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

Software-gestützte Pufferung: Virtueller Speicher

- Vergleich der Vorgehensweisen bei 'caching' und '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

Software-gestützte Pufferung: Virtueller Speicher

Plazierungsstrategie	durch Adr. festgelegt	Vermeidung von Bedeutungsgleichheit und Mehrdeutigkeit; Effizienzüberlegungen
Mehrdeutigkeit	falls virtuell adressiert, möglich	durch Wahl des Plazierungsortes vermieden
Bedeutungsgleichheit:	falls virtuell adressiert, möglich	durch Wahl des Plazierungsortes vermieden

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

BP 2 Software-gestützte Pufferung: Virtueller Speicher

❑ Kann durch vorausschauende Einlagerung die Zahl der Einlagerungen eines Prozesses reduziert werden?

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

Beweis:

Sei A eine vorausschauende Strategie und r_0, r_1, r_2, ... 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 $X_t \cap Y_t = \varnothing$, $X_t \cap S_{t-1} = \varnothing$ und $Y_t \subseteq S_{t-1}$.

BP 2 Software-gestützte Pufferung: Virtueller Speicher

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 funktioniere 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'.

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

3.2 Verteilter, gemeinsam genutzter Speicher

❑ Hardwarestruktur

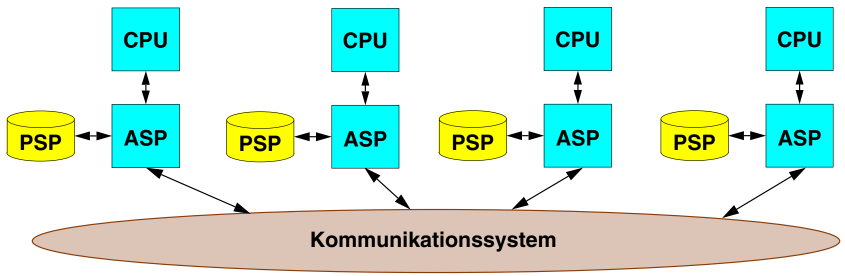

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ 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

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ **Wichtige Gesichtspunkte**

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

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ **Grundsätzliche Vorgehensweise**

Zuletzt von A angesprochene Seite wird von B lesend angesprochen

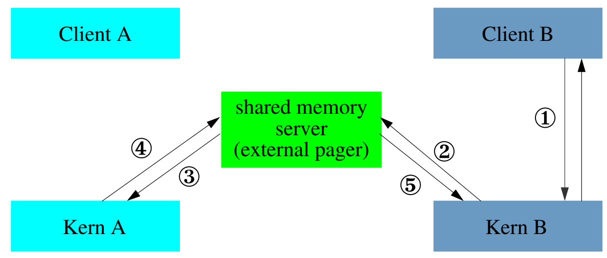

① Zugriff mit Seitenfehler
② data_request
③ lock_request (read only)
④ lock_completed
⑤ data_provided (read only)

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ **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**

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ **Kohärenzarten**

Strikte Konsistenz
Lesen liefert zuletzt geschriebenen Wert

Sequentielle Konsistenz
Die Ausführung erscheint als zeitliche Durchmischung der Operationen, wie sie bei Mehrprozeßbetrieb auftreten kann.

Prozessorkonsistenz
Schreibaufrufe eines Prozessors werden immer in der Reihenfolge ihrer Anforderung sichtbar. Über Anforderungen von verschiedenen Prozessoren kann keine Aussage über die Reihenfolge gemacht werden, in der ihre Ausführung sichtbar wird.

Schwache Konsistenz
Koordinierungsoperationen sind sequentiell konsistent.
Vor Zugriff auf Koord.-Variablen müssen alle Schreibvorgänge abgeschlossen sein.
Zugriff auf Daten nur, wenn alle vorherigen Zugriffe auf Koord.-Variablen abgeschlossen sind.

