5. Speicherungsstrukturen

- **Ziel:** Entwurf von
  - Speicherungsstrukturen für Sätze und komplexe Objekte
  - Hilfsstrukturen wie Freispeicherverwaltung, Adressierung usw.
- **Freispeicherverwaltung**
- **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
- **Probleme großer Objekte**
- **Speicherungsstrukturen für LOBs**
  - Segmente fester und variabler Größe
  - Zugriff über B*-Baum, Zeigerliste, . . .
- **DB-Anbindung externer Daten**
  - DataLinks-Konzept
  - Referentielle Integrität, Zugriffskontrolle, Transaktionskonsistenz, Koordiniertes Backup und Recovery

- **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 ↔ address
  - Attributwert ↔ record-id.list
  - Satz-Identifikator ↔ record-id.list
  - Adresse ↔ {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
  - Freispeicherverwaltung
  - Adressierungsverfahren von und zwischen physischen 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

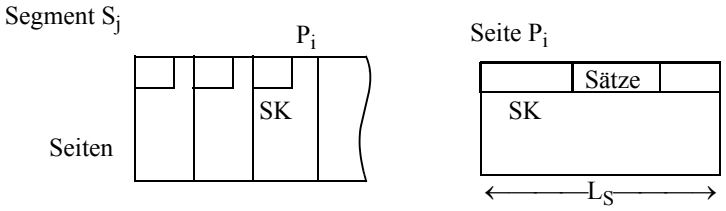

➥ in SK (Seitenkopf):
ID von P_i,
Freiplatz-Info,
Typ, Org.-Daten

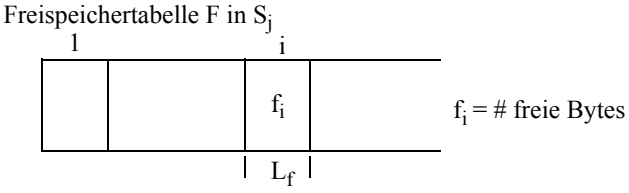

Freispeicherverwaltung (2)

- **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**

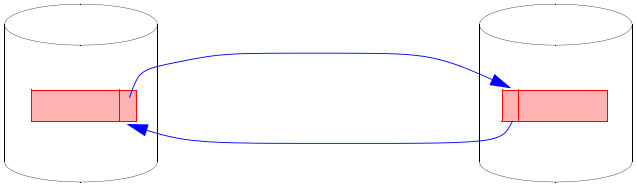

  - langfristige Speicherung der Datensätze
  - Vermeiden von „Technologieabhängigkeiten“
  - Unterstützung von Migration u. a.

