

Vorlesung

Programmierung Paralleler Systeme

Wintersemester 1998/99

(10317)

I Inhaltsverzeichnis

A Organisatorisches	1
A.1 Inhalt	2
A.2 Vorlesung, Übung, Schein, Folien, URL	3
B Einführung	1
B.1 Programmierung paralleler Systeme, warum?	1
B.2 Ebenen der Parallelität	2
1 Prozessorebene	3
2 Speicherebene	10
3 Systemebene	13
4 Netzwerkebene	28
B.3 Klassifikation	29
B.4 Programmiermodelle	31
B.5 Lokaler vs. Globaler Adreßraum	38
B.6 Leistungsausbeute	41
1 Grundlagen für Prozessoreffizienz	42
2 Leistungsausbeute durch Parallelisierung	45

I Inhaltsverzeichnis

C Optimierung des Speicherzugriffs	49
C.1 Virtuelle Adressierung	49
1 Grundlagen	49
2 Translation Look-Aside Buffer TLB	55
C.2 Caches	58
1 Grundlagen	58
2 Zugriffskonflikte	65
C.3 Ein/Ausgabe	69
1 "Klassisches" Lesen/Schreiben in Dateien	69
2 Speicherabgebildete Dateien	70
D SUN Enterprise X000	76
D.1 Systemarchitektur	77
1 Gigaplane Bus	78
2 CPU/Memory Modul	79
3 I/O Board	81

I Inhaltsverzeichnis

E Pthreads	83
E.1 Grundlagen	83
1 Prozeßmodell	84
2 Threadmodell	88
E.2 Basic Pthread Management	94
1 Erzeugung	94
2 Thread-Attribute	95
3 Terminierung	96
4 Rückgabewerte	97
5 Beispiel zur Thread-Erzeugung	98
6 Identifikation	101
7 Initialisierungen	102
8 Threadlokale globale Variablen	104
E.3 Synchronisation	106
1 Mechanismen zur Thread-Koordination	108
2 Mutex	109
3 Condition-Variablen	113

I Inhaltsverzeichnis

E.4 Parallelisierungsmodelle	121
1 Master-Slave Modell	121
2 Pipeline Modell	122
3 Boss-Worker Modell	123
E.5 Attribute	124
E.6 Thread Scheduling	126
1 Festlegung des Thread-Modells (1 x 1, M x 1, M x N).....	126
2 Scheduling Strategie.....	129
3 Threadpriorität.....	130
4 Scheduling Parameter.....	131
5 Vererbung von Scheduling Parametern.....	132
6 Priority Inversion.....	133
7 Entkopplung von Threads (detached threads)	137
E.7 UNIX Interaktion	139
1 Bibliotheksaufrufe	140
2 Signale	143
3 Abbruch eines Threads	149
4 Der Cleanup Stack.....	154
5 Fork/Exec/Exit	160
6 Interprozeß-Synchronisation	166

I Inhaltsverzeichnis

E.8 Zusammenfassung	167
F Übung 1 _____	168

A Organisatorisches

■ Dozenten

- ◆ Dr. F. Bellosa, IMMD IV, Frank.Bellosa@informatik.uni-erlangen.de
- ◆ Dr. G. Wellein, RRZE, Gerhard.Wellein@rrze.uni-erlangen.de

■ Vorlesung und Übungen

- ◆ für Studierende der Fachrichtung Informatik im Hauptstudium,
für Studierende der Ingenieur- und Naturwissenschaften im Hauptstudium
- ◆ 4 anrechenbare Semesterwochenstunden
2 SWS Vorlesung, 2 SWS Übungen

A.1 Inhalt

- Vorlesung
 - ◆ Architekturprinzipien und Programmiermodelle von Parallelrechnern
 - ◆ Effiziente Nutzung von Monoprozessoren (Cache, Speicher, E/A)
 - ◆ Threads und Koordinierung in Multiprozessoren mit gemeinsamem Speicher
 - ◆ Architektur und Programmierung von Rechnern mit verteiltem Speicher
 - ◆ Architektur und Programmierung von Vektorrechnern

- Übungen
 - ◆ Einsatz von Cache-, TLB- und Speicher-angepassten Datenstrukturen
 - ◆ Speicherabgebildete Dateien
 - ◆ Posix Threads (Pthreads)
 - ◆ **Message Passing Interface(MPI)**
 - ◆ Unterstützung der Vektorisierung durch Programmgestaltung und Direktiven

A.2 Vorlesung, Übung, Schein, Folien, URL

- Vorlesung: 15.3. - 19.3. und 22.3. - 26.3. von 9:00 bis 12:15 im 0.031
- Übungen: 15.3. - 19.3. und 22.3. - 25.3. von 13:00 bis 16:00 im 01.153
- Schein: nach einer mündliche Prüfung am 26.3.
- Folien: werden im WWW zur Verfügung gestellt.
- URL zur Vorlesung:
 - ◆ http://www4.informatik.uni-erlangen.de/Lehre/WS98/V_PPS/
 - ◆ hier findet man Folien zum Ausdrucken und Zusatzinformationen

B Einführung

B.1 Programmierung paralleler Systeme, warum?

- Nutzung von *mehr* Hardware zur Lösung eines Problems
 - ◆ Nutzung brachliegender Ressourcen
 - ◆ Anschaffung von spezieller Hardware für das parallele Rechnen
- Potentielle Erweiterbarkeit der Hardware bei wachsender Problemgröße
- Abbildung der nebenläufigen Problemstellung auf eine parallele Lösung (z.B. verteilte Anlagensteuerung, Telefonnetz)
- Verknüpfen bestehender sequentieller Komponenten zu einem parallelen System
- Zuverlässigkeit durch Replikation

B.2 Ebenen der Parallelität

- Prozessorebene
- Speicherebene
- Systemebene, Verbindungsnetz
- Netzwerkebene
- E/A-Ebene (nicht Teil dieser Vorlesung)

1 Prozessorebene

■ Parallelisierung des Befehlsstroms

◆ Sequentiell:

Die einzelnen Phasen einer Befehlsausführung werden sequentiell abgearbeitet. Ein Instruktionsstrom.

◆ Pipelining:

verschiedene Phasen verschiedener Instruktionen werden parallel verarbeitet. Ein Instruktionsstrom.

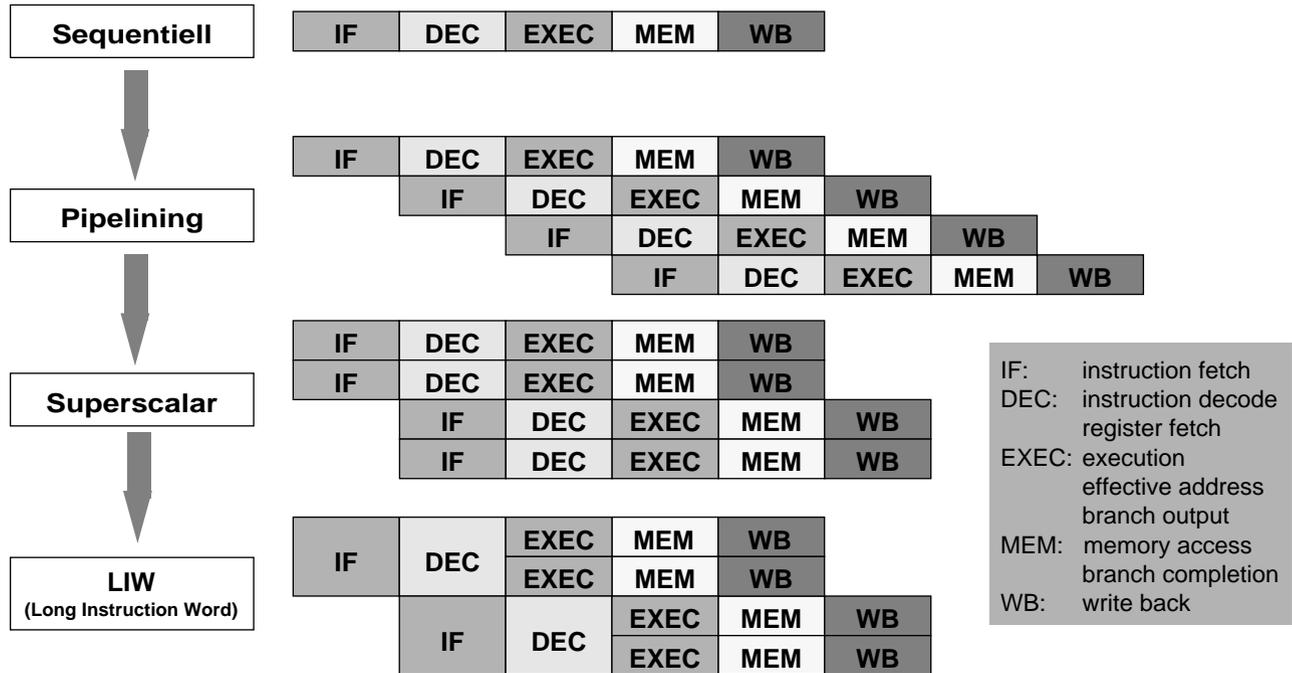
◆ Superscalar:

die Möglichkeit mehrere Funktionen parallel zu verarbeiten
z. B. Load / Store : Add / Multiply : Branch
Paralleler Instruktionsstrom ausgewählter Instruktionstypen.

◆ VLIW (Very Large Instruction Word):

“Breite” Instruktions-Verarbeitung:
Mehrere Befehle eine parallelen Instruktionsstroms werden bearbeitet.

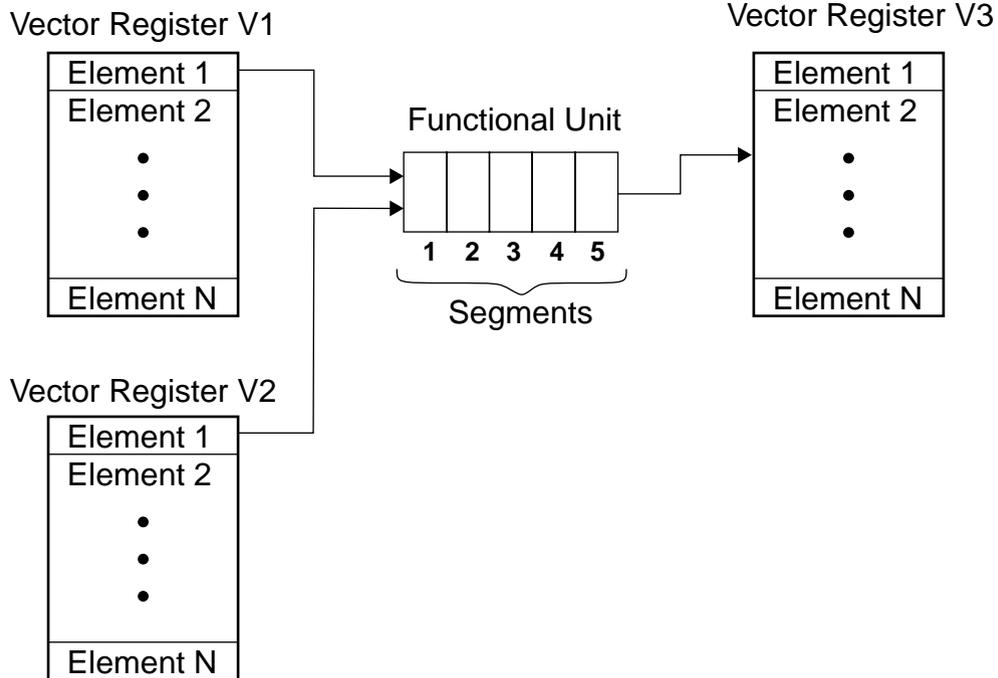
1 Prozessorebene (2)



1 Prozessorebene (3)

■ Parallelisierung des Datenstroms

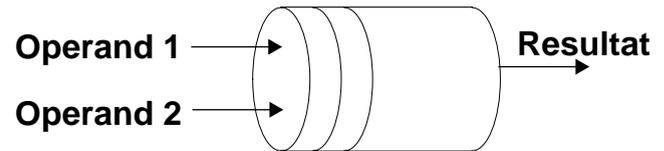
◆ Vektoreinheiten



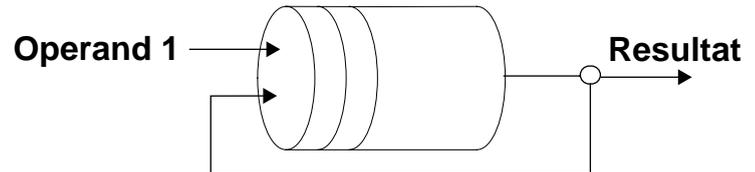
1 Prozessorebene (4)

■ Vektorverarbeitung in Kombination mit "Instruktionsparallelität"

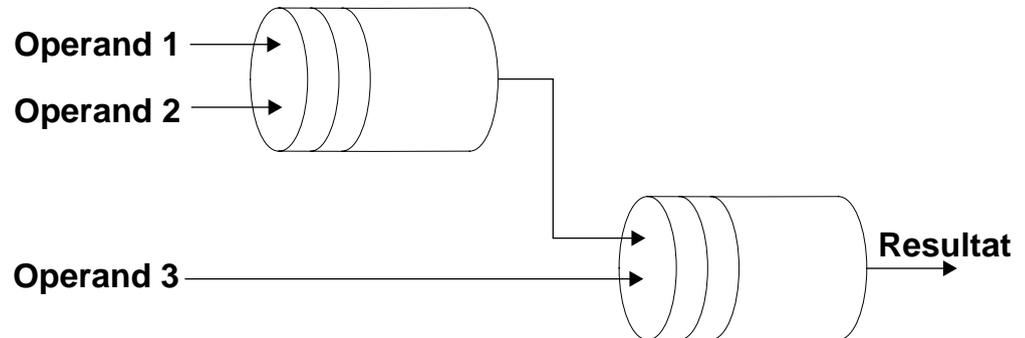
◆ normale Betriebsart



◆ Rückkopplung

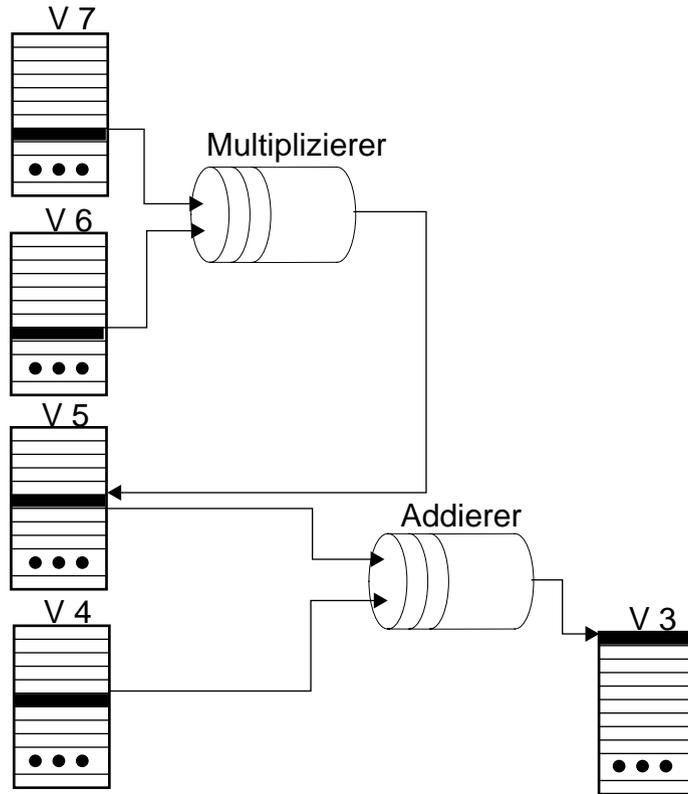


◆ Verkettung (Chaining)



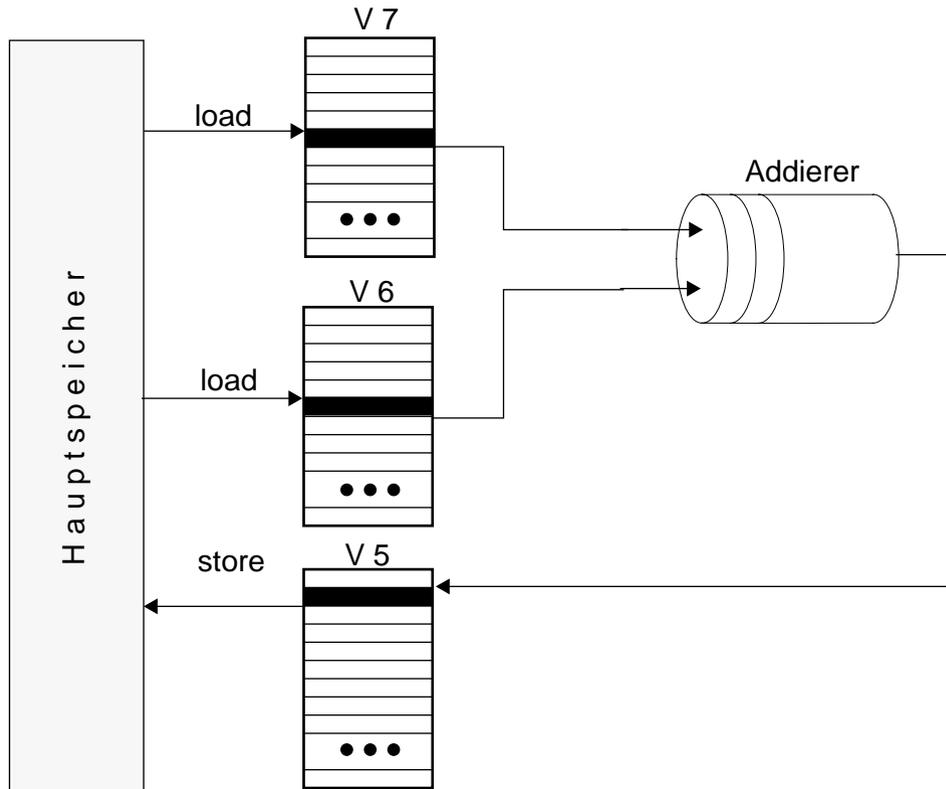
1 Prozessorebene (5)

