

BP 2 Software-gestützte Pufferung: Virtueller Speicher

3 In Software realisierte Pufferspeicher

3.1 Virtueller Speicher

Pufferung auf externen Speichern (vorwiegend Plattenspeichern) angelegter 'virtueller' Adreßräume im Arbeitsspeicher (paging)

Speicherplatz wird nur für tatsächlich belegte Teile der virtuellen Adreßräume angelegt

Adressierung der Puffer erfolgt in der Terminologie der Hardwareüberlegungen physikalisch? Ist also für Betriebssystemfunktionen unproblematisch?

Interpretation von Befehls- und Datenadressen erfolgt bezüglich des jeweils eingestellten Adreßraums

Virtuelle Adreßräume können überlappend sein!

Betreiben gemeinsamer Bereiche unproblematisch

Zur Vereinheitlichung des Speicherzugriffs im Betriebssystem, werden Dateien beim Öffnen in den virtuellen Adreßraum gelegt (memory mapped files); können also in mehrere Adreßräume eingeblendet sein oder in einem Adreßraum mehrfach

21.05.01 Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

3.1-1

BP 2 Software-gestützte Pufferung: Virtueller Speicher

Vergleich der Vorgehensweisen bei 'caching' und 'paging'!

	Caching	Paging
Ebene E_i	Arbeitsspeicher	Plattenspeicher
Ebene E_{i-1}	Cache	Arbeitsspeicher
Pufferadr.	kontextbezogen (virtuell) oder speicherbezogen (physikalisch)	kontextbezogen
Speicheradr.	physikalische Adr.	Blockadr. am Plattenspeicher
Index	Teil der Adresse	ermittelt über Tabelle
Index bestimmter Adresse	zeitl. unveränderlich	zeitl. veränderlich
Zeile	Pufferzeile	Kachel
Zeilenlänge	Pufferzeilenlänge	Kachelgröße
Markierung	versch. Varianten	physikalische Markierung (Kachel-Seiten-Tabelle)
write on hit	write-back/through	write-back
write on miss	allocating/nonallocating	allocating
Holstrategie	auf Anforderung	auf Anforderung oder (evtl. nur teilweise) vorausschauend
Ersetzungsstrategie	LRU	Second Chance

21.05.01 Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

3.1-2

BP 2 Software-gestützte Pufferung: Virtueller Speicher

	Caching	Paging
Plazierungsstrategie	durch Adr. festgelegt	Vermeidung von Bedeutungs- gleichheit und Mehrdeutigkeit; Effizienz- überlegungen
Mehrdeutigkeit	falls virtuell adressiert, möglich	durch Wahl des Plazierungsortes ver- mieden
Bedeutungsgleichheit:	falls virtuell adressiert, möglich	durch Wahl des Plazierungsortes ver- mieden

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.1-3

BP 2 Software-gestützte Pufferung: Virtueller Speicher

Wahl der Strategien

- **Holstrategie:**
 - Vorausschauend (prefetching)
 - Bei Fehlzugriff (on demand, demand paging)
- **Plazierungsstrategie:**
 - Wo frei (derzeit Normalfall)
 - Unter Berücksichtigung von Erfordernissen effizienter Pufferspeichernutzung
 - Bei NUMA-Architekturen Berücksichtigung der Threadaffinität
- **Ausräum-(Ersetzungs-)Strategie:**
 - Siehe Systemprogrammierung I

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.1-4

Kann durch vorzeitige Einlagerungen die Zahl der Einlagerungen eines Prozesses reduziert werden?

Satz: Zu jeder vorzeitig einlagernden Strategie kann eine Strategie konstruiert werden, die nur auf Anforderung einlagert und dabei höchstens so viele Einlagerungen verursacht wie die vorzeitig einlagernde.

Beweis:

Sei A eine vorausschauende Strategie und $r_1, r_2, \dots$ eine Referenzfolge.

Es sei S_t die Menge der nach dem t -ten Zugriff im Arbeitsspeicher befindlichen Seiten.

X_t bzw. Y_t seien die beim Übergang von S_{t-1} zu S_t ein- bzw. ausgelagerten Seiten, d. h.

