4.3 Virtuelle Caches

4.3.1 Die Arbeitsweise

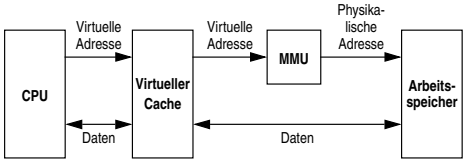

- Beispiel: i860 on-chip cache
- Prüfung der Zugriffsrechte
  - write-through
    - hit: virtuelle Adresse auch an MMU zur Prüfung
    - miss: bei write-allocate mit phys. Adr. aus ASP lesen
  - write-back
    - miss: Prüfung verbunden mit laden evtl. Rückschreiben unter Nutzung der MMU
    - hit: Falls schon modifiziert, dann erlaubt

      falls nicht modifiziert, parallel Prüfung mittels MMU

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

4.3.2 Probleme

- Mehrdeutigkeit (ambiguity)

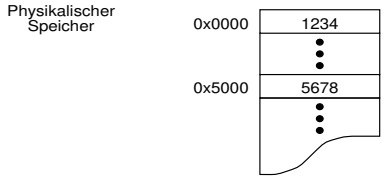

Zeitpunkt 1:

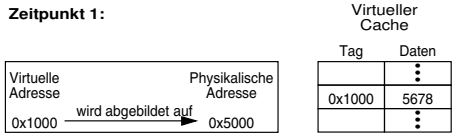

Zeitpunkt 2:

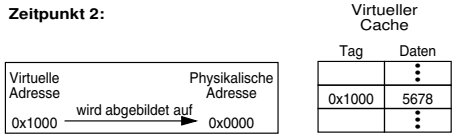

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

- Bedeutungsgleichheit (alias, synonym)

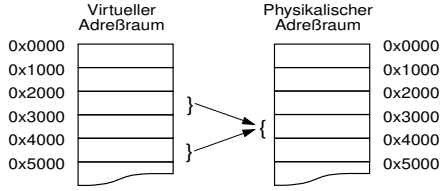

Nach Ansprechen von 0x2000 und 0x4000

Virtueller Cache

Tag	Daten
	⋮
0x2000	1234
	⋮
0x4000	1234
	⋮

Nachfolgende Modifikation von 0x2000

Virtueller Cache

Tag	Daten
	⋮
0x2000	5678
	⋮
0x4000	1234
	⋮

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

4.3.3 Verwaltung virtueller Caches

- Kontextumschaltung

  Da gleiche Adressen in unterschiedlichen Adreßräumen unterschiedliche physikalische Adressen referenzieren können, muß Cache invalidiert werden (Vorsicht bei write-back!)
- fork

  Bei write-back modifizierte Cachezeilen in ASP transferieren

  Wie wird Kopie angelegt, falls kein copy-on-write?

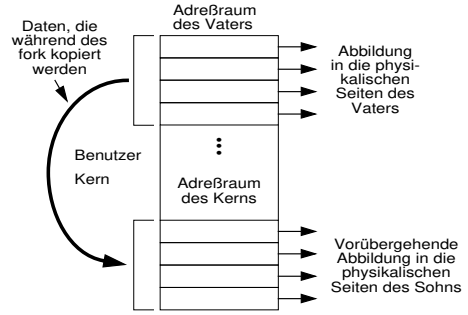

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

- exec

  Cache muß invalidiert werden

  write-back benötigt kein Rückschreiben, da bisherige Daten aufgegeben werden.
- exit

  kein Rückschreiben
- brk und sbrk

  Vergrößerung unproblematisch

  Verkleinerung:Führt zu nicht mehr abgebildeten Seiten, die aber noch teilweise im Cache sein können, also Cache (selektiv) invalidieren

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

- Gemeinsamer Speicher (shared memory) und speicherabgebildete Dateien (memory mapped files)

  Führt zum Problem der Bedeutungsgleichheit

  Mehrfachzuordnung eines gemeinsamen Segments an einen Prozeß unter verschiedenen virtuellen Adressen:
  - verbieten
  - nicht in Cache puffern
  - Adreßraum direkt abgebildet zusammen mit write_allocate: nur solche virtuelle Anfangsadressen zulassen, die auf die gleiche Cache-Zeile abgebildet werden (Beispiel: Sun 3/200)
  - Kachel zu jedem Zeitpunkt nur unter einer virtuellen Anfangsadresse zugänglich machen
  - Abkoppeln von gemeinsamen Segmenten wie Verkürzung von BSS

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

- EA
  - Gepufferte E/A ohne Komplikationen
  - Ungepufferte E/A
    - bei write Informationen evtl. noch im Cache, also Rückschreiben vor E/A-Start
    - bei read muß Cache geleert werden

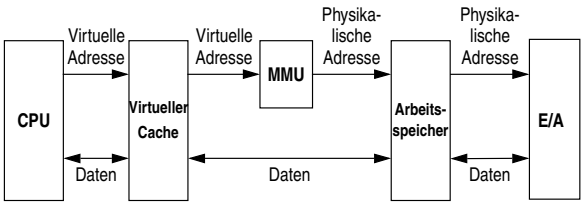

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

- Besondere Probleme, wenn E/A-Bereich nicht mit Anfangsadresse einer Cache-Zeile beginnt oder seine Länge kein Vielfaches der Cachezeilengröße ist

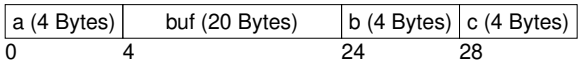

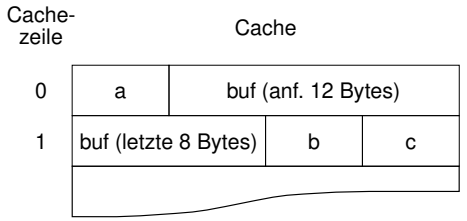

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig

- Mehrdeutigkeiten Benutzer-/Kernadreßraum
  - Cache-Invalidierung bei Verlassen des Systemzustands
  - write-back: Rückschreiben von Systemdaten muß bei Verlassen des Systemzustands erfolgen

4.3.4 Schlußfolgerung

- Virtuelle Caches bieten hohe Verarbeitungsgeschwindigkeit, da MMU nur bei Zugriffsfehlern benutzt wird
- Sie erfordern häufiges Räumen des Cache, was bei großen Caches zeitaufwendig ist
- Das Betriebssystem muß die Phänomene der Mehrdeutigkeit und Bedeutungsgleichheit berücksichtigen, insbesondere bei asynchroner E/A

Reproduktion jeder Art oder Verwendung dieser Unterlage zu Lehrzwecken außerhalb der Universität Erlangen-Nürnberg ist ohne Genehmigung des Autors unzulässig