# 3. DB-Pufferverwaltung

- **Rolle der DB-Pufferverwaltung**[1]
  - Ablauf des Zugriffs auf den DB-Puffer
  - logische und physische Seitenreferenzen

- **Speicherzuteilung im DB-Puffer**

- **Suche im DB-Puffer**

- **Seitenersetzungsverfahren**
  - Klassifikation von Ersetzungsverfahren
  - LRU, FIFO, CLOCK, GCLOCK, LRD, LRU-K ...

- **Ersetzungsverfahren – Einbezug von Kontextwissen**

- **Seitenersetzung bei virtuellem Speicher**

---

1. Effelsberg, W., Härder, T.: Principles of Database Buffer Management, in: ACM Transactions on Database Systems 9:4, Dec. 1984, pp. 560-595.

# Rolle der DB-Pufferverwaltung

## in einem Datenbanksystem

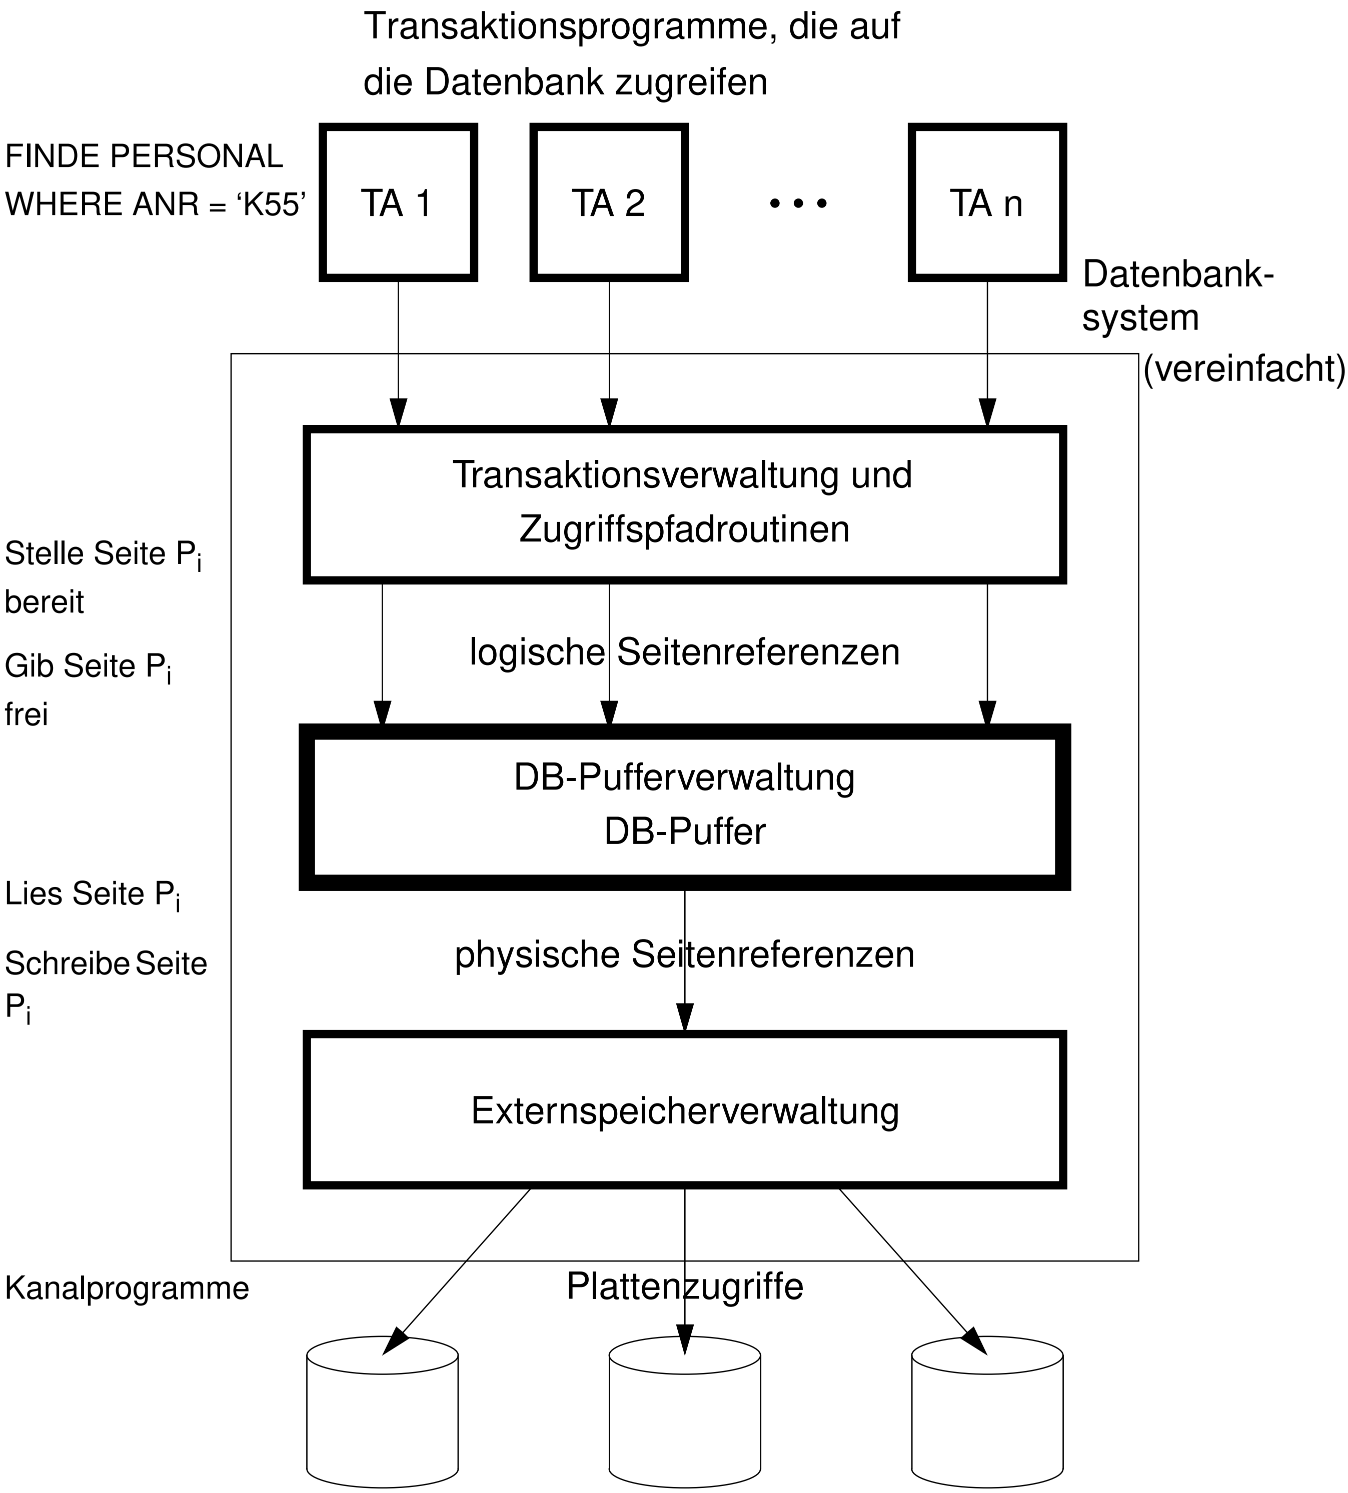

# Vergleich mit Betriebssystemfunktionen

- **Ersetzungsalgorithmen im DB-Puffer in Software implementiert – Seitenersetzung in Adreßräumen bei Virtuellem Speicher ist HW-gestützt**

- **Seitenreferenz vs. Adressierung**

  nach einem FIX-Aufruf kann eine DB-Seite mehrfach bis zum UNFIX referenziert werden

  ➥ unterschiedliches Seitenreferenzverhalten

  ➥ andere Ersetzungsverfahren ?

- **Können Dateipuffer des Betriebssystems als DB-Puffer eingesetzt werden?**

1. **Zugriff auf Dateipuffer ist teuer (SVC:** *supervisor call***)**

2. **DB-spezifische Referenzmuster können nicht mehr gezielt genutzt werden**

   BS-Ersetzungsverfahren sind z. B. nicht auf zyklisch sequentielle oder baumartige Zugriffsfolgen abgestimmt

3. **Normale Dateisysteme (DVS) bieten keine geeignete Schnittstelle für Prefetching**

   In DBVS ist aufgrund von Seiteninhalten oder Referenzmustern eine Voraussage des Referenzverhaltens möglich; durch Prefetching läßt sich in solchen Fällen eine Leistungssteigerung erzielen

4. **Selektives Ausschreiben von Seiten zu bestimmten Zeitpunkten (z. B. für Logging) nicht immer möglich in existierenden Dateisystemen**