■ Chaining zwischen Registern



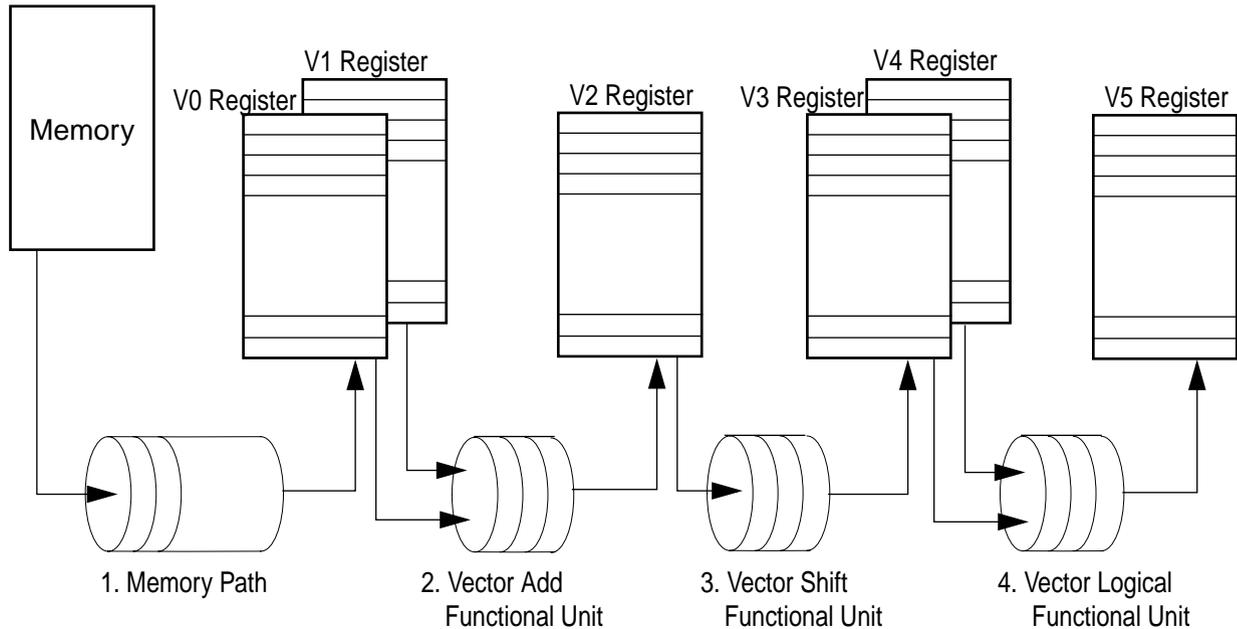
1 Prozessorebene (6)

■ Chaining zum Speicher



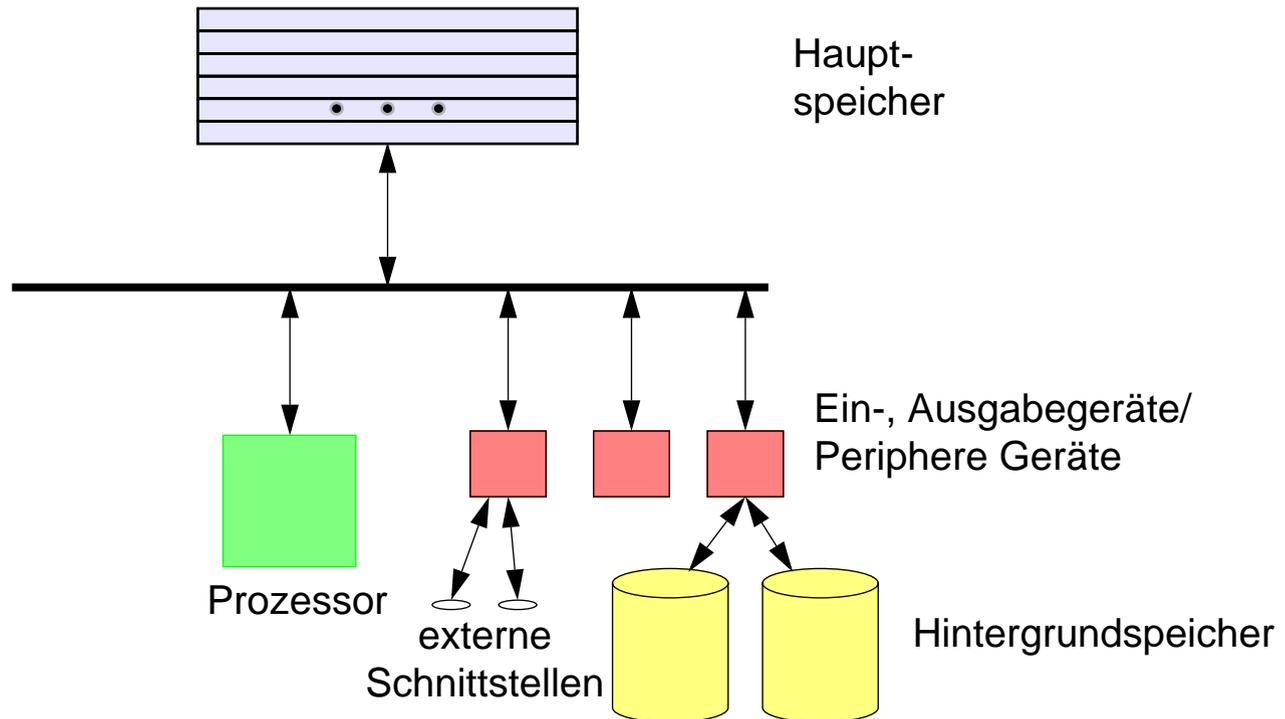
1 Prozessorebene (7)

◆ Beispiel:



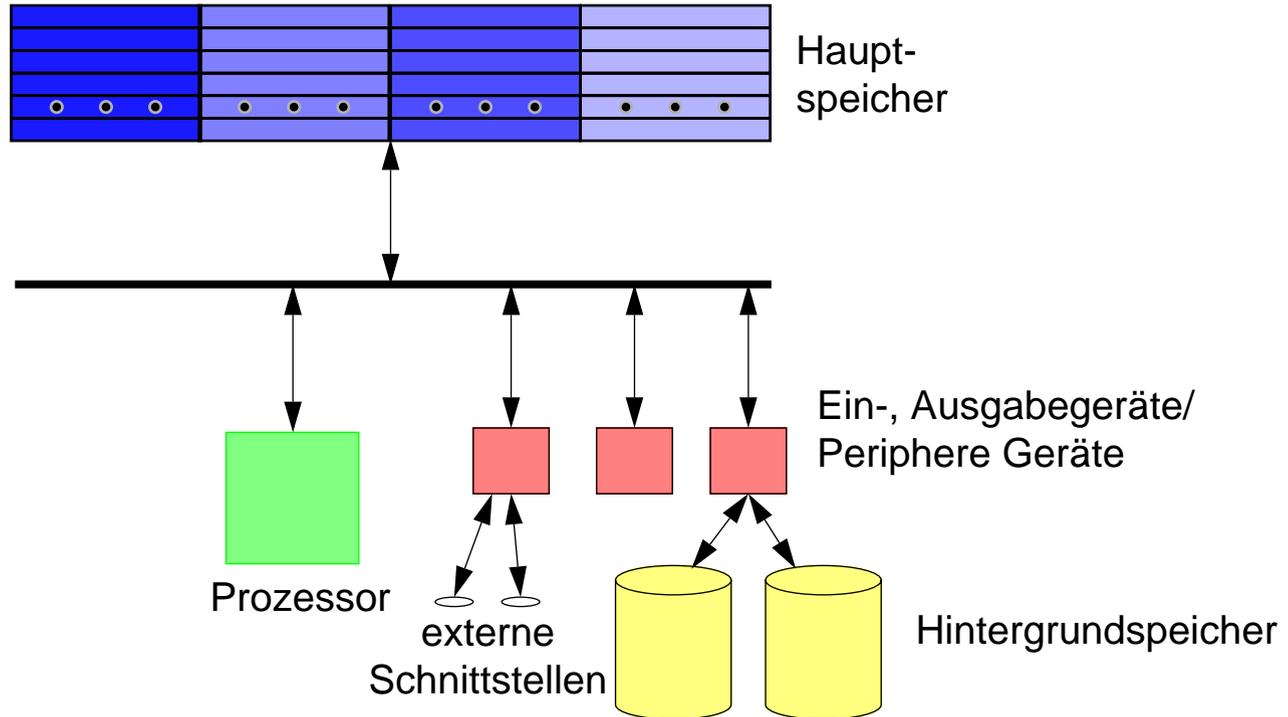
2 Speicherebene

■ Hauptspeicher mit einer Speicherbank



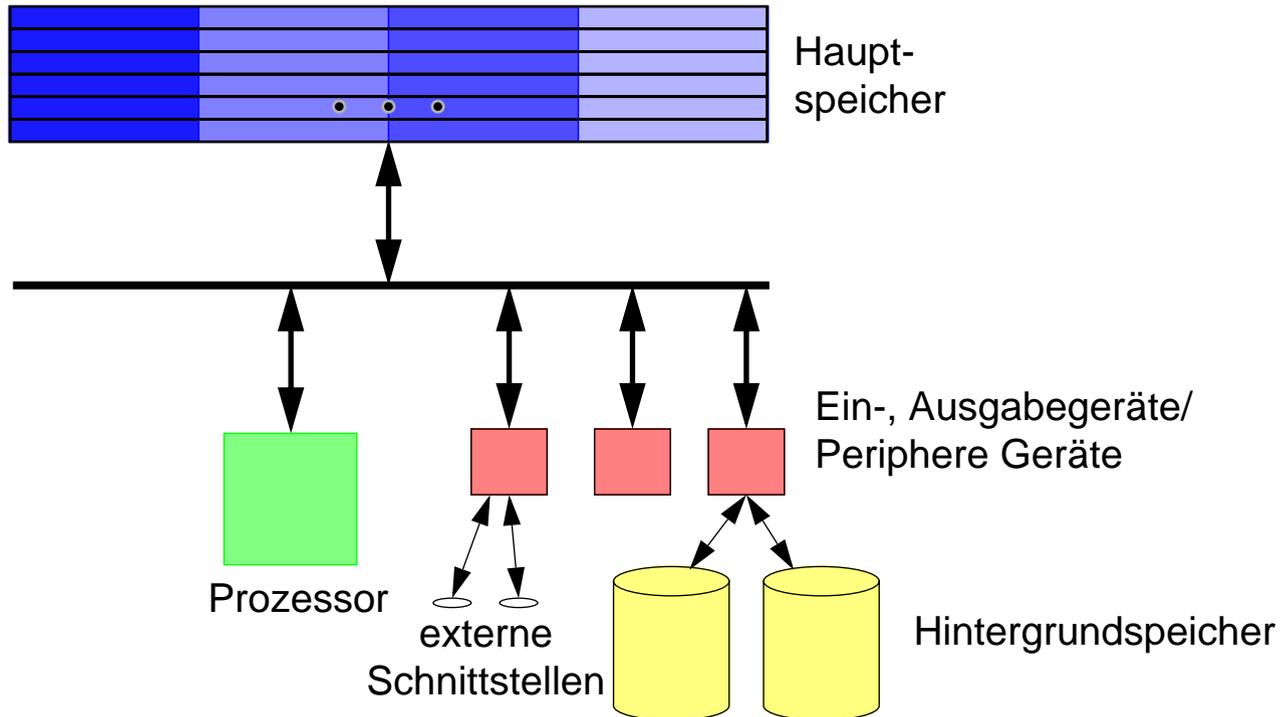
2 Speicherebene (2)

■ Parallelisierung des Zugriffs durch Speicherbänke



2 Speicherebene (3)

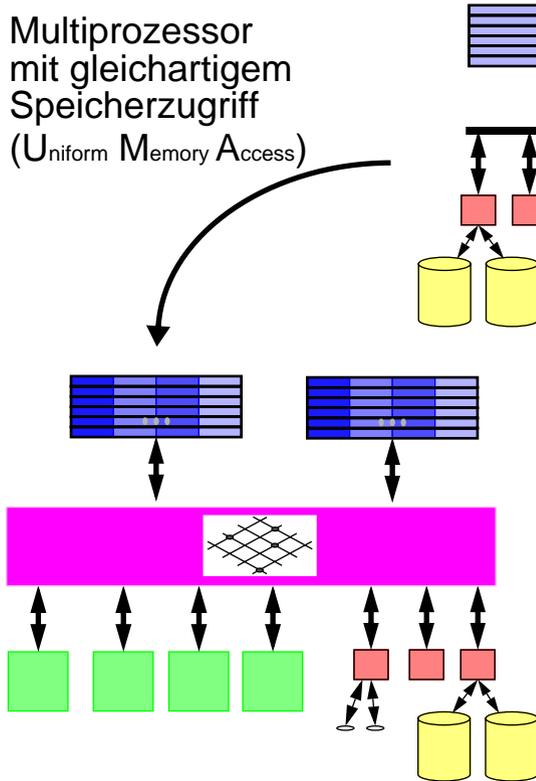
- Parallelisierung des sequentiellen Zugriffs durch Interleaving



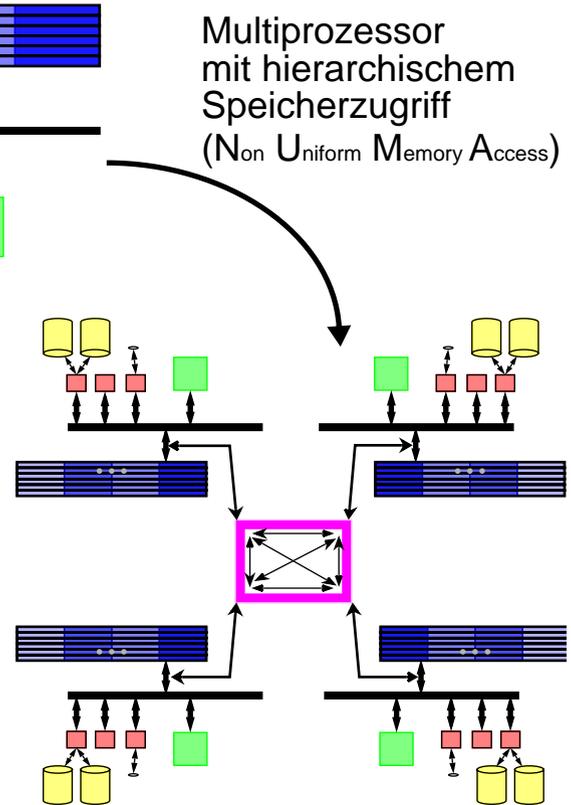
3 Systemebene

■ Multiprozessoren mit globalem Adreßraum

Multiprozessor
mit gleichartigem
Speicherzugriff
(Uniform Memory Access)

