4. Satzverwaltung

- Einführung
- Zuordnung Sätze - Seite
  - Freispeicherverwaltung (im Segment, in der Seite)
  - Abbildung von Sätzen in Seiten
- Clusterung / Speicherung komplexer Objekte
- Satzadressierung
  - TID
  - Zuordnungstabelle / PPP
- Zuordnung Attribute - Sätze
  - Repräsentation von Attributwerten
  - Abbildung von Attributwerten
- Speicherung von BLOBs/CLOBs
  - sequenzielle Speicherung vs. Positionsbaum
- Column Stores
  - Datenkompression

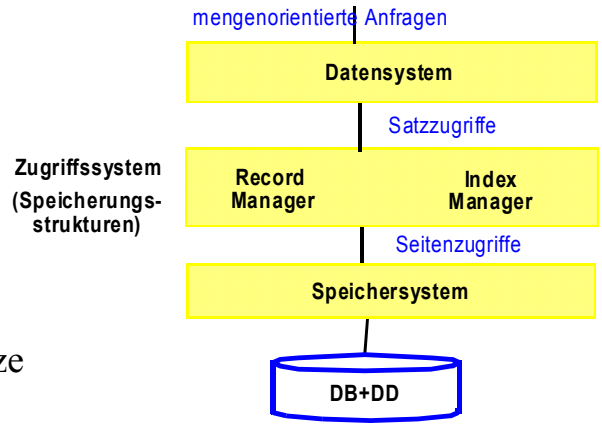

Row Store vs. Column Store

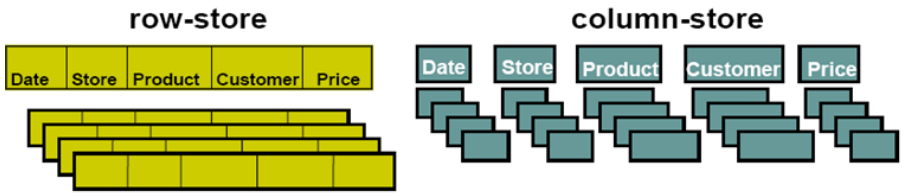

Standard-Modell in DBS: Sätze von Tabellen werden vollständig innerhalb je einer Seite gespeichert

\+ einfaches Hinzufügen neuer Sätze

\- Lesen nicht benötigter Attribute

Spaltenweise Zerlegung und Speicherung von Tabellen

\+ nur relevante Daten werden gelesen

\- mehrere Zugriffe zum Einfügen neuer Sätze

Besonders geeignet zur Analyse-Unterstützung, z.B. für Data Warehouses

Satzoperationen

- Einfügen eines Satzes (INSERT)
  - Seite mit ausreichend freiem Platz bestimmen
  - einfach falls beliebige Seite möglich
  - ansonsten (z.B. bei festgelegter Sortierreihenfolge) ggf. Platz zu schaffen
- Bulk load (Laden zahlreicher Sätze)
  - initialer Füllgrad der Seite beachten (Parameter PCTFREE o.ä.)
- Satzänderung (Update) mit Änderung der Satzlänge
  - bei Wachstum sollte Satz möglichst in Ursprungsseite bleiben
- Löschen eines Satzes (Delete)
  - zunächst wird Speicherplatz nur als wiederverwendbar gekennzeichnet (free vs. reusable)
  - periodisches Kompaktieren (reusable -> free)
- Reorganisation
  - Zusammenlegen freier und wiederverwendbarer Bereiche

Freispeicherverwaltung

- Freispeicherverwaltung (Free Place Administration, FPA) für
  - Segmente (Auswahl von Seiten zur Speicherung von 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

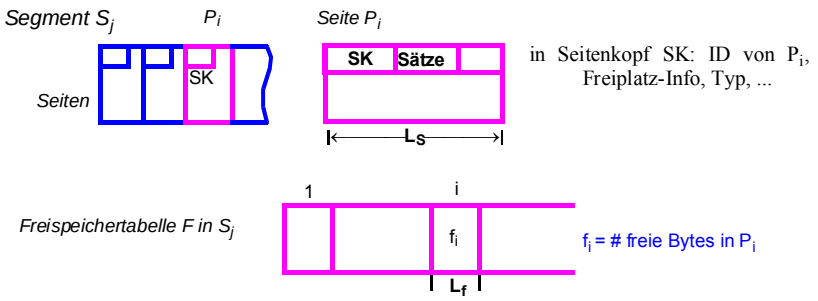

Freispeicherverwaltung (2)

- Größe der Freispeichertabelle F

  Einträge pro Seite der Länge L_S $\quad k = \left\lfloor \frac{L_S - L_{SK}}{L_f} \right\rfloor$

  mit s=#Seiten im Segment -> $\quad n = \left\lceil \frac{s}{k} \right\rceil$ Seiten für F

- Lage von F
  - Segmentanfang bzw. -ende
  - äquidistante Verteilung
- Art der FPA
  - exakt: $L_f = 2$ Bytes
  - unscharf: $L_f = 1$ Byte (oder weniger)
    -> f_i in Vielfachen von $\lceil L_S / 256 \rceil$
- FPA innerhalb von P_i
  - exaktes f_i in SK
  - zusammenhängende Verwaltung (Verschiebungen!) oder Freispeicherkette (best-fit/ first-fit)

Freispeicherverwaltung (3)