Freigabe (Release) Konsistenz
Jede der beiden Koordinierungsoperationen acquire und release ist prozessorkonsistent
Vor Ausführung von release müssen alle vorherigen Schreib- und Lesevorgänge des Prozesses abgeschlossen sein

Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ **Präzisierung der Vorstellungen**

Gharachorloo, K; Lenoski, D.; Laudon J.; Gibbons, P.; Gupta, A.; Hennessy, 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 Speicheroperation 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.**

Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ **Strikte Konsistenz**

Lesen liefert zuletzt geschriebenen Wert

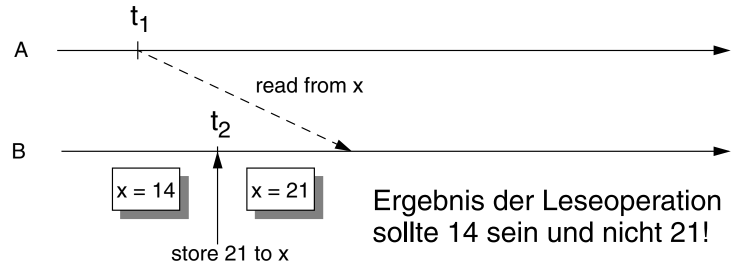

Ergebnis der Leseoperation sollte 14 sein und nicht 21!

⇨ Kaum realisierbar in einem verteilten System

Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ **Graphische Charakterisierung verschiedener Konsistenzmodelle**

v kann bzgl. irgendeines Prozessors erst ausgeführt werden, wenn u ausgeführt ist.

v kann bzgl. irgendeines Prozessors erst ausgeführt werden, wenn u **global** ausgeführt ist

◆ **Sequentielle Konsistenz**

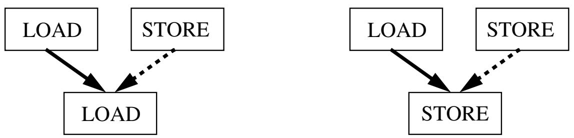

◆ **Prozessor-Konsistenz**

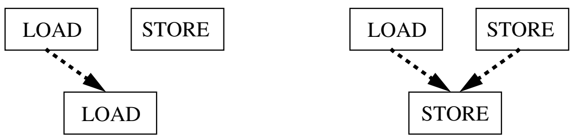

Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

❑ **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)

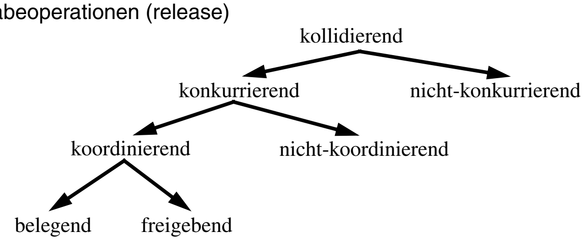

- Jede Speicheroperation eines Programms sei mit einer der Marken

  m_kollidierend, m_konkurrierend, m_nicht_konkurrierend, m_koordinierend, m_nicht_koordinierend, m_belegend oder m_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_konkurrierend markiert ist. Dann muß bei jedem Ablauf, in dem v nach (vor) u ausgeführt wird, wenigstens ein mit m_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 Schreibaufruf vor dem Leseaufruf erfolgt.

  Der Schreibaufruf muß mit m_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