- **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

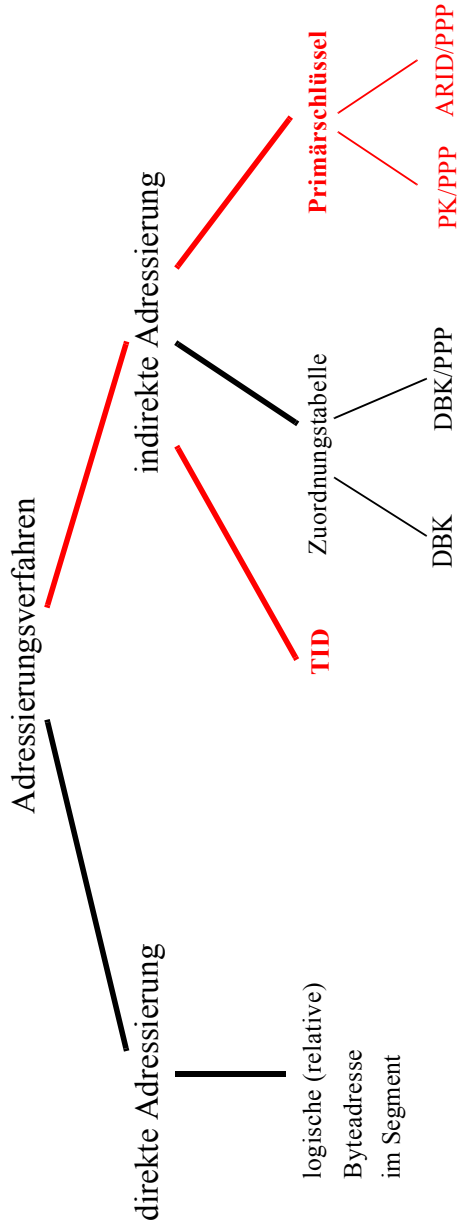

Satzadressierung: TID-Konzept

- **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**

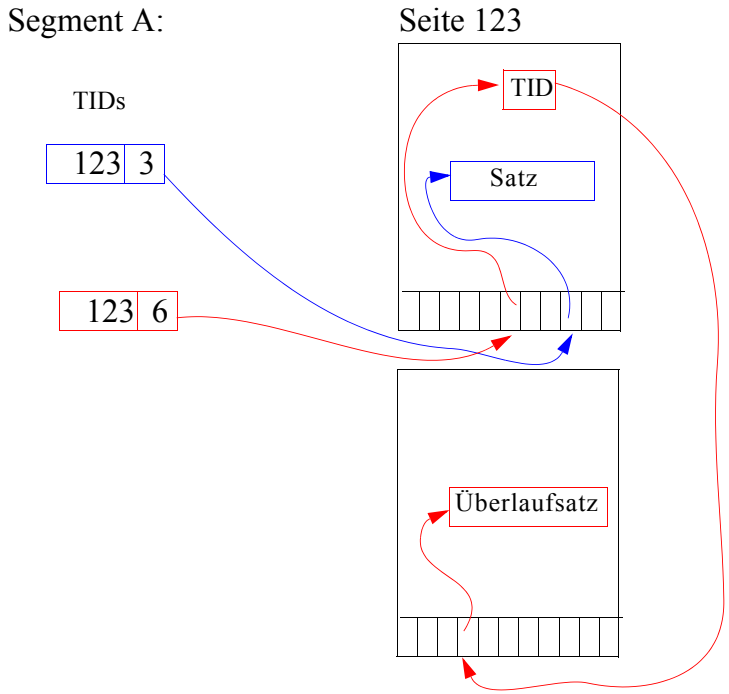

Satzadressierung über Zuordnungstabelle

- **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

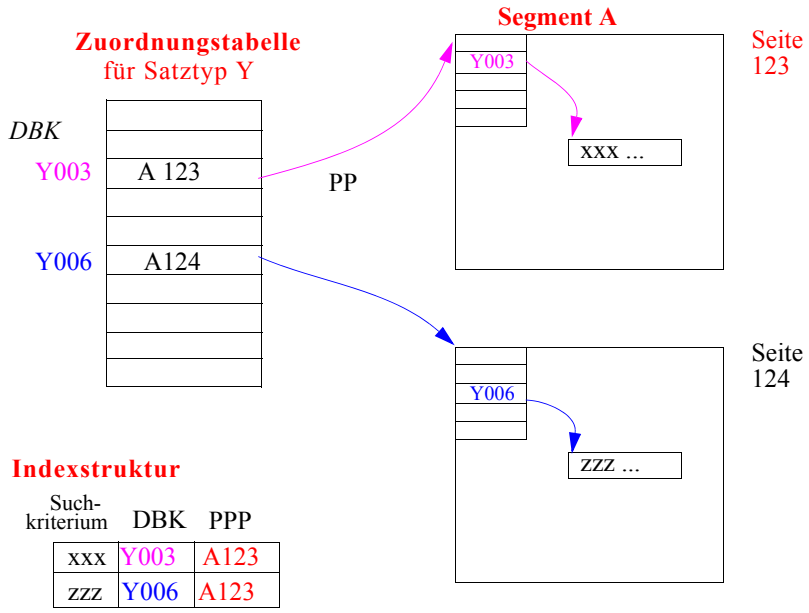

Indexstruktur

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**

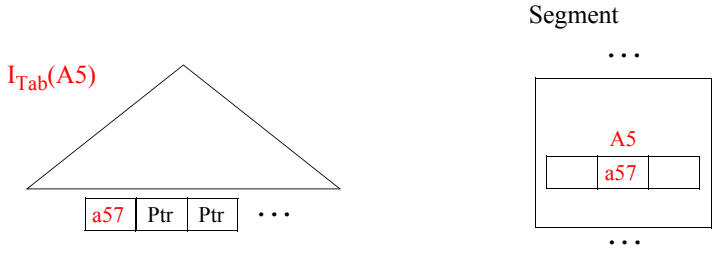

  - Sätze verschieben sich bei Aktualisierung nicht (kaum)
  - Adressierungsverfahren (Ptr):
    Es kommen TID, DBK und DBK/PPP in Frage
  - Indexunterstützung für ungeordnete Tabellen in DB2, Sybase, MS SQL-Server, Oracle, ...

Indexierung von Tabellen (2)

- **Index-organisierte Tabelle**

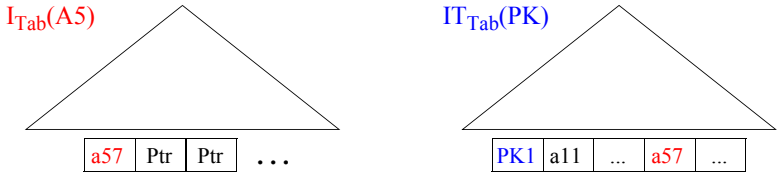

  - Split in IT_{Tab} erfordert viele Adressanpassungen in $I_{Tab}(Ai)$
    - bei TID
    - bei DBK
    - bei DBK/PPP
  - Verbesserung: logische Adressierung

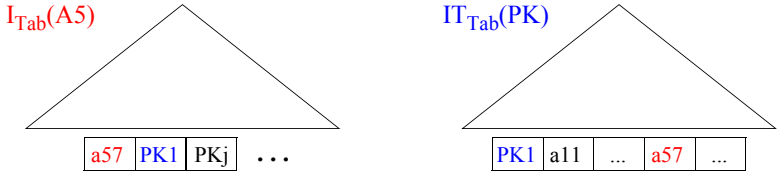

  - keine Wartung der $I_{Tab}(Ai)$ bei Split/Verschiebungen in IT_{Tab} nötig
  - **aber:** höhere Zugriffskosten bei Index-Scan usw.

- **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)

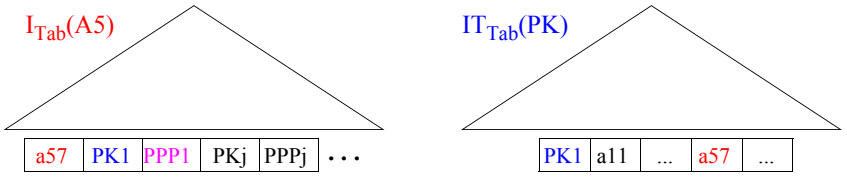

- Vereinigung der Vorteile beider Verfahren
- Was passiert bei langen Primärschlüsseln?

- **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 (Oracle-Lösung)
    - Nutzung einer Abbildungstabelle ATab
    - Verweis auf ATab durch ARID

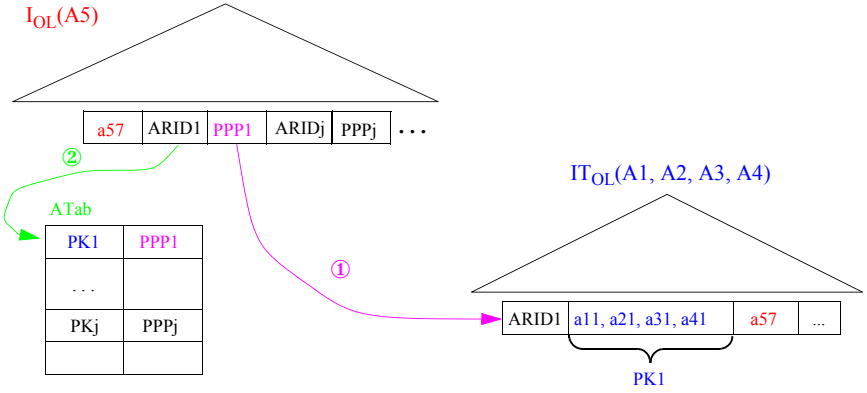

- Falls der Zugriff über PPP ① fehlschlägt, wird mit Hilfe von ARID ② ATab aufgesucht
- Alle I_{OL}(Ai) benutzen ATab
- Von dort kann über PPP oder über PK auf IT_{OL} zugegriffen werden

Hauptspeicherbasierte Adressierung

- **Aufgabe:**

  Programme sollen im HSP transiente und persistente Datenobjekte transparent 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]

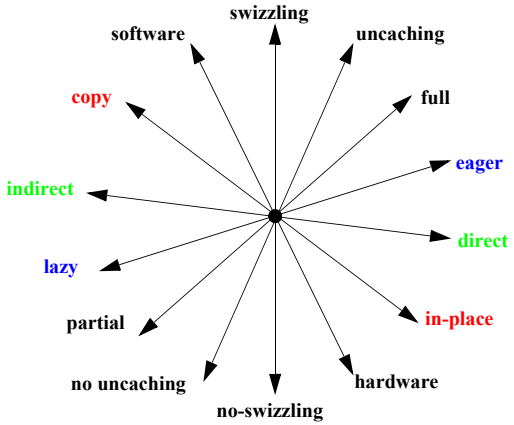

- **Klassifikation von Swizzling-Verfahren**

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

  - Ort:

  - *In-Place Swizzling:* Beibehaltung der Objektformate und der Seitenstrukturen
  - *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 Ersetzung 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)

- **Klassifikationskriterium: Ort**

in-place

DB-Puffer

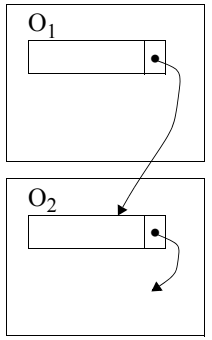

copy

Objektpuffer (Heap) befindet sich typischerweise im Client-Rechner

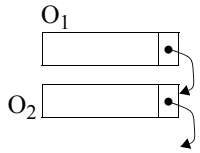

- **Klassifikationskriterium: Zeitpunkt**

eager

sobald im HSP (Lawineneffekt)

lazy

viele Möglichkeiten

- **Klassifikationskriterium: Art**

direct

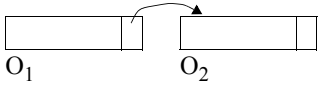

indirect

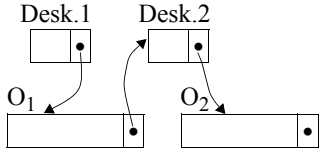

Pointer Swizzling (3)