- Alternative: pro Segment
  - Verweis auf aktuelle Seite für Einfügungen sowie
  - verkettete Liste leerer Seiten (Verweis pro leerer Seite erforderlich)

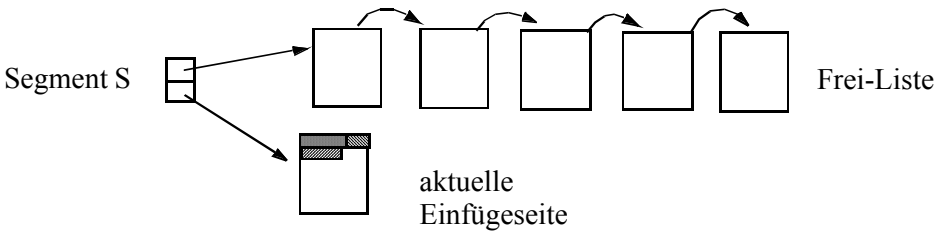

- falls aktuelle Seite voll ist, wird erste Seite der Frei-Liste die aktuelle Einfügeseite
- falls Seite durch Löschvorgänge leer wird, kommt sie an das Ende der Frei-Liste

Abbildung von Sätzen in Seiten

- Organisation
  - n Satztypen pro Segment
  - m Sätze verschiedenen Typs pro Seite
- oft vollständige Speicherung von Sätzen pro Seite
  - Voraussetzung: Satzlänge < Seitenlänge (S_L <= $L_S - L_{SK}$)
  - bei variabler Satzlänge: Verweise auf Satzbeginn (am Anfang oder Ende der Seite)

a) feste Satzlänge

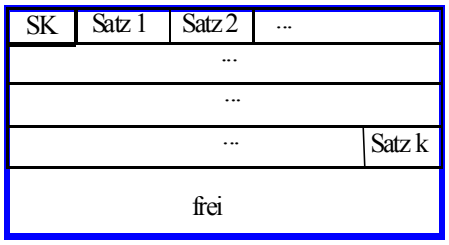

b) variable Satzlänge

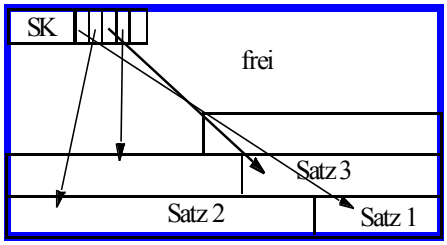

Seitenaufbau (2)

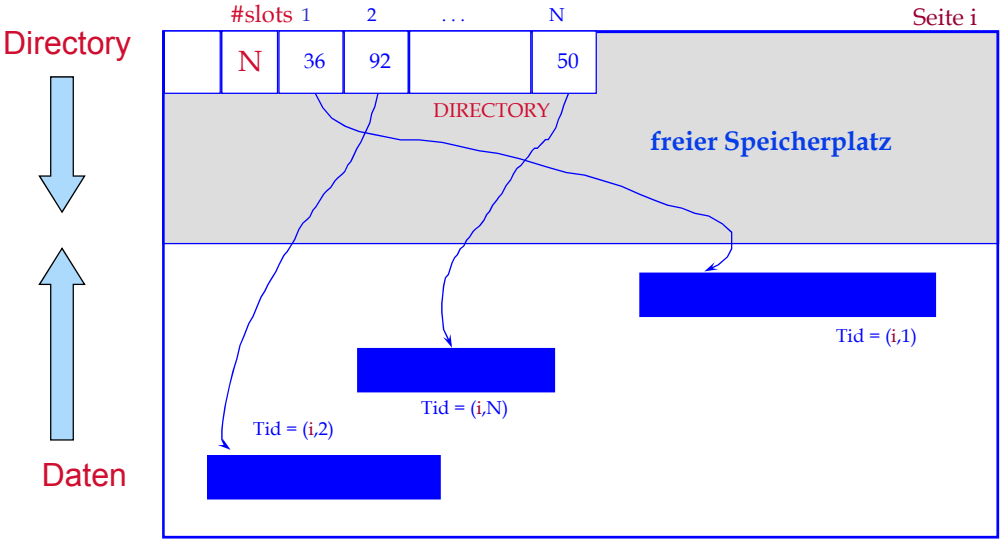

Satz-ID (Tuple ID) = <Seiten-ID, slot #>

Abbildung von Sätzen in Seiten (3)

- Aufspalten von Sätzen auf mehrere Seiten ("spanned records", **Spannsatz**)

Bsp.: attributweises Aufspalten

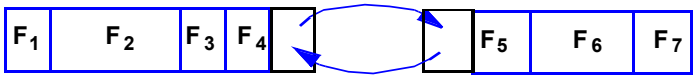

- mögliche Gründe
  - Satzgröße S_L > Seitengröße L_S - L_{SK}
  - schlechte Platzausnutzung bei fester Satzlänge (Bsp.: L_S=4096 B, S_L=2050 B)
  - Auslagern selten benötigter Attribute
  - Auslagern variabler Satzanteile
- Spezialfall: separate Speicherung für große Attribute ("long filelds") wie BLOBs (z.B. für Video-Clips) oder Texte (CLOBs)

Sortierte Speicherung von Sätzen

- Ziel: schneller Zugriff auf Sätze eines Satztyps in Sortierreihenfolge eines Attributes (z.B. Primärschlüssel)
- physisch benachbarte Speicherung in Sortierordnung: Clusterung
  - optimaler sortiert sequenzieller Zugriff: bei N Sätzen und mittlerem Blockungsfaktor B lediglich N/B physische Seitenzugriffe
  - pro Satztyp kann Clusterung nur bezüglich eines (Sortier-)Kriteriums erfolgen, falls keine Redundanz eingeführt werden soll
  - Änderungen können sehr teuer werden (Domino-Effekt)
    Verschiebekosten: N/(2*B) Seiten => Splitting-Technik

K1	K8	K17
K3	K9	K18
K4	K11	• • •
K6	K12	

Änderung bei sortiert-sequenzieller Speicherung

- Einfügen von K7?