➥ DBVS muß eigene Pufferverwaltung realisieren

# Eigenschaften von DB-Referenzstrings

- **Typische Referenzmuster in DBS**

**1. Sequentielle Suche**

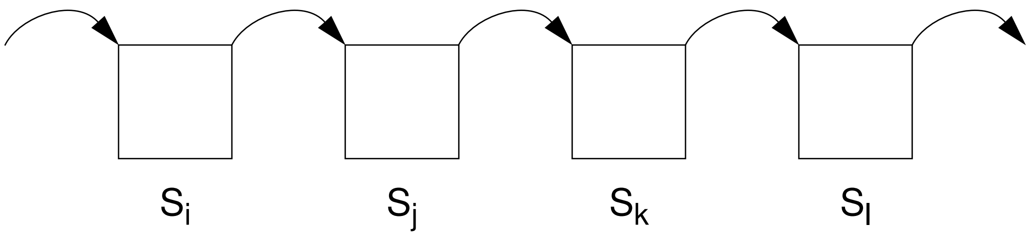


Bsp.: Durchsuchen ganzer Satztypen (Relationen)

**2. Hierarchische Pfade**

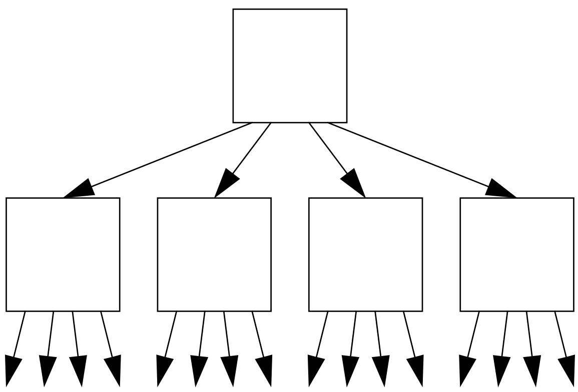

Bsp.: Suchen mit Hilfe von B*-Bäumen

**3. Zyklische Pfade**

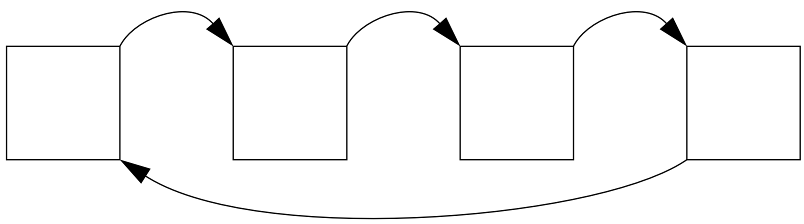

Bsp.: Abarbeiten von Sets, Suchen in DBTT-/Datenseiten

# Relative Referenzmatrix (DOA-Last)

ca. 17 500 Transaktionen, 1 Million Seitenreferenzen auf ca. 66 000 verschiedene Seiten

| | P1 | P2 | P3 | P4 | P5 | P6 | P7 | P8 | P9 | P10 | P11 | P12 | P13 | Total |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| TT1 | 9.1 | 3.5 | 3.3 | | 5.0 | 0.9 | 0.4 | 0.1 | | | | 0.0 | | 22.3 |
| TT2 | 7.5 | 6.9 | 0.4 | 2.6 | 0.0 | 0.5 | 0.8 | 1.0 | 0.3 | 0.2 | 0.0 | | | 20.3 |
| TT3 | 6.4 | 1.3 | 2.8 | 0.0 | 2.6 | 0.2 | 0.7 | 0.1 | 1.1 | 0.4 | | 0.0 | 0.0 | 15.6 |
| TT4 | 0.0 | 3.4 | 0.3 | 6.8 | | | 0.6 | 0.4 | | | 0.0 | | | 11.6 |
| TT5 | 3.1 | 4.1 | 0.4 | | 0.0 | | 0.5 | 0.0 | | | | | | 8.2 |
| TT6 | 2.4 | 2.5 | 0.6 | | 0.7 | | 0.9 | 0.3 | | | | | | 7.4 |
| TT7 | 1.3 | | 2.6 | | | 2.3 | 0.1 | | | | | | | 6.2 |
| TT8 | 0.3 | 2.3 | 0.2 | | 0.0 | | 0.1 | | | | | | | 2.9 |
| TT9 | 0.0 | 1.4 | 0.0 | | | | | 1.1 | | | | | | 2.6 |
| TT10 | 0.3 | 0.1 | 0.3 | | | 1.0 | 0.1 | | | | | 0.0 | | 1.8 |
| TT11 | | 0.9 | | | | | | 0.2 | | | | | | 1.1 |
| TT12 | | 0.1 | | | | | | | | | | | | 0.1 |
| Total | 30.3 | 26.6 | 11.0 | 9.4 | 8.3 | 4.9 | 4.1 | 3.3 | 1.4 | 0.6 | 0.0 | 0.0 | 0.0 | 100.0 |
| partition size (%) | 31.3 | 6.3 | 8.3 | 17.8 | 1.0 | 20.8 | 2.6 | 7.3 | 2.6 | 1.3 | 0.8 | 0.0 | 0.0 | 100.0 |
| % referenced | 11.1 | 16.6 | 8.0 | 2.5 | 18.1 | 1.5 | 9.5 | 4.4 | 5.2 | 2.7 | 0.2 | 13.5 | 5.0 | 6.9 |

