4. Speicherungsstrukturen

- **Freispeicherverwaltung**
  - im Segment
  - in der Seite
- **Externspeicherbasierte Satzadressierung**
  - TID
  - Zuordnungstabelle
  - Indexierung von Tabellen (Satzmengen)
- **Hauptspeicherbasierte Satzadressierung**
  - Klassifikation der Lösungskonzepte
  - *Pointer-Swizzling*-Verfahren
- **Abbildung von Sätzen**
  - feste/variable Felder
  - Partitionierung
- **Speicherungsstrukturen für komplexe Objekte**
  - Listen- und Mengenkonstruktoren
  - Tupelkonstruktoren

Speicherungsstrukturen

- **Operationen**

  insert <record> at <location> with <database-key>

  retrieve <record> with <database-key>

  add <entry> to <B*-tree>

  retrieve <address-list> from <B*-tree> for <value>

Abbildungsfunktionen

- Satz-Identifikator $\leftrightarrow$ address
- Attributwert $\leftrightarrow$ record-id.list
- Satz-Identifikator $\leftrightarrow$ record-id.list
- Adresse $\leftrightarrow$ {occupied, free}

FIX P_i, FIX P_j, UNFIX P_j,

FIX P_k, UNFIX P_i, ...

- **Eigenschaften der oberen Schnittstelle**
  - Nicht-flüchtiger Speicher mit Adressierungshilfen
  - Freispeicher-Verwaltung
  - Adressierungsverfahren für physische Sätze
  - Adressierungsverfahren zwischen verschiedenen Sätzen
  - Zugriffspfade zur Realisierung von Inhaltsadressierbarkeit

Freispeicherverwaltung

- **Freispeicherverwaltung (FPA) für**
  - Externspeicher (Allokation von Dateien)
  - Segmente (Allokation von internen Sätzen)
  - Seiten (Verwaltung von belegten/freien Einträgen)

- **Für alle Seiten eines Segmentes:**
  - Einfügen/Ändern → Suche nach n freien Bytes
  - Löschen/Ändern → Freigabe oder Markierung von Speicherplatz
  - allgemein: Suche, Belegung und Freigabe von Speicherplatz in S_j

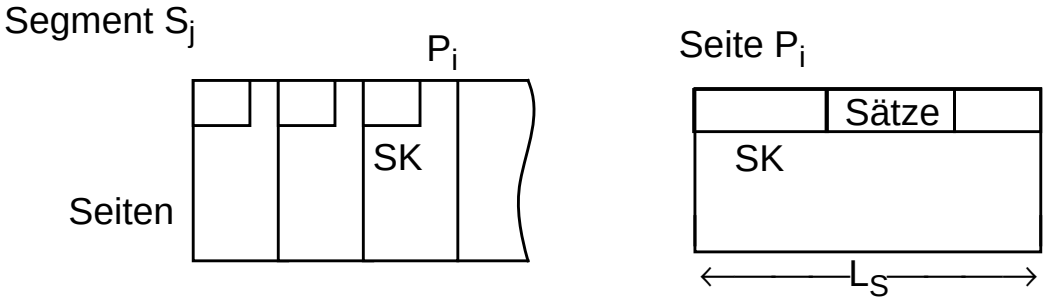

➥ in SK (Seitenkopf):

ID von P_i,

Freiplatz-Info,

Typ, Org.-Daten

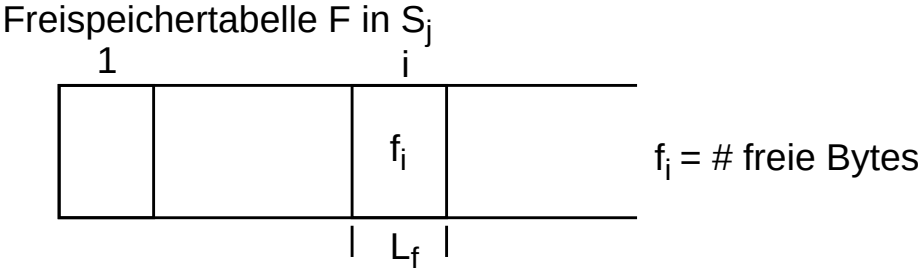

Freispeicherverwaltung (2)

- **Größe von F**

  Einträge pro Seite der Länge L_S

$$k = \left\lfloor \frac{L_S - L_{SK}}{L_f} \right\rfloor$$

  mit s=#Seiten im Segment

  ➥ $$n = \left\lceil \frac{s}{k} \right\rceil$$ Seiten für F

- **Lage von F**

  - Segmentanfang
  - äquidistante Verteilung $i \cdot k + 1$ (i=0,1,2,...)
  - Segmentende

- **Art der FPA**

  - exakt: $L_f = 2Bytes$
  - unscharf: $L_f = 1Byte$ (oder weniger)

  Einheiten von $f_i \rightarrow \lceil L_S / 256 \rceil$ - Vielfache

  bei $L_S = 4KB \rightarrow 16Bytes$

- **FPA innerhalb von P_i**

  - exaktes f_i in SK
  - zusammenhängende Verwaltung (Verschiebungen!)
  - Freispeicherkette (*best-fit* / *first-fit*)

Externspeicherbasierte Satzadressierung

- **Problemstellung**

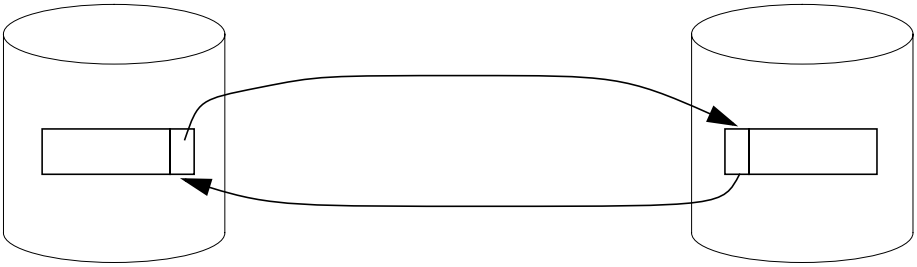

  - langfristige Speicherung der Datensätze
  - Vermeiden von „Technologieabhängigkeiten“
  - Unterstützung von Migration u. a.

- **Allgemeine Form einer Satzadresse**
  - DBID, SID, TID und ggf. Relationenkennzeichnung (RID)
  - Relation vollständig in einem Segment gespeichert: TID
    DBID, SID im DB-Katalog
  - Relation in mehreren Segmenten: SID, TID

- **Ziele der Adressierungstechnik:**
  - schneller, möglichst direkter Satzzugriff
  - hinreichend stabil gegen geringfügige Verschiebungen
    (Verschiebungen innerhalb einer Seite ohne Auswirkungen)
  - seltene oder keine Reorganisationen

- **Adressierung in Segmenten**
  - logisch zusammenhängender Adreßraum
  - direkte Adressierung (logische Byte-Adresse, RBA)

    ➥ instabil bei Verschiebungen

➥ deshalb indirekte Adressierung

Techniken zur externspeicherbasierten Satzadressierung

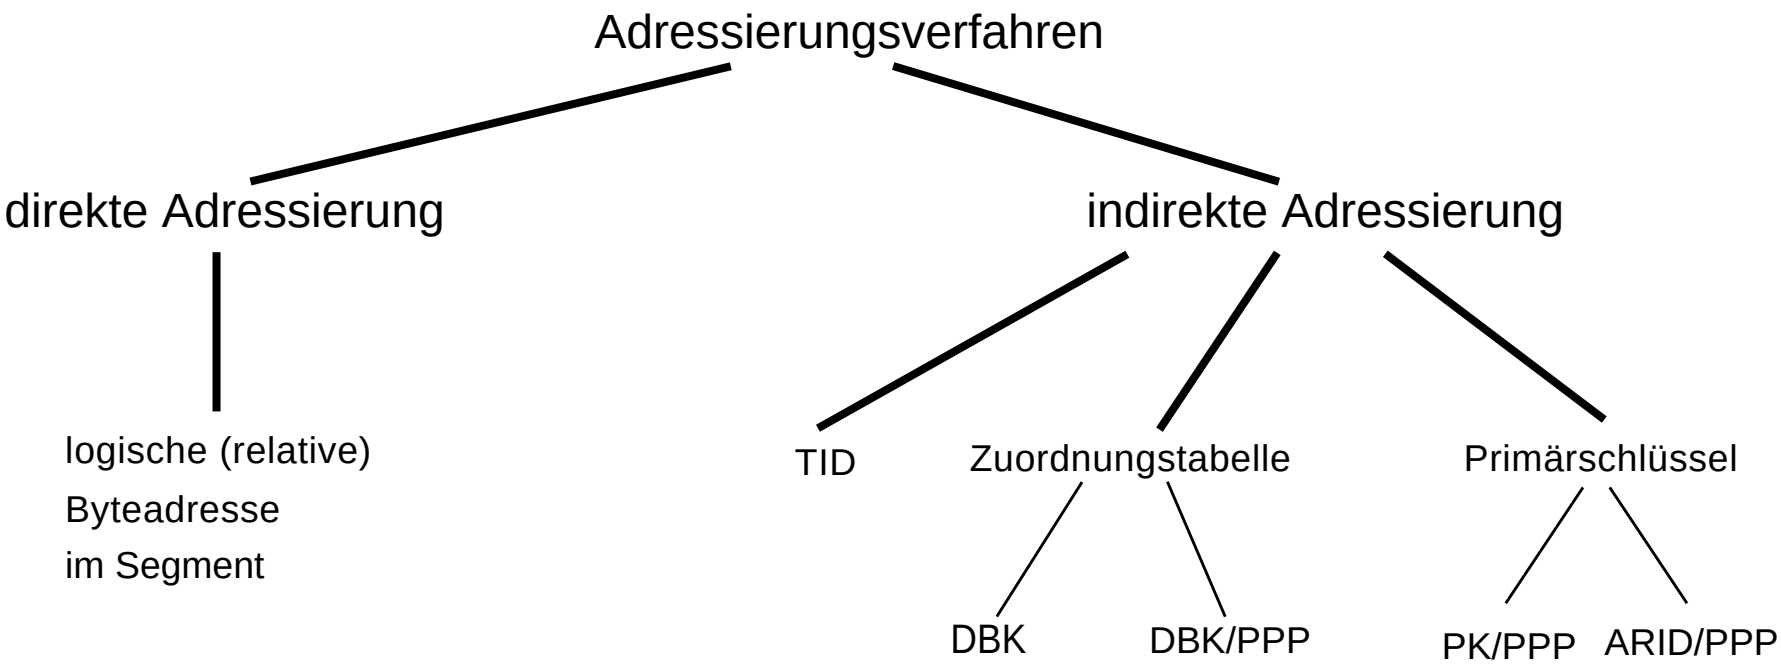

Satzadressierung: TID-Konzept

- **TID (*tuple identifier*) besteht aus zwei Komponenten:**
  - Seitennummer (3 B)
  - relative Indexposition innerhalb der Seite (1 B)
  - dient zur Adressierung in einem Segment (z. B. SID = A)
- **Migration eines Satzes in andere Seite ohne TID-Änderung möglich**

  ➥ Einrichten eines Stellvertreter-TID in Primärseite
- **Überlaufkette: Länge <= 1**

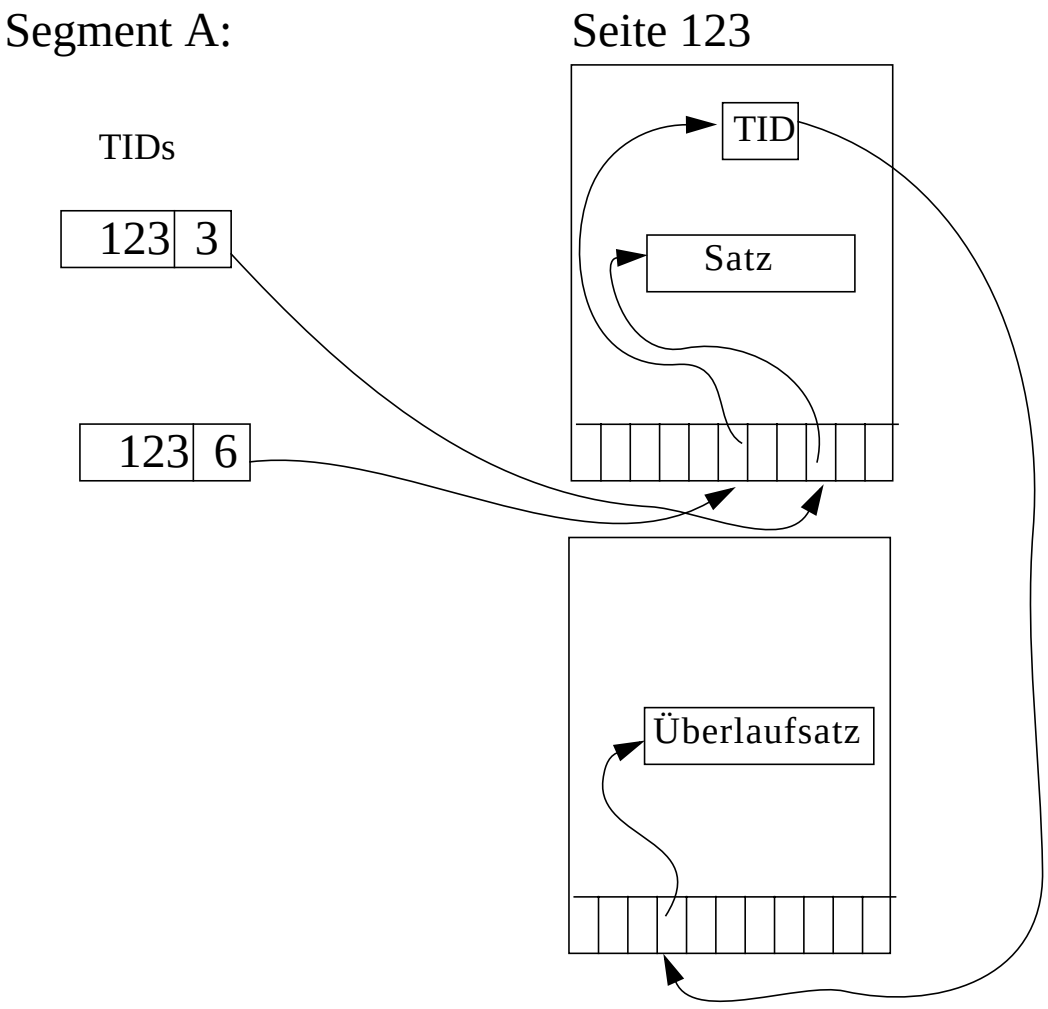

Satzadressierung über Zuordnungstabelle

- **Jeder Satz erhält eindeutigen logischen Identifikator**
  - Datenbankschlüssel (DBK)
  - Vergabe der DBK erfolgt i. allg. durch DBVS
  - systeminterne Verweise auf Sätze erfolgen ausschließlich über den DBK