- **Direktes und indirektes Swizzling – Prinzip**

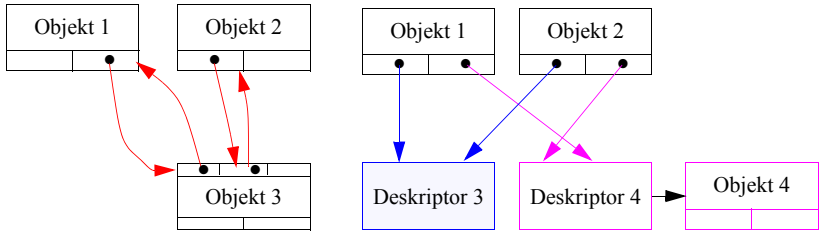

a) Symmetrische Referenzen

b) Referenzierung von Deskriptoren

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

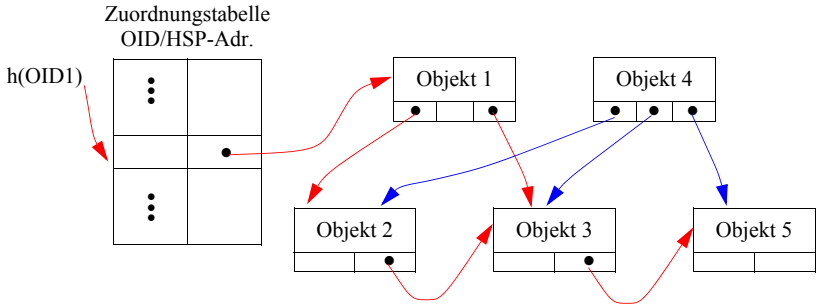

a) Direktes Swizzling in einem Objektpuffer

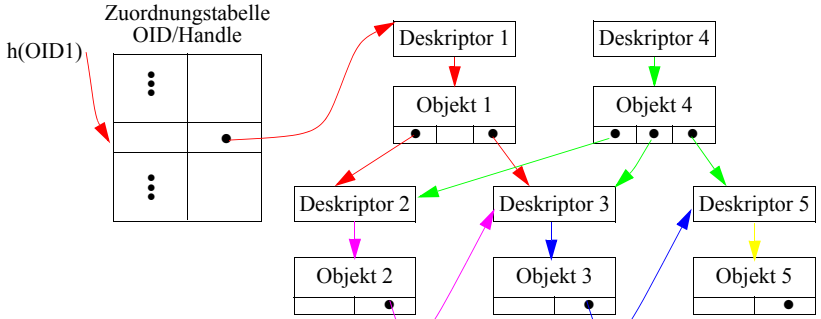

b) Indirektes Swizzling in einem Objektpuffer

Pointer Swizzling (4)

- **Tests**

Lazy:	Test, ist Swizzling schon erfolgt?
Eager:	kein Test
Indirect:	Test, ist Objekt schon/noch da?
Direct:	kein Test (aber kein Ersetzen des Objektes nach Swizzling oder Unswizzling)

- **Kosten**

Eager/Direct:	0 Tests	(kein Ersetzen)
Eager/Indirect:	1 Test (→ Ersetzen mit Referenz-Zähler)	(im Deskriptor)
Lazy/Direct:	1 Test (→ Ersetzen mit symmetrischen Zeigern)	(+ Heuristik-Kosten)
Lazy/Indirect:	2 Tests	(+ Heuristik-Kosten (> 3 Refs))

Pointer Swizzling (5)

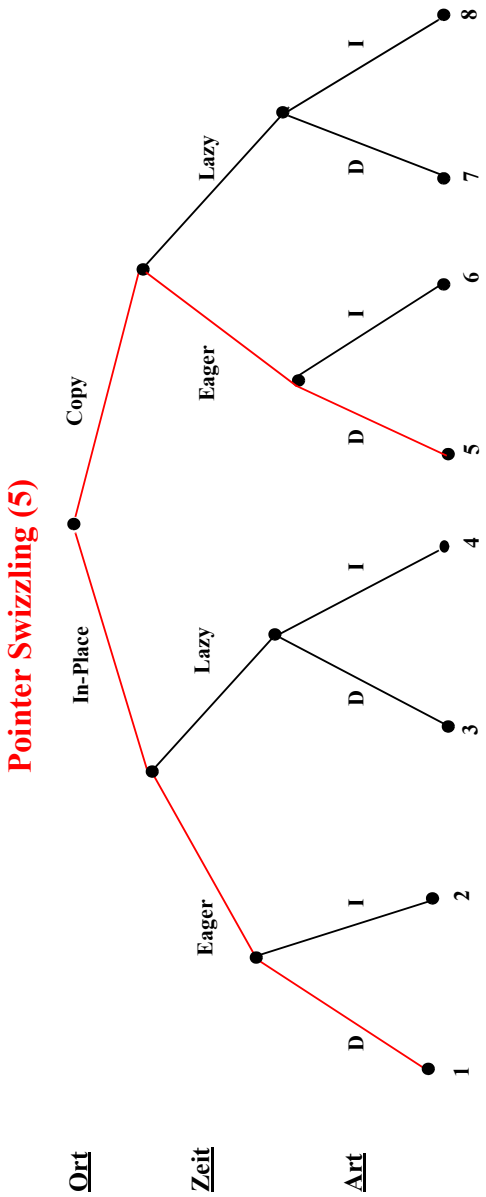

Bemerkungen:

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:

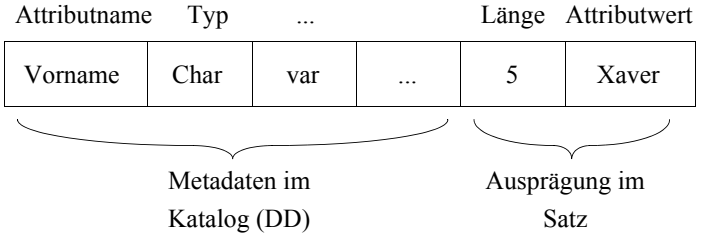

  - Satz- und Zugriffspfadbeschreibung im Katalog
  - besondere Methoden der Speicherung
    - Blank-/Nullunterdrückung
    - Zeichenverdichtung
    - kryptographische Verschlüsselung
    - Symbol für undefinierte Werte
  - Tabellenersetzung für Werte: KL = Kaiserslautern
- **Organisation**
  - n Satztypen pro Segment
  - m Sätze verschiedenen Typs pro Seite
  - Satzlänge < Seitenlänge: $S_L \leq L_S - L_{SK}$

Speicherungsstrukturen für Sätze

- **Entwurfsziele**
  - Speicherplatzökonomie
  - schnelles Aufsuchen des i-ten Feldes
    (weitgehende Berechnung aus Kataloginformation)
  - dynamische Erweiterung (ALTER TABLE ...)

- **Konkatenation von Feldern fester Länge**

  Katalog: f5 | f8 | f80 | f6 | ... |

  z. B. TID

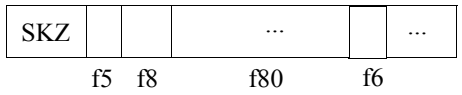

  - speicheraufwendig
  - unflexibel

- **Zeiger im Vorspann**

  Katalog: f5 | v | v | f6 | ... |

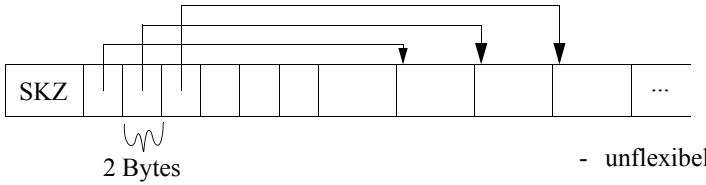

  - unflexibel

- **Eingebettete Längenfelder**

  Katalog: f5 | v | v | f6 | f2 | v |

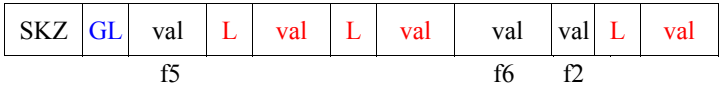

  - stärkere Nutzung des Katalogs
  - dynamische Erweiterung möglich

Speicherungsstrukturen für Sätze (2)