K1	K8	K17
K3	K9	K18
K4	K11	• • •
K6	K12	

- Splitting-Technik:
  - Änderungen auf max. 3 Seiten beschränkt

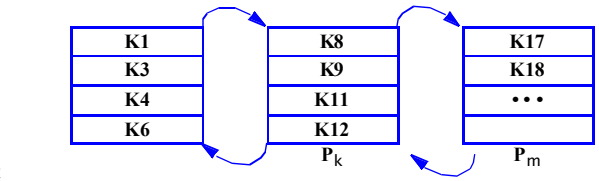

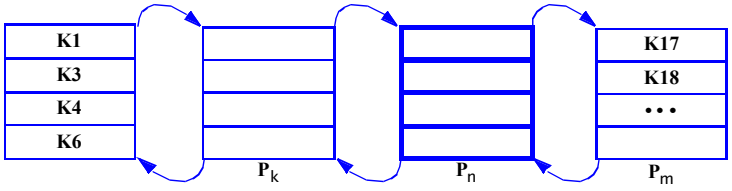

Mehrere Satztypen pro Seite

- satztyp-übergreifende Clusterung von häufig zusammen benötigten Sätzen
- kann v.a. für schnelle Join-Bearbeitung vorteilhaft sein (hierarchische Clusterung entlang von 1:n-Beziehungen)

Select KNAME, KTO-NR, KTOSTAND
From KUNDE, KONTO
Where KONTO.KU-NR=KUNDE.KU-NR

- nachteilig jedoch, wenn Anfragen auf 1 Satztyp dominieren

  Select *
  From KUNDE

Speicherung komplexer Objekte

- Attribut eines (Anker-) Satzes können Kollektionen (Menge, Liste) von Sätzen enthalten
  - Beispiel: Abteilung - Mitarbeiter, Kunde - Konten, etc.
- generelle Speicheranordnung zwischen Ankersatz und zugehörigen Sätzen

1. physische Nachbarschaft der Sätze: **Clusterung** (Listen, materialisierte Speicherung)

2. referenzierte Speicherung / **Verzeigerung** (Mini-Directory, Pointer-Array)

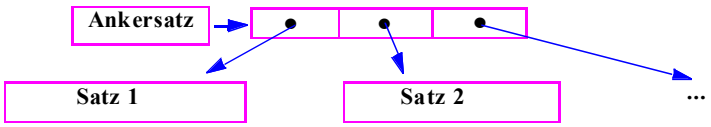

Speicherung komplexer Objekte (2)

- beliebig tiefe Schachtelung komplexer Objekte: auf jeder Stufe kann zwischen den Speichermöglichkeiten gewählt werden
- 2-stufiges Beispiel: komplexes Objekt Firma mit Abteilungen und Mitarbeitern

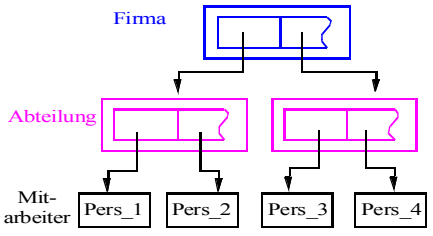

1) Verzeigerung / Verzeigerung

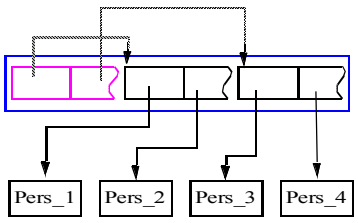

2) Clusterung / Verzeigerung

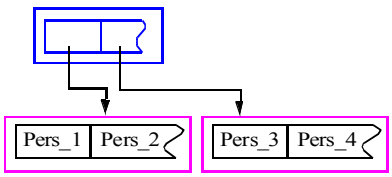

3) Verzeigerung / Clusterung

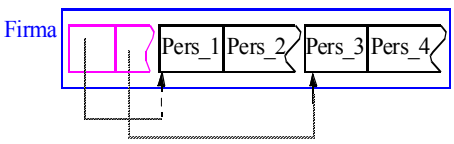

4) Clusterung / Clusterung

Externspeicherbasierte Satzadressierung

- DB-Adresse eines Satzes (OID): Segment-ID (bzw. Satztyp-ID) + Adresse im Segment
- Ziele:
  - 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

