3.3 Verteilte Dateisysteme

❑ Architektur

◆ Dateidienst-Interface

- Verlagerungsmodell (upload/download model)
  - Ganze Dateien werden vom Dienstleister zum Dienstnehmer transferiert und dort bearbeitet

  - Nach Beendigung der Arbeit werden sie zum Dienstleister zurücktransferiert

- Typisch für Massenspeichersysteme, z. B. Unitree

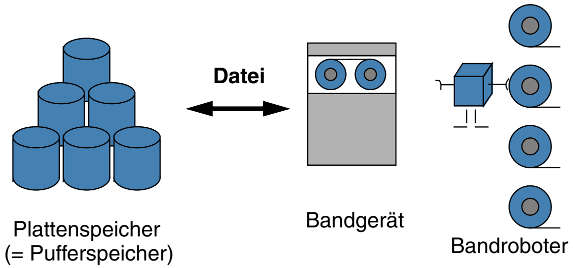

Ebene i-1:	Plattenspeicher
Ebene i:	Magnetbandroboter
Granulat:	Datei
write on hit:	write back
write on miss:	allocating
Kohärenz:	keine besonderen Maßnahmen erforderlich

◆ Fernzugriffsmodell (remote access model)

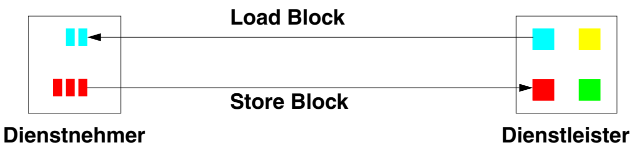

- Nur die benötigten Blöcke werden zum Dienstnehmer transferiert
- Nicht mehr benötigte Blöcke werden zurücktransferiert
- Weiterer Gestaltungsspielraum:
  write back/through?
  allocating?
  Kohärenz? (Unix: Prozessorkohärenz)
- Beispiel: NFS (Network File System von Sun)

❑ Führung von Zustandsinformation

◆ Zustandslose Dienstleister (stateless servers)

- Nach Bedienung eines Auftrags wird keine Information über diesen Auftrag gehalten
- Der Auftrag muß alle zu seiner Abwicklung notwendigen Informationen mitbringen (vollständige Dateinamen oder äquivalente Information, Lese-/Schreibzeiger, Zugriffserlaubnis, ...)
- Nachrichten werden dadurch länger
- Für jeden Aufruf muß erneut die Bestimmung des physikalischen Speicherorts vorgenommen werden
- Bessere Beherrschbarkeit transienter Ausfälle des Dienstleisters
- Keine Tabellen notwendig

  ➡ Keine Beschränkung der Zahl von Dienstnehmern
- Koordinierung von Zugriffen nicht möglich

  ➡ Besonderer Koordinator erforderlich

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

- Zustandsbehaftete Dienstleister (stateful servers)
  - Für jeden Dienstnehmer wird Information über den Bearbeitungszustand seiner geöffneten Dateien gehalten
  - Nur der Auftrag zum Öffnen einer Datei benötigt den vollständigen Dateinamen
    - ⇒ Dienstnehmer erhält Kennung zur (fälschungssicheren) Benennung des zuständigen Dateideskriptors
  - Weitere Lese-Schreibaufträge müssen nur diese Benennung mitliefern
    - ⇒ Lokalisierung der Information nicht von Grund auf neu vorzunehmen
  - Schwieriger Wiederanlauf; erfordert Kooperation mit den Dienstnehmern