- **Optimierung: eingebettete Längenfelder mit Zeigern**

  Katalog: f5 | v | v | f6 | f2 | v |

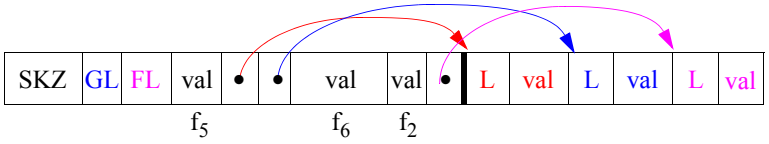

  - Adresse des n-ten Attributs kann berechnet werden
  - dynamische Erweiterbarkeit

- **Satzabbildung: Bewertung der Verfahren**

	Konkatenation von Feldern fester Länge	Zeiger im Vorspann	Eingebettete Längenfelder	Eingebettete Längenfelder mit Zeigern
Speicherplatz-ökonomie				
Zugriffsgeschwin-digkeit innerhalb des Satzes				
Erweiterbarkeit				

Speicherungsstrukturen für Sätze (3)

- **Anforderungen**

	Vorname	Name	Beruf	
OID	Xaver			

  - ≥ 200 Attribute/Satz ?
  - $S_L \leq L_S - L_{SK}$
  - Muss passen für n relationale DBMS
  - Indexierung

- **Extreme Lösung: AOW**

A	OID	W
Vorname	XYZ 0815	Xaver

Abbildung auf n-äre Relation DR

AID	OID	W1	W2	W3	W4	W5
A15	XYZ 0815	∅	∅	∅	Xaver	∅
			FLOAT		VARCHAR	
Typen:		INT		MONEY		OWN

  - Suche des gesamten Tupels mit 200 Attributen ?

    ➥ über OID

  - Index auf allen Attributen

```
Suche:      Select *
            FROM        Pers(DR)
            WHERE       Vorname = 'Xaver'
            (OR) AND    Beruf = 'Prog.'
            (OR) AND    Alter > 50
```


Speicherungsstrukturen für Sätze (4)

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

  ➥ Eingeführte 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**

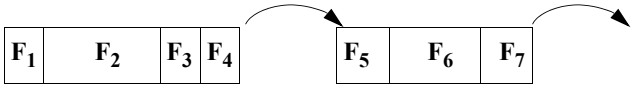

  - Ordnung nach Referenzhäufigkeiten
  - Verbesserung der Clusterbildung
  - Wiederholter Überlauf möglich
  - wird unvermeidlich bei der Einbeziehung von Attributen vom Typ TEXT oder BILD

Speicherungsstrukturen für komplexe Objekte[1]

- **Komplexe Objekte werden gebildet aus**
  - atomaren Werten und darauf
  - rekursiv angewandten Mengen-, Listen- und Tupelkonstruktoren
- **Modell für komplexe Objekte (eNF^2)**

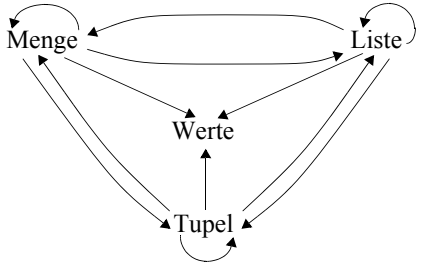

- **Speicherungsstrategie**
  - Orthogonalität ist wichtig: keine Enummeration aller Möglichkeiten
  - Ablegen von häufig gemeinsam zugegriffenen Substrukturen in eine oder wenige Speichereinheiten
  - selten gemeinsam zugegriffene Substrukturen separieren

  ➥ Anwendungswissen!
- **Leistungsaspekte**
  - werden bei komplexen Objekten/Operationen wesentlich bestimmt von den Speicherungsstrukturen
  - Minimierung von Ein-/Ausgabe: Clusterbildung
  - Berücksichtigung des Wachstums beim Anlegen eines komplexen Objektes

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

Speicherungsstrukturen für komplexe Objekte (2)

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

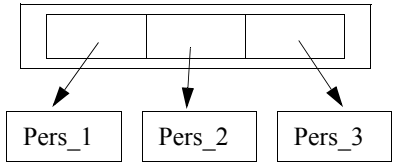

Referenzierte Speicherung

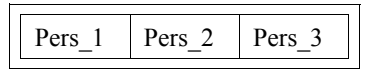

Materialisierte Speicherung

Speicherungsstrukturen für komplexe Objekte (3)

- **Zweimalige Anwendung des Mengenkonstruktors**
  - { {Pers_1 , Pers_2} , {Pers_3 , Pers_4} }
  - Vorgabe variabel langer Arrays als Konstruktordatenstrukturen
- **Vier Implementierungen**

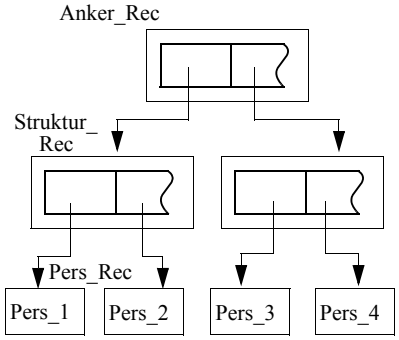

1. Elemente äußere Menge : referenziert
   Elemente innere Menge : referenziert

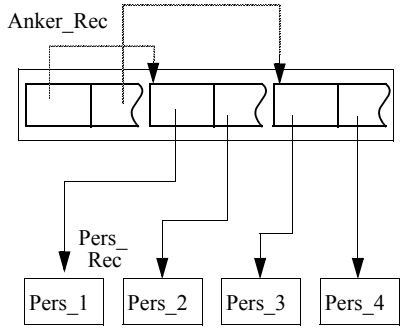

2. Elemente äußere Menge : materialisiert
   Elemente innere Menge : referenziert

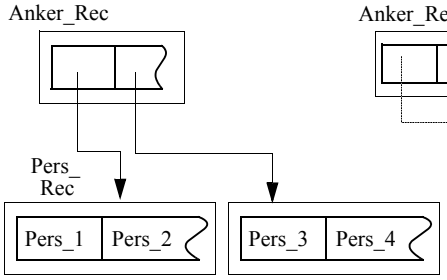

3. Elemente äußere Menge : referenziert
   Elemente innere Menge : materialisiert

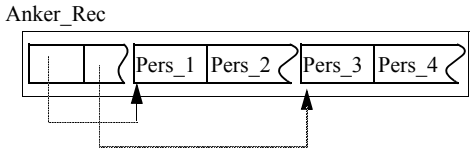

4. Elemente äußere Menge : materialisiert
   Elemente innere Menge : materialisiert

- 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 Satz (Record) oder zu mehreren Sätzen
  - 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 Sätze 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**

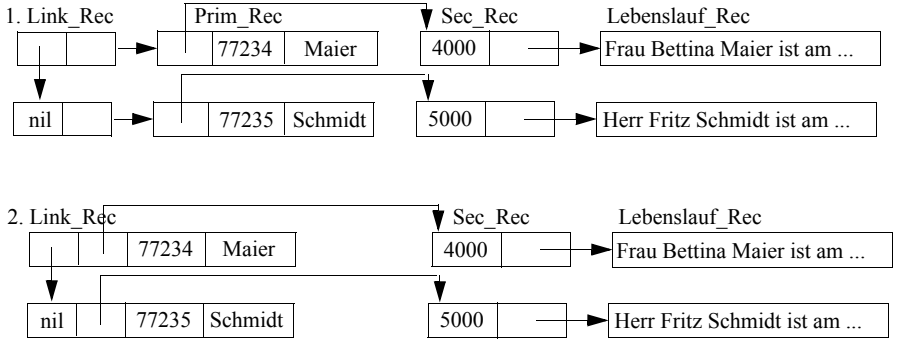

Große Objekte

- **Anforderungen**
  - idealerweise keine Größenbeschränkung
  - allgemeine Verwaltungsfunktionen
  - zugeschnittene Verarbeitungsfunktionen, . . .
- **Beispiele für große Objekte (heute bis n (=4) TByte)**
  - Texte, CAD-Daten
  - Bilddaten, Tonfolgen
  - Videosequenzen, . . .
- **Prinzipielle Möglichkeiten der DB-Integration**

Speicherung als LOB in der DB (meist indirekte Speicherung)

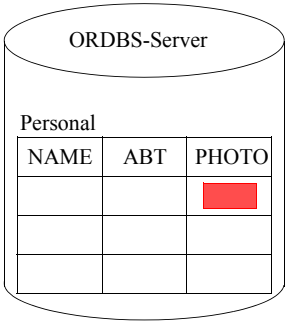

BLOB - *Binary Large Object*
für Tonfolgen, Bilddaten usw.