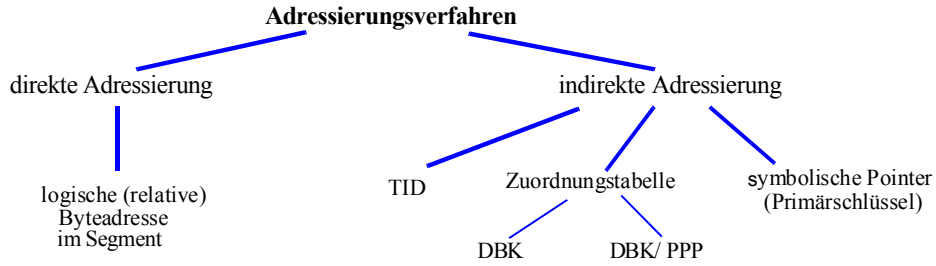

Satzadressierung: TID-Konzept

- TID (Tuple Identifier) dient zur Adressierung in einem Segment und besteht aus zwei Komponenten:
  - Seitennummer (3-6 B)
  - relative Indexposition innerhalb der Seite (1-2 B)
- Satzverschiebungen innerhalb einer Seite bleiben ohne Auswirkungen auf TID und Zugriffskosten

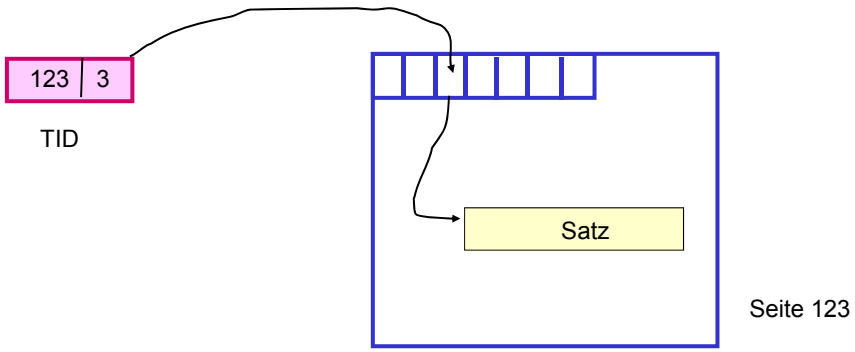

TID-Adressierung (2)

- Migration eines Satzes in andere Seite
  - Vorwärtsverweis in Primärseite (Stellvertreter-TID)
  - eigentliche TID-Adresse bleibt stabil
- Überlaufkette: Länge <= 1 -> max. Zugriffskosten: 2 Seitenzugriffe

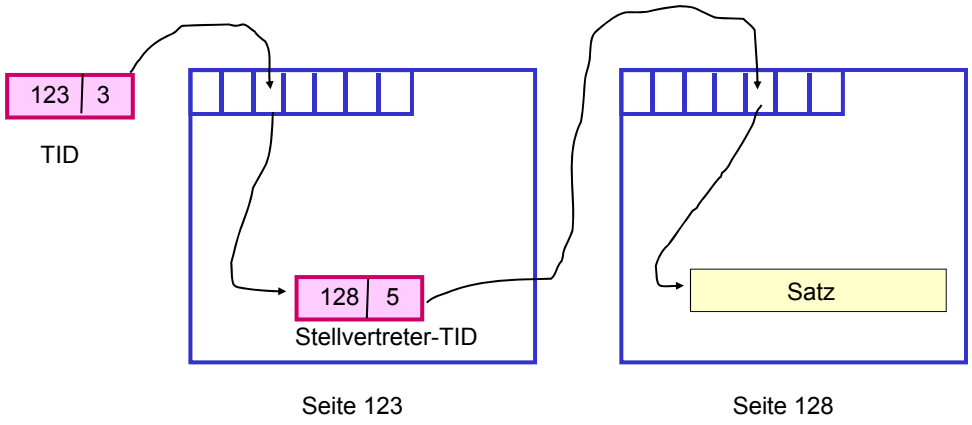

Satzadressierung über Zuordnungstabellen

- jeder Satz erhält eindeutigen Identifikator: OID bzw. Datenbankschlüssel (DBK)
  - Vergabe erfolgt i.a. durch DBVS
  - systeminterne Verweise auf Sätze erfolgen über DBK / OID
- Zuordnungstabelle enthält pro OID zugehörigen Page Pointer (PP)
  - Segment-ID (1-2 B) + Seitennummer (3-6 B)
- 'Probable Page Pointers' (PPP) in Zugriffspfaden ersparen u.U. Zugriff auf Zuordnungstabelle

Indexstruktur

Such-kriterium	DBK	PPP
xxx	Y003	A123
zzz	Y006	A123

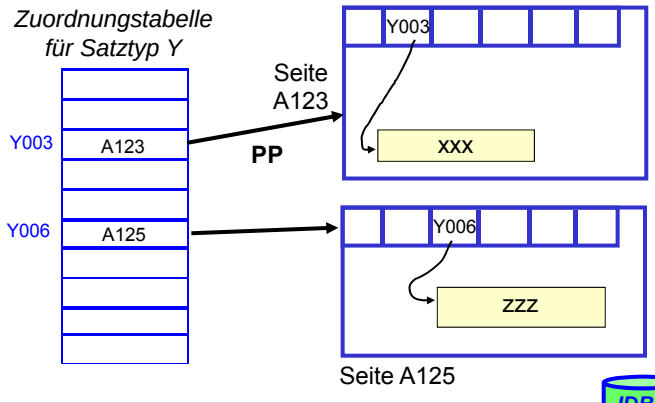

Repräsentation von Attributwerten

- Repräsentation von DBS-Datentypen
  - Int (short): 2 Bytes, z.B. 35 ist 0000 0000 0010 0011
  - Real, Floating Point: n Bits für Mantisse, m für Exponent
  - Character: 1 Byte pro Zeichen, z.B. ASCII-Codierung
  - Boolean: 1 Byte pro Wert (z.B. TRUE: 1111 1111, FALSE: 0000 0000);
    - weniger als 1 Byte pro Wert i.a. zu aufwendig
  - DATE: INTEGER (#Tage seit 1. Jan. 1900) bzw.
    YYYYMMDD (8 Zeichen) oder YYYYDDD (7 Zeichen)
  - TIME: INTEGER (Sekunden seit Mitternacht), Zeichen: HHMMSS