# Speicherzuteilung im DB-Puffer

- global
  (1 gemeinsamer Pufferbereich)
- lokal /
  partitionierte Pufferbereiche
  - statisch
    - gleichförmige Partitionen
    - angepaßte Partitionen
  - dynamisch

**Partitionierungsmöglichkeiten:**

- eigener Pufferbereich pro Transaktion
- TA-Typ-bezogene Pufferbereiche
- Seitentyp-bezogene Pufferbereiche
- DB-(Partitions)spezifische Pufferbereiche

# Dynamische Pufferallokation – Working-Set-Ansatz (WS)

- **pro Pufferpartition P soll Working-Set im Puffer bleiben;
  Seiten, die nicht zum Working-Set gehören, können ersetzt werden**

- **bei Fehlseitenbedingung muß Working-Set bekannt sein,
  um Ersetzungskandidat zu bestimmen**
  - Fenstergröße (*Window Size*) pro Partition: w (P)
  - Referenzzähler pro Partition: RZ (P)
  - letzter Referenzzeitpunkt für Seite i: LRZ (P, i)
  - ersetzbar sind solche Seiten, für die RZ (P) - LRZ (P, i) > w (P)

- **Fenstergröße kritischer Parameter → Thrashing-Gefahr**

| | | | | | | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| **P1:** | **A** | **A** | | **C** | | | **A** | **A** | | | **G** | **H** | | **A** |
| **P2:** | | | **B** | | **D** | **E** | | | **E** | **F** | | | **F** | |
| Referenz-string | | | | | | | | | | | | | | |

# Suche im DB-Puffer

- **Sequentielles Durchsuchen der Pufferrahmen**
  - sehr hoher Suchaufwand
  - Gefahr vieler Paging-Fehler bei virtuellen Speichern

- **Nutzung von Hilfsstrukturen**
  (Eintrag pro Pufferrahmen)

  1. **unsortierte oder sortierte Tabelle**

  2. **Tabelle mit verketteten Einträgen**
     - geringere Änderungskosten
     - Anordnung in LRU-Reihenfolge möglich

  3. **Suchbäume (z. B. AVL-, m-Weg-Bäume)**

  4. **Hash-Tabelle mit Überlaufketten**
     - beste Lösung

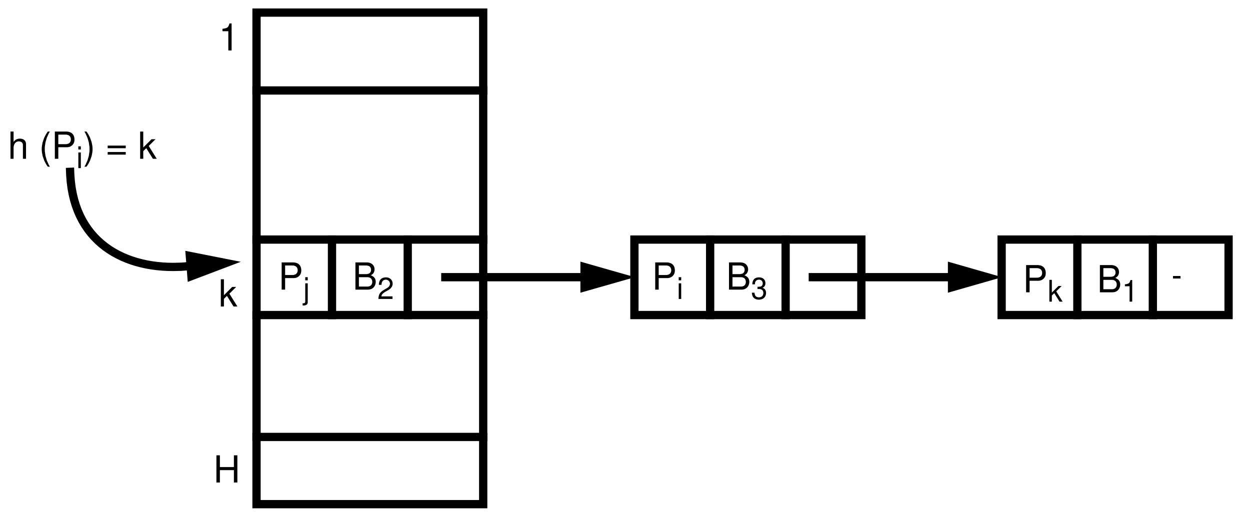

# Seitenersetzungsverfahren

- **Klassifikation**

**Verfahrensklassen**

| **preplanning** | **prefetching** | **demand fetching** |
|---|---|---|
| Programmanalyse, Vorabuntersuchung des Datenbedarfs | physische Datenstrukturierung, Clusterbildung, Verarbeitungswissen | keine Vorausaktionen |
| ➥ große Fehlrate, ungenaue Obermengen | ➥ datenmodellbezogen (hierarchisch), spekulative Entscheidungen | ➥ Lokalitätserhaltung im DB-Puffer |

- **Grundannahme bei Ersetzungsverfahren**:

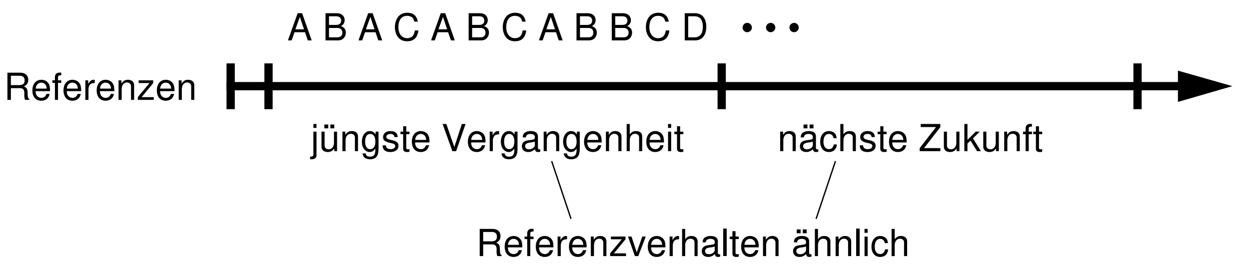

# Referenzverhalten und Ersetzungsverfahren

- **typischerweise** hohe Lokalität: Optimierung durch Ersetzungsverfahren
- **manchmal** Sequentialität oder zufällige Arbeitslast (RANDOM-Referenzen)

- **Prinzipielle Zusammenhänge**, die die Fehlseitenrate bestimmen

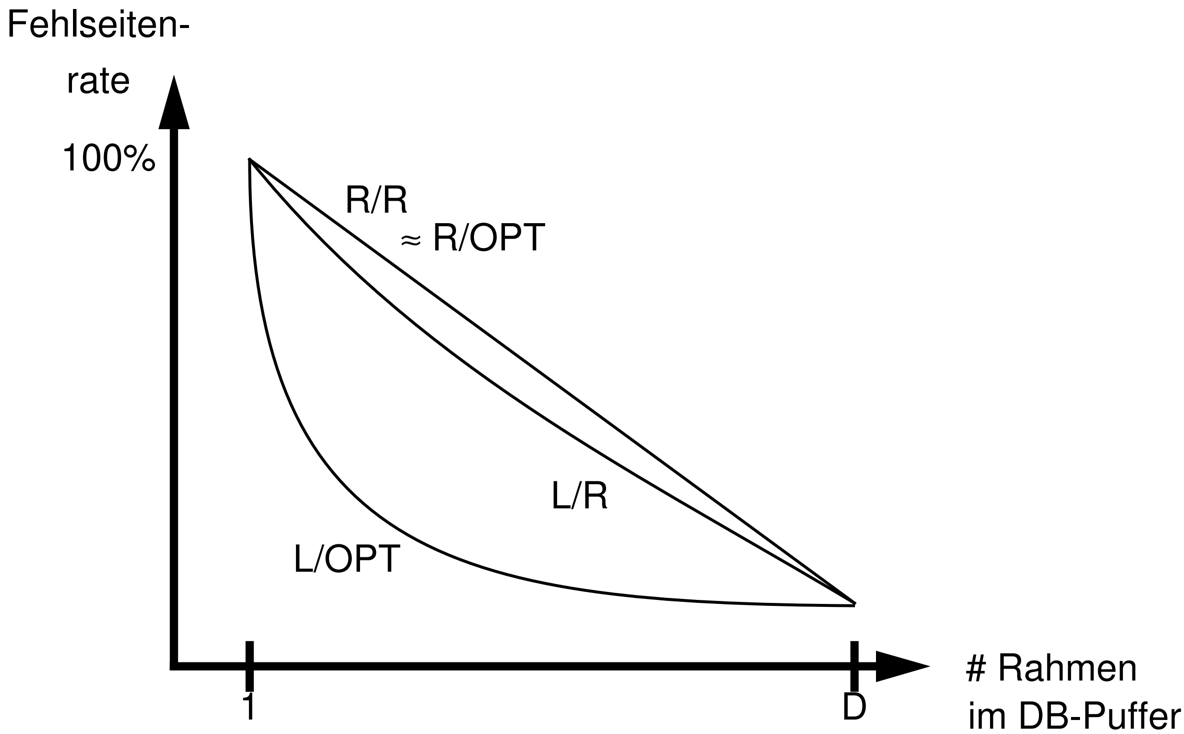


D = DB-Größe in Blöcken

- **Kombinationen:**

| | | | | |
|---|---|---|---|---|
| Referenzen: | RANDOM | RANDOM | Lokalität | Lokalität |
| Ersetzung: | RANDOM | OPT | RANDOM | OPT |

➥ Grenzfälle des Referenzverhaltens und der Ersetzungsverfahren zeigen Optimierungsmöglichkeiten auf

# Behandlung geänderter Seiten im DB-Puffer

- **Ersetzung einer geänderten Seite erfordert ihr vorheriges (synchrones) Zurückschreiben in die DB**

  ➥ Antwortzeitverschlechterung

- **Abhängigkeit zur gewählten *Ausschreibstrategie*:**

**FORCE**: alle Änderungen einer Transaktion werden spätestens beim EOT in die DB zurückgeschrieben („write-through“)

\+ i. a. stets ungeänderte Seiten zur Ersetzung vorhanden

\+ vereinfachte Recovery (nach Rechnerausfall sind alle Änderungen beendeter TA bereits in die DB eingebracht)

\- hoher E/A-Overhead

\- starke Antwortzeiterhöhung für Änderungstransaktionen

**NOFORCE**: kein Durchschreiben der Änderungen bei EOT (verzögertes Ausschreiben, „deferred write-back“)

➥Seite kann mehrfach geändert werden, bevor ein Ausschreiben erfolgt (geringerer E/A-Overhead, bessere Antwortzeiten)

**vorausschauendes (asynchrones) Ausschreiben geänderter Seiten**

erlaubt auch bei NOFORCE, vorwiegend ungeänderte Seiten zu ersetzen

➥ synchrone Schreibvorgänge in die DB lassen sich weitgehend vermeiden

# Kriterien für die Auswahl der zu ersetzenden Pufferseite

| Verfahren | Kriterien: Alter | letzte Referenz | Referenz-häufigkeit | andere Kriterien |
|---|---|---|---|---|
| **OPT** | - | - | - | **Vorauswissen** |
| **RANDOM** | - | - | - | --- |
| **LFU** | | | | |
| **FIFO** | | | | |
| **LRU** | | | | |
| **CLOCK** | | | | |
| **GCLOCK** | | | | |
| **LRD(V1)** | | | | |
| **LRD(V2)** | | | | |
| **LRU-K** | | | | |