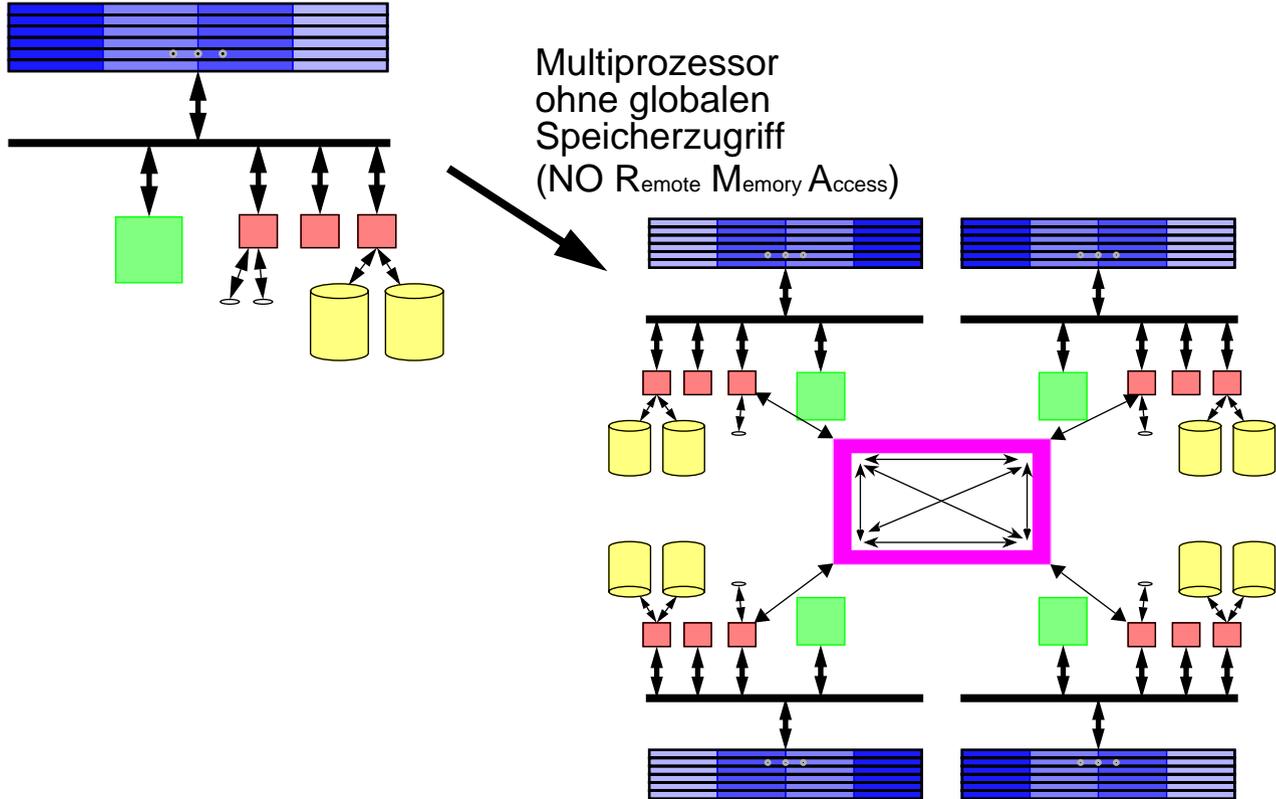


Multiprozessor
mit hierarchischem
Speicherzugriff
(Non Uniform Memory Access)



3 Systemebene (2)

■ Multiprozessor mit lokalem Adreßraum



3 Systemebene (3)

■ Verbindungsnetzwerke für Multiprozessoren

◆ Wunsch: Vollständiges Verbindungsnetzwerk; Komplexität steigt mit $K!$

◆ Abhilfe:

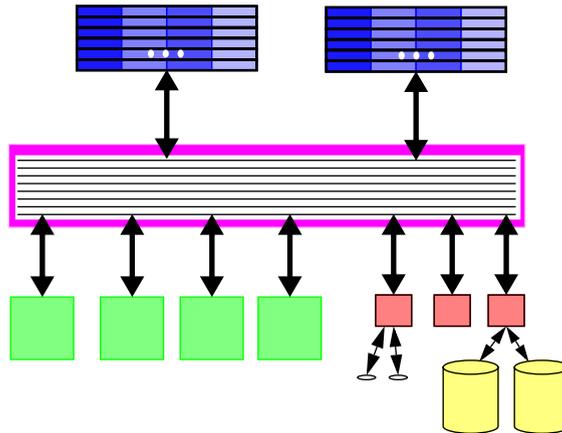
- Einschränkung der Nachbarschaftsbeziehung
- globale Kommunikation wird mehrstufig mit - möglichst autarken, nicht die Rechenleistung einzelner Knoten belastenden - Routern realisiert.

◆ Kriterien der Bewertung von statischen Verbindungsnetzwerken

- Anzahl der direkt erreichbaren Nachbarknoten (Links)
- Anzahl der Zwischenstufen die erforderlich sind um den am weitesten entfernten Knoten zu erreichen (Durchmesser).
- Anzahl der Knoten in der nächsten Ausbaustufe (Ausbauinkrement)
- Anzahl der Verbindungssegmente (Komplexität)

3 Systemebene (4)

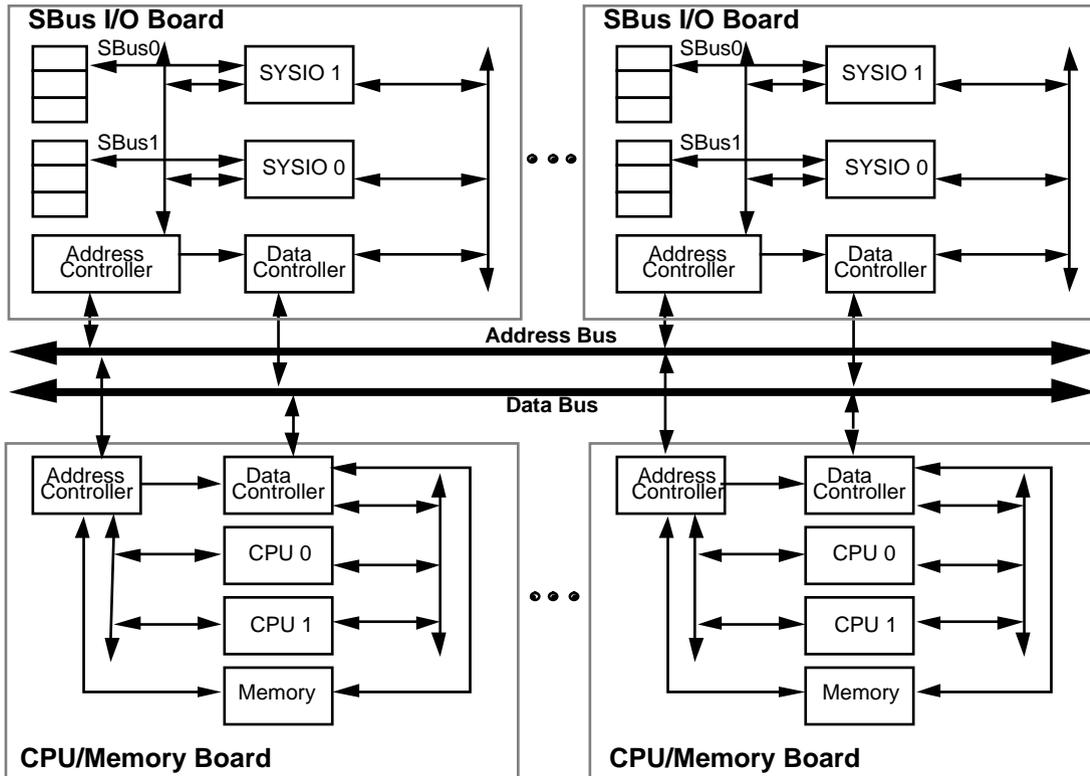
- Bussysteme (meist in UMA Multiprozessoren).



- Maximal erreichbare Prozessorzahl liegt heute bei 24 Prozessoren.
- Parallelisierung durch Aufspaltung in Address- und Datenbus
- Latenzverbergung durch Transaktionskonzept
- Bustakt kann nur durch Verkürzung des Busses gesteigert werden (-> Centerplane Ansatz, maximaler Bustakt derzeit bei ca. 100 Mhz).
- Beispiel: SUN Enterprise 3000/4000/6000 Server

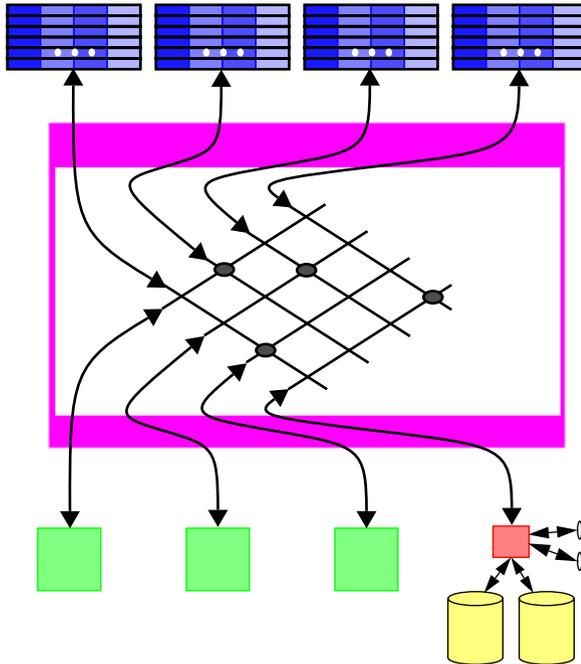
3 Systemebene (5)

Architektur SUN Enterprise X000



3 Systemebene (6)

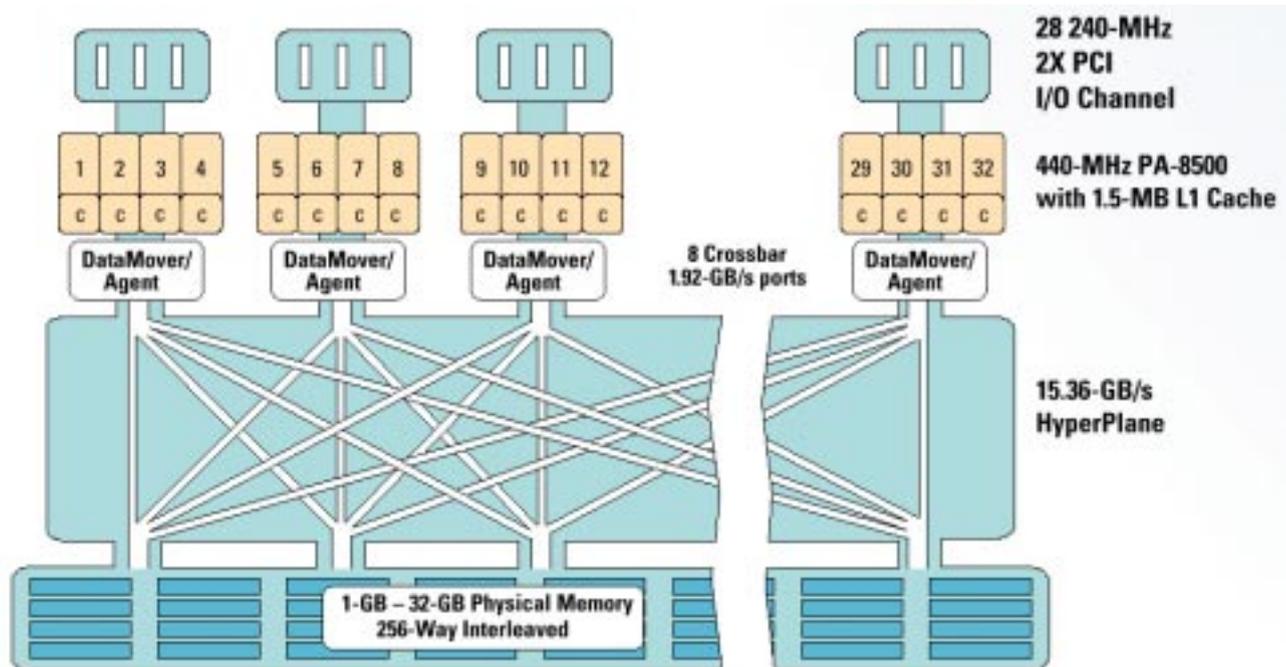
■ Kreuzschiene=Crossbar in UMA Multiprozessoren



- Nichtblockierende Verbindung zum Hauptspeicher
- Hohe Bandbreite
- Hardware-Komplexität steigt quadratisch
- Maximal erreichbare Prozessorzahl liegt heute bei 32 Prozessoren
- Beispiel: HP V2500 Klasse

3 Systemebene (7)

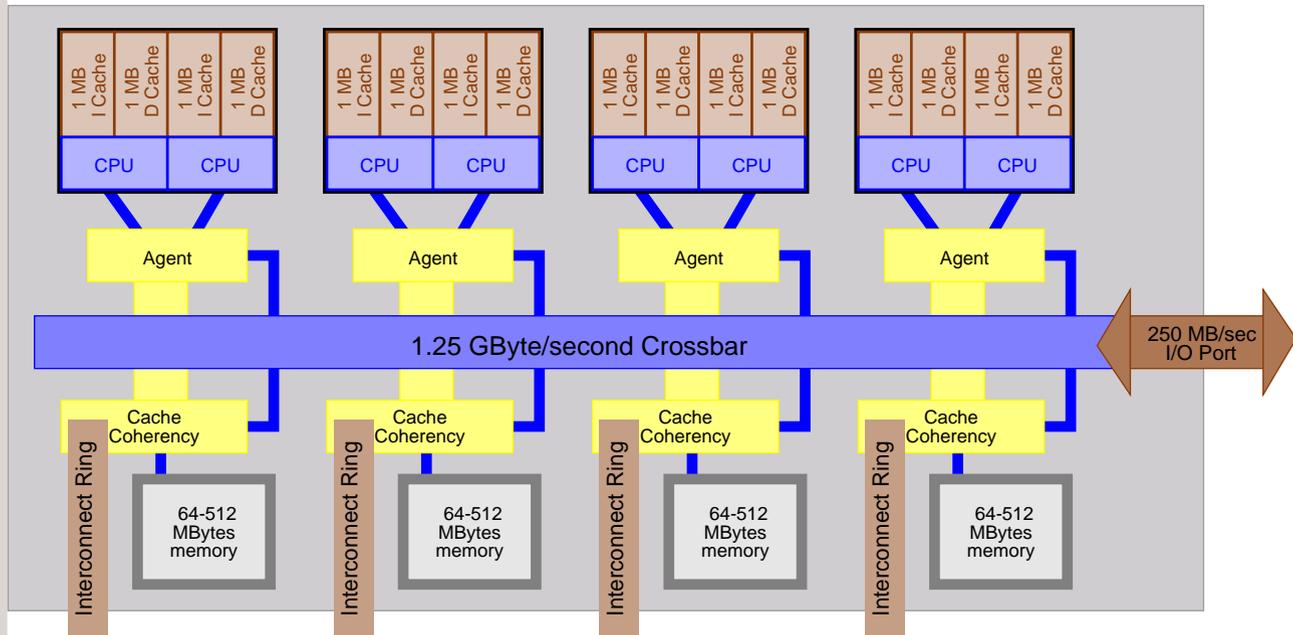
■ Architektur HP V2500 Class



3 Systemebene (8)

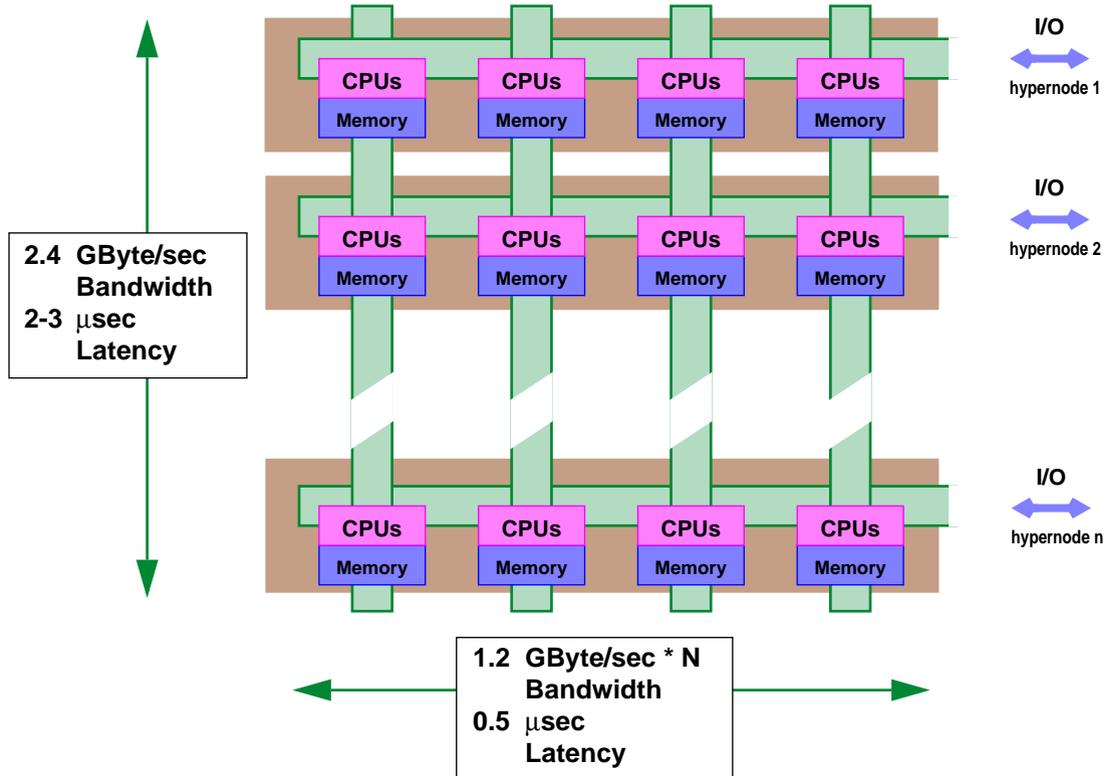
■ Multiprozessoren mit hierarchischem Speicherzugriff (NUMA)

Convex SPP1600 - Hypernode Architektur (RRZE)