$S_t = S_{t-1} + X_t - Y_t$ mit $X_t \cap Y_t = \emptyset$, $X_t \cap S_{t-1} = \emptyset$ und $Y_t \subseteq S_{t-1}$.

Konstruktion einer Anforderungsstrategie A' :

- P_t seien die zum Zeitpunkt t von A aber nicht von A' eingelagerten Seiten.
- R_t seien die zum Zeitpunkt t von A wieder ausgelagerten Seiten, die aber noch nicht von A' ausgelagerten wurden, also $R_t = (R_{t-1} + Y_t - X_t) \cap S'_t$.


Mit diesen Bezeichnungen gilt $S'_t = S_t + R_t - P_t$.

- Bis erstmalig alle Kacheln belegt sind, muß A mindestens so viele Einlagerungen wie A' gemacht haben, da ja A' nur angesprochene Seiten einlagert.
- Sind zu einem Zeitpunkt unter A' alle Kacheln belegt sind und es muß eine Einlagerung erfolgen, so wird eine Seite aus $R_{t-1} + Y_t$ ausgelagert.
- Angenommen diese Vorgehensweise funktioniert bis t und es sei eine Seite einzulagern, die unter A bereits im Arbeitsspeicher ist und nicht zu Y_t gehört. Dann kann R_{t-1} nicht leer sein, denn es muß unter A eine der Seiten aus S'_{t-1} ausgelagert worden sein, um Platz für r_t zu haben. Wenn A' eine der Seiten aus $R_{t-1} + Y_t$ auslagert, so muß diese bis zum nächsten Ansprechen auch von A wieder eingelagert werden.
- Also ist auch bis zum nächsten Zeitpunkt die Zahl der Einlagerungen unter A mindestens so groß wie unter A' .

3.2

Verteilter, gemeinsam genutzter Speicher

Hardwarestruktur



21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-7

Programmierparadigmen

Nachrichtensysteme

Prozesse (Threads) versenden und empfangen Nachrichten

Gemeinsamer Speicher

Prozesse benutzen den ASP als Pufferspeicher

Anforderungen für gemeinsam genutzten Speicher

- Beispiel: parallele Bearbeitung von Satellitendaten mit evtl. unterschiedlichen Programmen
- Differenzierte Behandlung der Regionen bei fork: 'text'-Segmente können gemeinsam genutzt werden
- Manche Regionen (z. B. solche die Dateien beherbergen) können für den erzeugten Prozeß irrelevant sein
- Bei manchen Regionen kann der Anfangszustand relevant sein, aber es sollen erzeugender und erzeugter Prozeß eigene Kopien besitzen
- Algorithmen für Realisierung von gemeinsam genutzten Speicher sowohl für NORMA- als auch für NUMA-Architekturen von Interesse

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-8

Wichtige Gesichtspunkte

- Struktur und Granularität
- Kohärenz-Semantik
- Skalierbarkeit
- Implementierung
 - Datenlokalisierung und Zugriff
 - Kohärenzprotokoll (write-invalidate, write-update)
 - Ersetzungsstrategie
 - Seitenflattern (Thrashing)
 - Interaktionsmechanismen


21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-9

Grundsätzliche Vorgehensweise

Zuletzt von A angesprochene Seite wird von B lesend angesprochen



- j Zugriff mit Seitenfehler
 k data_request
 l lock_request (read only)
 m lock_completed
 n data_provided (read only)


21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-10

Probleme?

Performanz: Eine Seite könnte ständig zwischen zwei oder mehr Prozessoren hin- und hergeschoben werden


 **Seitenflattern (thrashing)**

Lösung: Replizieren von Seiten

 **Kohärenzprotokoll erforderlich**

Frage: Anforderungen an das Kohärenzprotokoll anwendungsabhängig

 **abgestufte Kohärenzprotokolle**

Kohärenzarten

Präzisierung der Vorstellungen

Gharachorloo, K; Lenoski, D.; Laudon J.; Gibbons, P.; Gupta, A.; Hennesy, J.: Memory Consistency and Event Ordering in Scalable Shared-Memory Multiprocessors. Proc. 17th Annual Int. Symp. on Computer Architecture, May 28-31, 1990, Seattle Washington, pp.15-26.