# Least-Frequently-Used (LFU)

- Führen eines Referenzzählers pro Seite im DB-Puffer

- Ersetzung der Seite mit der geringsten Referenzhäufigkeit

| RZ | |
|---|---|
| 2 | |
| 4 | |
| 1 | |
| 3 | |
| 3 | |
| 6 | |
| 1 | |
| 3 | |

- Alter einer Seite wird nicht berücksichtigt

# FIFO (First-In First-Out)

- **die älteste Seite im DB-Puffer wird ersetzt**

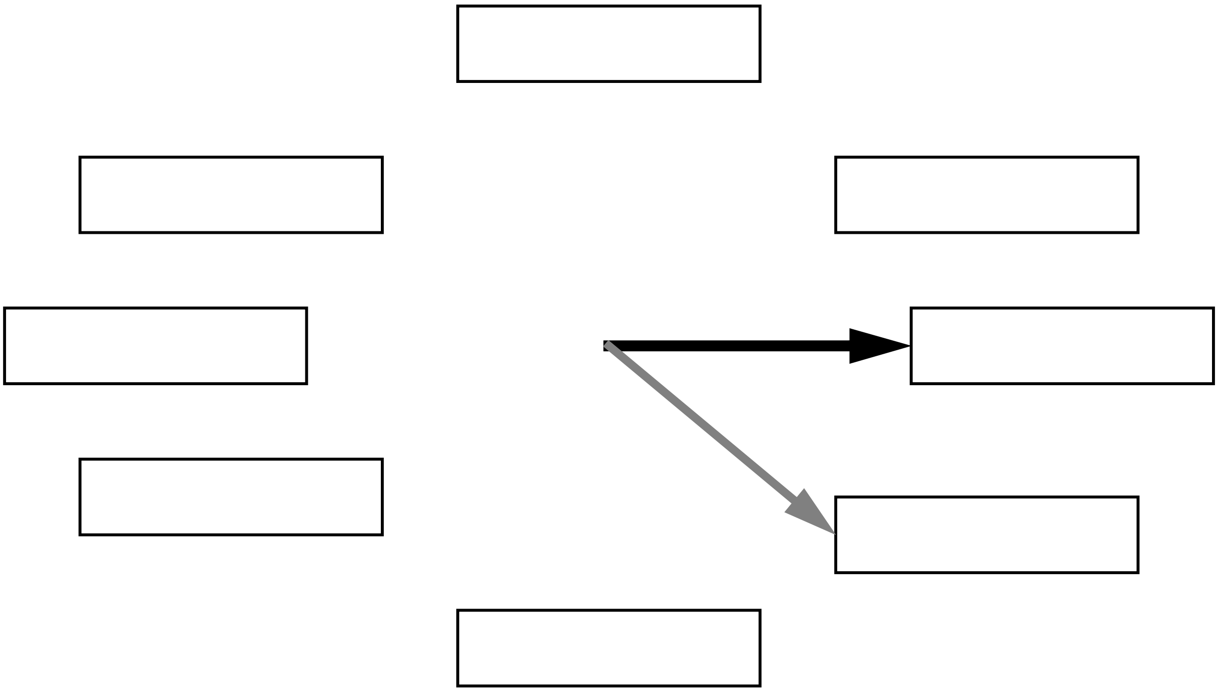

- **Referenzierungsverhalten während Pufferaufenthaltes wird nicht berücksichtigt**

  ⇒ nur für strikt sequentielles Referenzverhalten geeignet

# Least-Recently-Used (LRU)

- **Beispiel (Puffergröße 4):**

  1. Referenz der Seite C

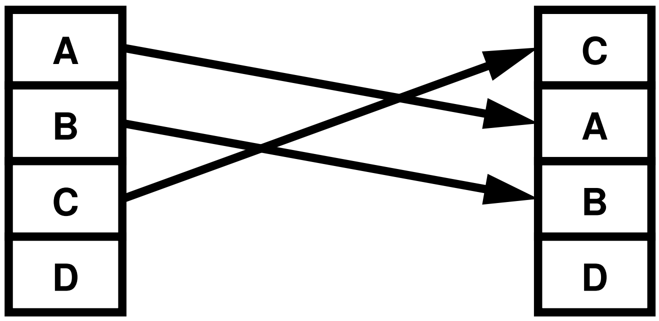


**LRU-Stack**

  2. Referenz der Seite E

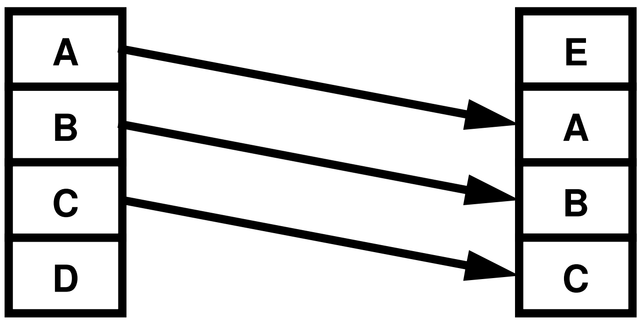


- **Unterscheidung zwischen**
  ***Least-Recently-Referenced*** **und**
  ***Least-Recently-Unfixed***

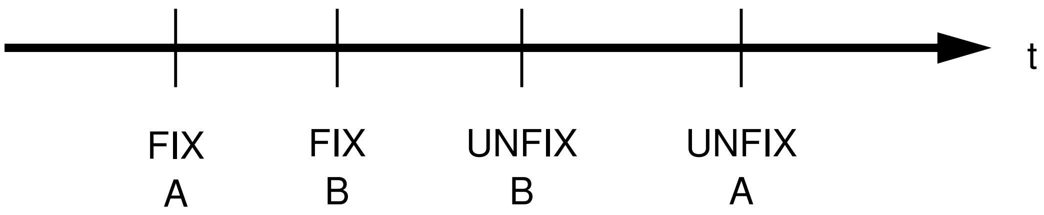

# CLOCK (Second Chance)

- **Erweiterung von FIFO**
- **Referenzbit pro Seite, das bei Zugriff gesetzt wird**
- **Ersetzung erfolgt nur bei zurückgesetztem Bit**

  (sonst erfolgt Zurücksetzen des Bits)