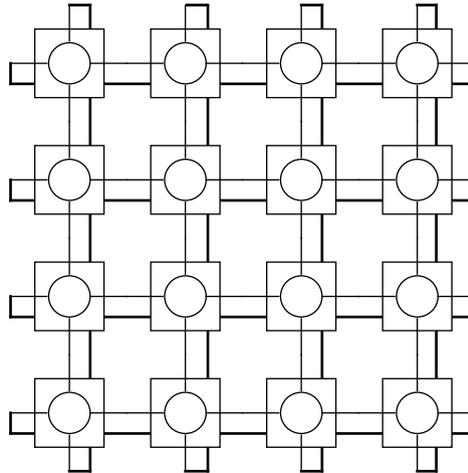
3 Systemebene (9)

■ Convex SPP1 - Speicherhierarchie



3 Systemebene (10)

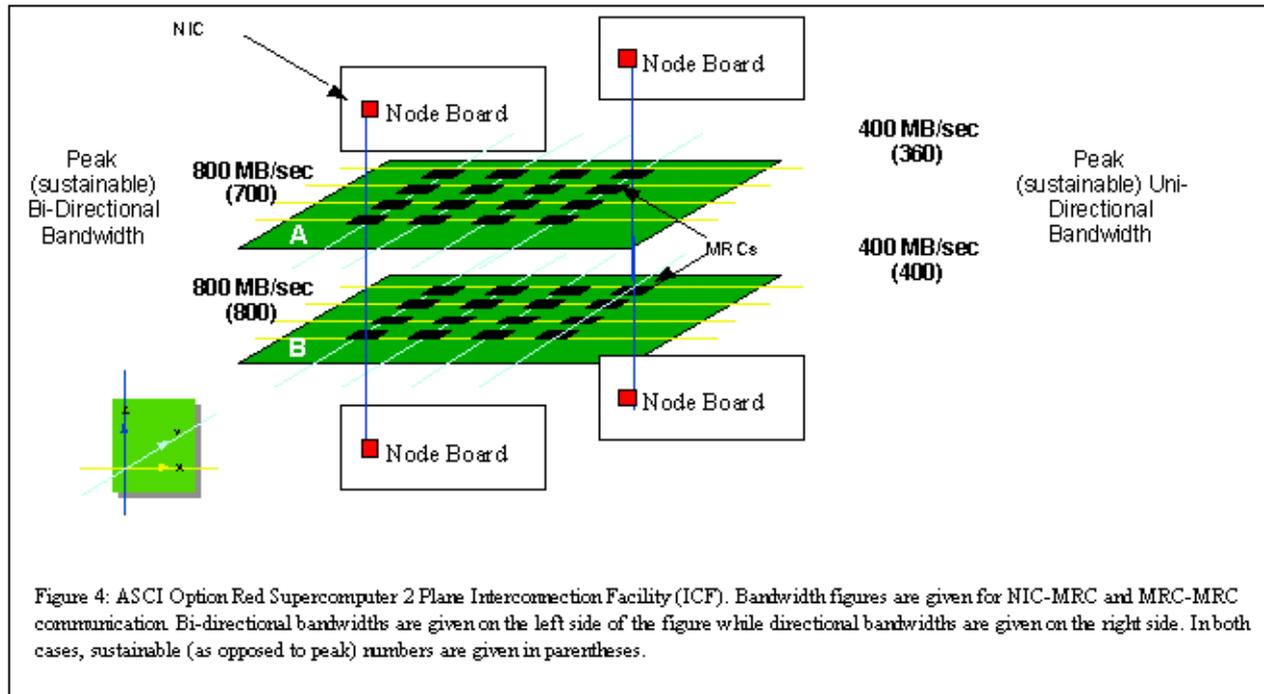
■ 2D (3D) Torus



- ◆ Links pro Knoten: 4 (6)
- ◆ Anzahl der Knoten: $K = q^{2(3)}$; $q = \text{Kantenlänge}$; Komplexität: $A = 2 \cdot q^2$ ($3 \cdot q^3$)
- ◆ Ausbauinkrement: $I = 2(q + 1) - 1$ ($3q^2 + 3q + 1$)
- ◆ Max. Routingstufen: $D = 2 \cdot \lfloor q/2 \rfloor$; ($3 \cdot \lfloor q/2 \rfloor$)
- ◆ Typische Vertreter: Intel ASCI Red (9152 PPro), *Cray T3E (2048 Alpha)*

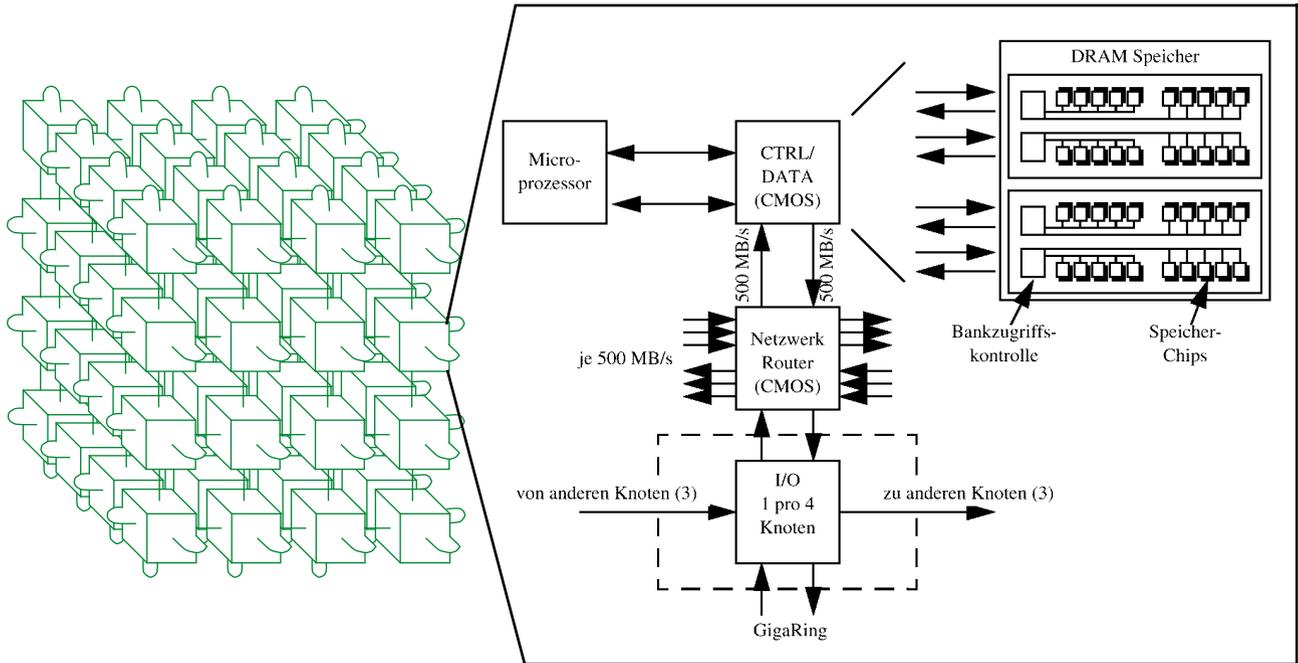
3 Systemebene (11)

■ Beispiel NORMA MP: Intel ASCI (Accelerated Strategic Computing Initiative) Red



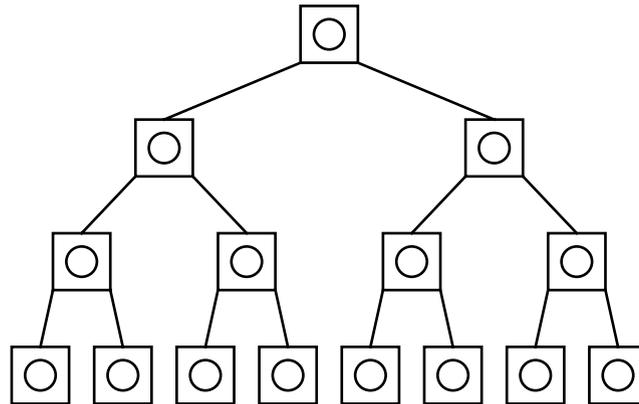
3 Systemebene (12)

- Beispiel NUMA MP: Cray T3E mit DEC Alpha 21164 CPU (600 MHz)



3 Systemebene (13)

■ Binärbaum

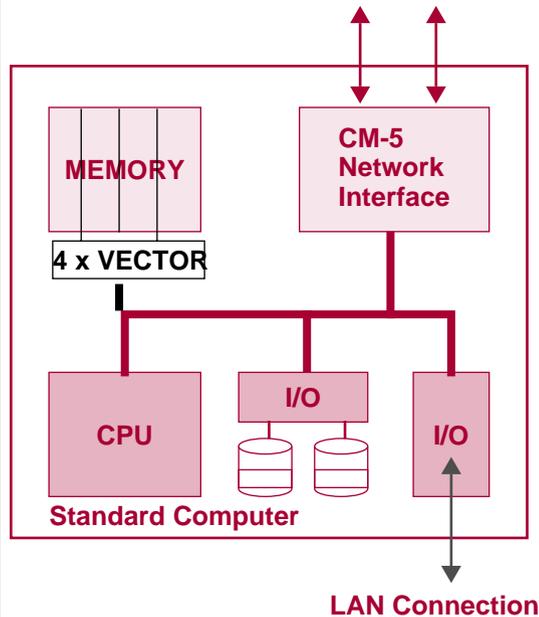


- ◆ Links pro Knoten: 3;
- ◆ Anzahl der Knoten: $K = 2^d - 1$; $d = \text{Ebenezahl}$
- ◆ Ausbauinkrement: $I = K + 1$;
- ◆ Max. Routingstufen: $D = 2(\text{ld}(K+1)-1) = 2(d - 1)$
- ◆ Vermeidung des Kommunikationsengpasses zur Wurzel hin: Fat-Tree
- ◆ Typischer Vertreter: Thinking Machines CM5

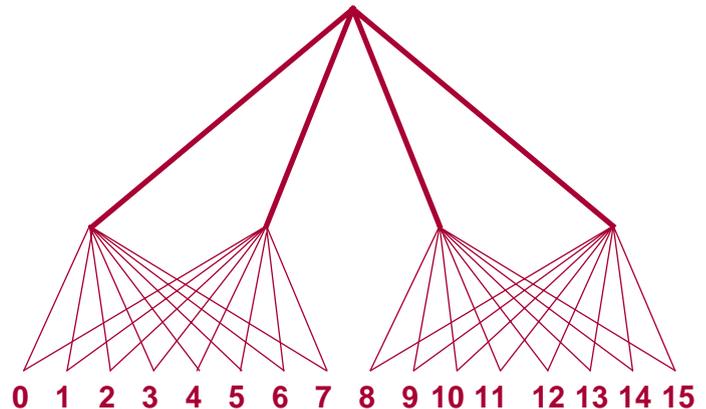
3 Systemebene (14)

■ Beispiel NORMA MP: Thinking Machines CM-5 am IMMD

to CM-5 internal communications networks



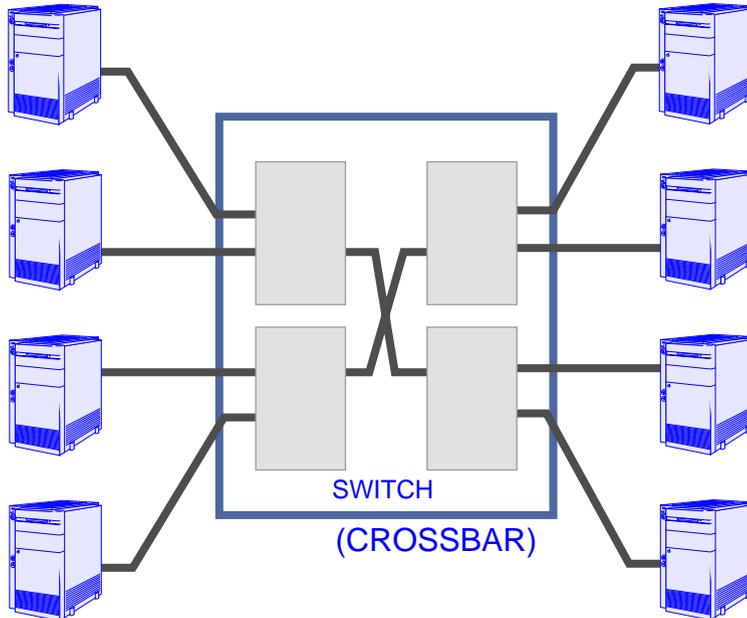
Data Net Implementation: 16 Leaves



3 Systemebene (15)

■ Verbindungnetz mit zentraler Paketvermittlung

◆ Beispiel NORMA MP: IBM SP-2 (max. 128 Prozessoren) am LRZ München



- 70 Knoten IBM 9000/590 (66.7 MHz, 267 MFlop/s)
- 4 dicke, 256MByte
- 56 dünne, 128MB, geringere Speicherbandbreite, kleinerer E/A-Ausbau, gleiche Peak-Leistung
- 300 μ sec Latenz (IP)
- 40 μ sec Latenz(IBM Prot.)
- 12 MB/s Pt. - Pt. Bandbr. (IP)
- 35 MB/s Pt. - Pt. Bandbr.

4 Netzwerkebene

- Verbindung von mehreren Rechnern mit IP-Technologie zu einem Cluster
- Keine Spezialhardware erforderlich
- Die LAN-Technologie nähert sich immer mehr dem Spezialnetzwerk an
 - ◆ Myri-Net ca. 300 MBit/s
 - ◆ ATM 622 MBit/s
 - ◆ Ethernet 1 Gbit/s

B.3 Klassifikation

■ nach Flynn

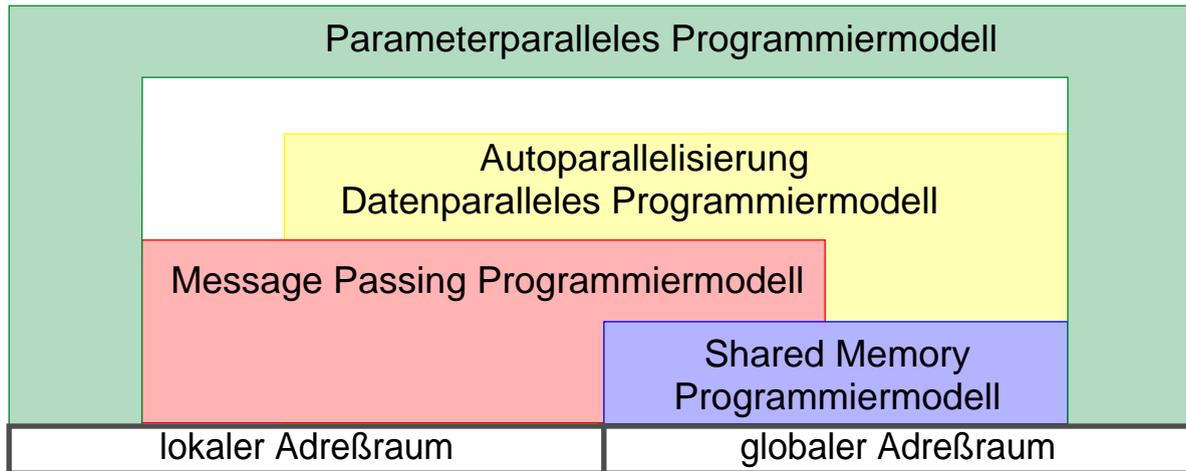
Data - Stream Instruction Stream	SINGLE	MULTIPLE
SINGLE	SISD Klass. von Neumann- Architektur (Monoprozessor)	SIMD Vektor - Array - Prozessoren
MULTIPLE	MISD nicht sinnvoll	MIMD Parallelrechner - aus SISD - Prozessoren - aus SIMD - Prozessoren

B.3 Klassifikation (2)

■ Typische MIMD Vertreter

verteilte Speicherorganisation	<p>NORMA:</p> <ul style="list-style-type: none"> • Workstation-/Server-Cluster • IBM SP2 • Intel ASCI Red • Fujitsu VPP (?) 	<p>ccNUMA:</p> <ul style="list-style-type: none"> • Convex SPP • SGI Origin • Sequent NumaQ <p>NUMA:</p> <ul style="list-style-type: none"> • CRAY T3E
zentrale Speicherorganisation		<p>UMA:</p> <ul style="list-style-type: none"> • SUN Enterprise X000 • HP V-Class • DEC AlphaServer • IBM RS/6000 S70 • NEC SX/4 / CRAY T90
	lokaler Adreßraum	globaler Adreßraum

B.4 Programmiermodelle

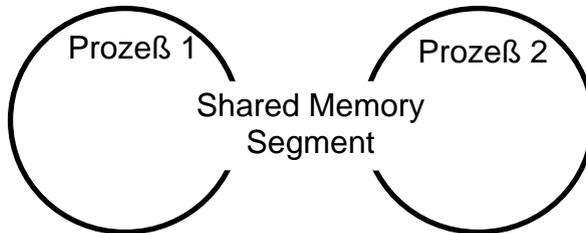


- Unabhängig vom Programmiermodell muß man beim Programmieren paralleler Systeme ein Optimum folgender Eigenschaften erreichen:
 - ◆ Minimierungen der Kommunikation
 - ◆ Maximierung des "lokalen" Verhaltens
 - ◆ Verteilung der Rechenlast auf alle Prozessoren (loadbalancing)