Bezeichnungen

- Eine **Load-Operation** eines Prozessors P_i wird zu einem Zeitpunkt als *ausgeführt bezüglich P_k* betrachtet, wenn ein späterer Anstoß einer Store-Operation durch P_k das Ergebnis der Load-Operation nicht beeinflussen kann.
- Eine **Store-Operation** eines Prozessors wird zu einem Zeitpunkt als *ausgeführt bezüglich P_k* betrachtet, wenn ein späterer Anstoß einer LOAD-Operation durch P_k den Wert liefert, den die Store-Operation oder eine spätere, die gleiche Speicherstelle betreffende geschrieben hat.
- Eine **Speicherooperation** gilt als *ausgeführt*, wenn sie bezüglich aller Prozessoren ausgeführt ist.
- Eine **Load-Operation** gilt als *global ausgeführt*, wenn sie ausgeführt ist und die Store-Operation, die die Ursache für den erhaltenen Wert ist, ausgeführt ist.

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

3.2-13

In den folgenden Kohärenz-Definitionen wird **stillschweigend vorausgesetzt**, daß unter Prozessoren nur Monoprozessoren verstanden werden und ihre eigene Befehl

sarbeitung die übliche Ausführungs-Reihenfolge einhält.


Strikte Konsistenz

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

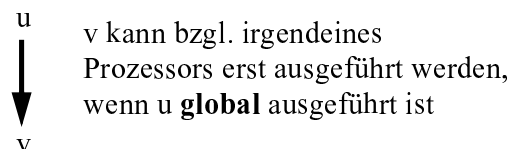
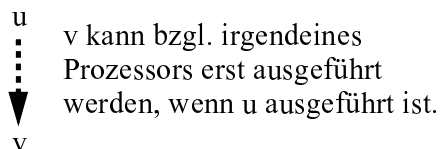
3.2-14

Lesen liefert zuletzt geschriebenen Wert





➔ Kaum realisierbar in einem verteilten System



Graphische Charakterisierung verschiedener Konsistenzmodelle



Sequentielle Konsistenz



Prozessor-Konsistenz




Klassifikation von Speicherzugriffen

Mehrere Speicherzugriffe sind

- **kollidierend** (conflicting), wenn sie den gleichen Speicherort betreffen und wenigstens einer eine STORE-Operation ist;
- **konkurrierend** (competing), wenn sie kollidieren und gleichzeitig zur Ausführung anstehen können,
- **koordinierend** (synchronizing), wenn sie zur Erzwingung von Ausführungsreihenfolgen konkurrierender Zugriffe benutzt werden.

Sie sind unterteilbar in

- Belegoperationen (acquire) und
- Freigabeoperationen (release)



Jede Speicheroperation eines Programms sei mit einer der Marken

$m_{\text{kollidierend}}$, $m_{\text{konkurrierend}}$, $m_{\text{nicht_konkurrierend}}$, $m_{\text{koordinierend}}$, $m_{\text{nicht_koordinierend}}$, m_{belegend} oder $m_{\text{freigebend}}$ markiert.

Definition

Ein Programm enthält **genügend koordinierende Zugriffe**, wenn folgendes gilt:

Es seien u und v zwei beliebige, kollidierende Zugriffe der beiden Fäden P_u und P_v , von denen wenigstens einer mit $m_{\text{konkurrierend}}$ markiert ist. Dann muß bei jedem Ablauf, in dem v nach (vor) u ausgeführt wird, wenigstens ein mit $m_{\text{koordinierend}}$ markierter Schreibzugriff (Lesezugriff) von P_u existieren und ein ebenso markierter Lesezugriff (Schreibzugriff) von P_v , die u und v so trennen, daß der Schreibaufufr vor dem Leseaufruf erfolgt.


Der Schreibaufufr muß mit $m_{\text{freigebend}}$, der Leseaufruf mit m_{belegend} markiert sein.

Ein Programm heißt **richtig markiert**, wenn gilt:


- Alle kollidierenden Zugriffe sind mit `m_kollidierend` markiert,
- alle konkurrierenden Zugriffe sind mit `m_konkurrierend` markiert und
- das Programm enthält (im vorangehend definierten Sinne) genügend mit `m_koordinierend` markierte Zugriffe.