- **Zuordnungstabelle enthält pro DBK zugehörigen PP**
  - SID (1 B)
  - Seitennummer (3B)

- **Hybrides Verfahren:**
  Verwendung von **'probable page pointers' (PPP)** in Zugriffspfaden erspart u. U. Zugriff auf Zuordnungstabelle

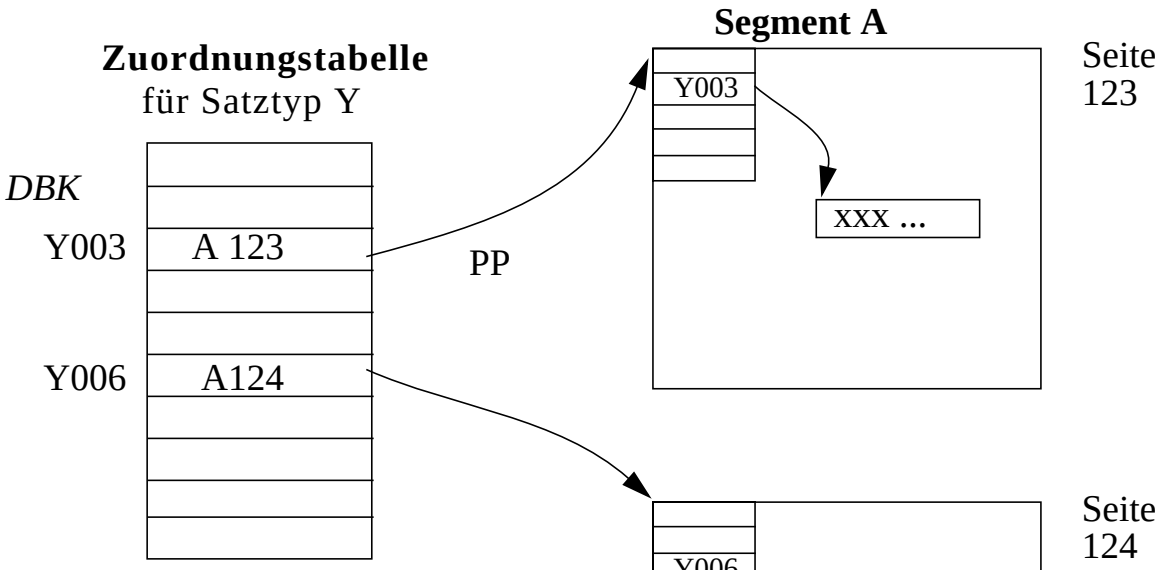

Indexstruktur

Such-kriterium	DBK	PPP
xxx	Y003	A123
zzz	Y006	A123

Indexierung von Tabellen

- **Speicherung von Tabellen**
  - **ungeordnete Tabelle**:
    Sätze (Zeilen) sind im Segment verstreut (Heap)
  - **geordnete Tabelle**:
    Sätze sind in B*-Baum eingebettet (key-sequenced table);
    es wird dadurch eine Clusterbildung erzielt

  ➥ Wir bezeichnen eine solche Tabelle als Index-organisierte Tabelle (IT)

- **Indexierung von Tabellen**
  - mit sekundären Indexen für Spalten Ai : $I_{Tab}(Ai)$
  - Nutzung verschiedener Adressierungsverfahren
    - TID (physisch)
    - DBK (indirekt: logisch/physisch)
    - PK (Primärschlüssel: logisch)
    - hybride Verfahren

- **Wie spielen Adressierung und Tabellenspeicherung zusammen?**

- **Ungeordnete Tabelle**

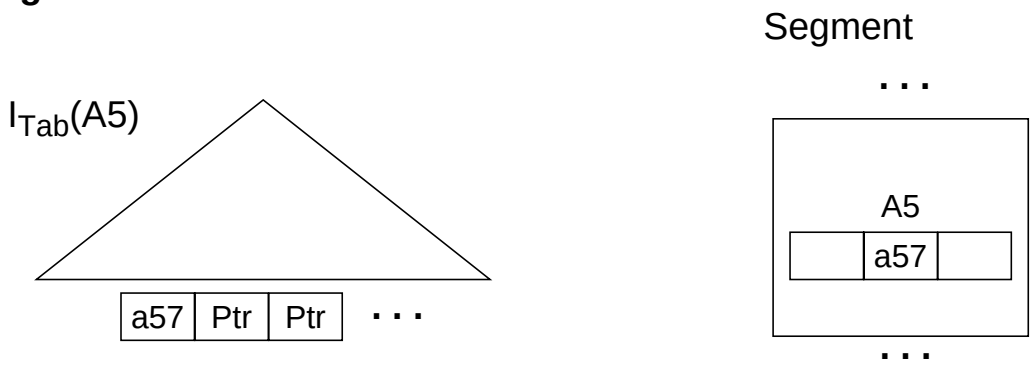

  - Sätze verschieben sich bei Aktualisierung nicht (kaum)
  - Adressierungsverfahren (Ptr):
    Es kommen TID, DBK und DBK/PPP in Frage
  - Indexunterstützung für ungeordnete Tabellen in DB2, Sybase, MS SQL-Server, Oracle, ...

Indexierung von Tabellen (2)

- **Index-organisierte Tabelle**

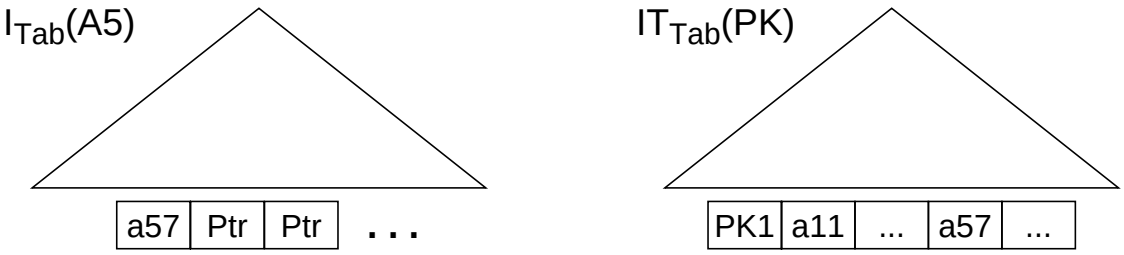

  - Split in IT_{Tab} erfordert viele Adreßanpassungen in I_{Tab}(Ai)
    - bei TID
    - bei DBK
    - bei DBK/PPP
  - Verbesserung: logische Adressierung

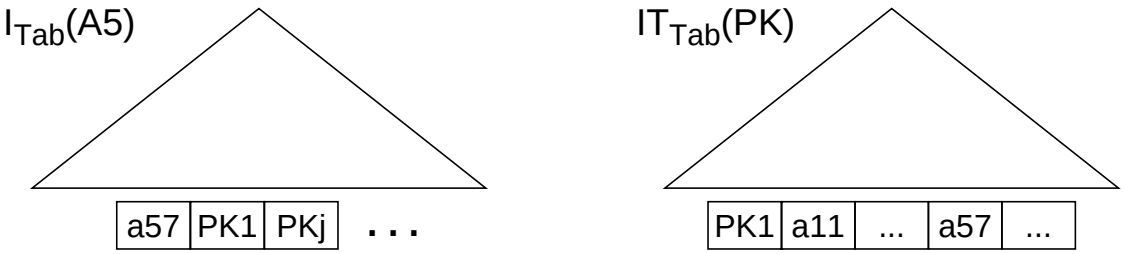

  - keine Wartung der I_{Tab}(Ai) bei Split/Verschiebungen in IT_{Tab} nötig
  - **aber:** höhere Zugriffskosten bei Index-Scan usw.

- **Nutzung einer hybriden Adressierungstechnik**
  - Verweis hat zwei Komponenten
    - logischer Verweis: PK
    - physischer Verweis: wahrscheinliche DB-Seite (PPP, Guess-DBA)
  - Eintrag in Index

Attributwert	PK	PPP

Indexschlüssel HRID = (Hybrid Row Identifier)

Indexierung von Tabellen (3)

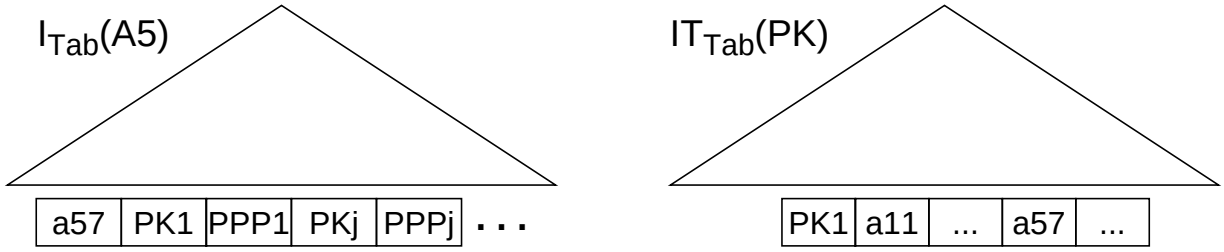

- Vereinigung der Vorteile beider Verfahren
- Was passiert bei langen Primärschlüsseln?

- **Optimierung bei langen Primärschlüsseln**
  - Beispiel: Tabelle Order_Line des TPC-C-Benchmark:
    OL (ol-o-id, ol-w-id, ol-d-id, ol-number, ol-i-id, ...)
  - Vereinfachte Schreibweise:
    OL (A1, A2, A3, A4, A5, ...)
  - Vermeidung der PK-Speicherung im Index
    - Nutzung einer Abbildungstabelle ATab
    - Verweis auf ATab durch ARID

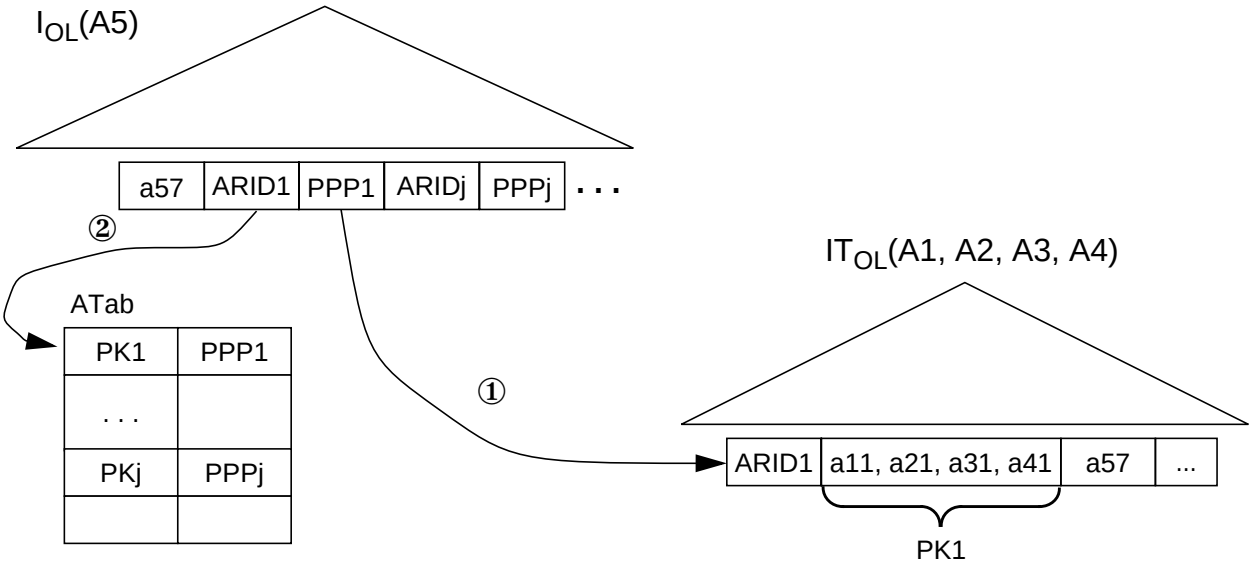

- Falls der Zugriff über PPP ① fehlschlägt, wird mit Hilfe von ARID ② ATab aufgesucht
- Alle I_{OL}(Ai) benutzen ATab
- Von dort kann über PPP oder über PK auf IT_{OL} zugegriffen werden
- Zugriffsschema entspricht der Oracle-Lösung