B.4 Programmiermodelle

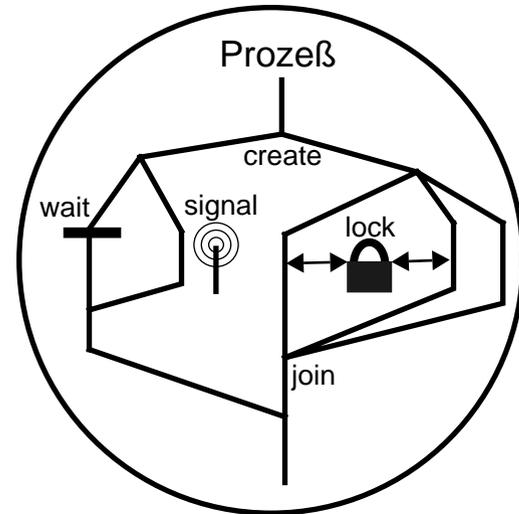
- Shared Memory Programmiermodell
 - ◆ Geeignet für UMA- und NUMA-Architekturen
 - ◆ Kommunikation über gemeinsame Speicherbereiche
 - ◆ Explizite Koordinierung
 - ◆ Aktivitätsträger sind Prozesse und/oder Threads

Parallele Prozesse



<code>shm_id = shm_get(Schlüssel, Größe, Zugriffsrechte)</code>	
<code>ptr = shm_at(shm_id)</code>	<code>shm_dt(ptr)</code>
<code>semaphore = sema_create(Schlüssel, Zugriffsrechte)</code>	
<code>wait(semaphore)</code>	<code>signal(semaphore)</code>

1 Prozeß + Parallele Threads



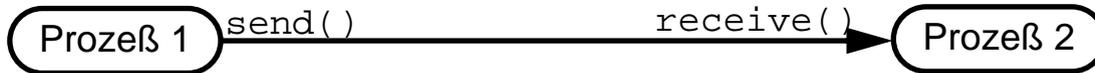
B.4 Programmiermodelle

- Shared Memory Programmiermodell (2)
 - ◆ Keine Unterstützung durch spezielle Sprachkonstrukte
 - ◆ Keine “automatische” Parallelisierung
 - ◆ Unterstützung durch Thread-Libraries (Pthreads-Library)
 - ◆ Prozessorzuordnungen ist meist beeinflussbar
 - ◆ Betriebssystem/Thread-Library sorgt für Lastverteilung
 - ◆ Feingranulare Parallelität möglich
 - ◆ Programmiersprachen: C; C++
 - ◆ Geeignet, hocheffiziente Programme zu schreiben

B.4 Programmiermodelle

■ Message Passing Programmiermodell

- ◆ Geeignet für alle MIMD Architekturen
- ◆ Kommunikation über *send/receive*-Mechanismen



- ◆ Explizite Koordinierung; implizit realisiert über *send/receive*-Mechanismen
- ◆ Aktivitätsträger sind Prozesse (lokal sind Threads möglich)
- ◆ Keine Unterstützung durch spezielle Sprachkonstrukte
- ◆ Keine "automatische" Parallelisierung
- ◆ Unterstützung durch Message Passing-Libraries: (PVM; MPI)
- ◆ NORMA: Feste Zuordnung Prozeß/Prozessor; Prozeßmigration unmöglich
- ◆ Geeignet für grobgranulare Parallelität; Grad ist abhängig von verwendeter Rechnerarchitektur (*Latenz/Bandbreite* des Verbindungsnetzwerks).
- ◆ Programmiersprachen: C; C++; Fortran
- ◆ Geeignet portable Programme für alle denkbaren Architekturen zu schreiben

B.4 Programmiermodelle

- Shared Memory - Autoparallelisierung/Datenparallele Programmierung
 - ◆ Geeignet für alle UMA/NUMA Architekturen
 - ◆ Implizite Kommunikation, realisiert über gemeinsame Speicherbereiche
 - ◆ Implizite Koordinierung
 - ◆ Aktivitätsträger sind Prozesse/Threads mit identischer Kontrollflußstruktur; dynamisch verschiedener Kontrollfluß möglich.
 - ◆ Unterstützung der parallelen Programmierung durch spezielle Sprachkonstrukte; typischer Weise “Feldverarbeitung”
 - ◆ Automatische Parallelisierung potentiell nebenläufiger Programmteile (z.B. Schleifen); Unterstützungsmöglichkeit durch Compilerdirektiven
 - ◆ Feingranulare Parallelität möglich
 - ◆ Nur ein Teil der Nebenläufigkeit des Lösungsverfahrens ist nutzbar.
 - ◆ Programmiersprachen: Fortran90/95, C, C++
 - ◆ Einfachere Fehlersuche, da Koordinierungsfehler nicht möglich sind.

B.4 Programmiermodelle

- Message Passing - Autoparallelisierung/Datenparallele Programmierung
 - ◆ Geeignet für alle MIMD Architekturen
 - ◆ Implizite Kommunikation/Koordination über *sent/receive* Mechanismen
 - ◆ Aktivitätsträger sind Prozesse mit identischer Kontrollflußstruktur; dynamisch verschiedener Kontrollfluß möglich
 - ◆ Unterstützung der parallelen Programmierung durch spezielle Sprachkonstrukte; typischer Weise “Feldverarbeitung”.
 - ◆ Automatische Parallelisierung potentiell nebenläufiger Programmteile (z.B. Schleifen); Unterstützungsmöglichkeit durch Compilerdirektiven
 - ◆ Geeignet für grobgranulare Parallelität; Grad ist abhängig von verwendeter Rechnerarchitektur (*Latenz/Bandbreite* des Verbindungsnetzwerks).
 - ◆ Nur ein Teil der Nebenläufigkeit des Lösungsverfahrens ist nutzbar.
 - ◆ Programmiersprachen: High Performance Fortran - HPF
 - ◆ Einfachere Fehlersuche durch implizite Kommunikation/Koordination, jedoch komplexer Debugger zur Überwachung einer Vielzahl von Rechnern

B.4 Programmiermodelle

- Parameterparalleles Programmiermodell
 - ◆ Keine dynamische Kommunikation zwischen den Komponenten des parallelen Systems
 - ◆ Master/Slave - Konfiguration, wobei der Masterprozeß an die sonst unabhängigen Slaveprozesse Parametersätze verteilt und ggf. die Ergebnisse wieder einsammelt und auswertet.
 - ◆ Im einfachsten Fall ist der Masterprozeß eine Shellprozedur.

B.5 Lokaler vs. Globaler Adreßraum

- NORMA Architekturen
 - ◆ Basis-Programmiermodell ist 'Message Passing'.
 - ◆ Das Verhältnis Befehlsausführungszeit/Latenzzeit zwischen Aktivitätsträgern(Threads, Prozesse) auf verschiedene Prozessoren liegt bestenfalls bei 1 : 10.000 (IBM SP-2);
Hinzu kommt ein erheblicher Protokoll - Overhead
 - ◆ Eine 'shared memory'-Programmiermodell kann als 'shared distributed memory' vom Betriebssystem über die Seitenadressierung simuliert werden, ist aber extrem ineffizient. ('paging' über 'message passing'); Beispiel: Intel Paragon

B.5 Lokaler vs. Globaler Adreßraum

■ UMA/NUMA Architekturen

◆ Basis-Programmiermodell ist 'Shared Memory'.

◆ Das Verhältnis Befehlsausführungszeit/Latenzzeit zwischen Aktivitätsträgern(Threads, Prozesse) auf verschiedene Prozessoren reduziert sich auf Speicherzugriffe.

Bei NUMA-Architekturen hängt die Zeit von der "Entfernung" ab.

Beispiel Convex SPP1600:	1 : 1	Register/Cache
	1 : 40	Nodespeicher (UMA)
	1 : 200	Internodespeicher (NUMA)

◆ Ein 'message passing'-Programmiermodell läßt sich effizient auf einem 'shared memory'-System simulieren.
('message passing' über 'shared data'-Segmente)

■ Schlußfolgerung:

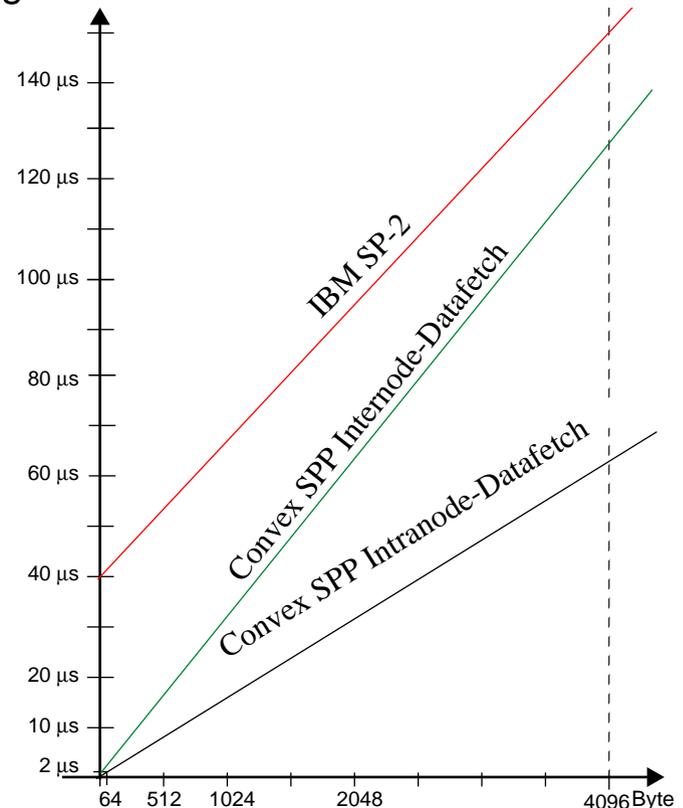
◆ Grobgranulare Parallelität ist geeignet für beide Architekturklassen

◆ Feingranulare Parallelität ist nur geeignet für 'shared memory'-Systeme

B.5 Lokaler vs. Globaler Adreßraum

■ Wann ist ein Programm grob-/feingranular?

- IBM SP-2
 - ◆ 40 μ s Latenz
 - ◆ 35MB/s
 - ◆ Transfereinheit "beliebig"
- Convex SPP1600
 - ◆ 0.5 μ s Latenz (Intranode)
1.2 GB/s Bandbreite
Transferblock 32 Byte
 - ◆ 2 μ s Latenz (Internode)
2.4 GB/s Bandbreite
Transferblock 64 Byte

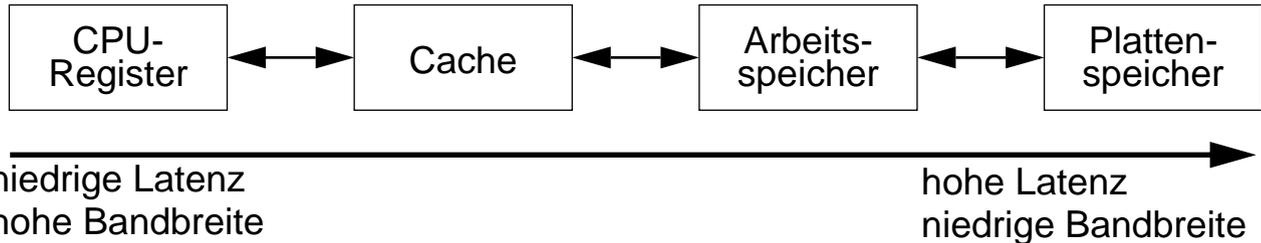


B.6 Leistungsausbeute

- Peak-Leistung ist die theoretisch obere Schranke
- Viele Leistungsmaße geben jedoch immer nur spezifische Teilaspekte wieder. Beispiele:
 - ◆ SPECmarks
 - ◆ LINPACK
 - ◆ LAPACK
 - ◆ TPC
 - ◆ Beliebt sind 'rankinglists' (TOP 500) egal welchen Aussagewert sie haben.
- Sequentielle Leistung:
 - ◆ Wie gut wird die Leistung des Prozessors im sequentiellen Fall ausgenutzt?
- Parallele Leistung
 - ◆ Welche Leistung erhält man durch die Parallelisierung?

1 Grundlagen für Prozessoreffizienz

- Schneller Speicherzugriff durch Ausnutzung der Speicherhierarchie



- ◆ Zeitliche Lokalität:

Wenn ein Speicherort angesprochen wird, dann wird er innerhalb eines kleinen Zeitintervalls mehrfach angesprochen

- ◆ Örtliche Lokalität:

Wenn ein Speicherort angesprochen wird, dann werden innerhalb eines kleinen Zeitintervalls überwiegend Speicherorte mit geringem Adreßabstand angesprochen

1 Grundlagen für Prozessoreffizienz (2)

■ Beispiel

```
int M = 10000;
int main()
{
    int i, j, k;
    int a[M][M], b[M][M], c[M][M];
    for (i = 0; i < M; i++)
        for (j = 0; j < M; j++) {
            a[i][j] = i; b[i][j] = j; c[i][j] = 0;
        }
    for (i = 0; i < M; i++)
        for (j = 0; j < M; j++)
            for (k = 0; k < M; k++)
                c[i][j] = c[i][j] + a[i][k] * b[k][j];
}
```

- ◆ `c[i][j]` weist zeitliche Lokalität auf
- ◆ `a[i][k]` weist örtliche Lokalität auf
- ◆ `b[k][j]` weist keines von beidem auf

1 Grundlagen für Prozessoreffizienz (3)

- Ausnutzung der Prozessorparallelität
 - ◆ architekturspezifische Codegenerierung (Prozessortyp, Cachegröße)
 - ◆ geringe Datenabhängigkeit im Code
 - (→instruction reordering, →outstanding loads, →instruction scheduling)
 - ◆ vorhersagbare Sprünge (→branch prediction, →loop unrolling)
 - ◆ vorhersagbare Speicherzugriffe (→prefetch operations)

- Ausnutzung optimierter Bibliotheken und Algorithmen
 - ◆ libc (allgemeine Bibliotheken z.B. `memcpy()`, `bsort()`)
 - ◆ NAG, BLAS, LAPACK (numerische Bibliotheken)
 - ◆ *Numerical Recipes*
 - ◆ ...

2 Leistungsausbeute durch Parallelisierung

- *Speedup* (im Vergleich zum Ablauf des gleichen Programms auf einem Prozessor)

$$s(p) = \frac{t(1)}{t(p)}$$

- Effizienz (im Vergleich zum Ablauf des gleichen Programms auf einem Prozessor)

$$e(p) = \frac{t(1) \cdot 100}{t(p) \cdot p} \%$$

- Eine andere Variante der Betrachtung wäre den *Speedup* bzw. die *Effizienz* durch “Vergrößerung” des Problems zu bestimmen.