CLOB - *Character Large Object*
für Textdaten

DBCLOB - *Double Byte Character Large Object (DB2)*
für spezielle Graphikdaten usw.

Speicherung mit DataLinks-Konzept in externen Datei-Servern

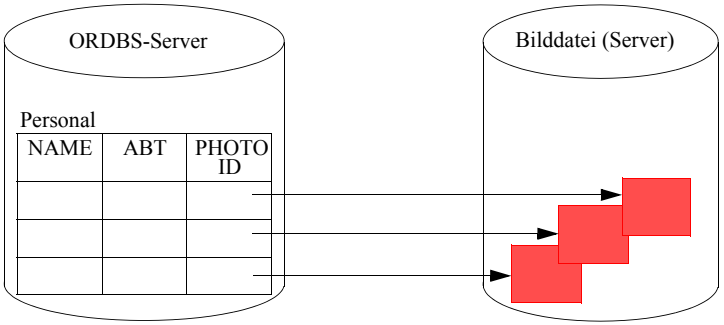

Große Objekte (2)

- **Erzeugung von LOB-Spalten**[1]

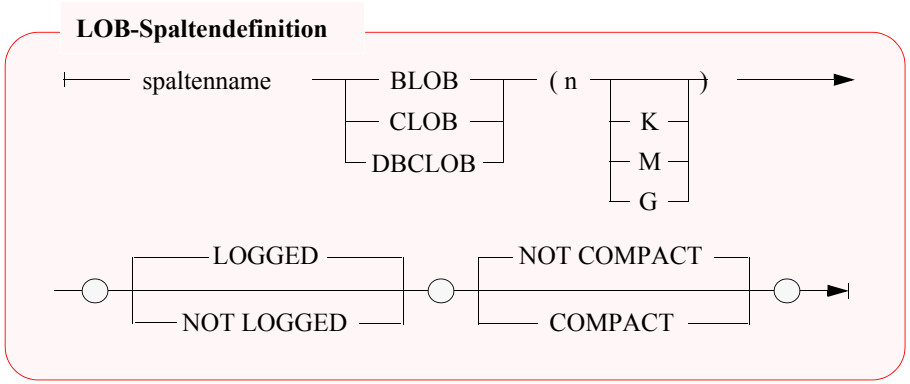

- **Beispiele**

```
CREATE TABLE    Absolvent
   (Lfdnr       Integer,
   Name         Varchar (50),
   . . .
   Photo        BLOB (5 M) NOT LOGGED COMPACT,     -- Bild
   Lebenslauf   CLOB (16 K) LOGGED NOT COMPACT);   -- Text

CREATE TABLE    Entwurf
   (Teilnr      Char (18),
   Änderungsstand  Timestamp,
   Geändert_von    Varchar (50)
   Zeichnung    BLOB (2 M) LOGGED NOT COMPACT);    -- Graphik

ALTER TABLE     Absolvent
   ADD COLUMN   Diplomarbeit CLOB (500 K)
                LOGGED NOT COMPACT;
```

1. Die Realisierungsbeispiele beziehen sich auf DB2 – Universal Database

Große Objekte (3)

- **Spezifikation von LOBs erfordert Sorgfalt**
  - **maximale Länge**
    - Reservierung eines Anwendungspuffers
    - Clusterbildung und Optimierung durch indirekte Speicherung; Deskriptor im Tupel ist abhängig von der LOB-Länge (72 Bytes bei <1K bis 316 Bytes bei 2G)
    - bei kleinen LOBs (< Seitengröße) direkte Speicherung möglich
  - **kompakte Speicherung**
    - COMPACT reserviert keinen Speicherplatz für späteres Wachstum
      - ➥ Was passiert bei einer LOB-Aktualisierung?
    - NOT COMPACT ist Default
  - **Logging**
    - LOGGED: LOB-Spalte wird bei Änderungen wie alle anderen Spalten behandelt (ACID!)
      - ➥ Was bedeutet das für die Log-Datei?
    - NOT LOGGED: Änderungen werden nicht in der Log-Datei protokolliert. Sog. Schattenseiten (shadowing) gewährleisten Atomarität bis zum Commit

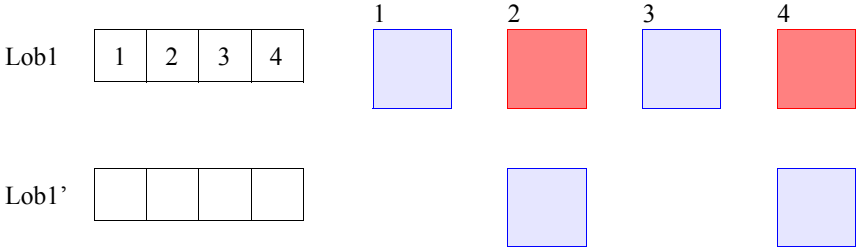

➥ Was passiert bei Gerätefehler?

Große Objekte (4)

- **Wie werden große Objekte verarbeitet?**
  - BLOB und CLOB sind keine Typen der Wirtssprache

  ➥ Spezielle Deklaration von BLOB, CLOB, ... durch SQL TYPE ist erforderlich, da sie die gleichen Wirtssprachentypen benutzen. Außerdem wird sichergestellt, dass die vom DBS erwartete Länge genau eingehalten wird.

- **Vorbereitungen im AWP erforderlich**
  - SQL TYPE IS CLOB (2 K) c1 (oder BLOB (2 K)) wird durch C-Precompiler übersetzt in

```
static struct c1_t
    {
    unsigned long length;
    char data [2048];
    } c1;
```

  - Erzeugen eines CLOB

```
c1.data = 'Hello';
c1.length = sizeof ('Hello')-1;
```

  kann durch Einsatz von Makros (z. B. c1 = SQL_CLOB_INIT('Hello');) verborgen werden

- **Einfügen, Löschen und Ändern**
  kann wie bei anderen Typen erfolgen, wenn genügend große AW-Puffer vorhanden sind

- **Hole die Daten des Absolventen mit Lfdnr. 17 ins AWP**

```
. . .
SELECT Name, Photo, Lebenslauf
INTO :x, :y :yindik, :z :zindik
FROM Absolvent
WHERE Lfdnr = 17;
```

Große Objekte (5)