- Strings: feste vs. variable Länge
  - feste (maximale) Länge: CHAR (15), VARCHAR (255)
  - variable Länge: vorgestellte Längenangabe bzw. spezielles Endezeichen
  - ggf. Tabellenersetzung für Werte (L = Leipzig), Verschlüsselung ...

Abbildung von Attributwerten in Sätzen

- Satz: Aggregation zusammengehöriger Attributwerte (Felder)

- Forderungen
  - günstiger Platzbedarf
  - Unterstützung dynamischer Attributlängen
  - effiziente Speicherung von Nullwerten
  - einfaches Hinzufügen neuer Attributdefinitionen
  - direkter Zugriff auf i-tes Attribut

- feste vs. variable Satzlänge

- festes vs. variables Satzformat
  - DBS meist festes Satzformat; Metadaten weitgehend im Katalog
  - variables Format z.B. für semistrukturierte/selbstbeschreibende Daten; eingebettete Metadaten

Variables Satzformat

- "selbstbeschreibende" Sätze: Mitführen von Attributnamen und Attributtypen
- Beispiel

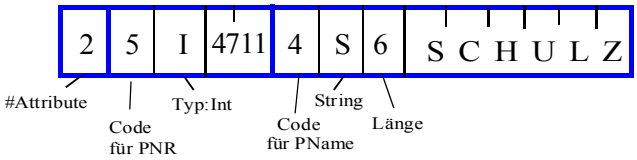

- Attributnamen / Tags können auch als Strings gespeichert werden
- keine Speicherung von Nullwerten
- i.a. hoher Platzbedarf / aufwändiger Zugriff
- große Flexibilität

Festes Satzformat

- Trennung von Metadaten (im Katalog) und gespeicherten Sätzen
  - pro Attribut:

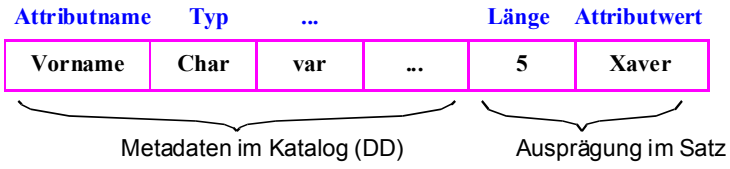

  - Satz- und Zugriffspfadbeschreibung im Katalog
  - Anzahl von Attributen, Reihenfolge, Datentypen, Bedeutung
- Unterschiedliche Realisierungsmöglichkeiten u.a. für
  - Verwaltung variabel langer Attributwerte
  - Adressierung des i-ten Attributes
  - Verwaltung von Nullwerten

Abspeicherungsformen

- eingebettete Längenfelder

  Beispiel: PERS (PNR, Name, Beruf, Gehalt, ANR, Ort)

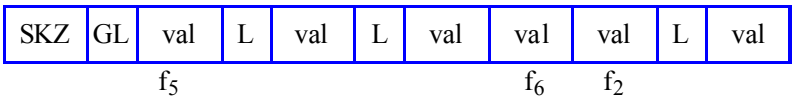

Katalogeintrag: f5 | v | v | f6 | f2 | v |
SKZ = Satzkennzeichen / OID
GL = Gesamtlänge (bzw. #Felder)

  - speicherökonomisch: viele Sätze pro Seite möglich
  - Nullwert: Länge 0
  - nicht repräsentierte Attribute haben per Definition Nullwert
  - einfaches Hinzufügen neuer Attribute
  - Bestimmung der Attributwertadresse erst zur Laufzeit

Abspeicherungsformen (2)

- Zerlegung von Sätzen in Teile mit fester und variabler Länge
  - fester Teil: Attributwerte fester Länge + Zeiger auf variabel lange Attributwerte im 2. Teil
  - variabler Teil: variabel lange Attributwerte mit eingebetteten Längenfeldern

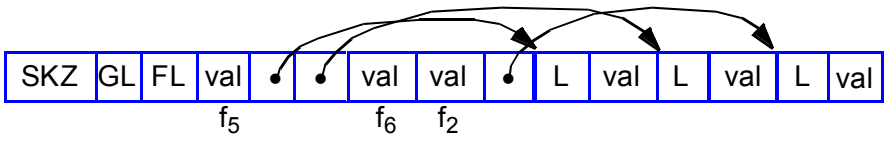

Katalogeintrag: f5 | v | v | f6 | f2 | v |
SKZ = Satzkennzeichen / OID
GL = Gesamtlänge
FL = Länge des festen Teils

  - Adresse für jedes Attribut an fester Position
  - effiziente Speicherung von Nullwerten
  - einfaches Hinzufügen neuer Attributdefinitionen