2 Leistungsausbeute durch Parallelisierung (2)

■ Amdahls Gesetz

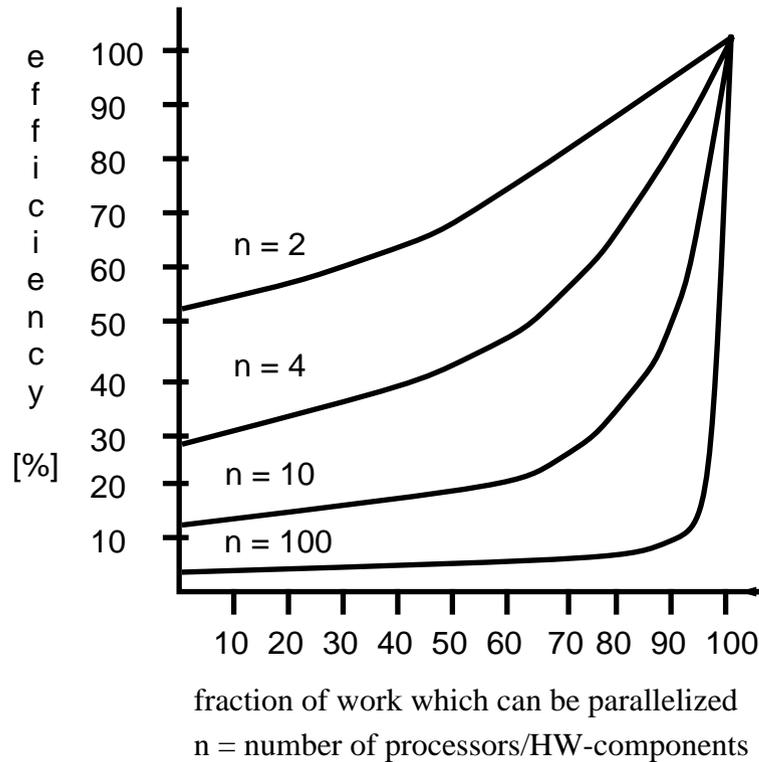
$$\blacklozenge (1) = t(1) \cdot (f_s + (1 - f_s)) = t_s + t_p \quad \begin{array}{l} f_s = \text{sequentieller Programmanteil} \\ f_p = \text{parallelisierbarer Programmanteil} \end{array}$$

$$\blacklozenge t(p) = t_s + \frac{t_p}{p}$$

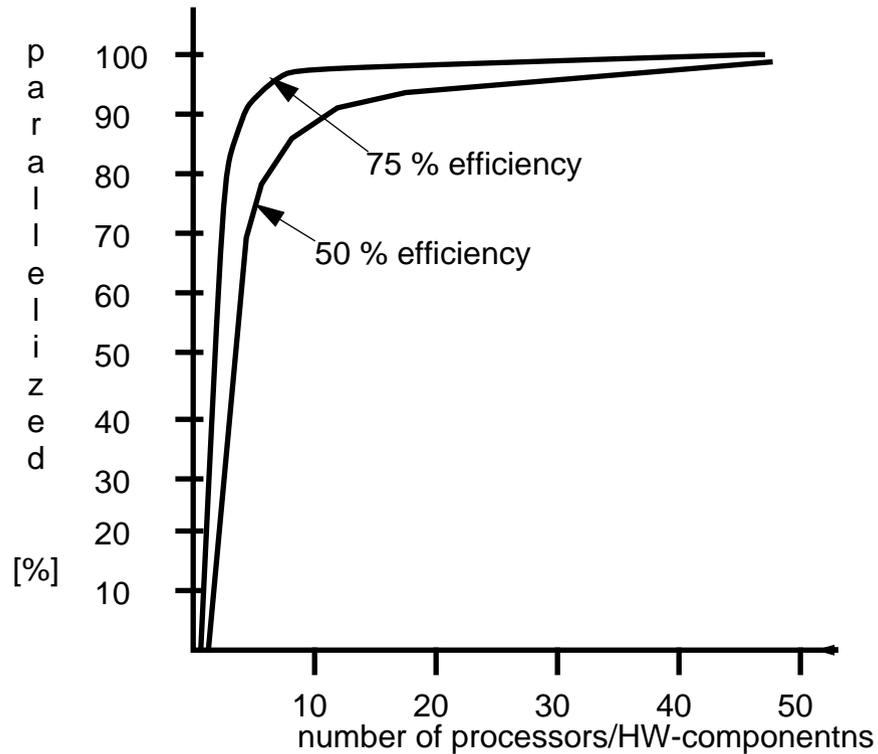
$$\blacklozenge (p) = \frac{1}{f_s + \frac{1 - f_s}{p}} \leq \frac{1}{f_s} \quad \text{d.h. der maximale Speedup bzw. die max. Effizienz sind durch den sequentiellen Anteil (wesentlich) beschränkt.}$$

- ◆ Der algorithmische Mehr-/Minderaufwand der durch die Parallelisierung des Problems selbst entsteht, wird bei diesen einfachen Abschätzungen nicht berücksichtigt, kann aber erheblich sein!
- ◆ Bei der Parallelisierung kann die effektive Speicherbandbreite der Prozessoren durch die Ausnutzung der Caches ansteigen (Parallelität auf Speicherebene). Damit wird ein superlinearer Speedup möglich.

2 Leistungsausbeute durch Parallelisierung (3)



2 Leistungsausbeute durch Parallelisierung (4)

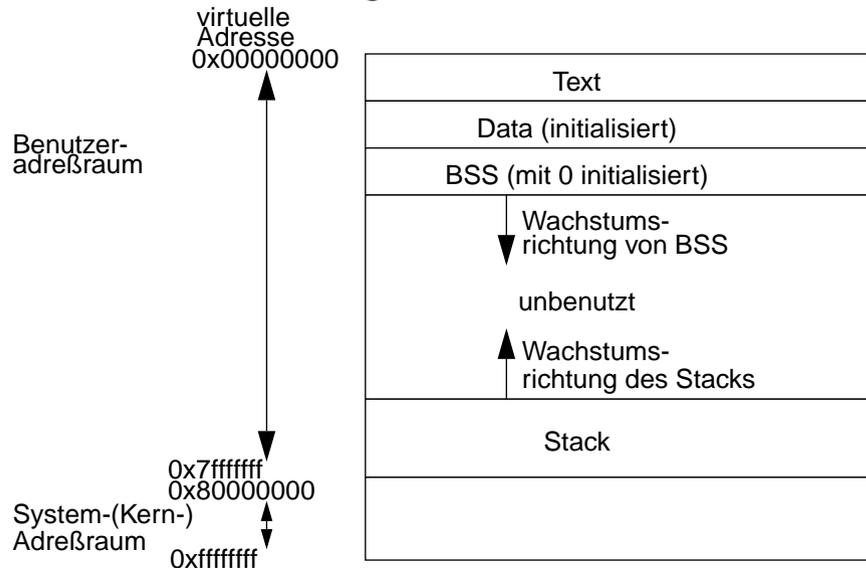


C Optimierung des Speicherzugriffs

C.1 Virtuelle Adressierung

1 Grundlagen

- Jeder Prozeß besitzt eigenen virtuellen Adreßraum

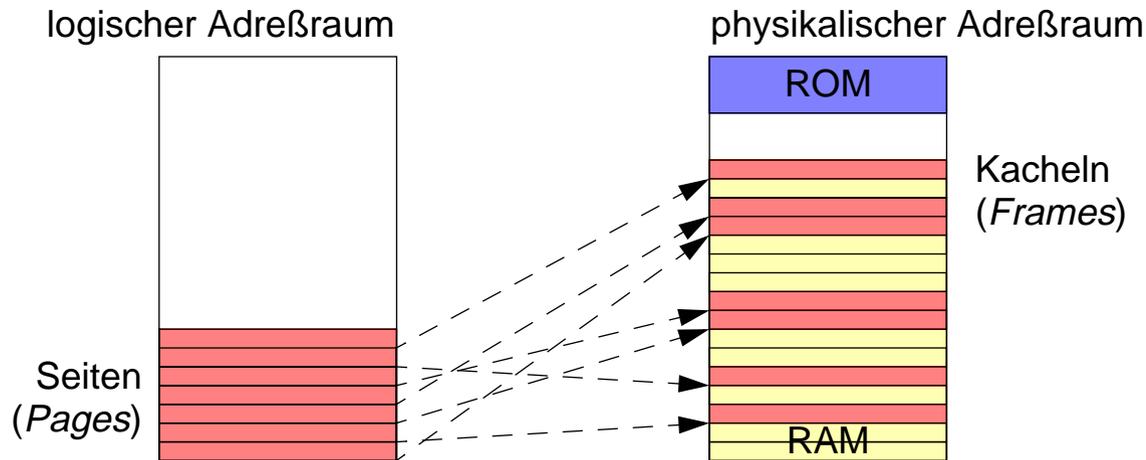


1 Grundlagen der virtuellen Adressierung (2)

- Ziel: Entkoppelung des Speicherbedarfs vom verfügbaren Hauptspeicher
 - ◆ Prozesse benötigen nicht alle Speicherstellen gleich häufig
 - bestimmte Befehle werden selten oder gar nicht benutzt (z.B. Fehlerbehandlungen)
 - bestimmte Datenstrukturen werden nicht voll belegt
 - ◆ Prozesse benötigen evtl. mehr Speicher als Hauptspeicher vorhanden
- Idee:
 - ◆ Vortäuschen eines großen Hauptspeichers
 - ◆ Einblenden benötigter Speicherbereiche
 - ◆ Abfangen von Zugriffen auf nicht-eingeblendete Bereiche
 - ◆ Bereitstellen der benötigten Bereiche auf Anforderung
 - ◆ Auslagern nicht-benötigter Bereiche

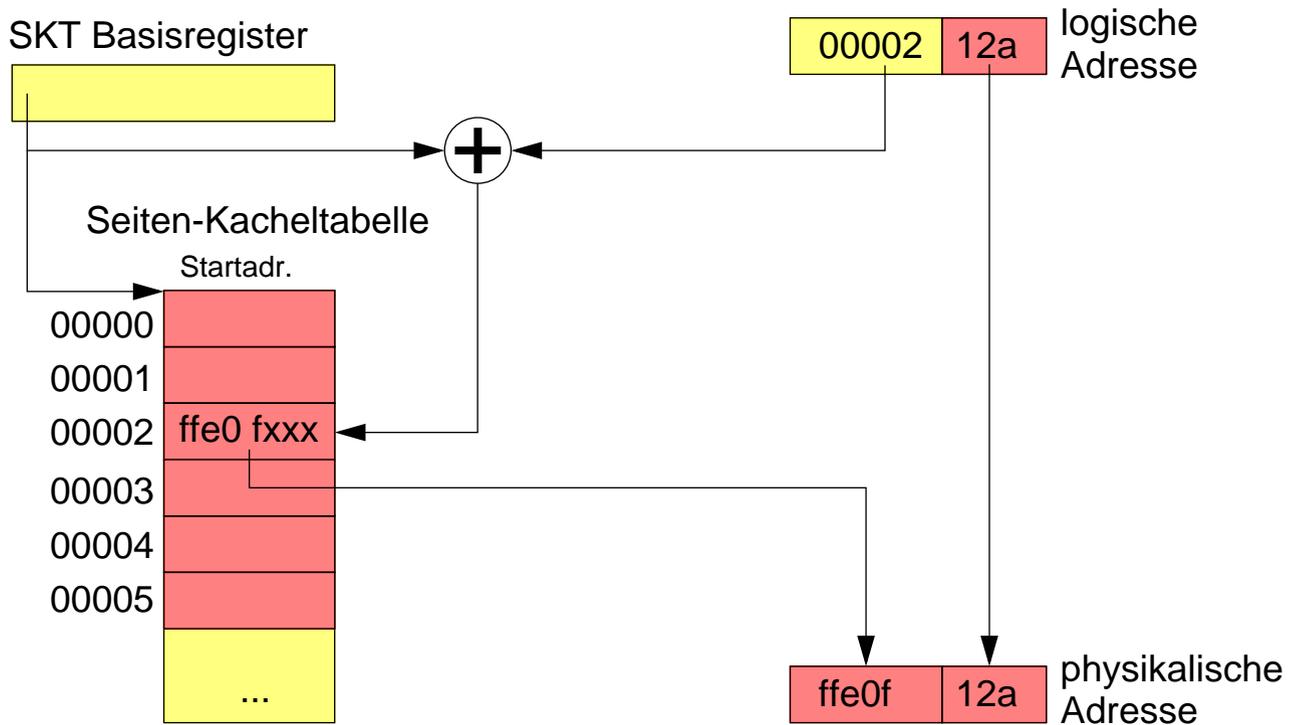
1 Grundlagen der virtuellen Adressierung (3)

- Einteilung des logischen Adreßraums in gleichgroße Seiten, die an beliebigen Stellen im physikalischen Adreßraum liegen können
 - ◆ Lösung des Fragmentierungsproblem
 - ◆ keine Kompaktifizierung mehr nötig
 - ◆ Vereinfacht Speicherbelegung und Ein-, Auslagerungen



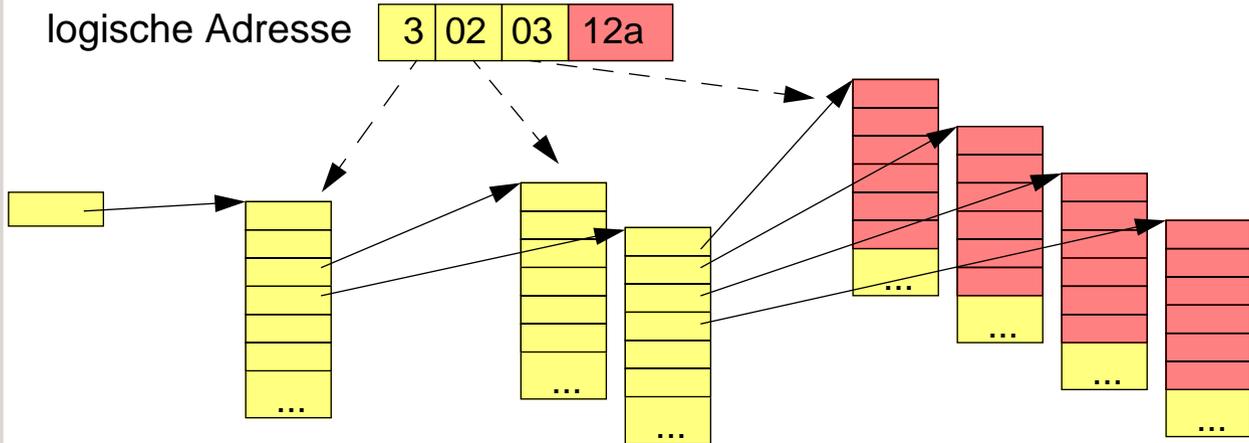
1 Grundlagen der virtuellen Adressierung (4)

- Tabelle setzt Seiten in Kacheln um

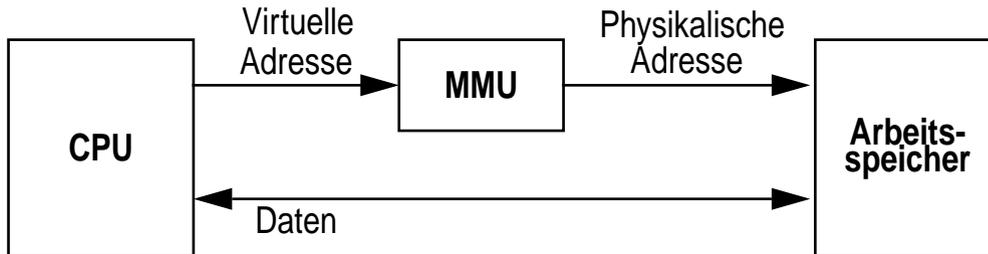


1 Grundlagen der virtuellen Adressierung (5)

■ Mehrstufige Seitenadressierung



■ MMU führt Adreßabbildung in Hardware durch

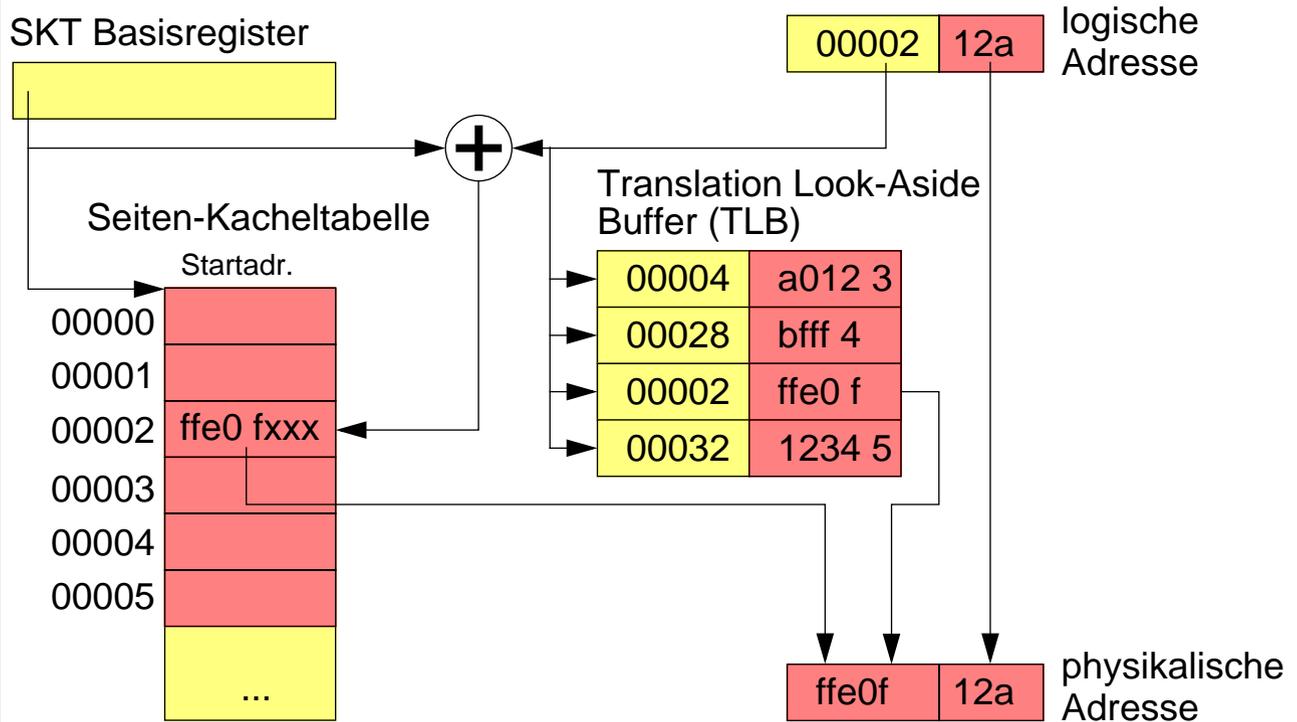


1 Grundlagen der virtuellen Adressierung (6)

- ▲ Seitenadressierung erzeugt internen Verschnitt
 - ◆ letzte Seite eventuell nicht vollständig genutzt
- Seitengröße
 - ◆ kleine Seiten verringern internen Verschnitt, vergrößern aber die Seiten-Kacheltabelle (und umgekehrt)
 - ◆ übliche Größen: 512 Bytes — 8192 Bytes (8192 Bytes bei UltraSPARC)
 - ◆ Systemaufruf: `getpagesize()`
- ▲ große Tabelle, die im Speicher gehalten werden muß
- ▲ viele implizite Speicherzugriffe nötig