- **Welche Operationen können auf LOBs angewendet werden?**
  - Vergleichsprädikate: =, <>, <, <=, >, >=, IN, BETWEEN
  - LIKE-Prädikat
  - Eindeutigkeit oder Reihenfolge bei LOB-Werten
    - PRIMARY KEY, UNIQUE, FOREIGN KEY
    - SELECT DISTINCT, . . ., COUNT (DISTINCT)
    - GROUP BY, ORDER BY
  - Einsatz von Aggregatfunktionen wie MIN, MAX
  - Operationen
    - UNION, INTERSECT, EXCEPT
    - Joins von LOB-Attributen
  - Indexstrukturen über LOB-Spalten
- **Wie indexiert man LOBs?**
  - Benutzerdefinierte Funktion ordnet LOBs Werte zu
  - **Funktionswert-Indexierung**

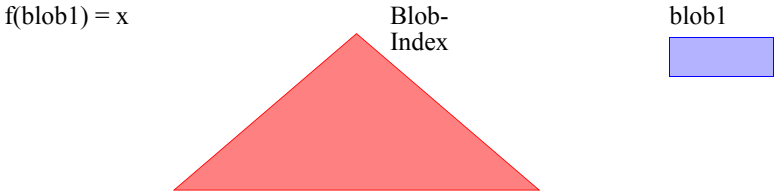

Große Objekte (6)

- **Ist die direkte Verarbeitung von LOBs im AWP realistisch?**

```
Bücher                                  EXEC SQL
  (Titel          Varchar (200),          SELECT Kurzfassung, Buchtext, Video
   BNR            ISBN,                   INTO :kilopuffer, :megapuffer, :gigapuffer
   Kurzfassung    CLOB (32 K),
   Buchtext       CLOB (20 M),            FROM Bücher
   Video          BLOB (2 G))             WHERE Titel = 'American Beauty'
```

- **Client/Server-Architektur**

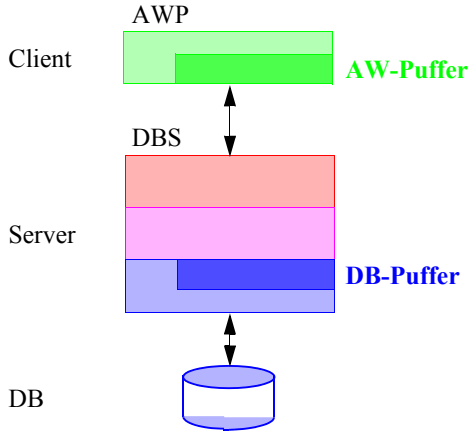

  - Allokation von Puffern?
  - Transfer eines ganzen LOB ins AWP?
  - Soll Transfer über DBS-Puffer erfolgen?
  - „Stückweise“ Verarbeitung von LOBs durch das AWP erforderlich!
    - ➥ Lokator-Konzept für den Zugriff auf LOBs

Speicherung großer Objekte[1]

- **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

- **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

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

Lange Felder in Exodus

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

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

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

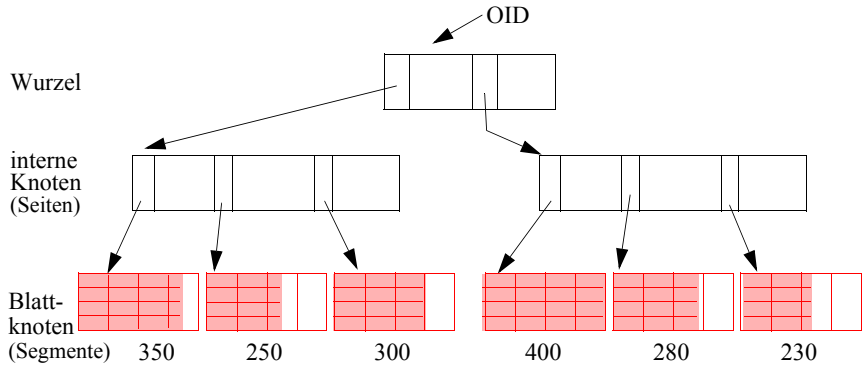

  - Byte 100 in der letzten Seite?

Exodus[1] (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)

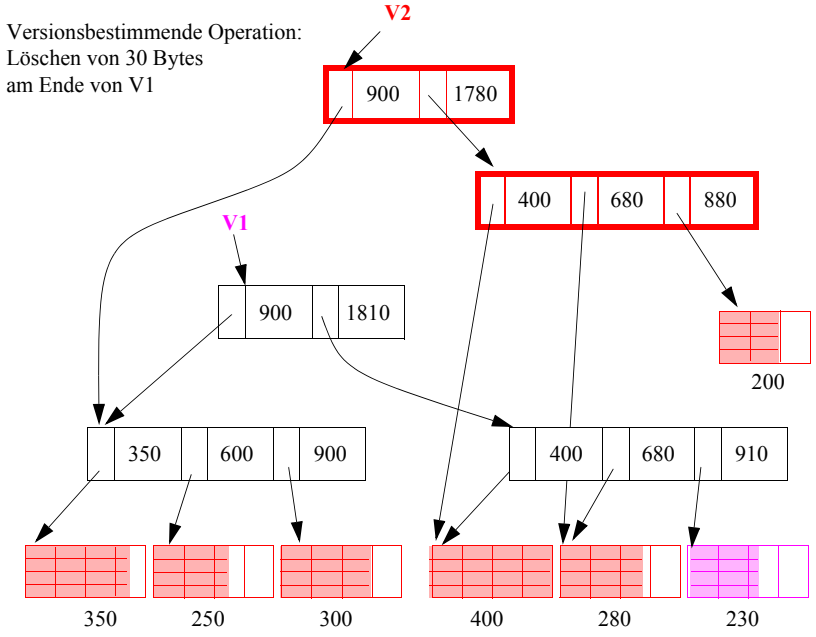

1. M.J. Carey, D.J. DeWitt, J.E. Richardson, E.J. Shekita: *Object and File Management in the EXODUS Extensible Database System*. Proc. 12th VLDB Conf., 1986, pp. 91-100

Lange Felder in Starburst

- **Erweiterte Anforderungen**
  - Effiziente Speicherallokation und -freigabe für Felder von 100 MB bis 2 GB
  - hohe E/A-Leistung:
    Schreib- und Lese-Operationen sollen E/A-Raten nahe der Übertragungs-geschwindigkeit 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.

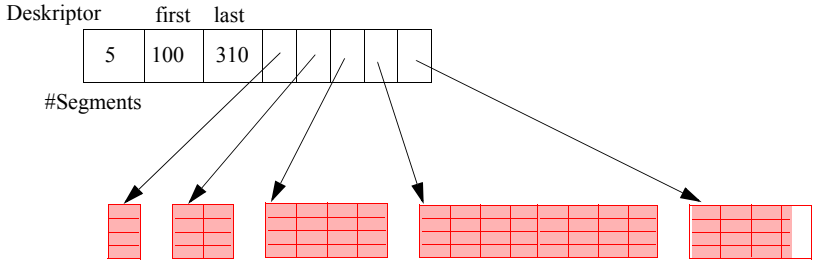

- **Segmentallokation bei vorab bekannter Objektgröße**
  - Objektgröße G (in Seiten)
  - G ≤ MaxSeg: es wird ein Segment angelegt
  - G > MaxSeg: es wird eine Folge maximaler Segmente angelegt
  - letztes Segment wird auf verbleibende Objektgröße gekürzt

Lange Felder in Starburst[1](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