Weitere Konsistenzmodelle:


Schwache Konsistenz




Freigabe-Konsistenz



Modellhafte Beispiele



Sequentielle Konsistenz




Prozessor-Konsistenz


21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-21



Schwache Konsistenz



Freigabe-Konsistenz

21.05.01


Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-22


Überlappung bei der Bearbeitung einer verteilten Hash-Tabelle



Sequentielle Konsistenz



Schwache Konsistenz



Freigabe-Konsistenz

Satz: Richtig markierte Programme liefern bei Freigabe-Konsistenz dieselben Ergebnisse wie bei sequentieller Konsistenz.

Beweis: Siehe eingangs angegebene Literaturstelle.

Algorithmen für die Platzierung von Seiten


	nicht vervielfachend	vervielfachend
Nicht migrierend	zentralisiert (central server)	allgemein vervielfachend (full-replication)
migrierend	migrierend (migration)	vervielfachend für Lesezugriff (read-replication)

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-25

Zentraler Server (Central-server algorithm)




Client	zentraler Server
Datenanforderung senden	Anforderung entgegennehmen Datenzugriff durchführen Antwort senden
Antwort entgegennehmen	

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-26

Migrationsalgorithmus



Client

Verwalter

Falls Block nicht lokal,
Speicherort ermitteln
und Anforderung senden

Antwort entgegennehmen
Datenzugriff durchführen


Anforderung entgegennehmen
Block senden

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-27

Vervielfachung für lesenden Zugriff (Schreibaufruf)



Client

Verwalter

Falls Block nicht lokal,
Speicherort ermitteln
und Anforderung senden

Antwort entgegennehmen
Invalidierung an alle anderen

Zugriff


Anforderung entgegennehmen
Block senden

Invalidierung vollziehen

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-28

Allgemeine Replikation


Client	Sequencer	Verwalter
Falls 'write' Daten an Sequencer	Sequenznummer anfügen Multicast	Daten empfangen 'update' lokal
Ausführung bestätigt 'update' lokal		

21.05.01

 Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
 Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
 ist ohne Genehmigung des Autors unzulässig

3.2-29

Vergleichende Analyse

**Stumm, M.; Zhou, S.: Algorithms Implementing Distributed Shared Memory.
 Computer, May 1990, pp. 54-64.**

- p** Zeit für Versenden oder Empfangen einer kurzen Nachricht (einige Byte)
 typischerweise einige msec
- P** Zeit für Versenden oder Empfangen einer langen Nachricht (8 KByte)
 typischerweise 20 bis 40 msec
- S** Zahl beteiligter Knoten
- r** Zahl der Leseaufrufe relativ zur Zahl der Schreibaufufe
- f** Wahrscheinlichkeit für einen Zugriffsfehler bei Zugriff zu nicht-replizierten
 Datenblöcken unter dem Migrationsalgorithmus
- f'** Wahrscheinlichkeit für einen Zugriffsfehler bei Zugriff zu nicht-replizierten
 Datenblöcken bei Vervielfachung für lesenden Zugriff

21.05.01

 Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
 Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
 ist ohne Genehmigung des Autors unzulässig

3.2-30

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

Zentraler Server	$C_z = \left(1 - \frac{1}{S}\right)4p$
Migration	$C_m = f(2P + 4p)$
Leseervielfachung	$C_{lv} = f\left(2P + 4p + \frac{Sp}{r+1}\right)$
Allg. Replikation	$C_{av} = \frac{1}{r+1}(S+2)p$
Typischerweise:	$P \approx 20p$

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-31

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

Leseervielfachung besser Zentraler Server besser

Migration besser Leseervielfachung besser

Leseervielfachung besser Allgemeine Replikation besser

Allg. Repl. besser Zentraler Server besser

21.05.01

Universität Erlangen-Nürnberg, Lehrstuhl für Informatik 4 (Verteilte Systeme und Betriebssysteme), F. Hofmann
Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg
ist ohne Genehmigung des Autors unzulässig

3.2-32