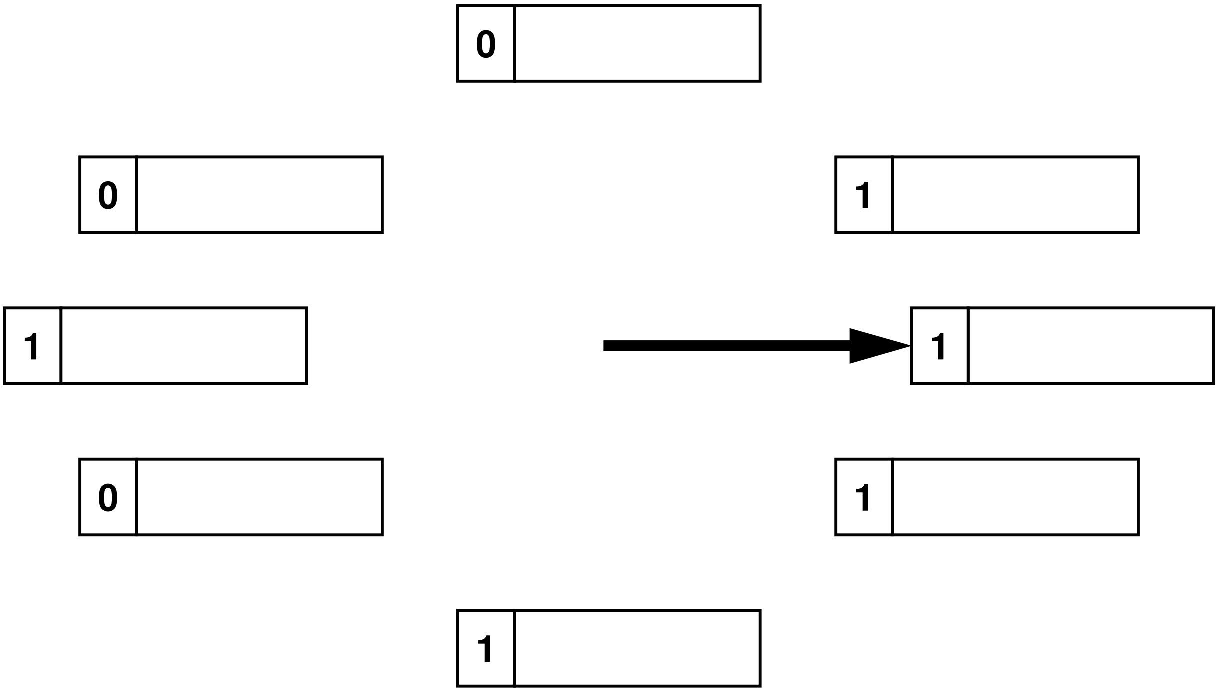


- **annähernde Berücksichtigung des letzten Referenzierungszeitpunktes**

# GCLOCK (Generalized CLOCK)

- **pro Seite wird Referenzzähler geführt (statt Bit)**

- **Ersetzung nur von Seiten mit Zählerwert 0**

  (sonst erfolgt Dekrementierung des Zählers und Betrachtung der nächsten Seite)

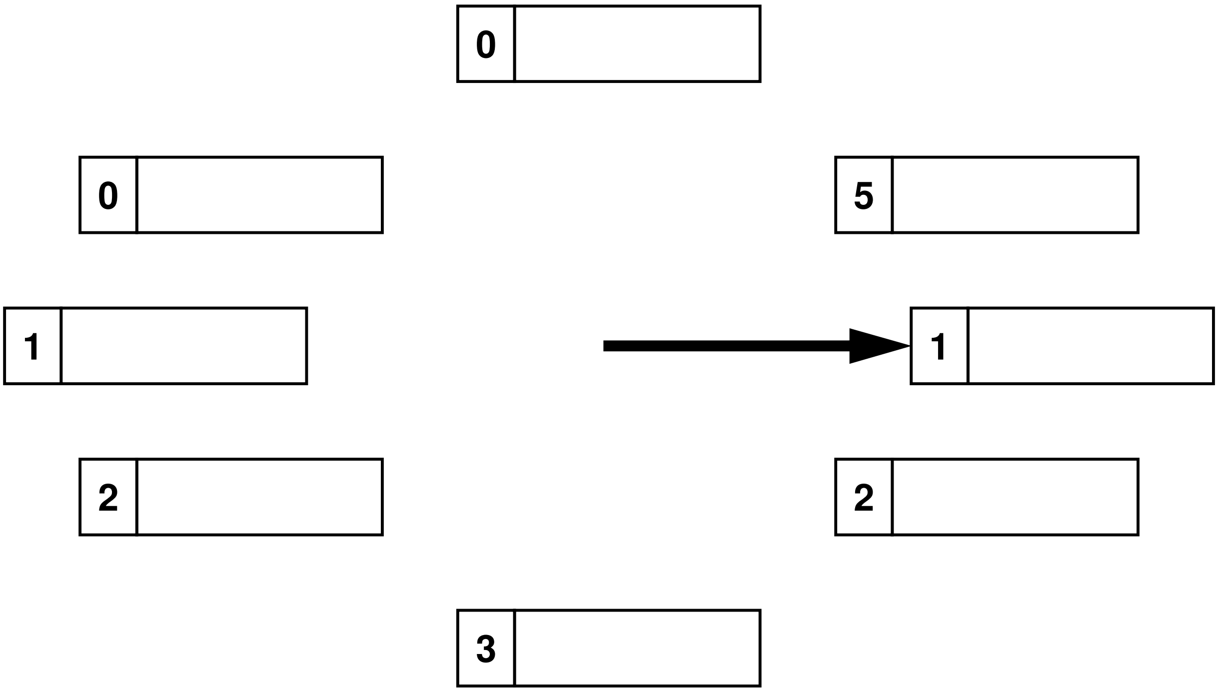


- **Verfahrensparameter:**
  - Initialwerte für Referenzzähler
  - Wahl des Dekrementes
  - Zählerinkrementierung bei erneuter Referenz
  - Vergabe von seitentyp- oder seitenspezifischen Gewichten

# Least-Reference-Density (LRD)

- **Referenzdichte: Referenzhäufigkeit während eines bestimmten Referenzintervalls**

- **Variante 1: Referenzintervall entspricht Alter einer Seite**

- **Berechnung der Referenzdichte:**

  Globaler Zähler GZ: Gesamtanzahl aller Referenzen
  Einlagerungszeitpunkt EZ: GZ-Wert bei Einlesen der Seite
  Referenzzähler RZ

  Referenzdichte $RD(j) = \frac{RZ(j)}{GZ - EZ(j)}$

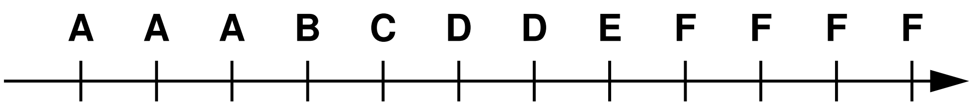


| | RZ | EZ | RD |
|---|---|---|---|
| **A** | | | |
| **B** | | | |
| **C** | | | |
| **D** | | | |
| **E** | | | |
| **F** | | | |

# Least-Reference-Density (2)

- **Variante 2: konstante Intervallgröße**

- **periodisches Reduzieren der Referenzzähler, um Gewicht früher Referenzen zu reduzieren**

  Reduzierung von RZ durch Division oder Subtraktion:

$$RZ(i) = \frac{RZ(i)}{K1} \qquad (K1 > 1)$$

oder

$$RZ(i) = \begin{cases} RZ(i) - K2 & \text{falls} \quad RZ(i) - K2 \geq K3 \\ K3 & \text{sonst} \quad (K2 > 0, K3 \geq 0) \end{cases}$$