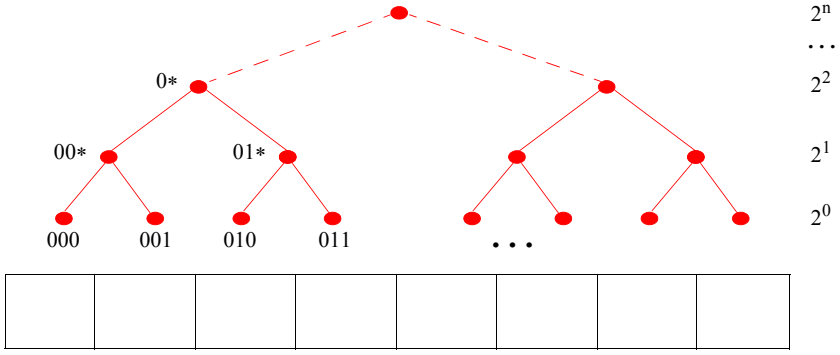

  - Zusammenfassung zweier Buddies der Größe $2^n \Longrightarrow 2^{n+1}$ $(n \geq 0)$

- **Verarbeitungseigenschaften**
  - effiziente Unterstützung von sequentiellem und wahlfreiem Lesen
  - einfaches Anhängen und Entfernen von Bytefolgen am Objektende
  - schwieriges Einfügen und Löschen von Bytefolgen im Objektinneren

1. T. J. Lehman, B. G. Lindsay: *The Starburst Long Field Manager*. Proc. 15th VLDB Conf., 1989, pp. 375-383

Starburst: Speicherorganisation zur Realisierung Langer Felder

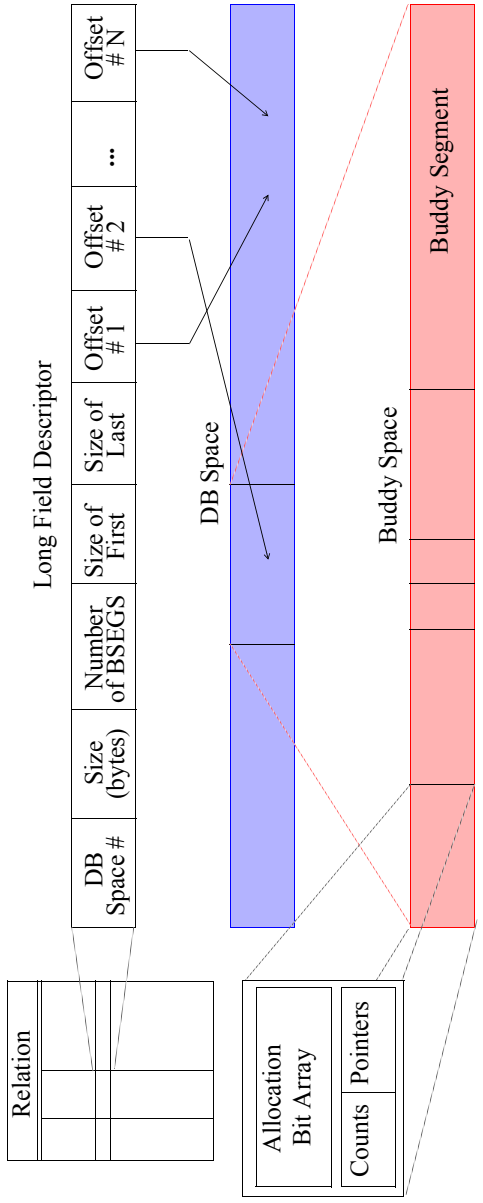

- **Aufbau eines Langen Feldes**
  - Deskriptor des Langen Feldes (< 316 Bytes) ist in Relation gespeichert
  - Long Field ist aufgebaut aus einem oder mehreren ***Buddy-Segmenten***, die in großen vordefinierten ***Buddy-Bereichen*** fester Länge auf Platte angelegt werden
  - Buddy-Segmente enthalten 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

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**

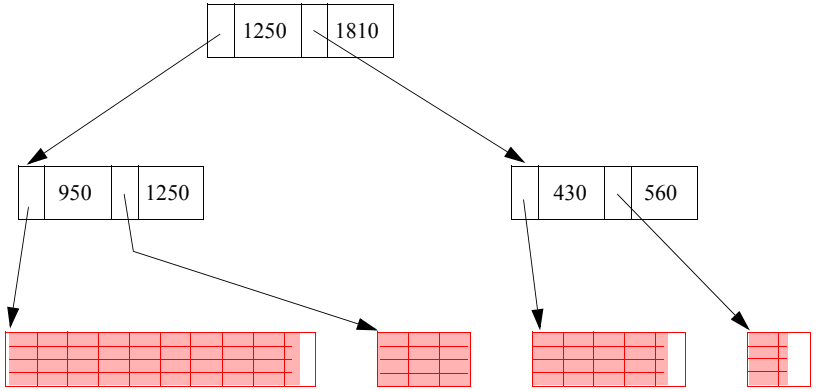

➥ Die Größen der einzelnen Segmente können sehr stark variieren

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

DB-Anbindung externer Daten

- **Motivation**
  - Die meisten Daten in einem Unternehmen sind in Dateien gespeichert.
  - Sie werden es auf lange Zeit bleiben und im Umfang zunehmen.
  - Da viele Anwendungen mit Dateien arbeiten, ist es erforderlich, auch diese Datenzugriffe zu unterstützen.
    (gleichförmiger Zugriff zu DBs und anderen Datenquellen, siehe OLE DB)
- **Eigenschaften**
  - Dateisysteme bieten nicht genügend Metadaten für Suchfunktionen und Integritätserhaltung.
  - DBMS unterstützen u. a. ein großes Spektrum an Funktionen, sind momentan aber nicht für die Speicherung einer großen Anzahl von BLOBs (Multimedia-Typen) optimiert.
  - BLOBs benötigen hierarchische Speicherverwaltung von leistungsfähigen Dateisystemen (z. B. Tertiärspeicher), die eine kosteneffektive Verwaltung der Daten für variierende Zugriffsmuster (häufig oder selten) gewährleisten.

➥ Verknüpfung von Dateisystemen und DBMSs soll Vorteile beider Ansätze nutzen!

- **Anwendungsbeispiele**
  - **CAD-Systeme:** Synchronisation von Millionen von Bauteilen (Zeichnungen und Baupläne in einem proprietären Format)
  - **Multimedia-Objekte:** Verwaltung von Bibliotheken für Bilder, Programme, Dokumente oder Videos
  - **HTML- und XML- Dateien:** DB-Unterstützung für die Funktionalität von Web-Server

DB-Anbindung externer Daten[1] (2)

- **Speichermodell für die DB-Anbindung**

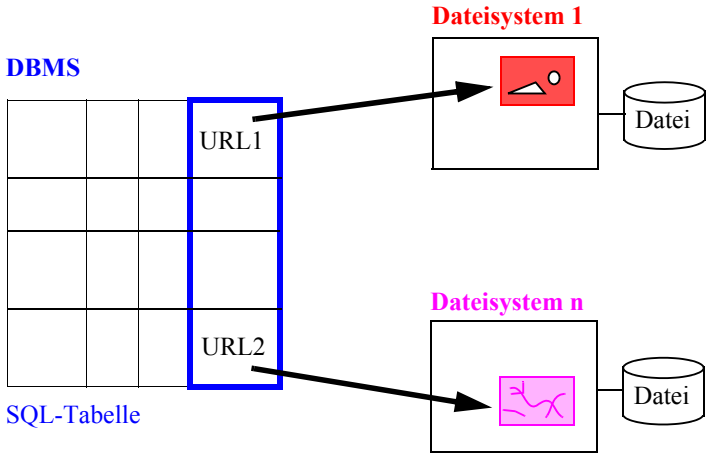

- **Welche Probleme sind zu lösen?**
  - **Referentielle Integrität**
  - **Zugriffskontrolle**
  - **Koordiniertes Backup und Recovery**
  - **Transaktionskonsistenz**
  - zusätzlich: Suche über
    - herkömmliche Datentypen
    - Inhalte externer Daten
  - Leistungsaspekte bei DB- und Datei-Anwendungen