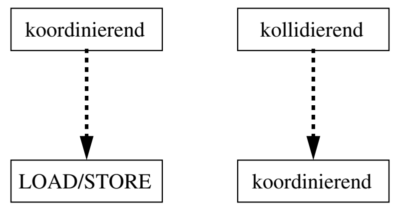

Koordinierende Zugriffe untereinander sequentiell konsistent

- Freigabe-Konsistenz

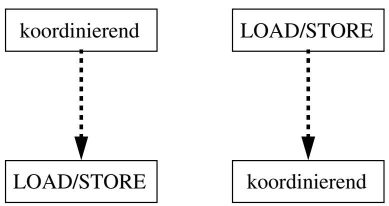

Koordinierende Zugriffe untereinander prozessor-konsistent

- Modellhafte Beispiele

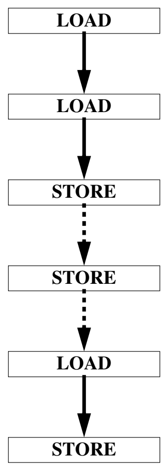

Sequentielle Konsistenz

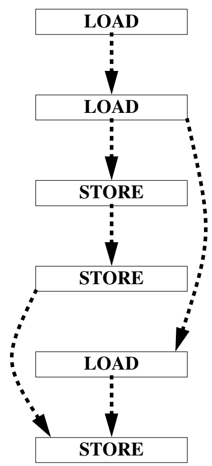

Prozessor-Konsistenz

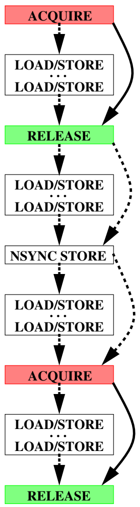

Schwache Konsistenz

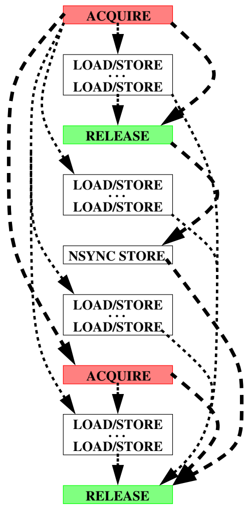

Freigabe-Konsistenz

- **Überlappung bei der Bearbeitung einer verteilten Hash-Tabelle**

Sequentielle Konsistenz

Schwache Konsistenz

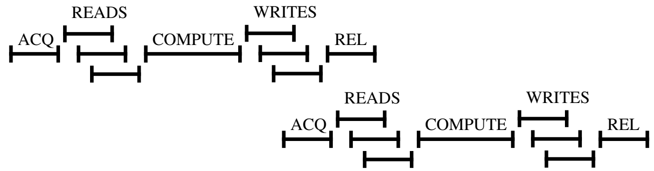

Freigabe-Konsistenz

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

  Beweis: Siehe eingangs angegebene Literaturstelle.

- **Algorithmen für die Plazierung von Seiten**

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

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

Zentraler Server (Central-server algorithm)

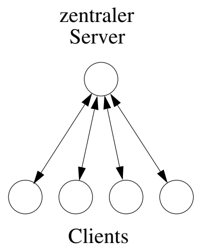

Client	zentraler Server
Datenanforderung senden	
	Anforderung entgegennehmen Datenzugriff durchführen Antwort senden
Antwort entgegennehmen	

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

Migrationsalgorithmus

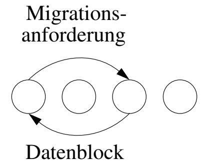

Client	Verwalter
Falls Block nicht lokal, Speicherort ermitteln und Anforderung senden	
	Anforderung entgegennehmen Block senden
Antwort entgegennehmen Datenzugriff durchführen	

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

Vervielfachung für lesenden Zugriff (Schreibaufruf)

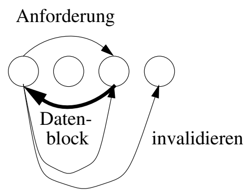

Client	Verwalter
Falls Block nicht lokal, Speicherort ermitteln und Anforderung senden	
	Anforderung entgegennehmen Block senden
Antwort entgegennehmen Invalidierung an alle anderen	
	Invalidierung vollziehen
Zugriff	

BP 2 Software-gestützte Pufferung: Verteilter gemeinsamer Speicher

Allgemeine Replikation

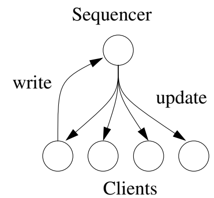

Client	Sequencer	Verwalter
Falls ‘write’ Daten an Sequencer		
	Sequenznummer anfügen Multicast	
		Daten empfangen ‘update’ lokal
Ausführung bestätigt ‘update’ lokal		

- **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 Schreibaufrufe

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

Zentraler Server $C_z = \left(1 - \frac{1}{S}\right)4p$ Migration $C_m = f(2P + 4p)$

Lesevervielfachung $C_{lv} = f'\left(2P + 4p + \frac{Sp}{r+1}\right)$ Allg. Replikation $C_{av} = \frac{1}{r+1}(S+2)p$

Typischerweise: $P \approx 20p$

Lesevervielfachung besser

Zentraler Server besser

Migration besser

Lesevervielfachung besser

Lesevervielfachung besser

Allgemeine Replikation besser

Allg. Repl. besser

Zentraler Server besser