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

- Grundsätzliche Möglichkeiten der Pufferung

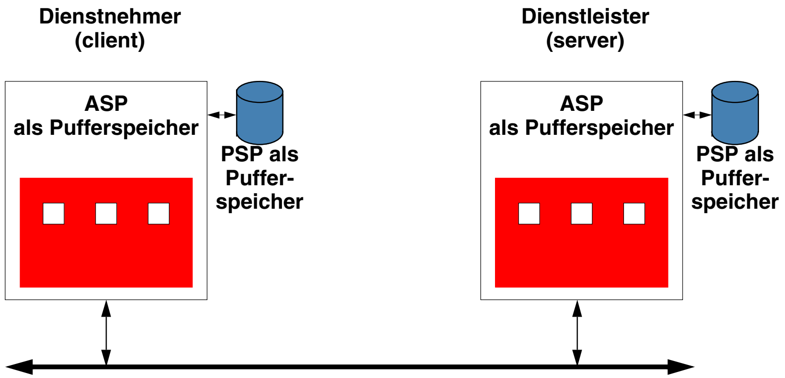

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

Vor- und Nachteile von Pufferung

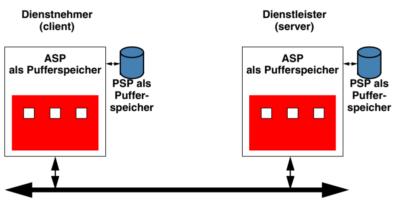

Dienstleister:
Pufferung im ASP reduziert E/A

Dienstnehmer:
Pufferung beim Dienstnehmer reduziert E/A und Netzwerkverkehr
Pufferung erzeugt Konsistenzprobleme

Pufferungsgranulate:
Dateien oder Dateiblöcke?

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

- Pufferung im Adreßraum des Dienstnehmers

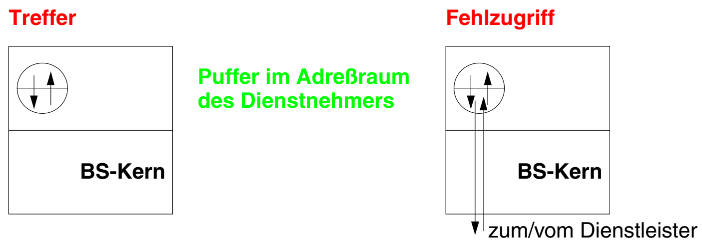

- Geringer Overhead
- Vorteilhaft, wenn Prozesse die gleiche Datei mehrfach öffnen/schließen
- Puffer wird bei Terminierung des Prozesses automatisch freigegeben

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

- Pufferung im Adreßraum des BS-Kerns

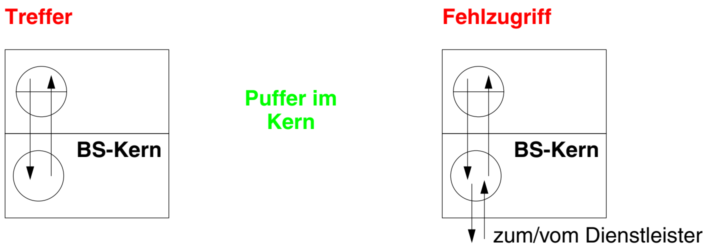

  - Jeder Zugriff ist mit einem Kernaufruf verbunden
  - Puffer überleben Prozeßterminierung

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

- Pufferung mit Pufferverwalter im Adreßraum des Dienstnehmers

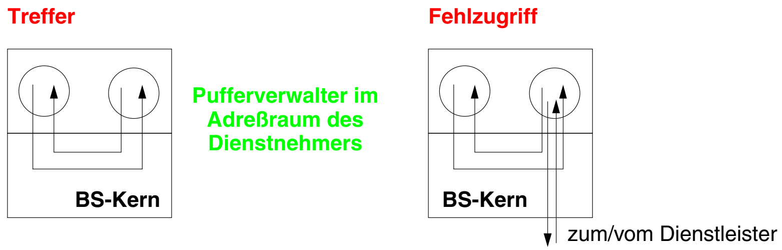

  - Kern frei von DFS-Code
  - Puffer überlebt Prozeßterminierung
  - Gepufferter Block kann im Rahmen eines Demand Paging ausgelagert werden!