2 Translation Look-Aside Buffer TLB

- Schneller Registersatz wird konsultiert bevor auf die SKT zugegriffen wird



2 Translation Look-Aside Buffer (2)

- Schneller Zugriff (< 1 Taktzyklus) auf Seitenabbildung, falls Information im voll-assoziativen Speicher des TLB
 - ◆ keine impliziten Speicherzugriffe nötig

- Bei Zugriffen auf eine nicht im TLB enthaltene Seite wird die entsprechende Zugriffsinformation in den TLB eingetragen
 - ◆ Ein alter Eintrag muß zur Ersetzung ausgesucht werden
 - Random
 - Round Robin

- TLB Größe
 - ◆ Pentium: Daten TLB = 64, Code TLB = 32, Seitengröße 4K
 - ◆ Sparc V9: Daten TLB = 64, Code TLB = 64, Seitengröße 8K
 - ◆ Größere TLBs bei den üblichen Taktraten zur Zeit nicht möglich

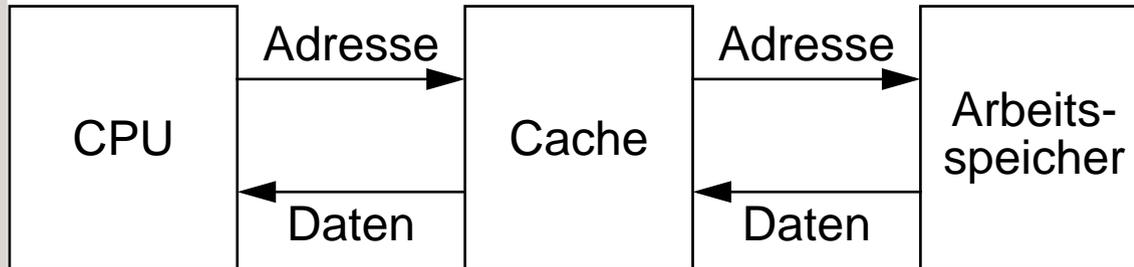
2 Translation Look-Aside Buffer (3)

- Der TLB kann nur einen kleinen Teil des Adreßraums abbilden.
(z.B. UltraSPARC Ili 64 Einträge x 8 KB = 512 KB)
- Ein TLB-Zugriffsfehler wird in der Regel durch Software aufgelöst.
(Durchsuchen der SKT und Einlagerung im TLB; < 32 Instruktionen).
 - ◆ Vorteil: Flexibles Design der SKT möglich
 - ◆ Nachteil: 1 Trap ist nötig
(Overhead of precise exceptions in pipelined/superscalar CPUs)
 - ◆ Ausnahmen: Intel x86, teilw. Motorola/IBM PowerPC, HP PA-RISC)
- TLB-Zugriffsfehler erscheinen nicht in der OS-Statistik.
- 1 TLB-Zugriffsfehler = 2 Speicherzugriffe (bis zu 1000 Zyklen!)
- Schon eine Arbeitsmenge von 8KB kann den TLB überfordern.
→ siehe Übung

C.2 Caches

1 Grundlagen

■ Funktion



- ◆ Pufferspeicher zur Ausnutzung der zeitlichen und örtlichen Lokalität
- ◆ Zugriff auf gespeicherte Daten mit geringer Latenz und hoher Bandbreite
- ◆ Reduktion der Zugriffe auf den Arbeitsspeicher (wichtig in Multiprozessen)
- ◆ Puffer für asynchrone Prefetch-Operationen

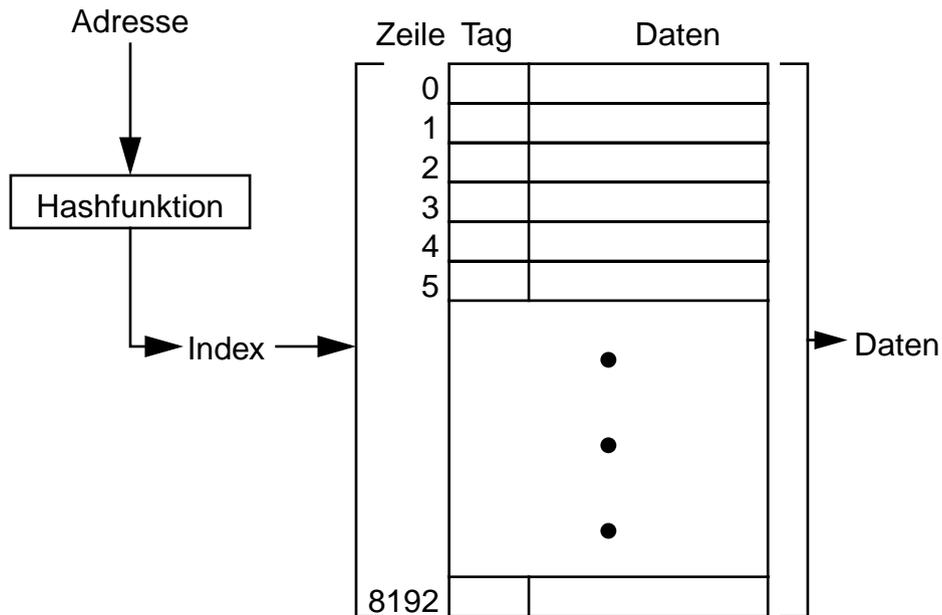
1 Grundlagen (2)

■ Organisation

◆ Aufbau aus Cache-Zeilen fester Länge (typischerweise 32/64 Bytes)

◆ Abbildung der Adresse auf die Zeile (1):

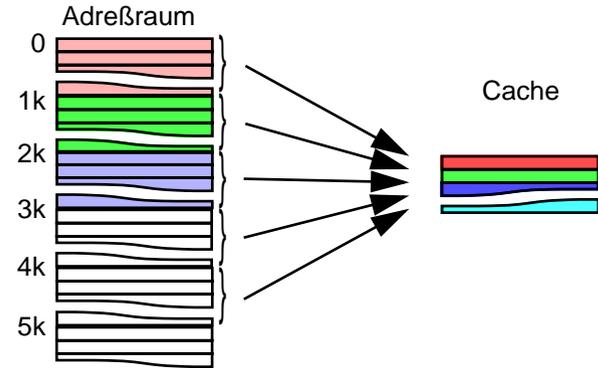
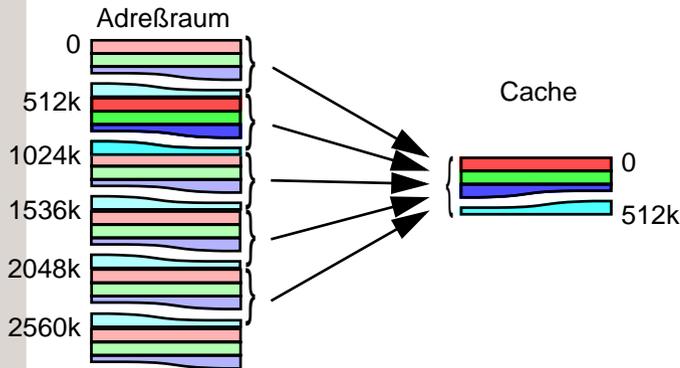
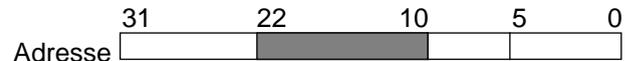
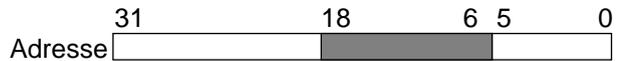
Beispiel: Direkt abgebildeter Cache (direct mapped cache)



1 Grundlagen (4)

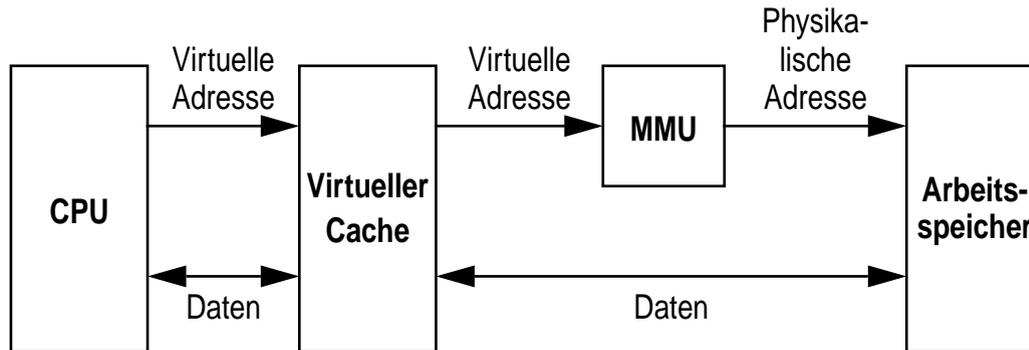
■ Hash-Algorithmen

- ◆ Modulo-Hashing, z. B. Bits 0 - 5 zur Auswahl des Bytes innerhalb einer Zeile, Bits 6 - 18 zur Auswahl der Zeile, Bits 19 - 31 sind Tag
- ◆ Hashing durch Ausschnitt aus der Adresse, z. B. Bits 10 - 22 als Zeilenadresse. Dieses Verfahren wird bei Caches jedoch nicht eingesetzt.



1 Grundlagen (5)

■ Virtuelle Caches



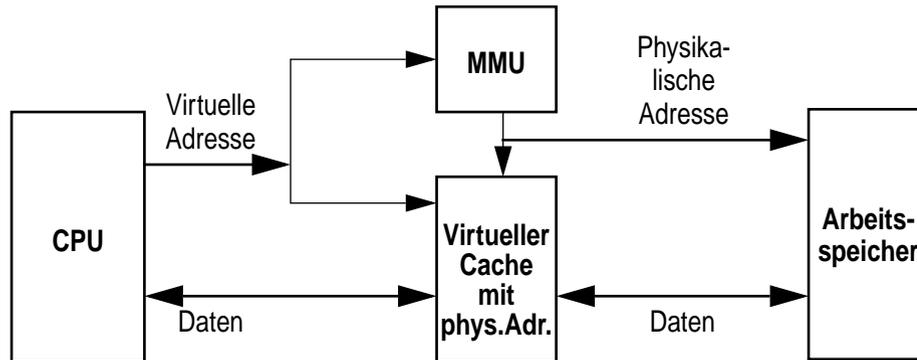
◆ Probleme:

- Mehrdeutigkeit (ambiguity):
Zwei identische virtuelle Adressen zeigen auf verschiedene Speicherbereiche
- Bedeutungsgleichheit (alias):
Verschiedene virtuelle Adressen zeigen auf den gleichen Speicherbereich

◆ Lösung: Systemsoftware kann Probleme mit viel Aufwand verhindern

1 Grundlagen (6)

■ Virtuelle Caches mit physikalischen Adressen als Tags



◆ Vorteil:

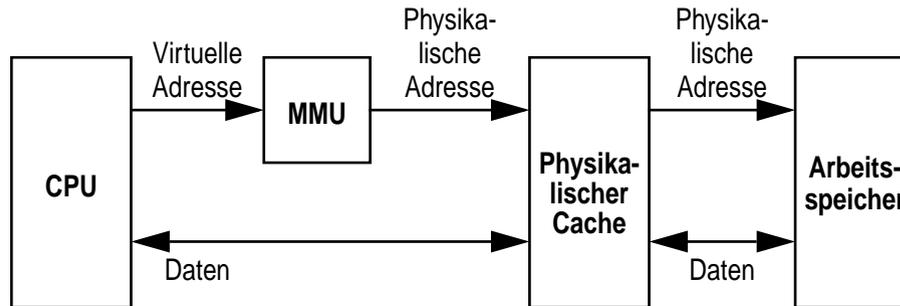
- Keine Mehrdeutigkeiten mehr

◆ Nachteile:

- Bedeutungsgleichheiten noch möglich (→OS Unterstützung nötig)
- Suchgeschwindigkeit durch Umsetzungsgeschwindigkeit der MMU begrenzt
- Problematischer Einsatz in Multiprozessoren mit gemeinsamem Speicher (Welche Zeile soll invalidiert werden?)

1 Grundlagen (7)

■ Physikalische Caches



◆ Vorteile

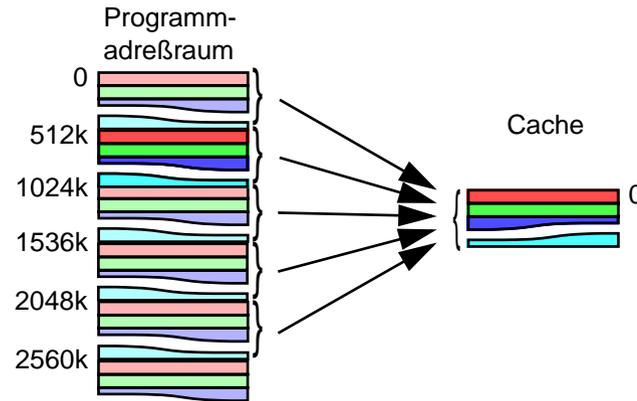
- Absolute Transparenz aus Sicht des Prozessors
- Keine performancekritische Systemunterstützung nötig
- Multiprozessoren mit gemeinsamem Adreßraum können mit einem Cache-Kohärenzprotokoll in Hardware aufgebaut werden.

◆ Nachteil:

- Bei jedem Zugriff ist Adreßumsetzung durch MMU erforderlich

2 Zugriffskonflikte

- Virtueller Cache (z.B. PA-RISC 1.1 CPUs in Convex SPP 1600)

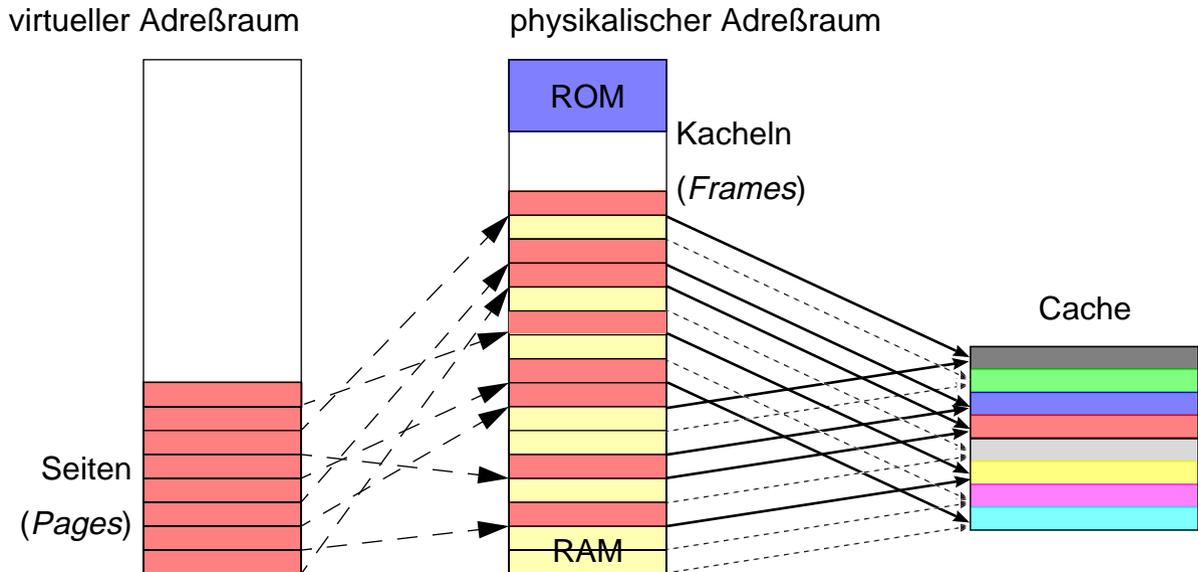


- ◆ Datenstrukturen, bei denen die Differenz der Adreßbereiche einem Vielfachen der Cachegröße entspricht, werden auf die selbe Cachezeile abgebildet.
- ◆ Virtuelle Caches mit physikalischen Tags werden häufig als first-level Caches eingesetzt (z.B. UltraSPARC II 16 KB direct mapped).
→ siehe Übung

2 Zugriffskonflikte (2)

■ Physikalische Caches

- ◆ Seitenkonflikte durch zufällige Anforderung von physikalischem Speicher:



Zusammenhängender virtueller Speicher wird in der Regel auf beliebige freie physikalische Seiten abgebildet

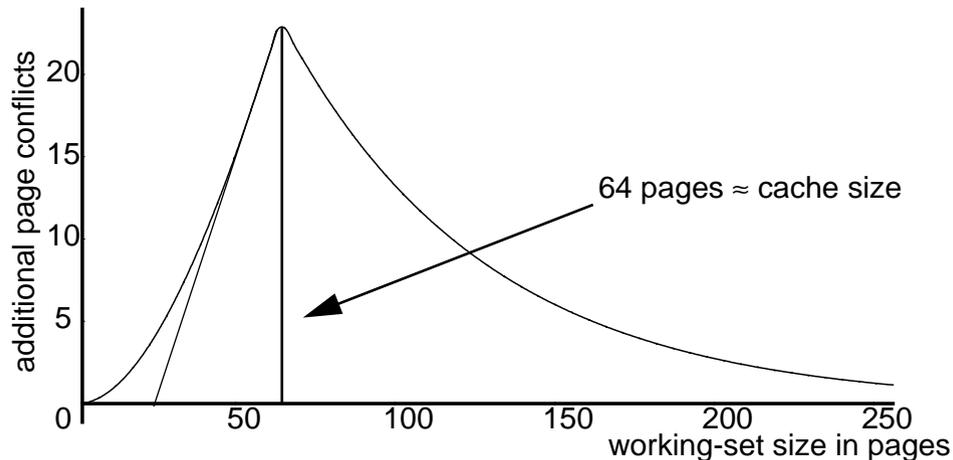
2 Zugriffskonflikte (3)