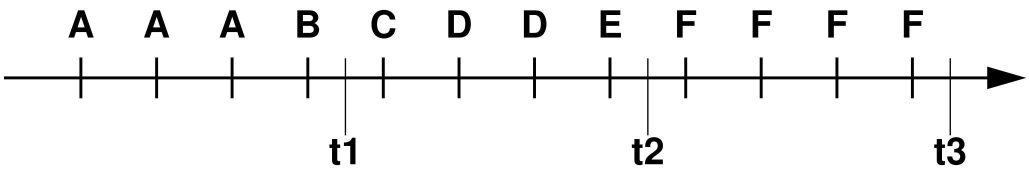


| | t1 | t2 | t3 |
|---|---|---|---|
| **RZ(A)** | | | |
| **RZ(B)** | | | |
| **RZ(C)** | | | |
| **RZ(D)** | | | |
| **RZ(E)** | | | |
| **RZ(F)** | | | |

# LRU-K

- **Aufzeichnung der K letzten Referenzzeitpunkte** (pro Seite im DB-Puffer)
  - Aufwendigere Aufzeichnung gewährleistet aktuelle Ersetzungsinformation; Methode benötigt kein explizites „Altern“ über Tuning-Parameter wie LRD-V2
  - Gegeben sei bis zum Betrachtungszeitpunkt t der Referenzstring $r_1, r_2, \dots, r_t$. **Rückwärtige K-Distanz $b_t(P, K)$** ist die in Referenzen gemessene Distanz rückwärts bis zur K-jüngsten Referenz auf Seite P:

    **$b_t(P, K) = x$**, wenn $r_{t-x}$ den Wert P besitzt und es genau K-1 andere Werte i mit $t-x < i \leq t$ mit $r_i = P$ gab.

    **$b_t(P, K) = \infty$**, wenn P nicht wenigstens K mal in $r_1, r_2, \dots, r_t$ referenziert wurde

- **Beispiel (K=4)**

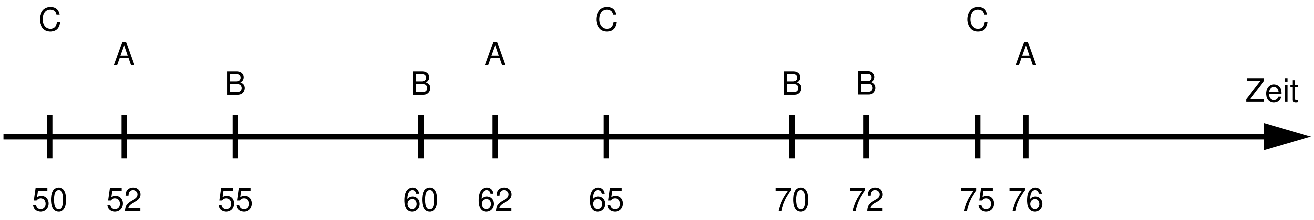


- **Zur Ersetzung genügt es, die $b_t(P_i, K)$ der Pufferseiten zu berücksichtigen!**
  - Sonderbehandlung für Seiten mit weniger als K Referenzen erforderlich
  - Wie hängt LRU-K mit LRD zusammen? Approximation der Referenzdichte?

- **LRU-2 (d.h. K=2) stellt i. allg. beste Lösung dar**[1]
  - ähnlich gute Ergebnisse wie für K > 2, jedoch einfachere Realisierung
  - Verfahren reagiert schneller auf Referenzschwankungen als bei größeren K

---

1. O‘Neil, E.J., O‘Neil, P.E., Weikum, G.: The LRU-K Page Replacement Algorithm for Database Disk Buffering. Proc. ACM SIGMOD Conf. Washington. D.C. 1993. 297–306

# Ersetzungverfahren –
# Einbezug von Kontextwissen

- **Ausnutzung von Kontextwissen bei mengenorientierten Anforderungen**

  ➥ Verbesserung in relationalen DBS möglich

- **Zugriffspläne durch Optimizer**
  - Zugriffscharakteristik/Menge der referenzierten Seiten kann bei der Erstellung von Plänen vorausgesagt/abgeschätzt werden
  - Zugriffsmuster enthält immer Zyklen/Loops (mindestens Kontrollseite – Datenseite, *nested loop join* etc.)
  - Kostenvoranschläge für Zugriffspläne können verfügbare Rahmen berücksichtigen
  - Bei Ausführung wird die Mindestrahmenzahl der Pufferverwaltung mitgeteilt

- **<u>Hot-Set</u>: Menge der Seiten im Referenzzyklus**

  Prinzipieller Verlauf der Fehlseitenrate (**FSR**) bei speziellen Operationen

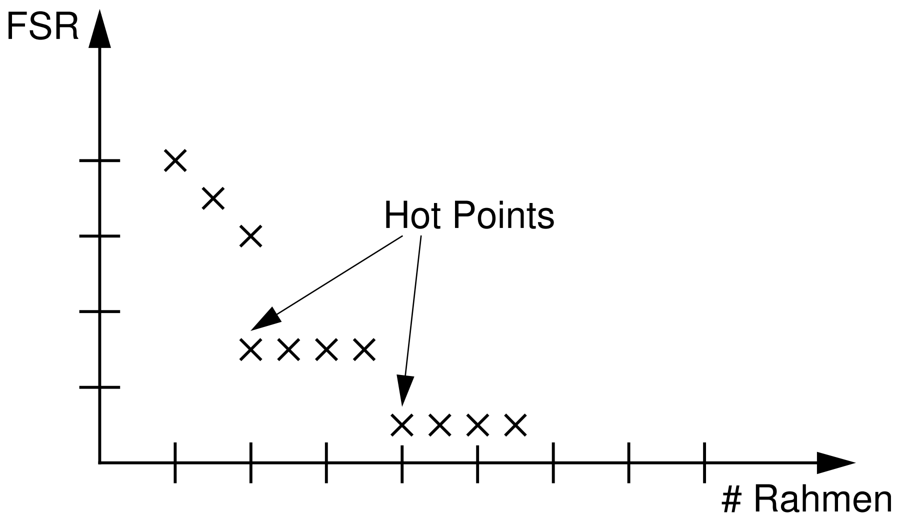

# „Hot-Set"-Modell

- ***Hot Point*:**
  abrupte Veränderung in der FSR, z. B. verursacht durch Schleife beim Verbund
- ***Hot Set Size* (HSS):**
  größter *Hot Point* kleiner als der verfügbare DB-Puffer
- Optimizer berechnet HSS für die verschiedenen Zugriffspläne (Abschätzung der #Rahmen)
- Beispiel:

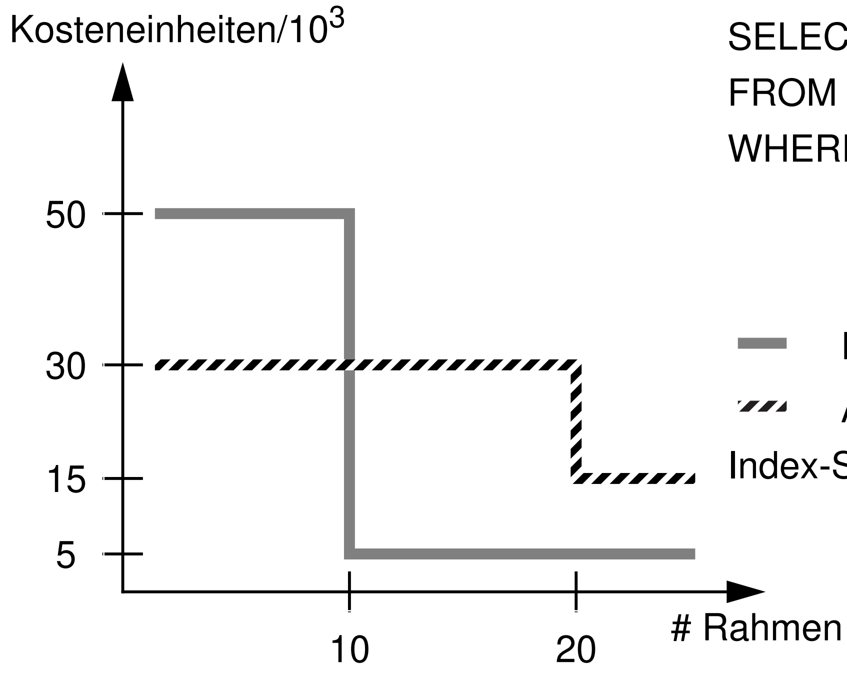


```
SELECT   *
FROM     ABT X, PERS Y
WHERE    X.ANR = Y.ANR
         AND ...
```

PERS in äußerer Schleife
ABT in äußerer Schleife
Index-Scan für beide Relationen

- **Anwendungscharakteristika**
  - Berücksichtigung der HSS in den Gesamtkosten
  - Auswahl abhängig von verfügbarer DB-Puffergröße
  - Bindung zur Laufzeit möglich

# Seitenersetzung
# bei virtuellem Speicher

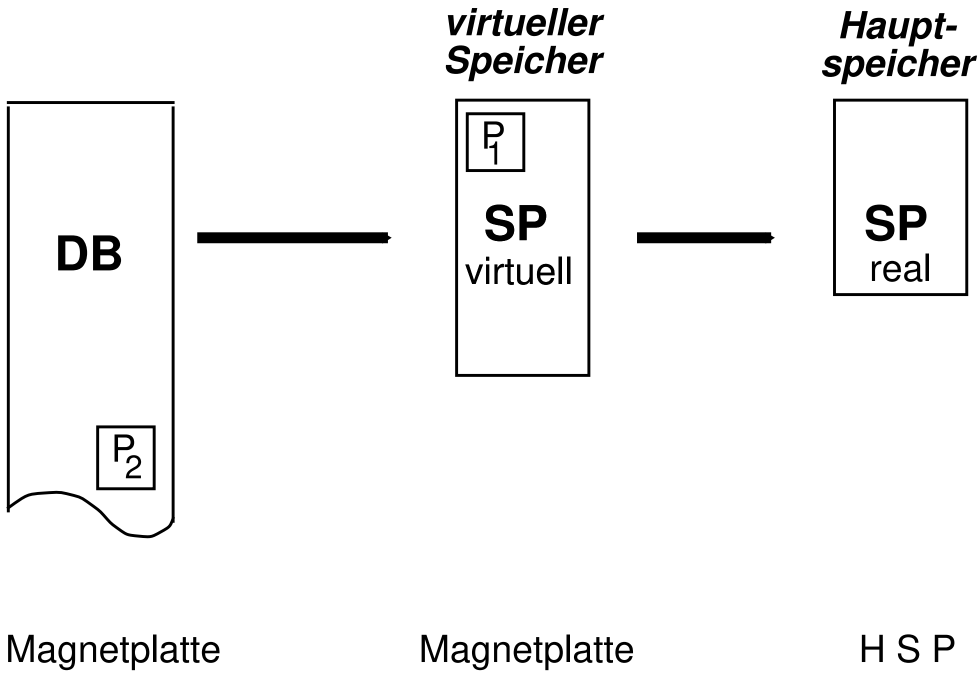


- **Page Fault:**

  $P_i(P_1)$ in SP virtuell, aber nicht in SP real (HSP)

- **Database Fault:**

  $P_i(P_2)$ nicht in SP virtuell,

  Seitenrahmen für $P_i$ jedoch in SP real

- **Double Page Fault:**

  $P_i(P_2)$ nicht in SP virtuell, ausgewählter

  Seitenrahmen nicht in SP real

# Zusammenfassung

- **Referenzmuster in DBS sind Mischformen**
  - sequentielle, zyklische, wahlfreie Zugriff
  - Lokalität innerhalb und zwischen Transaktionen
  - „bekannte“ Seiten mit hoher Referenzdichte
- **Ohne Lokalität ist jede Optimierung** der Seitenersetzung sinnlos (~ RANDOM)
- **Suche im Puffer durch Hash-Verfahren**
- **Speicherzuteilung:**
  - global ⇒ alle Pufferrahmen für alle Transaktionen (Einfachheit, Stabilität ...)
  - lokal ⇒ Sonderbehandlung bestimmter Transaktionen/Anfragen/ DB-Bereiche
- **Behandlung geänderter Seiten:** NOFORCE, asynchrones Ausschreiben
- **Seitenersetzungsverfahren**
  - „zu genaue“ Verfahren sind schwierig einzustellen (⇒ instabil)
  - Nutzung mehrerer Kriterien: Alter, letzte Referenz, Referenzhäufigkeit
  - CLOCK ~ LRU, aber einfachere Implementierung
  - GCLOCK, LRD, LRU-K relativ komplex
  - LRU-2 guter Kompromiss; vorletzter Referenzzeitpunkt bestimmt „Opfer“
- **Erweiterte Ersetzungsverfahren**
  - Nutzung von Zugriffsinformationen des Query-Optimierers
  - Hot-Set-Modell
- **Double-Paging sollte vermieden werden**