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

Konsistenz

- Write-Through
  - Jede Modifikation wird sofort an den Dienstleister weitergeleitet
  - Pufferung sehr effektiv für Lesen, aber nicht für Schreiben
  - Wenn die Pufferung Prozeßterminierung überlebt, muß Gültigkeit mit dem Dientstleister abgeglichen werden (z. B. durch Versionsnummern)
- Delayed Write
  - Notieren, daß modifiziert wurde, aber kein sofortiges Informieren des Dienstleisters
  - Alle Modifikationen in regelmäßigen Abständen (z. B. 30 Sekunden) zum Dienstleister senden ➡ effizienter
  - Reduziert Transporte für temporäre Dateien, die modifiziert, gelesen und getilgt sein können, bevor der Dienstleister informiert werden muß.
  - Klare Semantik wird aufgegeben zugunsten größerer Effizienz

    ➡ was andere Prozesse lesen ist zeitabhängig

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

- Write on close
  - Anpassung an Sitzungs-Semantik und Rückschreiben zum Dienstleister alle 30 Sekunden, nachdem die Datei geschlossen wurde

    ➡ getilgte Dateien werden nicht zurückgeschickt!
  - Modifikationen können verloren gehen, wenn zwei Prozesse die gleiche Datei modifizieren
- Centralized controller
  - Führt Buch über alle geöffneten Dateien und die zugehörigen Dienstnehmer
  - Kollidierende Aufrufe können auf drei Arten behandelt werden:
    - Aufruf ablehnen
    - Aufruf in Warteschlange aufnehmen
    - Aufruf genehmigen, aber alle evtl. betroffenen Dienstnehmer veranlassen die Pufferung des betreffenden Blocks gegebenenfalls zu invalidieren und im weiteren nicht puffern

      ➡ unverlangte Nachrichten an Dienstnehmer
  - Skaliert nicht und ist nicht robust gegen transiente Rechnerausfälle

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

❑ **Beispiel: Network File System (NFS)**

McKusick, M. K.; Bostic, K.; Karels, M. J.; Quarterman, J. S.: The Design and Implementation of the 4.4BSD Operating System. Addison-Wesley, 1996, 580 pages.

- **Von vielen Herstellern für Unix und MS-DOS unterstützt**
- **Hardwareunabängig**
- **Architektur:**
  - **Dienstgeber exportieren Dateien**
  - **Dienstnehmer montieren sie in ihren Dateibaum**
  - **Inanspruchnahme von Diensten über Fernaufrufe (RPC, XDR)**

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

◆ **Architektur**

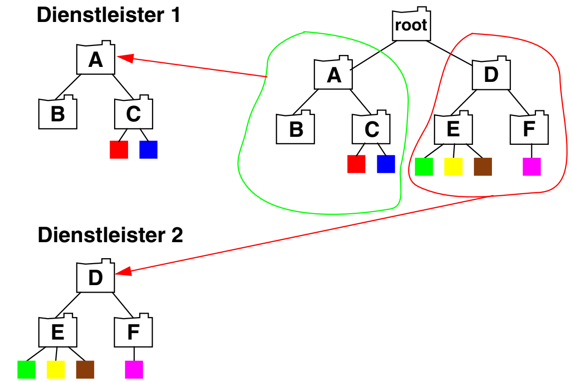

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

◆ **Montageprotokoll**

- **Dienstnehmer sendet an den Dienstgeber den Pfadnamen des Verzeichnisses, das in seinem eigenen Verzeichnis montiert werden soll.**
- **Wenn der Pfadname gültig ist und das Verzeichnis exportierbar ist, gibt der Dienstleister ein *file handle* zurück.**

file handle = (file system type, disk, directory's i-node number,
security information)

- **Automounting (durch den Dienstnehmer): Wenn eine Datei geöffnet wird, werden alle in einer besonderen Tabelle verzeichneten Dienstleister kontaktiert. Montiert wird das erste angebotene Dateisubsystem.**

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

◆ **Zugriffsprotokoll**

- **NFS ist zustandslos** ⇨ **keine Zustandsinformation über geöffnete Dateien**
  ⇨ **es gibt in NFS keinen *open*-Aufruf**
  ⇨ **es gibt keine Koordinierungsunterstützung**
- **Es gibt eine *lookup*-Operation:**

  Vor der Bearbeitung einer Datei führt der Dienstnehmer einen Aufruf von *lookup* mit dem Pfadnamen aus. Der Dienstleister gibt ein *file handle* zurück, das bei künftigen Aufrufen benutzt wird.
- **Lese- und Schreibaufrufe müssen neben dem *file handle* auch die Angabe enthalten, ab welcher Stelle wieviele Byte gelesen/geschrieben werden sollen.**
- **Lese- und Schreibaufrufe an NFS wirken atomar.**