Darstellung und Handhabung langer Felder

- lange Attribute, z.B. für Typen TEXT, IMAGE, VIDEO erfordern Sonderbehandlung
- Speicherung als BLOBs oder CLOBs unter Kontrolle des DBS
- Anforderungen
  - idealerweise keine Größenbeschränkungen
  - allgemeine Verwaltungsfunktionen
  - gezieltes Lesen und Schreiben von Teilbereichen
  - Verkürzen, Verlängern und Kopieren
  - Suche nach vorgegebenem Muster, Längenbestimmung. . .
- Darstellung großer Speicherobjekte
  - besteht potentiell aus vielen Seiten
  - ist eine uninterpretierte Bytefolge
  - OID-Verweis (Adresse) im Satz zeigt auf Objektkopf (header) des großen Objekts
  - unterschiedliche Speicherungsstrukturen möglich: Kette von Einträgen fester Länge, sequenzielle Liste (Datei), B*-Baum etc.

Clusterung für lange Felder

- Implementierung im Starburst-Prototyp
  - Grundlage für DB2-Realisierung
  - effiziente Speicherallokation und -freigabe für Feldgrößen von bis zu 2 GB (Sprache, Bild, Musik oder Video)
- hohe E/A-Leistung durch Clusterung
  - Schreib- und Lese-Operationen sollen E/A-Raten nahe der Übertragungsgeschwindigkeit der Magnetplatte erreichen
- Prinzipielle Repräsentation
  - 1 oder mehrere „Segmente“ (Cluster) zur Darstellung des langen Feldes
  - Deskriptor mit Liste der Segmentbeschreibungen

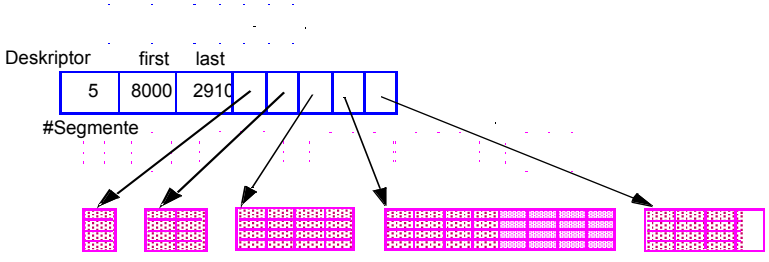

Clusterung für lange Felder (2)

- Datenallokation bei unbekannter Objektgröße
  - Wachstumsmuster der Segmentgrößen wie im Beispiel:
    1, 2, 4, ..., 2^n Seiten werden jeweils zu einem Segment zusammengefasst
  - MaxSeg = 2048 Seiten für n = 11
  - falls MaxSeg erreicht wird, werden weitere Segmente der Größe MaxSeg angelegt
  - Das letzte Segment wird auf die verbleibende Objektgröße gekürzt
- Datenallokation 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
- Verarbeitungseigenschaften
  - effiziente Unterstützung von sequenziellen und wahlfreien Lesevorgängen
  - einfaches Anhängen und Entfernen von Bytefolgen am Ende des Objektes
  - schwieriges Einfügen und Löschen von Bytefolgen in der Mitte des Objektes

Baum-artige Verwaltung von langen Feldern / BLOBs

- Physische Darstellung als B*-Baum
  - Blattseiten enthalten die Daten
  - interne Seiten (Tabellen) und Wurzel entsprechen einem Index für Bytepositionen
  - interne Seiten und Wurzel speichern für jede Kind-Seite Einträge der Form (Zähler, Seiten-#)
  - Zähler enthält die maximale Bytenummer, die zum jeweiligen Teilbaum gehört (links stehende Knoten (Einträge) in einer Seite zählen zum Teilbaum).
  - Zähler im weitesten rechts stehenden Eintrag der Wurzel enthält Länge des Objektes
- Repräsentation sehr langer dynamischer Objekte
  - bis zu 8 GB mit drei Baumebenen
  - Speicherplatznutzung typischerweise ~ 80 %

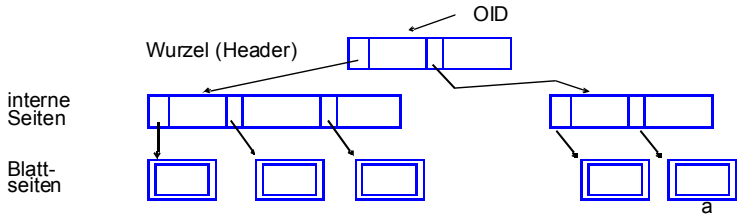

Byte 100 in Seite a?