Hauptspeicherbasierte Adressierung

- **Aufgabe**:
  Programme sollen im HSP transparent transiente und persistente Datenobjekte verarbeiten können.
  - Ausschließliche Nutzung von direkten Adressen im HSP (Virtuelle Adressierung), d. h., Zugriff auf persistente Objekte ist im HSP genauso effizient wie auf transiente Objekte.
  - Keine Mehrkosten für Programme, die nur auf transiente Objekte zugreifen
  - Abbildungskosten für persistente Objekte sollen nicht bei jedem Zugriff anfallen

- **Abbildung von persistenten Objekten auf Externspeichern (ES) auf solche in Virtuellen Speichern (VS)**
  - Persistente Adressen (z. B. SID, RID, TID) sind lang (z. B. 64 Bit), Virtuelle Adressen dagegen kürzer (z. B. 32 Bit)
  - Übersetzung der Zeiger (*pointer swizzling*) vom langen Format mit indirekter Adressierung ins kürzere Format mit möglichst direkter Adressierung

- **Ziel**:
  Schnelle Verarbeitung von Pointerfolgen im VS — z. B. 10^5 Refs/sec
  - Objektverarbeitung: Traversierung von Referenzfolgen und Navigation in vernetzten Objektstrukturen
  - Direkter Zugriff im HSP ist wesentlich billiger als Zugriff über persistente Adresse (Lokalisierung einer Seite im DB-Puffer und Suche des Objektes in der Seite)
  - ggf. zusätzliche Zugriffspfade zur Suche im HSP:
    B*-Baumzugriff erfordert h+1 direkte Pointerreferenzen

Pointer-Swizzling

- **Dimensionen von Pointer-Swizzling[1]**

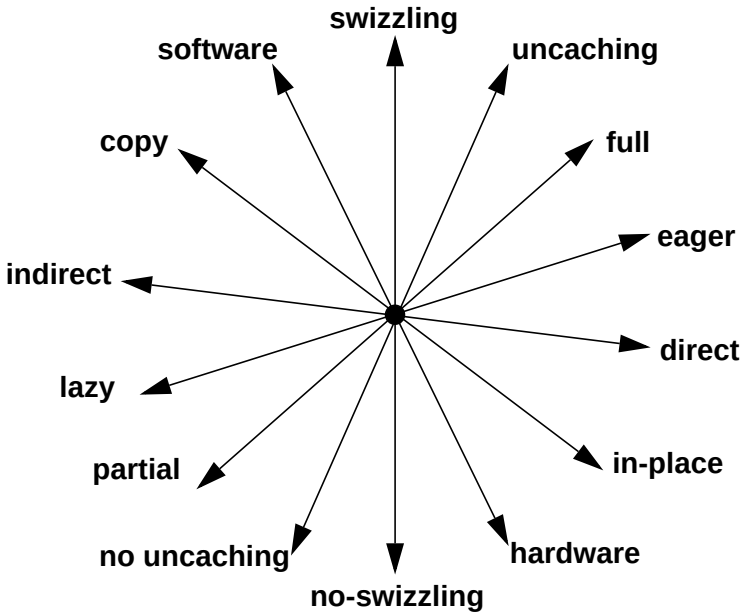

- **Klassifikation von Swizzling-Verfahren**

  - wichtigste Kriterien: Ort, Zeitpunkt und Art (orthogonal)

  - Ort:

  - *In-Place Swizzling:* Beibehaltung der Objektformate und der Seiten-strukturen
  - *Copy Swizzling:* Kopieren der Objekte in einen Puffer und Umstellen der Zeiger in den Kopien

  - Zeitpunkt:

  - *Eager Swizzling:* Umstellen aller Zeiger, sobald die Objekte in den Hauptspeicher gebracht werden
  - *Lazy Swizzling:* Umstellen der Zeiger bei Erstreferenz oder später (nach beliebigen Kriterien - Magische Zahl 3)

  - Art:

  - *Direct Swizzling:* Nutzung der Virtuellen Adresse des Objektes, dadurch kann die Erstetzung von Objekten während der Verarbeitung sehr schwierig oder gar unmöglich werden
  - *Indirect Swizzling:* Nutzung der Virtuellen Adresse von Objekt-Deskriptoren

---

1. White, S.J., DeWitt, D.J.: Quickstore: A High Performance Mapped Object Store, in: The VLDB Journal 4:4, Oct. 1995, pp. 629-674.

Pointer-Swizzling (2)

- **Direktes und indirektes Swizzling – Prinzip**

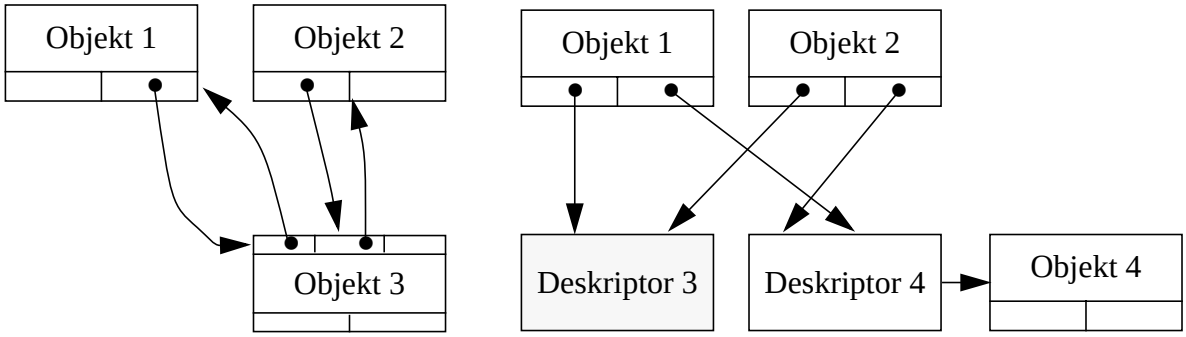

a) Symmetrische Referenzen

b) Referenzierung von Deskriptoren

- **Direkte und indirekte Variante beim Copy-Swizzling**

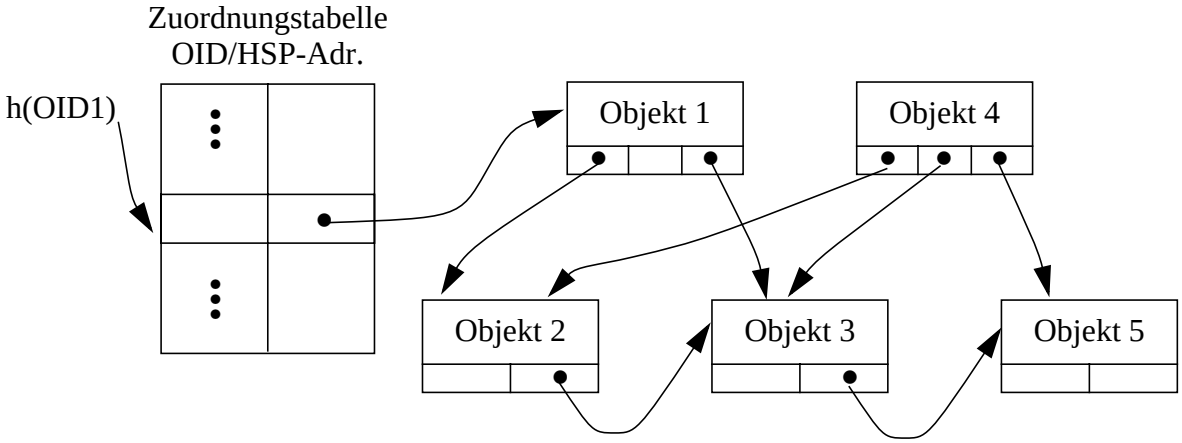

a) Direktes Swizzling in einem Objektpuffer

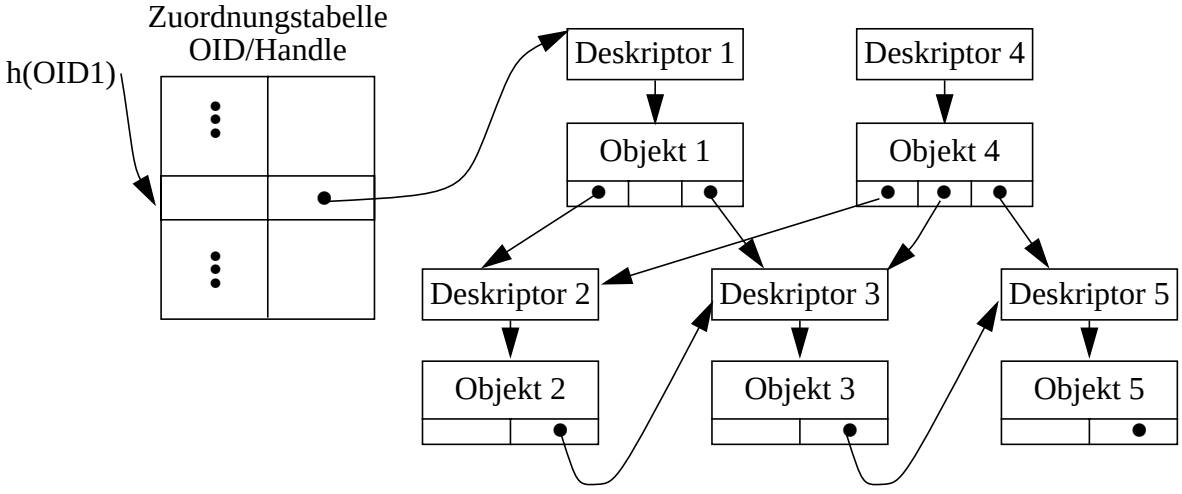

b) Indirektes Swizzling in einem Objektpuffer

Pointer-Swizzling (3)

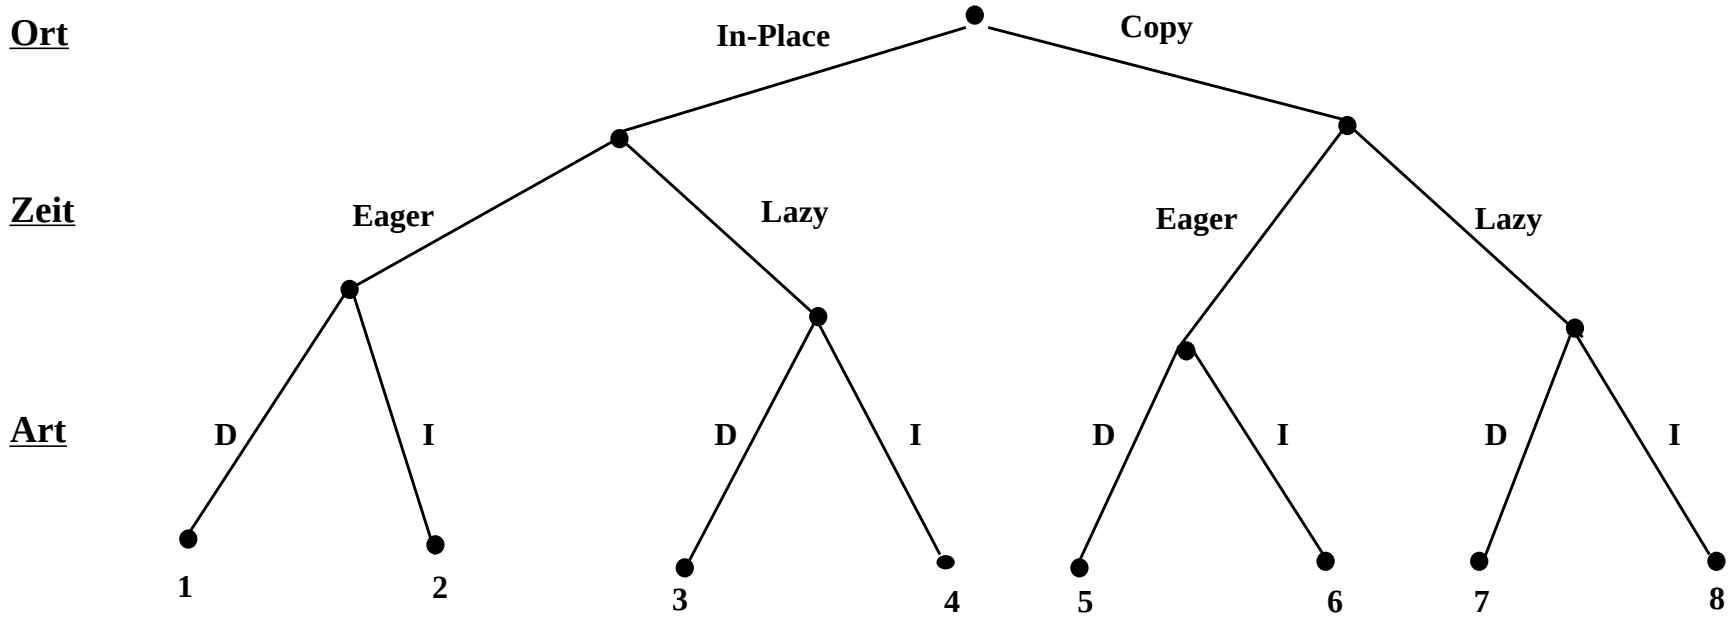

Bermerkungen:

1 + 5 : Swizzling von allen Seiten/Objekten bei Checkout, kein Ersetzen (*no uncaching*)
2 + 4 : Umständliche Organisation

Fragen:

- Welche Verfahren sind bei der Verarbeitung (beim Swizzling) am schnellsten?
- Welche Verfahren erlauben Objektersetzung (*uncaching*)?
- Wie kann Lazy/Direct (3 + 7) realisiert werden?