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

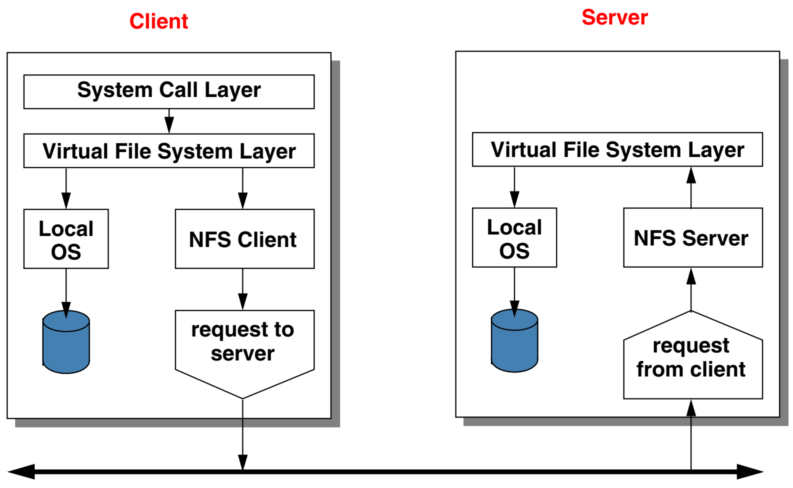

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

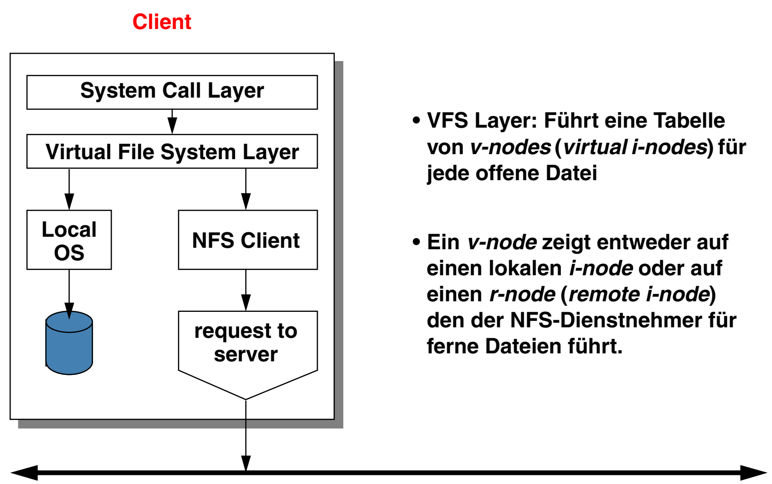

- VFS Layer: Führt eine Tabelle von *v-nodes* (*virtual i-nodes*) für jede offene Datei
- Ein *v-node* zeigt entweder auf einen lokalen *i-node* oder auf einen *r-node* (*remote i-node*) den der NFS-Dienstnehmer für ferne Dateien führt.

BP 2 Software-gestützte Pufferung: Verteilte Dateisysteme

◆ Implementierung von Sun

- Dienstnehmer puffern *i-nodes* und Dateidaten.
- Gepufferte Datenblöcke werden alle 3 Sekunden freigegeben, gepufferte Verzeichniseinträge alle 30 Sekunden.
- Wenn eine gepufferte Datei geöffnet wird, wird der Zeitpunkt ihrer letzten Modifikation überprüft. Gegebenenfalls werden neue Kopien beschafft.
- Alle 30 Sekunden werden alle im Puffer modifizierten Blöcke zurückgeschrieben.
- Der Dienstleister benutzt eigene Pufferungsmechanismen zur Reduktion des Verkehrs mit seinen Plattenspeichern.
- Übertragen werden jeweils 8 KB.
- Wenn die VFS Ebene 8 KB empfängt, fordert sie sofort die nächsten 8 KB an.
- Beim Schließen einer Datei erfolgt ein *write back*.