➥ Beteiligte Dateisysteme benötigen zusätzliche Kontrollkomponente, die mit dem DBMS über spezielle Protokolle kooperiert

1. Information Technology – Database Language SQL - Part 9: Management of External Data, International Standard, May 2001 (www.jtc1sc32.org)

DB-Anbindung externer Daten (3)

- **DataLinks-Konzept zur Verwaltung externer Daten**

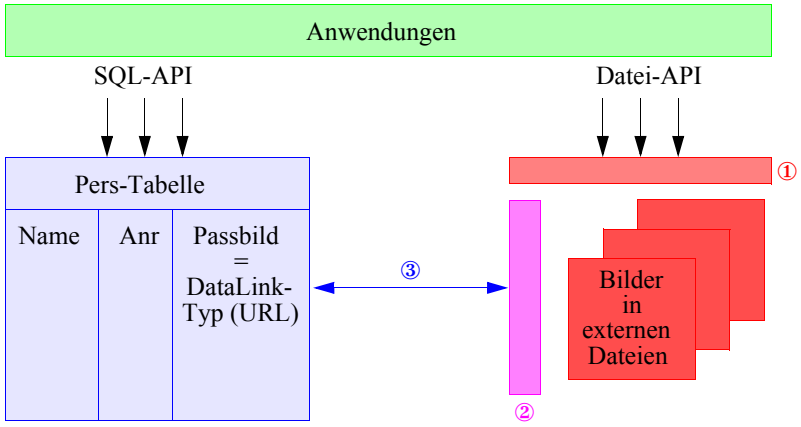

① DataLinks Filesystem Filter (DLFF)

- erzwingt referentielle Integrität beim Umbenennen und Löschen von Dateien
- erzwingt DB-zentrierte Zugriffskontrolle beim Öffnen einer Datei
- Datei-API bleibt unverändert – keine Änderungen in den Anwendungen
- DLFF liegt nicht im Lese-/Schreib-Pfad für externe Dateien (Performance!)

② DataLinks File Manager (DLFM)

- führt Link-/UnLink-Operationen transaktionsgeschützt durch
- gewährleistet referenzielle Integrität
- unterstützt koordiniertes Backup/Recovery

③ DBMS verwaltet/koordiniert Operationen auf externen Dateien

- über URL's referenziert
- durch DLFM-API (DataLinks File Manager)

DB-Anbindung externer Daten (4)

- **Verarbeitungsmodell aus der Sicht der Anwendung**
  - SQL-Zugriff auf Metadaten-Repository für externe Daten
  - Suche ist auch über den Inhalt externer Daten möglich
    ➥ Funktionswertindexierung
  - Liste von Referenzen der gesuchten Objekte
  - Anwendung referenziert externe Daten direkt über Datei-API.

- **DataLinks-Datentyp nach SQL:99 – Beispiel**

```
CREATE TABLE Pers (
  Name VARCHAR (30);
  Anr INTEGER,
  Passbild DATALINK (200)
        LINKTYPE URL
        FILE LINK CONTROL
                INTEGRITY all
                READ PERMISSION DB
                WRITE PERMISSION blocked
                RECOVERY yes
                ON UNLINK restore
  );
```

  - DBMS-Kontrolle lässt sich abgestuft aktivieren.
  - URL: http://servername/pathname/filename/
  - **Integrity:** URLs als Referenzen werden konsistent gehalten.
  - **Read Permission:** bleibt entweder beim Dateisystem oder wird ans DBMS delegiert. Autorisierung wird als Token in die URL eingebettet.
  - **Write Permission:** bleibt beim Dateisystem oder wird blockiert
  - **Recovery:** Nur bei Option WRITE PERMISSION blocked ist koordiniertes Backup und Recovery möglich.
  - **On Unlink:** Datei kann gelöscht oder zur Verwaltung ans Dateisystem zurückgegeben werden.

DB-Anbindung externer Daten (5)

- **DataLinks-Architektur**

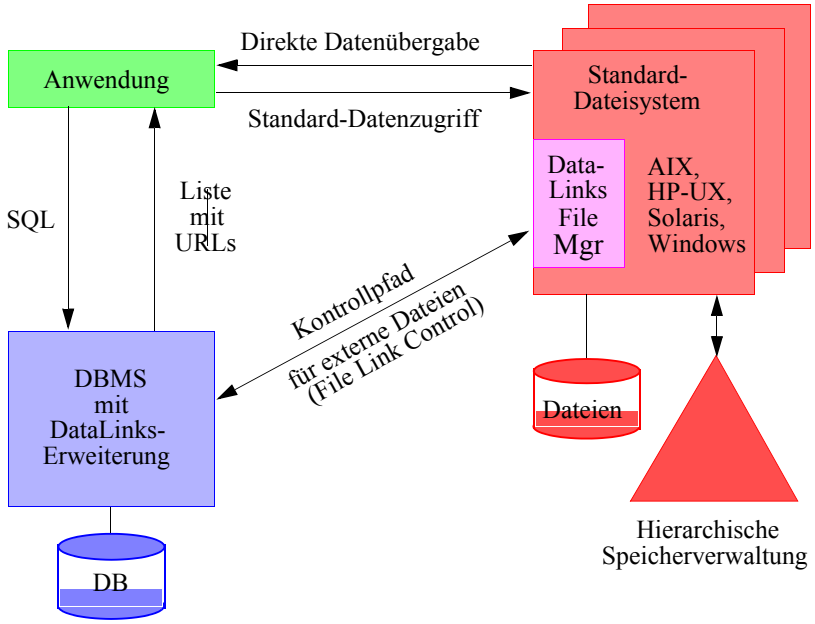

- **Typische Anwendung**
  - Integration von unstrukturierten und semi-strukturierten Daten mit Anwendungen auf DB-Basis
  - Reichweite: große Anzahl von Dateien in Rechnernetzwerken
  - Bei Funktionswertindexierung: Über URLs referenzierte Dateien bleiben weitgehend unverändert.
  - Benutzer extrahiert Features von Bildern oder Videos, speichert sie in der DB zwischen, um Auswertungen zusammen mit Prädikaten auf anderen DB-Daten zu machen.
  - *Query By Image Content* (QBIC) unterstützt Extraktion und Suche auf solchen Features.

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

Zusammenfassung (2)

- **Spezifikation großer Objekte hat großen Einfluss auf die DB-Verarbeitung**
  - Speicherungsoptionen, Logging
  - Einsatz benutzerdefinierter und systemspezifischer Funktionen
  - Deklarative SQL-Operationen, aber Cursor-basierte und „navigierende“ Verarbeitung von LOB-Werten
- **Spezielle Verarbeitungstechniken und gute Leistungseigenschaften erforderlich**
  - Transport zur Anwendung (Minimierung von Kopiervorgängen)
  - Anfrageoptimierung, Auswertung von LOB-Funktionen
  - Synchronisation, Logging und Recovery
- **Speicherung großer Objekte wird zunehmend wichtiger**
  - B*-Baum-Technik:
    flexible Darstellung, moderate Zugriffsgeschwindigkeit
  - große variabel lange Segmente (Listen): hohe E/A-Leistung
  - Auswahl verschiedener, auf Verarbeitungscharakteristika zugeschnittener Techniken
- **DB-Anbindung für externe Dateien**
  - DB-Unterstützung bei der Verwaltung, der Konsistenzerhaltung, und der inhaltsbasierten Suche wünschenswert.
  - **DataLinks-Konzept** bietet Referentielle Integrität, Zugriffskontrolle, Koordiniertes Backup und Recovery sowie Transaktionskonsistenz