Abbildung von Sätzen

- **Record-Mgr:**
  - physische Abspeicherung von Sätzen in Seiten
  - Operationen: Lesen, Einfügen, Modifizieren, Löschen

- **Satzbeschreibung**
  - pro Attribut:

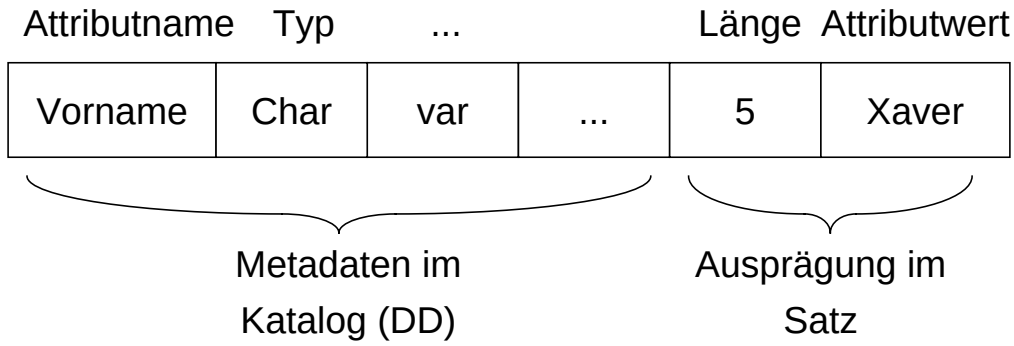

  - Satz- und Zugriffspfadbeschreibung im Katalog
  - besondere Methoden der Speicherung
    - Blank-/Nullunterdrückung
    - Zeichenverdichtung
    - kryptographische Verschlüsselung
    - Symbol für undefinierte Werte
  - Tabellenersetzung für Werte: KL = Kaiserslautern

- **Organisation**
  - n Satztypen pro Segment
  - m Sätze verschiedenen Typs pro Seite
  - Satzlänge < Seitenlänge: $S_L \leq L_S - L_{SK}$

Speicherungsstrukturen für Sätze

- **Konkatenation von Feldern fester Länge**

z. B. TID

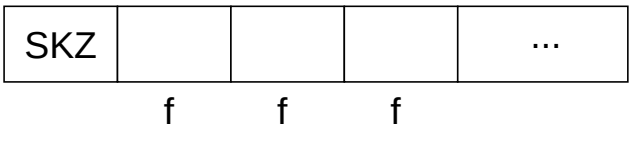

- speicheraufwendig
- unflexibel

- **Zeiger im Vorspann**

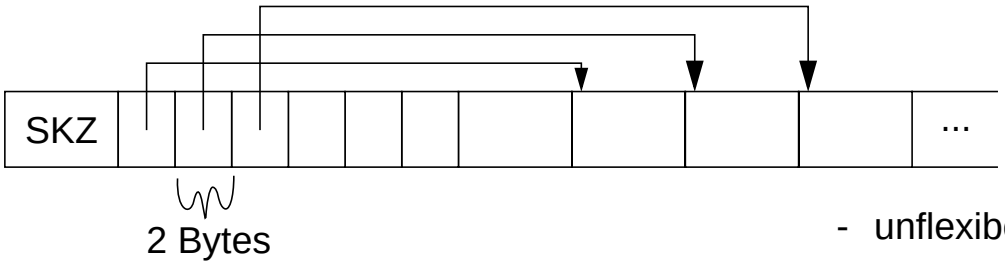

- unflexibel

- **Eingebettete Längenfelder**

Katalog: f_5 | v | v | f_6 | f_2 | v |

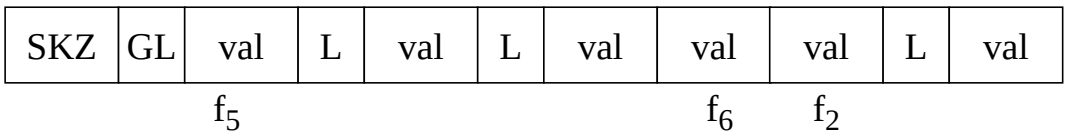

- dynamische Erweiterung möglich

- **Optimierung: eingebettete Längenfelder mit Zeigern**

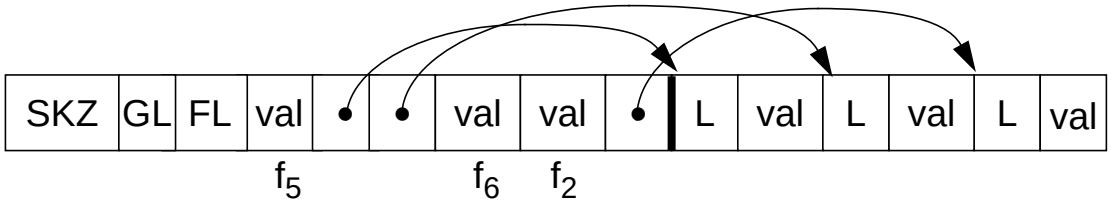

- Adresse des n-ten Attributs kann berechnet werden
- Erweiterung für EXPAND ?

Speicherungsstrukturen für Sätze (2)

- **Problem: dynamisches Wachstum/variable Länge**
  - Ausdehnung und Schrumpfung in einer Seite
  - Überlaufschemata
  - Garbage Collection

  ➥ Die eingeführten Möglichkeiten der Speicherung von Sätzen sind mit weiteren Optionen zu kombinieren

- **Strikt zusammenhängende Speicherung von Sätzen**
  - evtl. häufige Umlagerung bei hoher Änderungsfrequenz
  - Vorteile für indirekte Adressierungsschemata

- **Aufspaltung des Satzes**

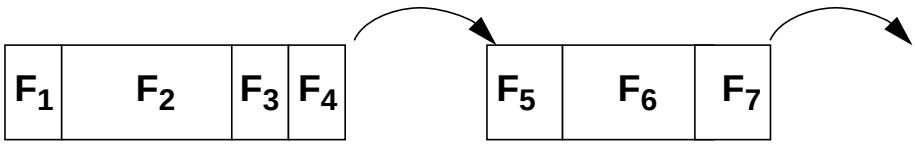

  - Ordnung nach Referenzhäufigkeiten
  - Verbesserung der Clusterbildung
  - Wiederholter Überlauf möglich
  - wird unvermeidlich bei der Einbeziehung von Attributen vom Typ TEXT oder BILD

Speicherungsstrukturen für komplexe Objekte[1]

- **Komplexe Objekte werden gebildet aus**
  - atomaren Werten und darauf
  - rekursiv angewandten Mengen-, Listen- und Tupelkonstruktoren

- **Einfaches Beispiel**

```
complex_object Mitarbeiter [. . .]
    set [. . .] of tuple   (Pers_Nr    [. . .]  :  integer,
                            Name       [. . .]  :  string (30),
                            Gehalt     [. . .]  :  real,
                            Lebenslauf [. . .]  :  var_string)
```

  [. . .] kennzeichnet Stelle für Speicherungsstrukturbeschreibung

- **Freiheitsgrade für physische Speicherungsstrukturen**
  1. Wahl der internen Speicherungsstrukturen zur Implementierung von Mengen, Listen und Tupeln (**Konstruktordatenstruktur**)
  2. Direkte Speicherung oder Referenzierung der Elemente einer Menge oder Liste bzw. der Attribute eines Tupels in der Konstruktordatenstruktur

- **Jeder Konstruktor erfordert eine Konstruktordatenstruktur**
  - Beispiel: einfache Menge {Pers_1, Pers_2, Pers_3}
  - variabel langer Array als Konstruktordatenstruktur

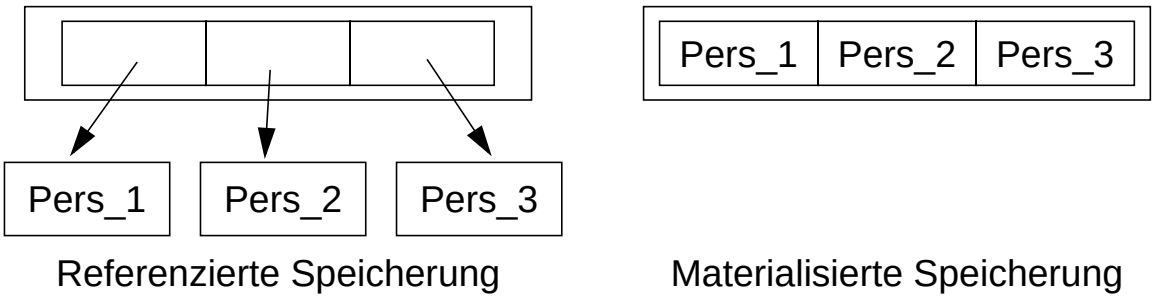

Referenzierte Speicherung Materialisierte Speicherung

1. Keßler, U., Dadam, P.: Benutzergesteuerte, flexible Speicherungsstrukturen für komplexe Objekte, Proc. BTW'93, Braunschweig, 1993, S. 206-225.

Speicherungsstrukturen für komplexe Objekte (2)

- **Zweimalige Anwendung des Mengenkonstruktors**

  - { {Pers_1 , Pers_2} , {Pers_3 , Pers_4} }

  - Vorgabe variabel langer Arrays als Konstruktordatenstrukturen

- **Vier Implementierungen**

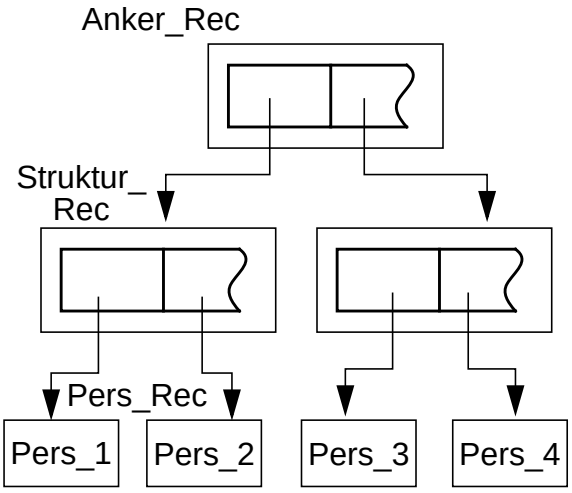

1. Elemente äußere Menge : referenziert
   Elemente innere Menge : referenziert

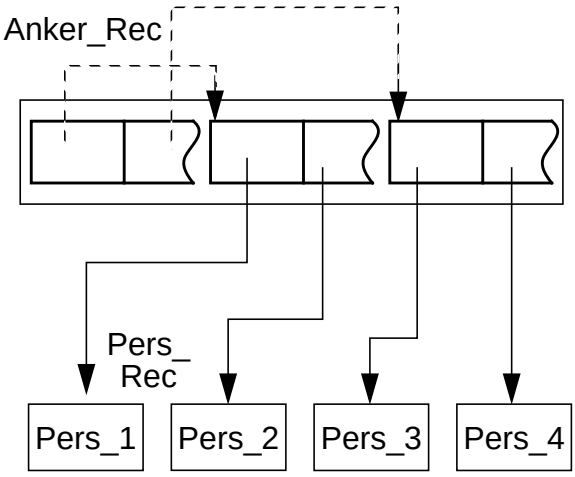

2. Elemente äußere Menge : materialisiert
   Elemente innere Menge : referenziert

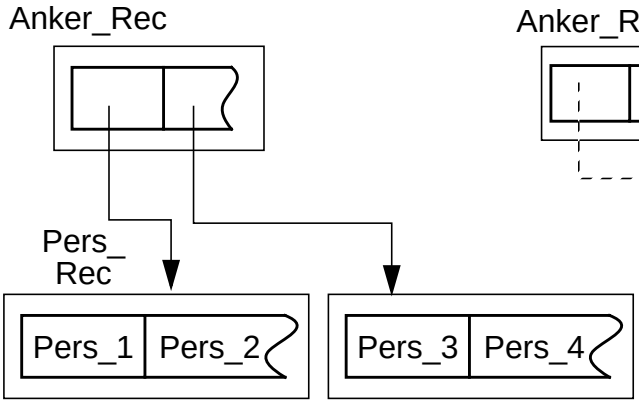

3. Elemente äußere Menge : referenziert
   Elemente innere Menge : materialisiert

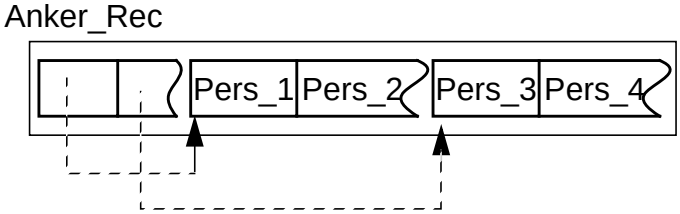

4. Elemente äußere Menge : materialisiert
   Elemente innere Menge : materialisiert

- Sind zusätzlich verkettete Listen als Konstruktordatenstrukturen zulässig, so erhält man insgesamt 16 Varianten