Baum-artige Verwaltung von BLOBs (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)

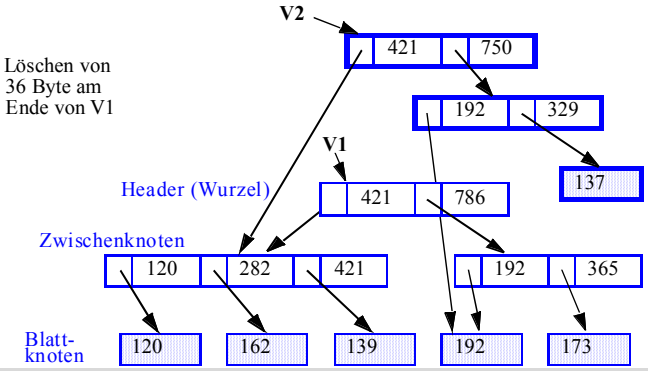

Column Stores

- spaltenweise statt zeilenweise Speicherung von Tabellen
- frühe Realisierungen im Rahmen vertikaler Partitionierung (Sybase IQ)
- viele neue Realisierungen seit ca. 2005, v.a. zur Unterstützung von Analyse-Anfragen / OLAP
  - Vertica (kommerzielle Version von C-Store), Infobright ICE, Monet DBX, SAP Hana …
- hybride Lösungen (z.B. MS SQLServer, DB2)

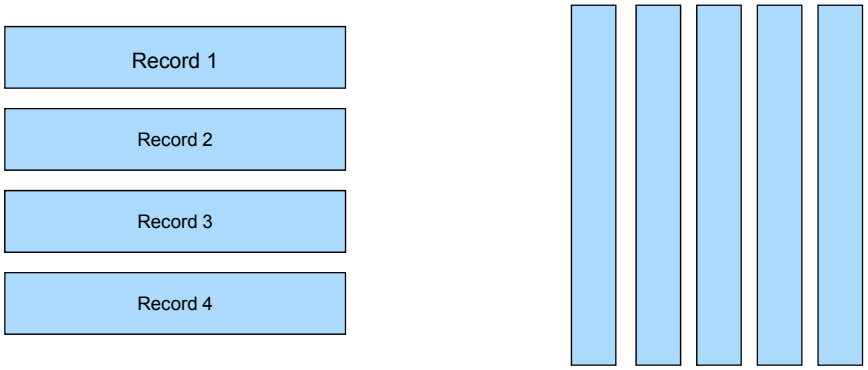

Spaltenweise Speicherung

- vertikale Partitionierung von Tabellen
- keine replizierte Speicherung des Primärschlüssels pro Partition, falls eindeutiger Zugriff über relative Satznummer
- starke E/A-Einsparungen verglichen mit Zugriff auf vollständige Sätze, wenn nur ein Attribut bzw. wenige Attribute auszuwerten
  - Bsp.: Berechnung von Durchschnittsgehalt, Umsatzsumme ...
- zusätzliche Einsparungen durch komprimierte Speicherung von Attributwerten

PNR	ANR	W-ORT	GEHALT
12345	K02	L	45000
23456	K02	M	51000
34567	K03	L	48000
45678	K02	M	55000
56789	K03	F	65000
67890	K12	L	50000

	PNR	ANR	W-ORT	GEHALT
0	12345	K02	L	45000
1	23456	K02	M	51000
2	34567	K03	L	48000
3	45678	K02	M	55000
4	56789	K03	F	65000
5	67890	K12	L	50000

Vorteile / Nachteile

- Vorteile Column Store
  - I/O-Einsparungen falls nur wenige Attribute benötigt
  - effiziente Aggregationsmöglichkeiten
  - OLAP-orientiert
  - Oft deutlich bessere Trefferraten im CPU-Cache durch Fokussierung auf relevante Daten
- Nachteile Column Store (-> Vorteile Row Store)
  - ungünstig für Operationen, die (fast) alle Attribute von Tupeln betreffen, z.B. für Änderungen / effizientes Einfügen neuer Tupel
  - weniger günstig für OLTP

Anfragen – Column vs. Row Store *

SELECT *
FROM Sales Orders
WHERE Document Number = '95779216'

SELECT SUM(Order Value)
FROM Sales Orders
WHERE Document Date > 2009-01-20

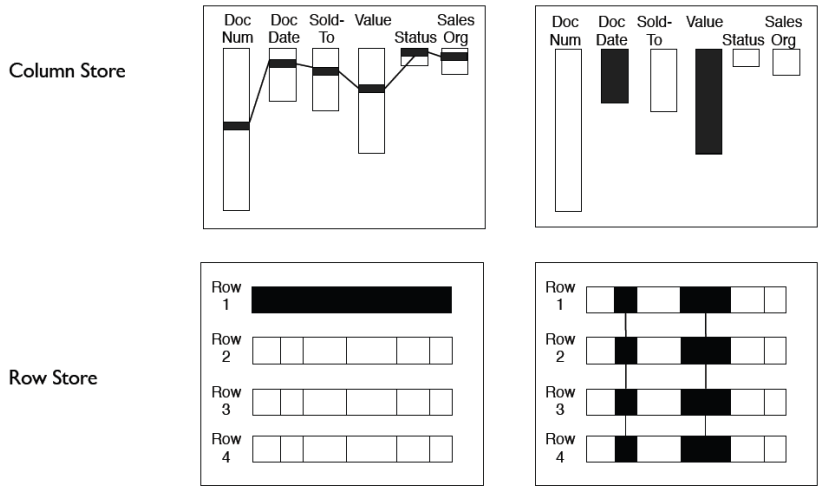

* Quelle: Hasso Plattner: Enterprise Applications – OLTP and OLAP – Share One Database Architecture

