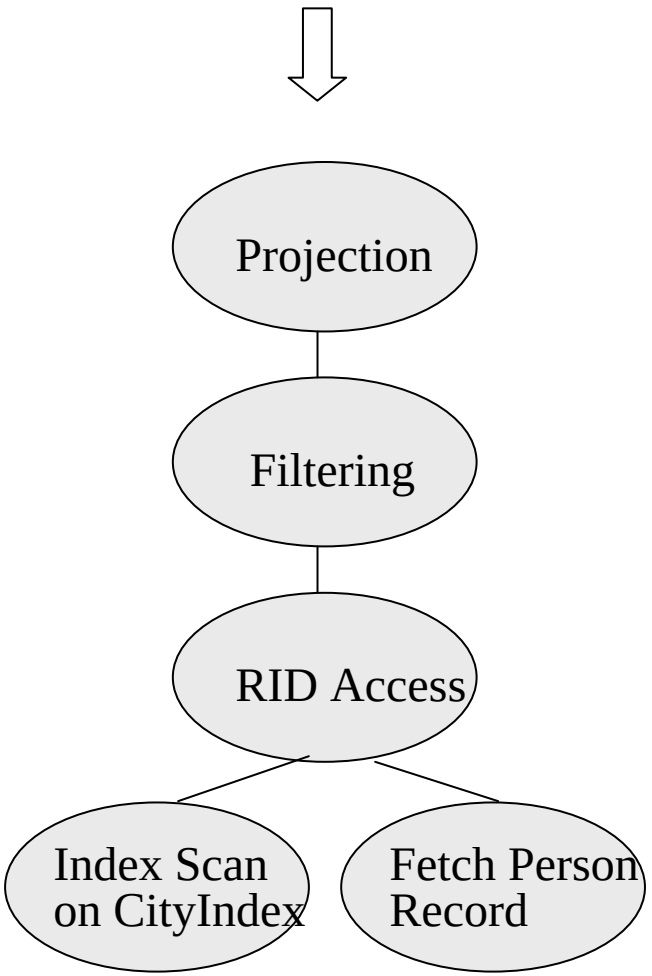

Ausführungspläne (Operatorbäume): Beispiel 1

```
Select Name, City, Zipcode, Street
From Person
Where Age < 30
And City = "Austin"
```

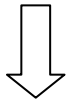

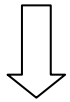

in Oracle8i:

```
SELECT STATEMENT
  TABLE ACCESS BY ROWID Person
    INTERSECT
      INDEX RANGE SCAN AgeIndex
      INDEX RANGE SCAN CityIndex
```

```
SELECT STATEMENT
  FILTER
    TABLE ACCESS BY ROWID Person
      INDEX RANGE SCAN CityIndex
```

Query-Optimierung

Weitere interne Operatoren als algorithmische Alternativen:

- Nested-Loop-Join
- Merge-Join
- Hash-Join
- Gruppierung mit Aggregation
- Hash-Gruppierung mit Aggregation
- usw.

Der Query-Optimierer

- generiert algebraisch äquivalente Ausführungspläne,
- bewertet deren Ausführungskosten (insbesondere #Plattenzugriffe)
- und wählt den (vermutlich) besten Plan aus.

Ausführungspläne (Operatorbäume): Beispiel 2

```
SELECT KNr, Name FROM Kunden K, Verkäufe V, Bücher B
WHERE K.Ort = „Saarbrücken“
AND K.KNr = V.KNr AND V.ISBN = B.ISBN
AND B.Kategorie = „Politik“
```

z.B.:

Query-Optimierer

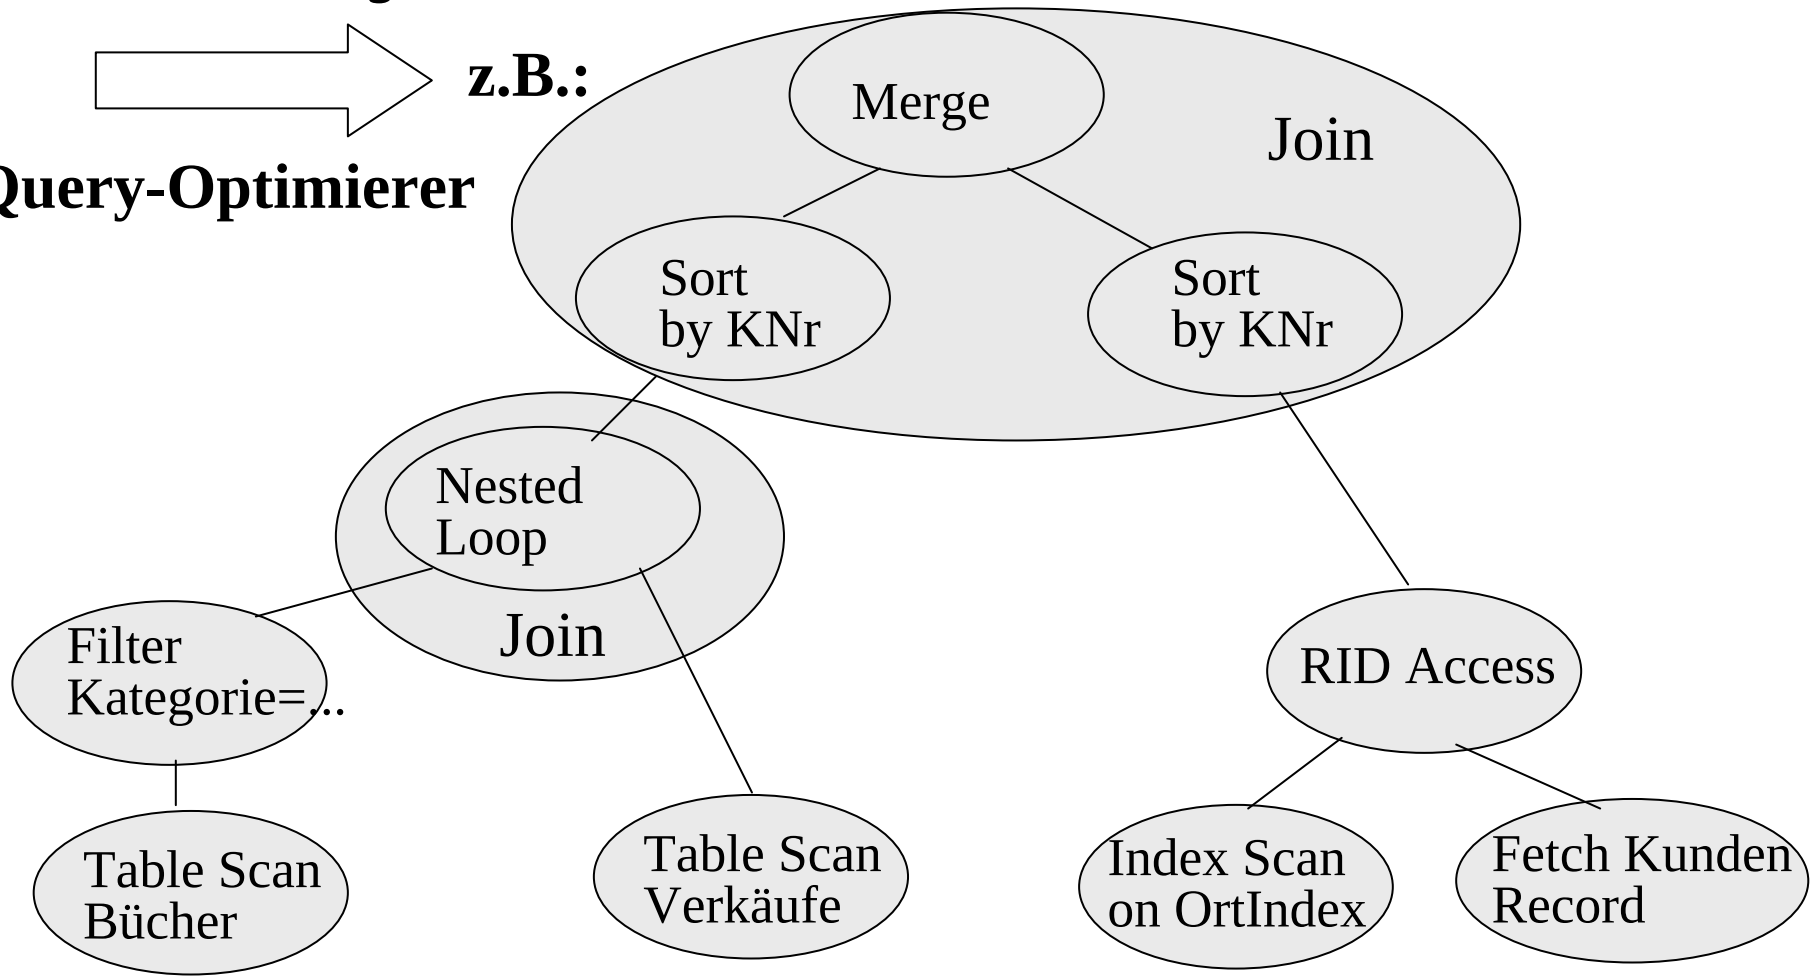

Ausführungspläne (Operatorbäume): Beispiel 2

```
SELECT KNr, Name FROM Kunden K, Verkäufe V, Bücher B
WHERE K.Ort = „Saarbrücken“
AND K.KNr = V.KNr AND V.ISBN = B.ISBN
AND B.Kategorie = „Politik“
```

Repräsentation in Oracle8i:

```
SELECT STATEMENT
    MERGE JOIN
        SORT
            NESTED LOOP
                FILTER
                    TABLE ACCESS   FULL          Bücher
                TABLE ACCESS       FULL          Verkäufe
         SORT
            TABLE ACCESS           BY ROWID      Kunden
                INDEX RANGE SCAN                 OrtIndex
```