Speicherungsstrukturen für Mengen- und Listenkonstruktoren

- **Unabhängige Freiheitsgrade**
  - Konstruktordatenstruktur
    - variabel langes Array
    - verkettete Liste
    - ...
  - Art der Speicherung der Elemente
    - direkt in Konstruktordatenstruktur
    - Referenzierung der Elemente über Zeiger

- Zur unabhängigen Spezifikation dieser Freiheitsgrade sind zwei Parameter (in einer Datendefinitionssprache) erforderlich:

```
object_type = . . .
        /* Definition einer Menge. */
        set   [implementation      =   implementation_type,
               element_placement   =   placement_type] of object_type |
        /* Definition einer Liste. */
        list  [implementation      =   implementation_type,
               element_placement   =   placement_type] of object_type | ...
```

- **Parameterwerte**

```
implementation_type    =    array | linked_list
placement_type         =    inplace | referenced (record_type_name)
```

- **Vollständige Definition der Speicherungsstruktur (Fall 1)**

```
complex_object Menge_von_Mengen_von_Pers [anchor_record_type=Anker_Rec]
    set [implementation=array, element_placement=referenced (Struktur_Rec)] of
        set [implementation=array, element_placement=referenced (Pers_Rec)] of
            Pers.
```

Speicherungsstrukturen für Tupelkonstruktoren

- **Prinzipiell existieren die gleichen Freiheitsgrade**
  - Wahl einer Konstruktordatenstruktur: Zuordnung des Tupels zu einem Record oder zu mehreren Records
  - materialisierte oder referenzierte Speicherung der Attributwerte

- **Neuer Parameter: „location“**

  attribute_description = attribute_name [location = location_type, element_placement = placement_type]

  ⇒ Für jedes Attribut kann „location“ und „element_placement“ separat spezifiziert werden

- **„location“ erlaubt die Optimierung des Satzzugriffs nach den Zugriffshäufigkeiten der einzelnen Attribute**

  location_type = primary | secondary (record_type_name)

  Die Konstruktordatenstruktur eines Tupels kann auf mehrere Records aufgeteilt werden. Mit „primary“ wird das zugehörige Attribut im Primärblock angelegt.

Speicherungsstrukturen – Beispiel

- **Ausprägung einer Mitarbeiterrelation**

Mitarbeiter			
Pers_Nr	Name	Gehalt	Lebenslauf
77234	Maier	4000	Frau Bettina Maier ist am ...
77235	Schmidt	5000	Herr Fritz Schmidt ist am ...

- **Definition einer dazugehörigen Speicherungsstruktur**

1. referenzierte Prim_Rec

```
complex_object Mitarbeiter [anchor_record_type=Link_Rec]
  set [implementation=linked_list, element_placement=referenced (Prim_Rec)]
    of tuple
    (Pers_Nr     [location=primary, element_placement=inplace] : integer,
    Name         [location=primary, element_placement=inplace] : string (30),
    Gehalt       [location=secondary (Sec_Rec),
                  element_placement=inplace] : real,
    Lebenslauf   [location=secondary (Sec_Rec),
                  element_placement=referenced (Lebenslauf_Rec)]] : var_string)
```

2. materialisierte Prim_Rec

```
complex_object Mitarbeiter [anchor_record_type=Link_Rec]
  set [implementation=linked_list, element_placement=inplace] of . . .
```

- **Dazugehörige Speicherungsstrukturen für die Mitarbeiterrelation**

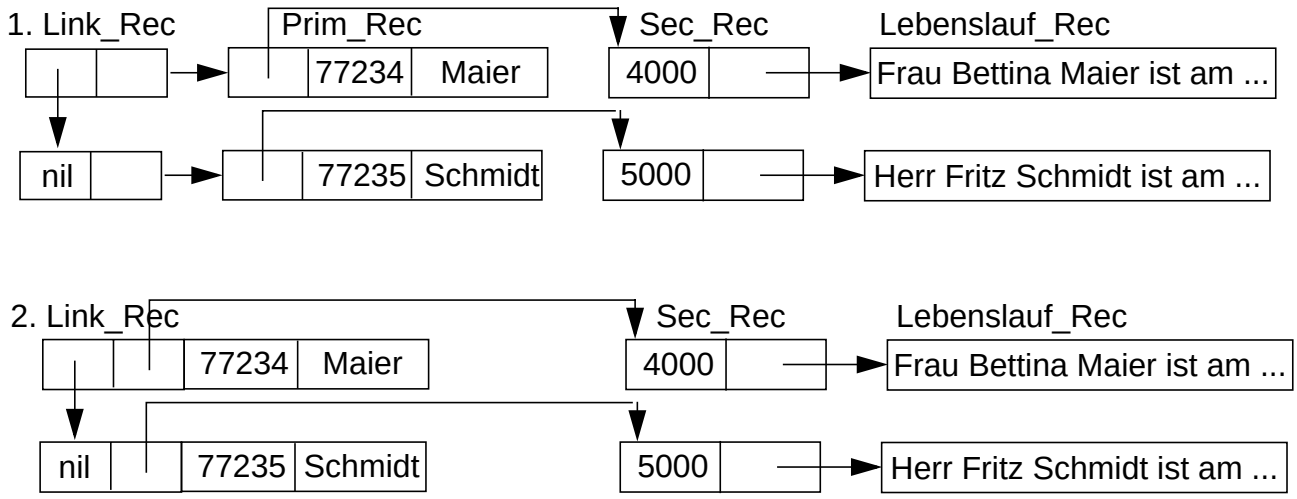

Zusammenfassung

- **Freispeicherinformation auf verschiedenen Ebenen erforderlich: Gerät, Segment (Datei), Seite**
- **Ziele bei der externspeicherbasierten Adressierung**
  - Kombination der Geschwindigkeit des direkten Zugriffs mit der Flexibilität einer Indirektion
  - Satzverschiebungen in einer Seite ohne Auswirkungen

  ➥ TID, DBK (Zuordnungstabelle) oder Primärschlüssel
- **Indexierung von Tabellen**
  - physische oder hybride Verfahren bei ungeordneten Tabellen
  - hybride Verfahren kombiniert mit Primärschlüssel bei geordneten Tabellen (Index-organisierte Tabellen)
- **Hauptspeicherbasierte Adressierung (*Pointer Swizzling*)**
  - transparenter Programmzugriff auf persistente und transiente Objekte
  - Abbildung von langen ES-Adressen auf Virtuelle Adressen
  - orthogonale Klassifikationskriterien: **Ort, Zeitpunkt, Art**
- **Abbildung von Sätzen**
  - Speicherung variabel langer Felder
  - dynamische Erweiterungsmöglichkeiten
  - Berechnung von Feldadressen
- **Speicherung komplexer Objekte**
  - Listen-, Mengen- und Tupelkonstruktoren
  - Konstruktor-Anwendung ist orthogonal und rekursiv

Direktes In-Place-Swizzling

- **Direktes In-Place-Swizzling - Anforderungen**
  - **HW-Unterstützung:** Nutzung des seitenbasierten Schutzmechanismus (P-Bit pro Seite) des VS
  - Erkennung von Referenzen auf persistente Objekte, die noch nicht im VS sind
  - Objekte im VS und ES haben gleiche Größe und Form (Seite)

- **Inhalt des ES vor Programmzugriff**

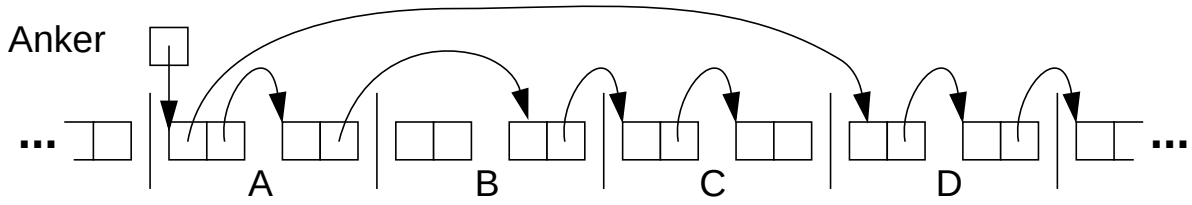

- **VS nach Übersetzung des Entry-Pointers**

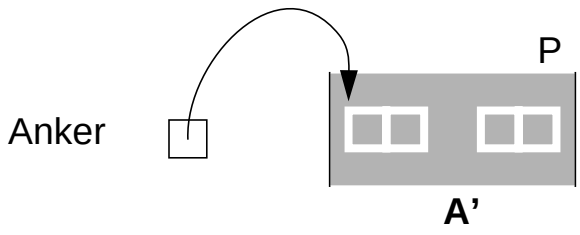

  - Für die Seite des Zielobjektes wird Speicherplatz angelegt
  - Die VS-Seite wird durch das P-Bit gegen Zugriffe geschützt

Direktes In-Place-Swizzling (2)

- **VS nach Entry-Pointer-Zugriff, der Seite A’ referenziert**

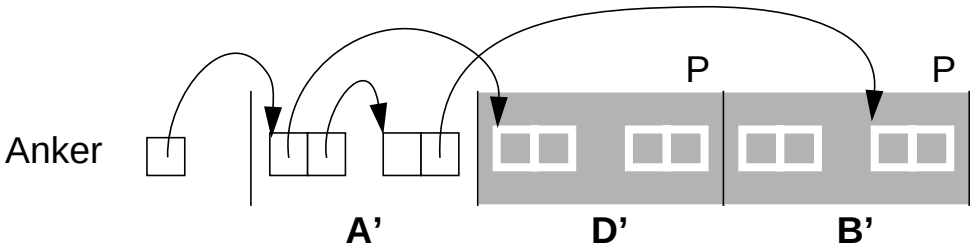

  - Wenn die zugriffsgeschützte Seite A’ referenziert wird, wird Seite A vom Externspeicher geholt und nach A’ übersetzt
  - Pointer-Strukturen müssen erkannt werden
  - Für alle Zeiger der Seite A muß Speicherplatz für die referenzierten Seiten angelegt werden, damit die Zeiger von A’ in Virtuelle Adressen übersetzt werden können
  - Der Zugriffsschutz für A’ wird aufgehoben, während er für D’ und B’ gesetzt wird

- Zustand des VS nach Traversierung von A’ und Referenzierung von B’

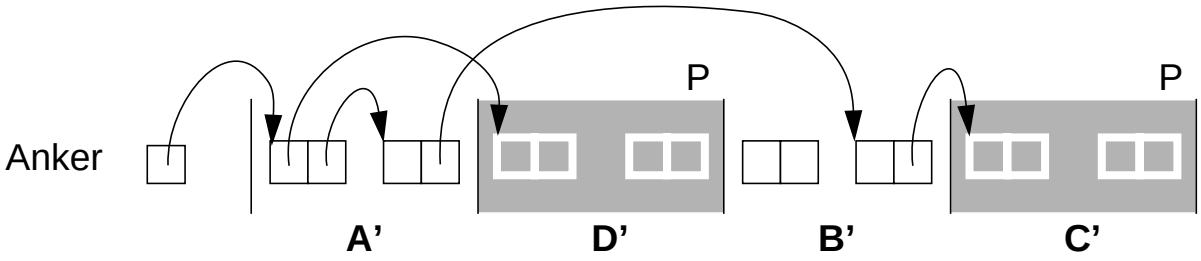

  - Wenn B’ referenziert wird, muß B gelesen und der Zeiger auf Seite C übersetzt werden in die Virtuelle Adresse von Seite C’
  - Für Seite C’ wird nur Speicherplatz reserviert

  ➥Adreßübersetzung impliziert, daß die Objekte in C und C’ die gleiche relative Position besitzen

Direktes In-Place-Swizzling (3)

- **Garbage Collection/Rückschreiben von Seiten (Unswizzling!)**
  - Selektives Entfernen/Zurückschreiben schwierig!

    ➥ Gibt es noch Referenzen auf eine Seite?