Datenkompression

- Column Stores nutzen oft komprimierte Speicherung von Attributwerten
  - reduzierter Speicherbedarf
  - reduzierter I/O-Aufwand
- leichtgewichtige Kompression mit geringem Aufwand zur Dekomprimierung
  - wünschenswert: Auswertungen auf komprimierten Werten selbst
- Zahlreiche Varianten
  - Run Length Encoding (RLE)
  - Bit Vector Encoding
  - Delta Coding
  - Wörterbuch-Kodierung
  - etc.
- pro Spalte kann das beste Kodierungsverfahren gewählt werden

Run Length Encoding (RLE) / Lauflängenkodierung

- Zusammenfassung von Nachbarn mit gleichem Wert
  (Wert, Startposition, #Vorkommen)
- effizient bei langen Folgen gleicher Werte
  - wird durch Sortierung der Attributwerte pro Spalte unterstützt
- einfache Dekodierung
- Auswertungen auch auf komprimierten Werten möglich

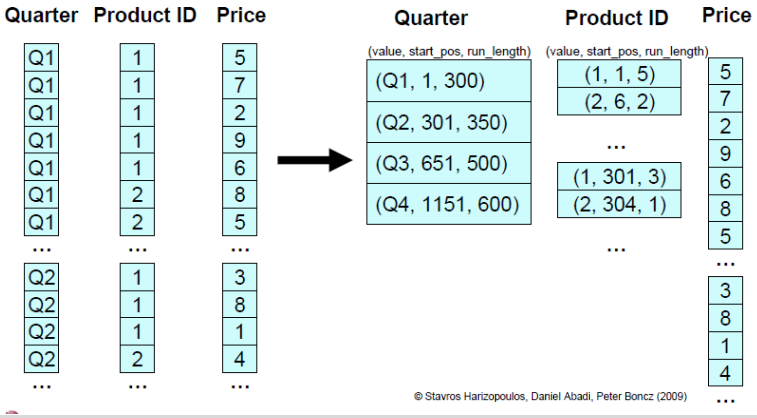

IDBS

Bit Vector Encoding

- Spalte wird für k mögliche Attributwerte durch k Bitvektoren repräsentiert
  - Bit 1 (0) für Bitliste j an Position i bedeutet, dass Satz i den Wert j (nicht) hat
- speichergünstig bei wenigen Attributwerten
  - kann mit RLE kombiniert werden (lange 1- bzw. 0-Folgen)
- effiziente Auswertungen von Selektionen

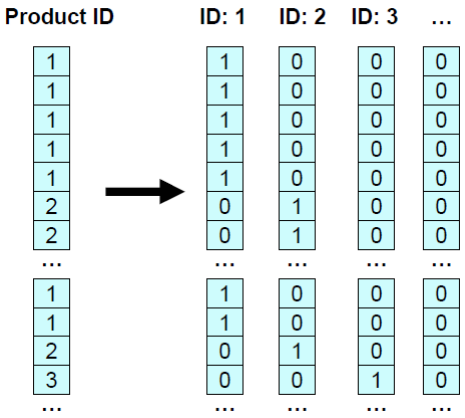

IDBS

Weitere Kompressionstechniken

- Delta / Difference Coding
  - Speicherung der Differenz zu Vorgängerwerten
  - oft kompakter, v.a. bei Sortierung

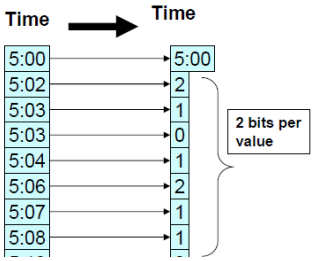

- Wörterbuch-Kodierung
  - erfordert keine Sortierung
  - günstig v.a. bei wenigen und langen Attributwerten
  - Auswertung auf komprimierten Daten möglich
  - Lookup zur Dekomprimierung

Dictionary

pos	value
0	Aachen
1	Karlsruhe
2	Leipzig
3	Münster

IndexVector

pos	value
0	0
1	0
2	0
3	1
4	0
5	0
6	2
7	3

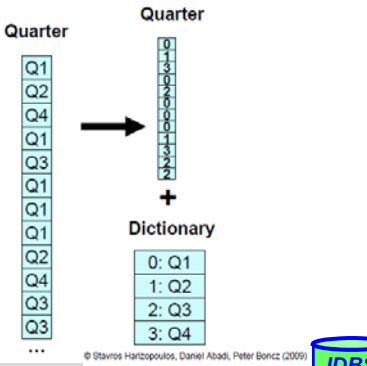

Zusammenfassung

- Freispeicherinformation auf verschiedenen Ebenen
  - Segment (Datei), Seite
- Abbildung von Sätzen:
  - meist festes Format, variable Länge
  - Spannsätze, Clusterung, komplexe Objekte
- Ziele bei der Satzadressierung
  - Kombination der Geschwindigkeit des direkten Zugriffs mit der Flexibilität einer Indirektion
  - Satzverschiebungen in Seite ohne Auswirkungen ⇒ TID-Konzept oder Zuordnungstabelle
- Speicherung variabel langer Felder
  - dynamische Erweiterungsmöglichkeiten
  - Berechnung von Feldadressen
- Speicherung großer Objekte (BLOBs, "long fields")
  - große sequenzielle Listen (Clusterung): hohe E/A-Leistung
  - B*-Baum-Technik: flexible Darstellung, moderate Zugriffsgeschwindigkeit
- Column Store-Techniken hilfreich für beschleunigte Anfragen
  - Kompressionsverfahren: RLE, Bit Vector- / Delta- / Dictionary-Kodierung