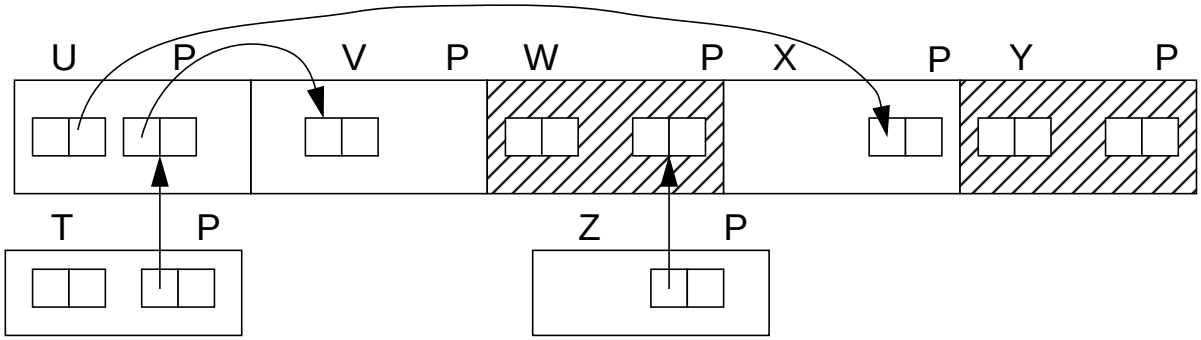

- **Algorithmus**
  - Invalidiere alle Seiten: Setze P-Bit
  - Nächster Verarbeitungsabschnitt baut Working-Set auf, ohne bereits vorhandene Seiten neu zu holen
  - Ersetzungskandidaten sind solche Seiten, die nicht referenziert wurden (P) seit der Generalinvalidierung und die nicht direkt erreichbar sind von solchen Seiten, die referenziert wurden

Beispiel

Satztyp PERS:(PNR DEC (8),
NAME CHAR(20) VAR,
WOHNORT CHAR(40) VAR
ANR CHAR(4)

Speichern von Satz (12345678, Fritz Schulz, Köln, A017)

a) feste Satzlänge

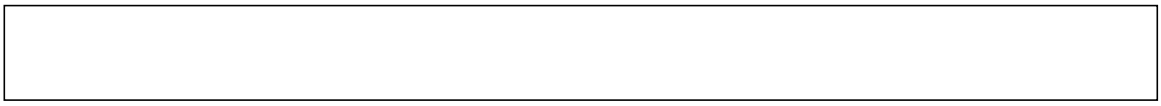

b) variable Satzlänge (Zeiger im Vorspann)

c) variable Satzlänge (eingebettete Längenfelder)

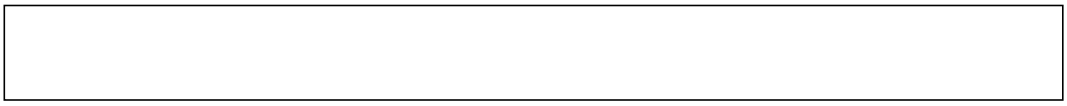

d) variable Satzlänge (eingebettete Längenfelder mit Zeiger)

Darstellung und Handhabung langer Felder[1]

- **Anforderungen**
  - idealerweise keine Größenbeschränkung
  - allgemeine Verwaltungsfunktionen
  - cursorgesteuertes Lesen und Schreiben (stückweise Handhabung)
  - Verkürzen, Verlängern und Kopieren
  - Suche nach vorgegebenem Muster, Längenbestimmung
  - ...

- **Darstellung großer Speicherobjekte**
  - besteht potentiell aus vielen Seiten oder Segmenten
  - ist eine uninterpretierte Bytefolge
  - Adresse (OID, *object identifier*) zeigt auf Objektkopf (*header*)
  - OID ist Stellvertreter im Satz, zu dem das lange Feld gehört
  - geforderte Verarbeitungsflexibilität bestimmt Zugriffs- und Speicherungsstruktur

1. Biliris, A.: The Performance of Three Database Storage Structures for Managing Large Objects, Proc. ACM SIGMOD'92 Conf., San Diego, Calif., 1992, pp. 276-285

Darstellung und Handhabung langer Felder (2)

- **Verarbeitungsprobleme**
  - Ist Objektgröße vorab bekannt?
  - Gibt es während der Lebenszeit des Objektes viele Änderungen?
  - Ist schneller sequentieller Zugriff erforderlich?
  - ...

- **Abbildung auf Externspeicher**
  - seitenbasiert
    - Einheit der Speicherzuordnung: eine Seite
    - „verstreute“ Sammlung von Seiten
  - segmentbasiert (mehrere Seiten)
    - Segmente fester Größe (EXODUS)
    - Segmente mit einem festen Wachstumsmuster (STARBURST)
    - Segmente variabler Größe (EOS)
  - Zugriffsstruktur zum Objekt
    - Kettung der Segmente/Seiten
    - Liste von Einträgen (Deskriptoren)
    - B*-Baum

Lange Felder in EXODUS*

- **Speicherung langer Felder**
  - Daten werden in (kleinen) Segmenten fester Größe abgelegt
  - bei bekannter Verarbeitungscharakteristik Wahl geeigneter Segmentgrößen möglich
  - Einfügen von Bytefolgen einfach und überall möglich
  - schlechteres Verhalten bei sequentiellem Zugriff

- **B*-Baum als Zugriffsstruktur**
  - Blätter sind Segmente fester Größe (hier 4 Seiten a 100 Bytes)
  - interne Knoten und Wurzel sind Index für Bytepositionen
  - interne Knoten und Wurzel speichern für jeden Kind-Knoten Einträge der Form (Zähler, Seiten-#)
    - Zähler enthält die maximale Bytenummer des jeweiligen Teilbaums (links stehende Seiteneinträge zählen zum Teilbaum).
    - Zähler im weitesten rechts stehenden Eintrag der Wurzel enthält Länge des Objektes

- **Repräsentation sehr langer dynamischer Objekte**
  - bis zu 1GB mit drei Baumebenen (selbst bei kleinen Segmenten)
  - Speicherplatznutzung typischerweise ~ 80 %

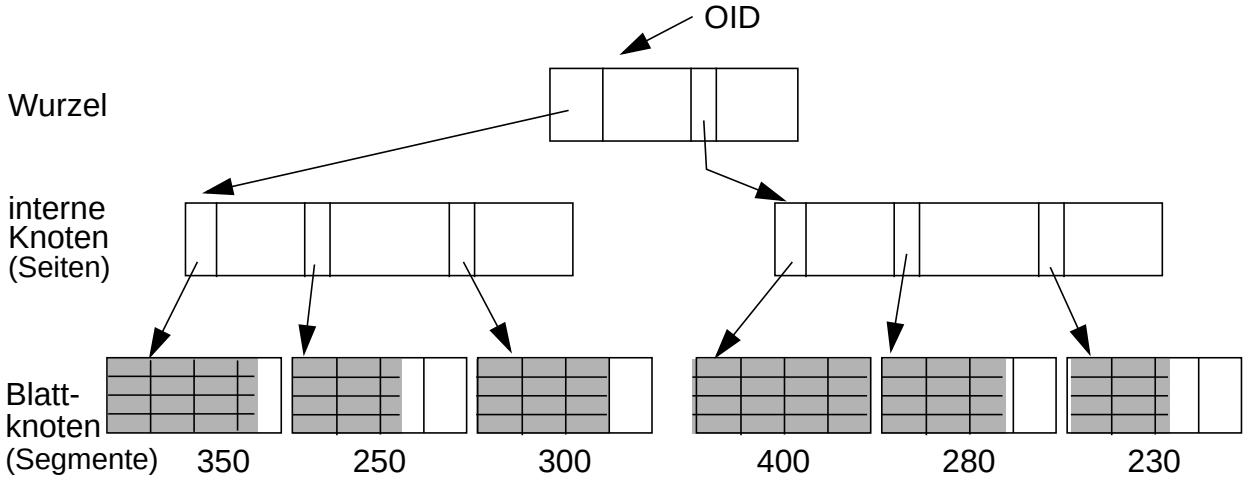

  - Byte 100 in der letzten Seite ?

EXODUS (2)

- **Spezielle Operationen**
  - Suche nach einem Byteintervall
  - Einfügen/Löschen einer Bytefolge an/von einer vorgegebenen Position
  - Anhängen einer Bytefolge ans Ende des langen Feldes

- **Unterstützung versionierter Speicherobjekte:**
  - Markierung der Objekt-Header mit Versionsnummer
  - Kopieren und Ändern nur der Seiten, die sich in der neuen Version unterscheiden (in Änderungsoperationen, bei denen Versionierung eingeschaltet ist)

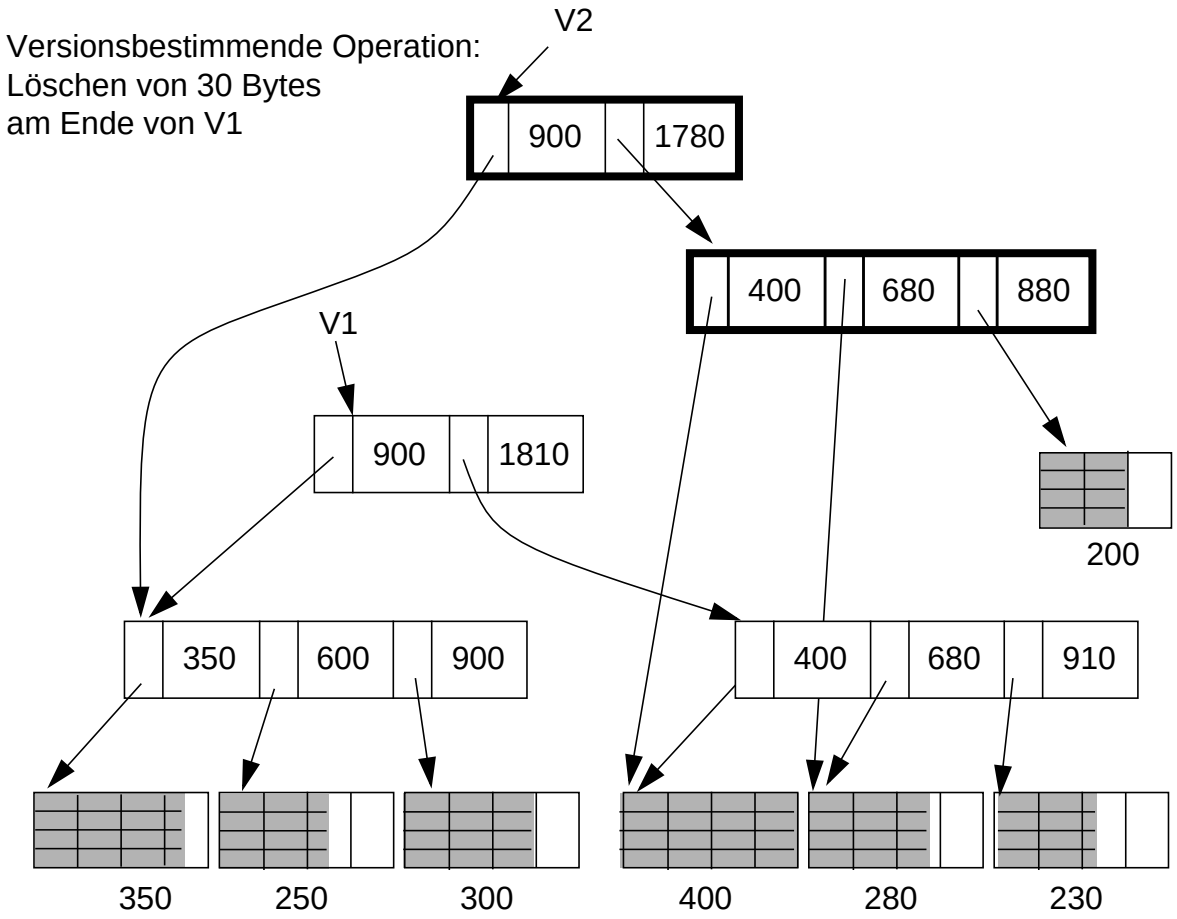

Lange Felder in STARBURST*

- **Erweiterte Anforderungen**
  - Effiziente Speicherallokation und -freigabe für Feldgrößen von bis zu 100 MB - 2 GB (Sprache, Bild, Musik oder Video)
  - hohe E/A-Leistung:
    Schreib- und Lese-Operationen sollen E/A-Raten nahe der Übertragungsgeschwindigkeit der Magnetplatte erreichen

- **Prinzipielle Repräsentation**
  - Deskriptor mit Liste der Segmentbeschreibungen
  - Langes Feld besteht aus einem oder mehreren Segmenten.
  - Segmente, auch als Buddy-Segmente bezeichnet, werden nach dem Buddy-Verfahren in großen vordefinierten Bereichen fester Länge auf Externspeicher angelegt

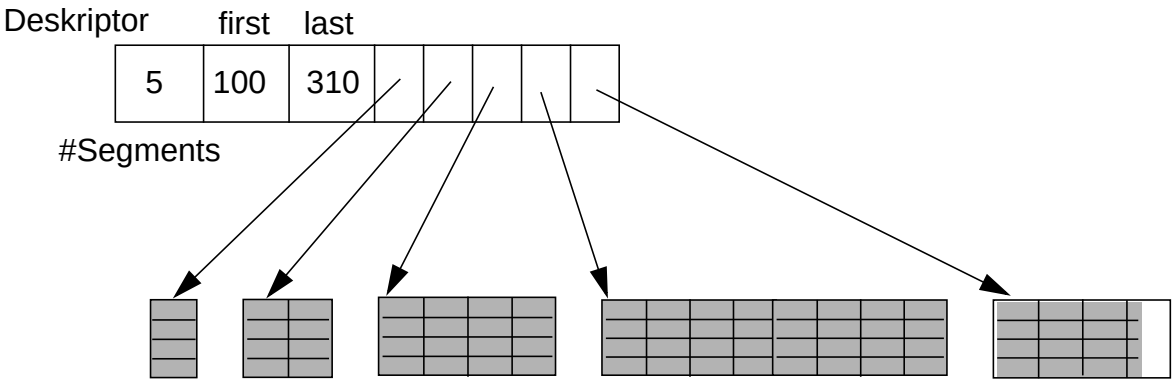

- **Segmentallokation bei vorab bekannter Objektgröße**
  - Objektgröße G (in Seiten)
  - G ≤ MaxSeg: es wird ein Segment angelegt
  - G > MaxSeg: es wird eine Folge maximaler Segmente angelegt;
  - letztes Segment wird auf verbleibende Objektgröße gekürzt

Lange Felder in STARBURST (2)

- **Segmentallokation bei unbekannter Objektgröße**
  - Wachstumsmuster der Segmentgrößen wie im Beispiel: 1, 2, 4, ..., 2^n Seiten werden jeweils zu einem Buddy-Segment zusammengefaßt
  - MaxSeg = 2048 für n = 11
  - Falls MaxSeg erreicht wird, werden weitere Segmente der Größe MaxSeg angelegt
  - Letztes Segment wird auf die verbleibende Objektgröße gekürzt

- **Allokation von Buddy-Segmenten** in sequentiellem Buddy-Bereich gemäß binärem Buddy-Verfahren

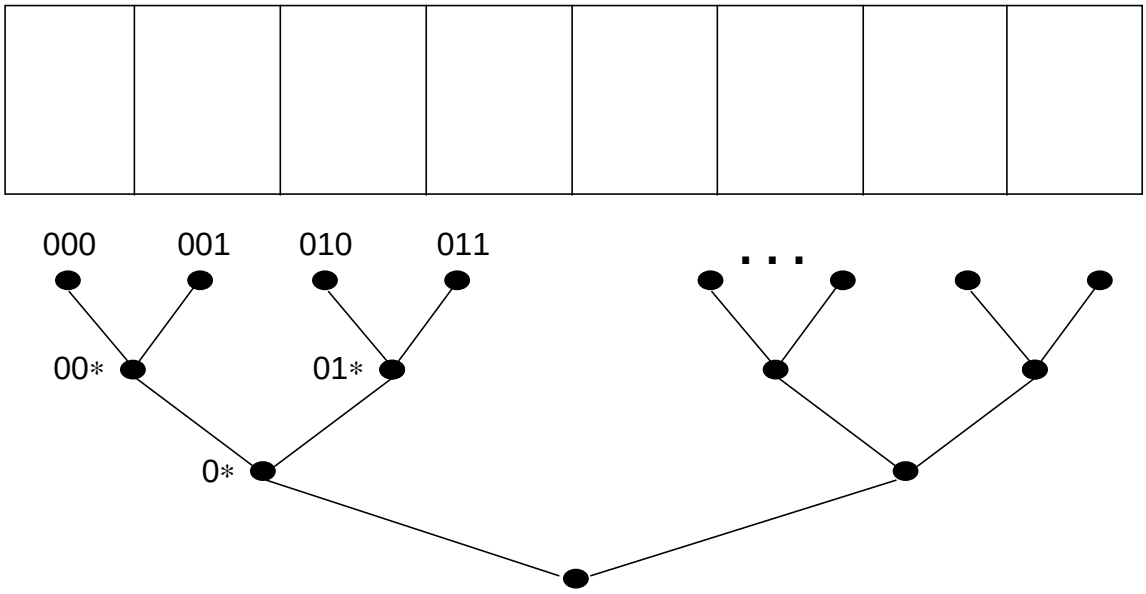

  - Zusammenfassung zweier Buddies der Größe $2^n \Longrightarrow 2^{n+1}$ ($n \geq 0$)

- **Verarbeitungseigenschaften**
  - effiziente Unterstützung von sequentiellen und wahlfreien Lesevorgängen
  - einfaches Anhängen und Entfernen von Bytefolgen am Objektende
  - schwieriges Einfügen und Löschen von Bytefolgen im Objektinnern

Speicherallokation mit variablen Segmenten

- **Verallgemeinerung des EXODUS- und STARBURST-Ansatzes in EOS**
  - Objekt ist gespeichert in einer Folge von Segmenten variabler Größe
  - Segment besteht aus Seiten, die physisch zusammenhängend auf Externspeichern angeordnet sind
  - nur die letzte Seite eines Segmentes kann freien Platz aufweisen

- **Prinzipielle Repräsentation**

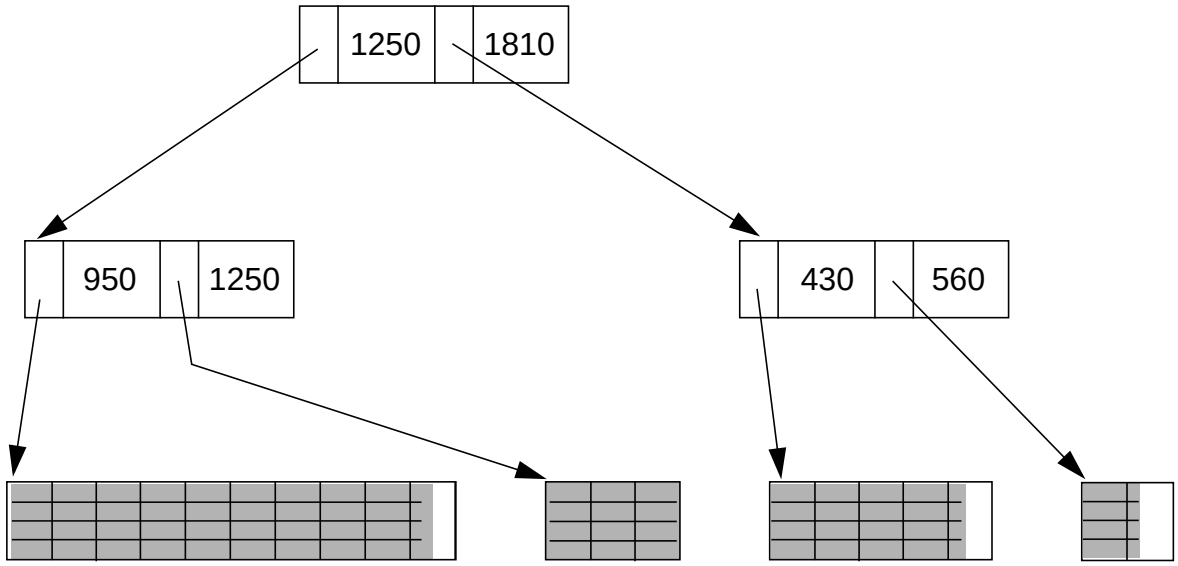

  ➥ Die Größen der einzelnen Segmente können sehr stark variieren

- **Verarbeitungseigenschaften**
  - die guten operationalen Eigenschaften der beiden zugrundeliegenden Ansätze können erzielt werden
  - Reorganisation möglich, falls benachbarte Segmente sehr klein (Seite) werden

Starburst: Speicherbelegung in einem Buddy-Bereich

- **Allokation von Buddy-Segmenten in sequentiellem Buddy-Bereich gemäß binärem Buddy-System**

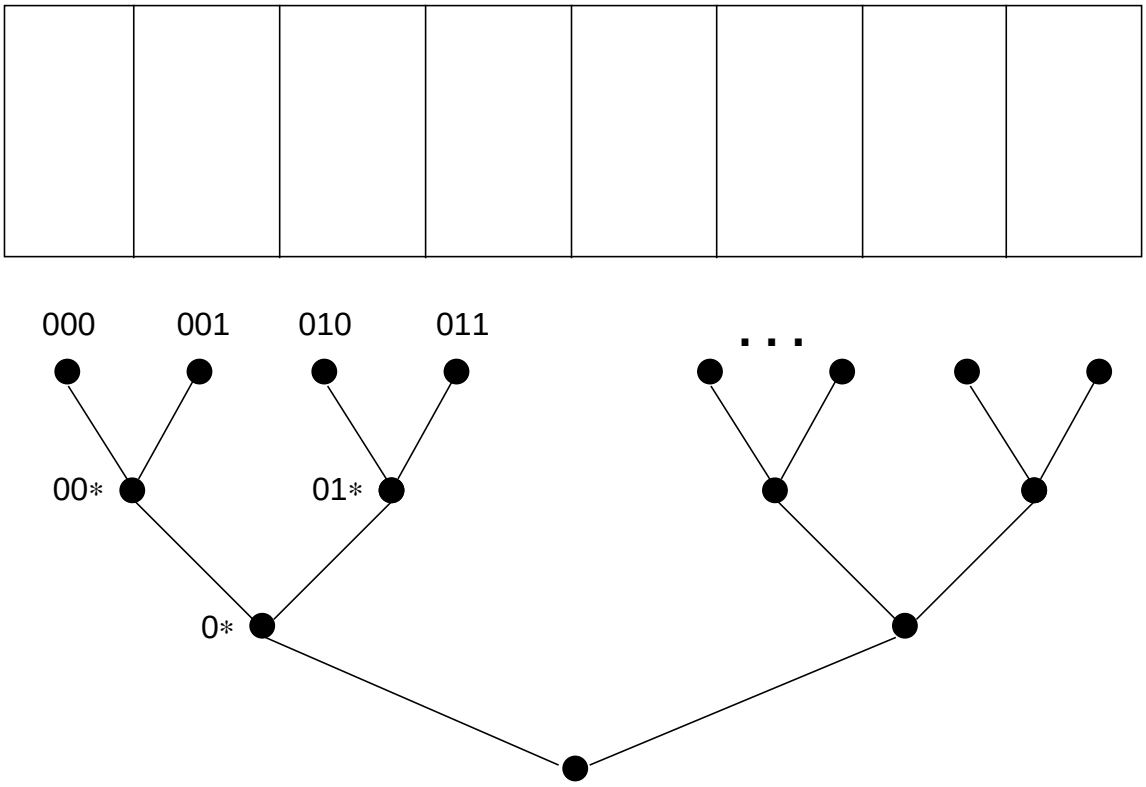

  - Zusammenfassung zweier Buddies der Größe $2^n \Longrightarrow 2^{n+1}$ ($n \geq 0$)

- **Erzeugen eines Langen Feldes**
  - zunächst sukzessives Bilden von Buddy-Segmenten mit jeweiliger Verdopplung der Segmentgröße (2^n, n = 0, 1, 2 . . .) bis zur maximalen Segmentgröße (2 MB)
    - bei weiterem Wachsen: sukzessive Zuordnung von maximalen Buddy-Segmenten (≤ 60)
  - Feldgröße bekannt:
    direkte Zuordnung von maximalen Buddy-Segmenten
  - letztes Buddy-Segment wird auf erforderliche Größe "gekürzt"

Starburst: Speicherorganisation zur Realisierung Langer Felder

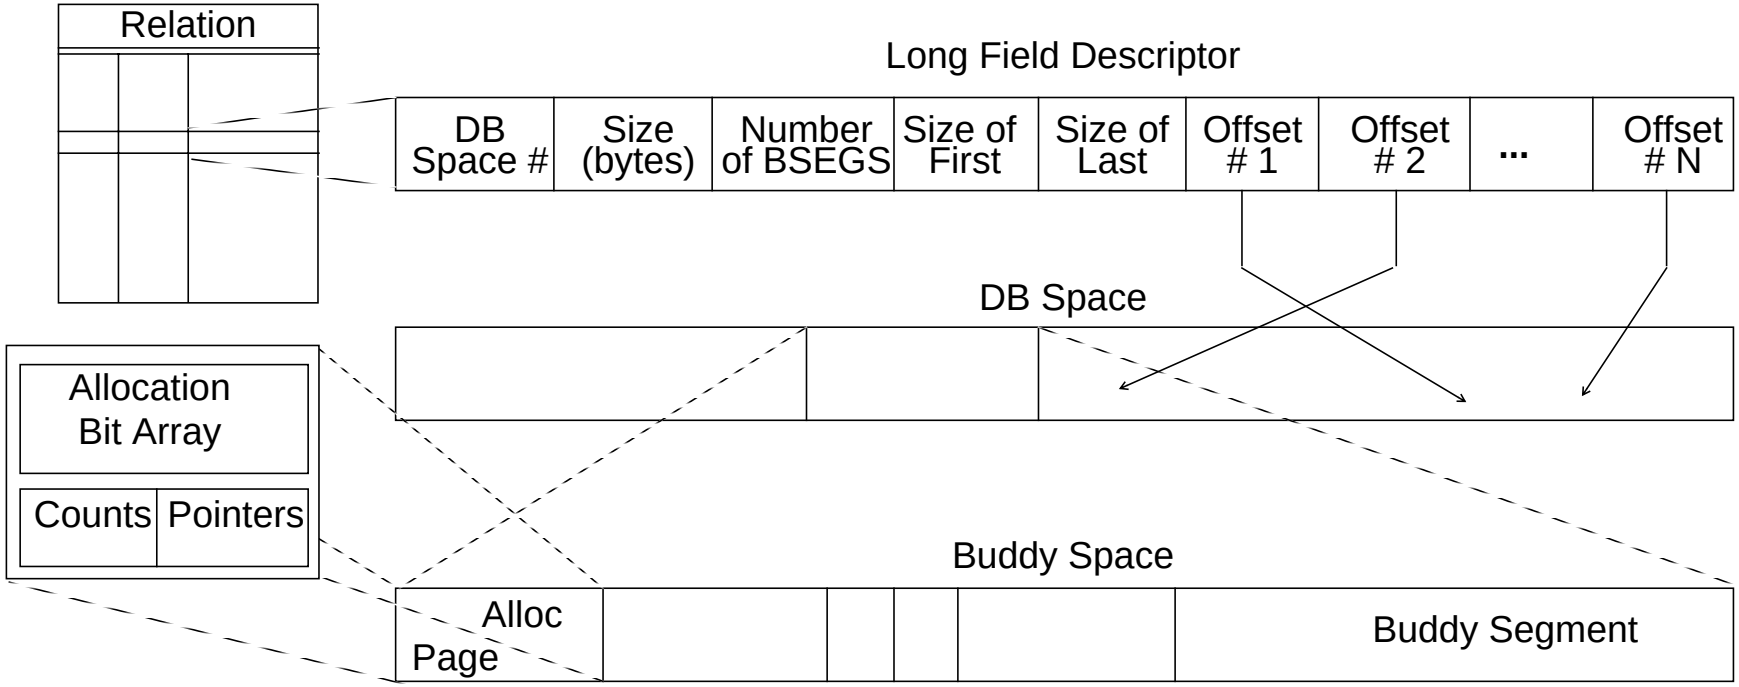

- **Aufbau eines Langen Feldes**
  - Deskriptor des Langen Feldes (< 255 Bytes) ist in Relation gespeichert
  - Long Field ist aufgebaut aus einem oder mehreren ***Buddy-Segmenten***, die in großen vordefinierten ***Buddy-Bereichen*** fester Länge auf Platte angelegt werden
  - Buddy-Segmente enthalten nur Daten und keine Kontrollinformation
  - Segment besteht aus 1, 2, 4, 8, ... oder 2048 Seiten (➥ max. Segmentgröße 2 MB bei 1 KB-Seiten)
  - Buddy-Bereiche sind allokiert in (noch größeren) DB-Dateien (DB Spaces). Sie setzen sich zusammen aus Kontrollseite (Allocation Page) und Datenbereich

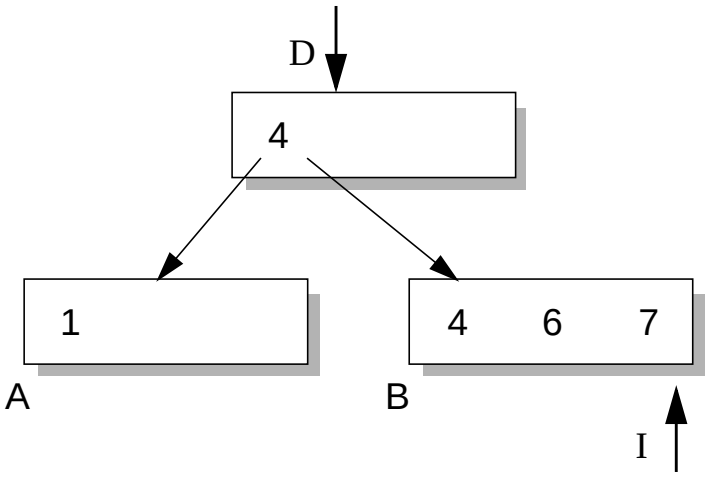
D
4
1
4 6 7
A
B
I

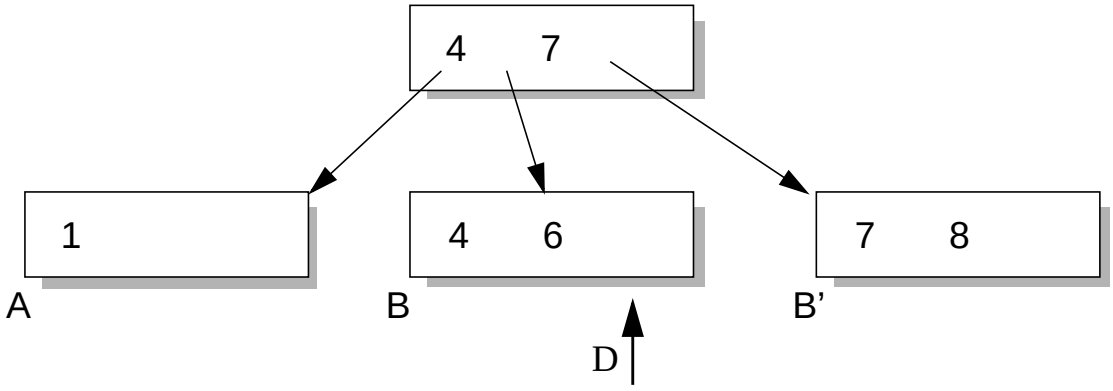
4 7
1
4 6
7 8
A
B
B'
D

5

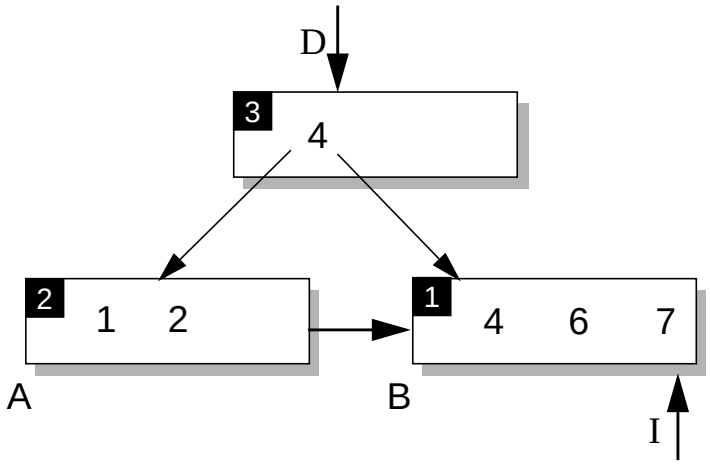

6

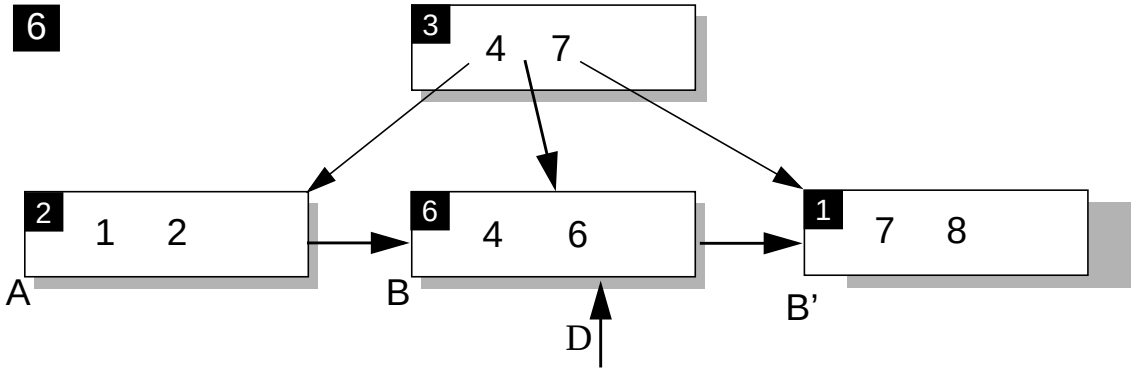

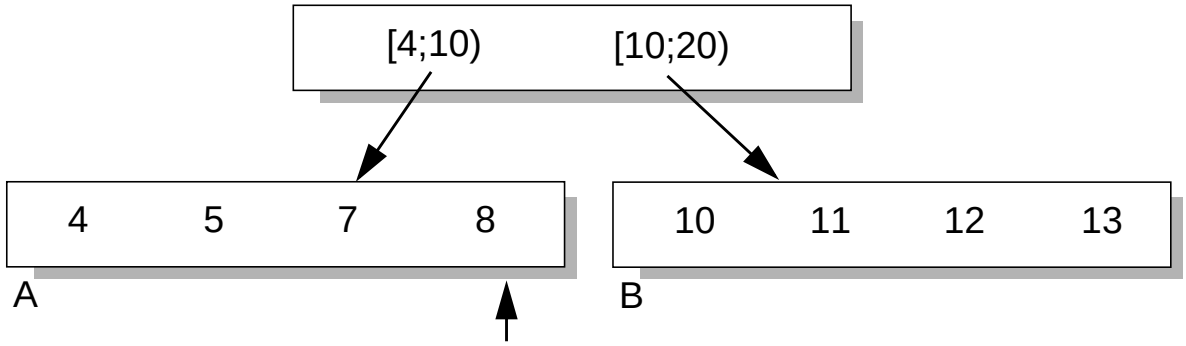
[4;10)
[10;20)
4
5
7
8
10
11
12
13
A
B

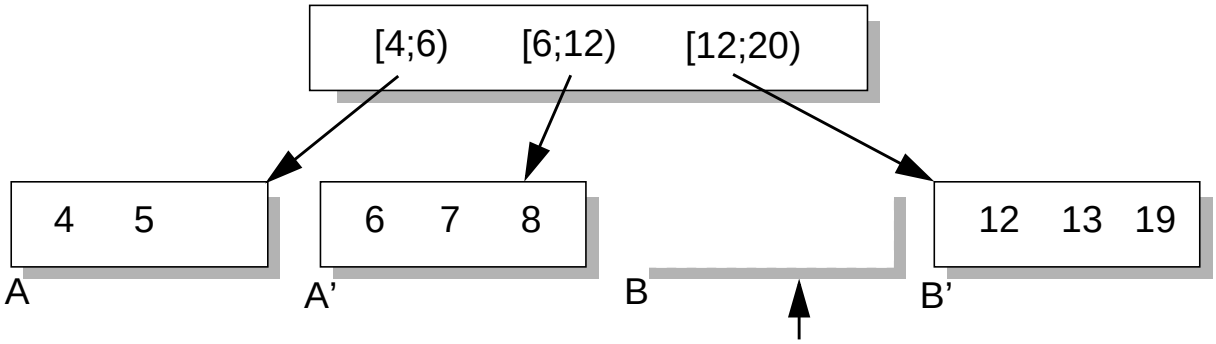
[4;6)
[6;12)
[12;20)
4
5
6
7
8
12
13
19
A
A'
B
B'

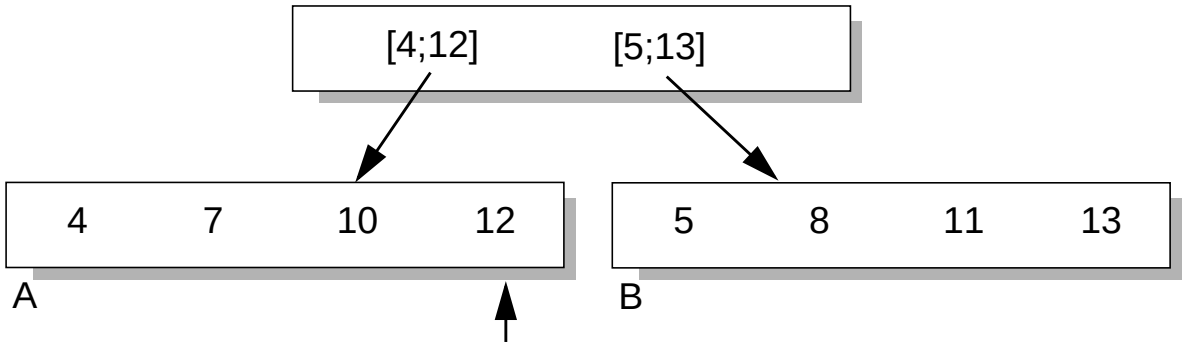
[4;12]
[5;13]
4
7
10
12
5
8
11
13
A
B

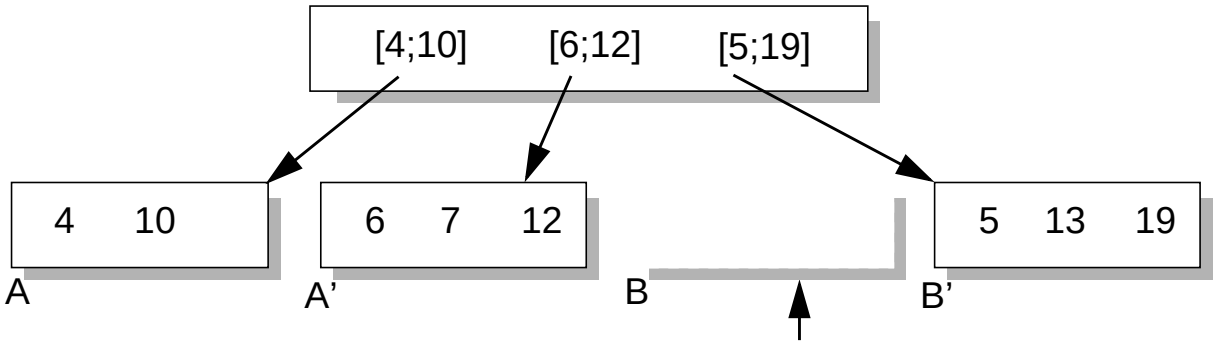
[4;10]
[6;12]
[5;19]
4
10
6
7
12
5
13
19
A
A'
B
B'