■ Physikalische Caches (2)

◆ Auswirkungen des "random page coloring":

- Es kommt zu Konflikten beim Cache-Zugriff
- Nur ein Teil des Caches wird ausgenutzt
- Erhebliche Laufzeitschwankungen!

$$X(p \text{ in bin}) = \binom{P}{p} \left(\frac{1}{C}\right)^p \left(1 - \frac{1}{C}\right)^{P-p}$$

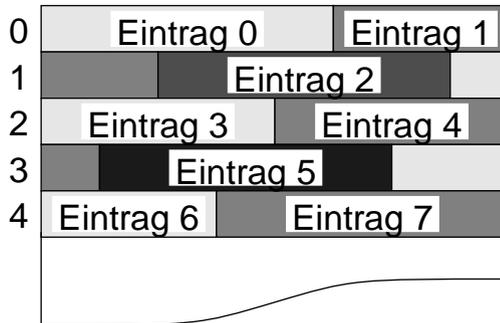


◆ Abhilfe: "Frischen" Speicher anfordern und im Speicher festhalten (mlock)

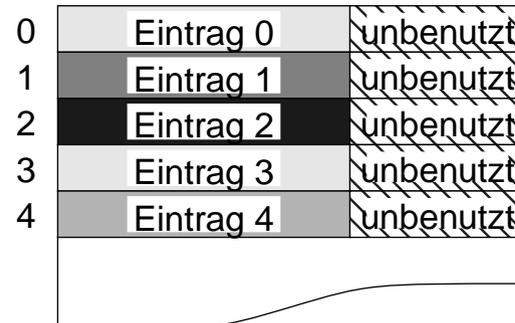
2 Zugriffskonflikte (4)

- Einfluß der Zeilenlänge des Caches auf die Datenstrukturen
 - ◆ Problem: Mehrfache Fehlzugriffe durch zeilenübergreifende 'non aligned' Datenstrukturen
 - ◆ Lösung: Auffüllen der Strukturen auf Vielfache der Zeilenlänge (Padding)

Zeile



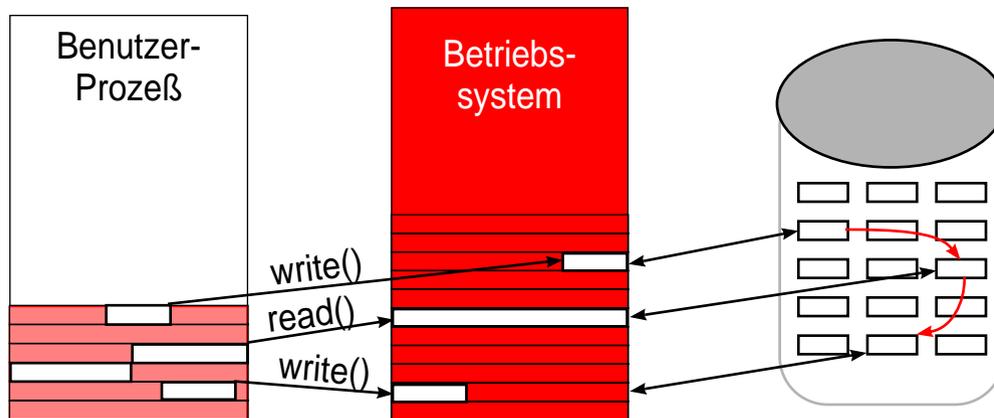
Zeile



C.3 Ein/Ausgabe

1 "Klassisches" Lesen/Schreiben in Dateien

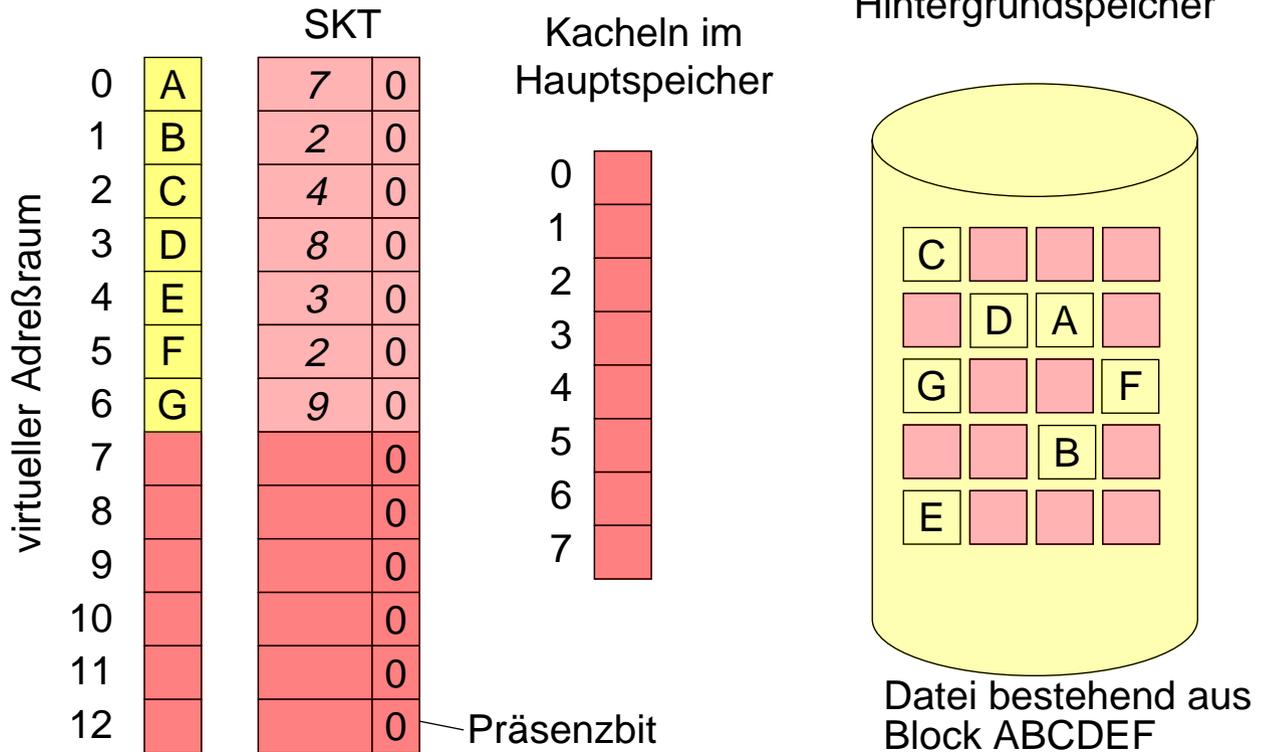
- open/seek/read/write Operationen
- Kopieren der Daten in den Kern
- Blockpufferung der Plattenblöcke im Betriebssystem



- Interessenkonflikt zwischen Speicherverwaltung und Buffercache

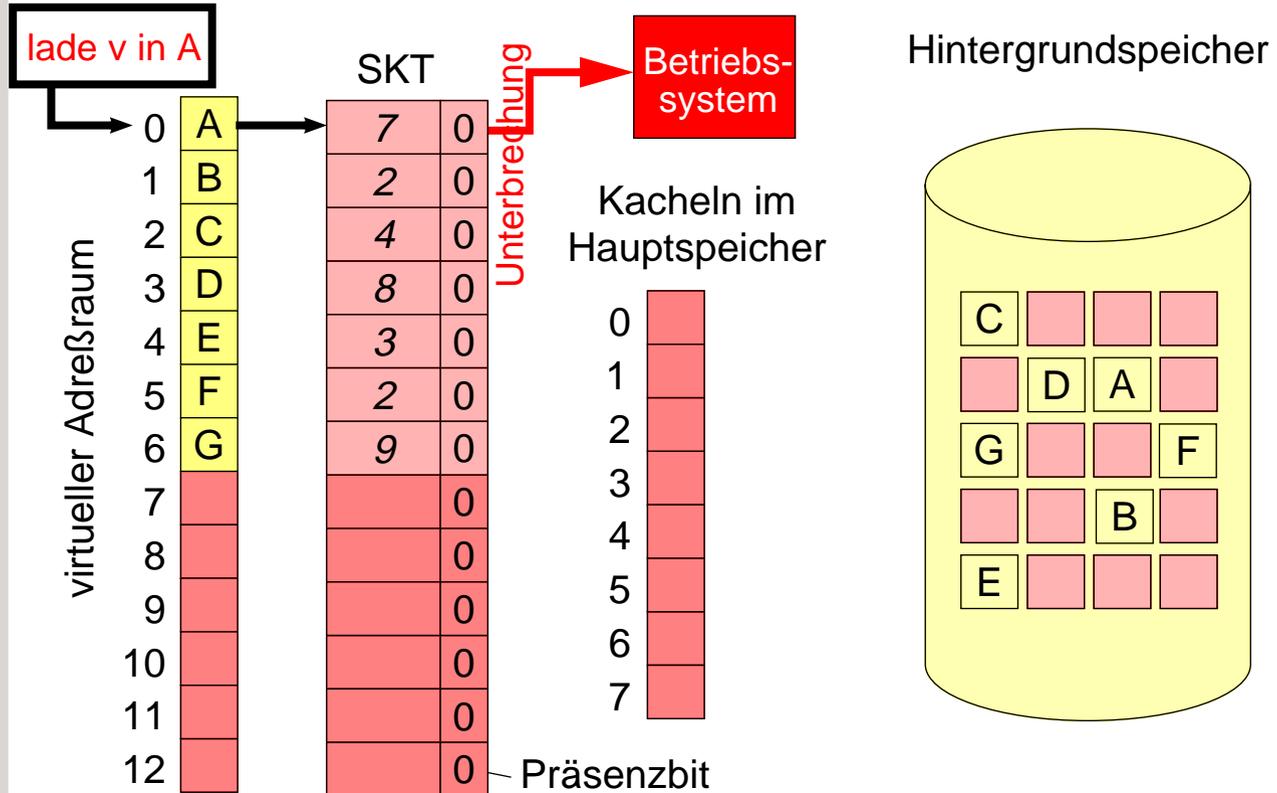
2 Speicher abgebildete Dateien

- Abbilden einer Datei auf virtuelle Seiten



2 Speicher abgebildete Dateien (2)

■ Reaktion auf Seitenfehler



2 Speicher abgebildete Dateien (3)

■ Einlagerung

lade v in A

virtueller Adreßraum

0	A
1	B
2	C
3	D
4	E
5	F
6	G
7	
8	
9	
10	
11	
12	

SKT

7	0
2	0
4	0
8	0
3	0
2	0
9	0
	0
	0
	0
	0
	0
	0
	0
	0
	0

Präsenzbit

Betriebs-system

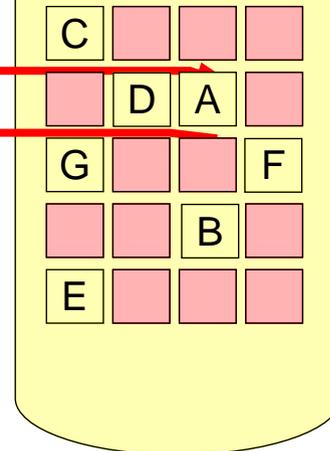
Kacheln im Hauptspeicher

0	
1	
2	A
3	
4	
5	
6	
7	

Einlagern der Seite

Hintergrundspeicher

Ermitteln der ausgelagerten Seite



2 Speicher abgebildete Dateien (4)

- Einblenden der physikalischen Seite

lade v in A

virtueller Adreßraum

0	A
1	B
2	C
3	D
4	E
5	F
6	G
7	
8	
9	
10	
11	
12	

SKT

2	1
7	0
4	0
8	0
3	0
5	0
9	0
	0
	0
	0
	0
	0
	0
	0
	0

Anpassen der SKT

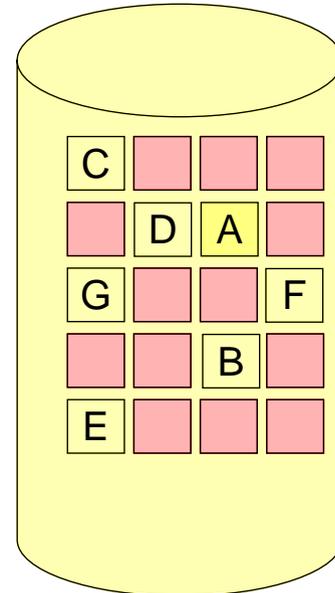
Betriebssystem

Kacheln im Hauptspeicher

0	
1	
2	A
3	
4	
5	
6	
7	

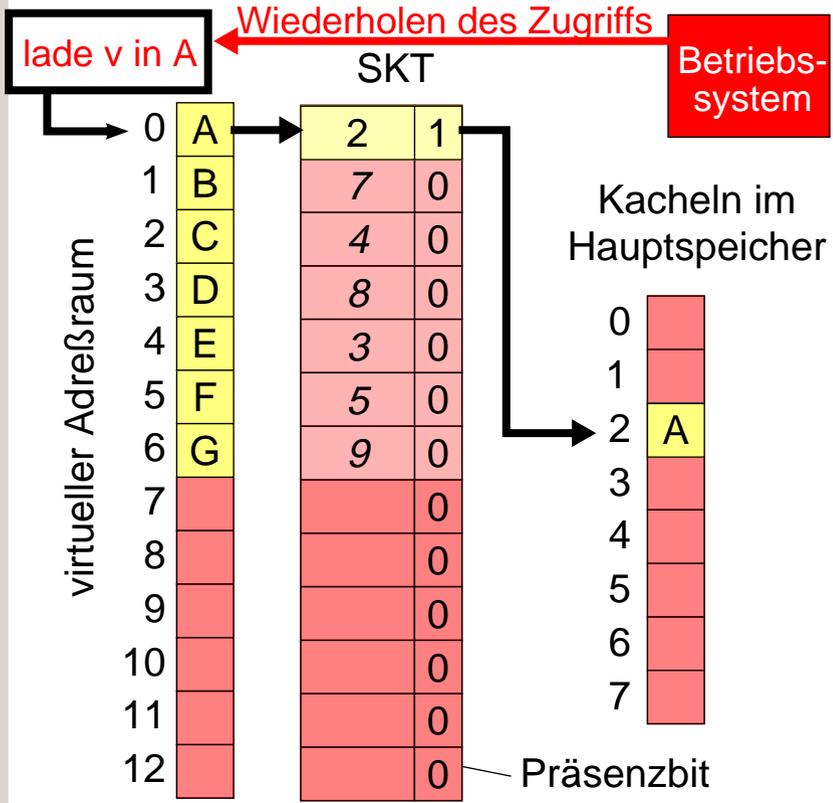
Präsenzbit

Hintergrundspeicher

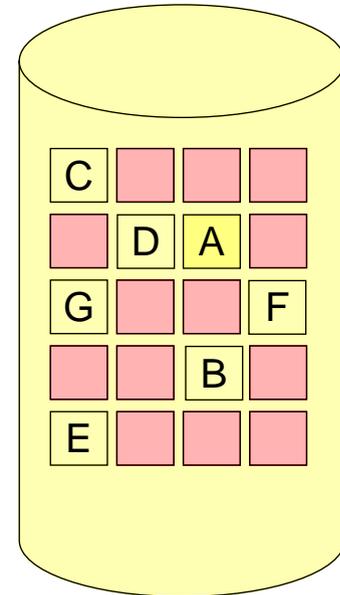


2 Speicher abgebildete Dateien (5)

■ Zugriff auf Seite



Hintergrundspeicher



2 Speicherabgebildete Dateien (6)

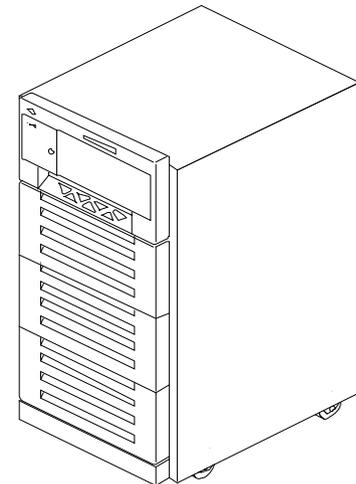
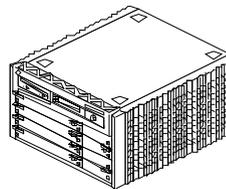
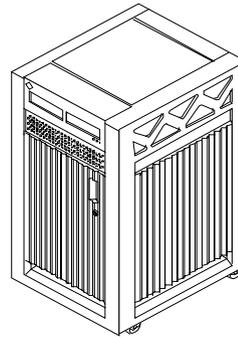
■ Aufrufe: `mmap()`, `munmap()`, `madvise()`, `msync()`

■ Vorteile:

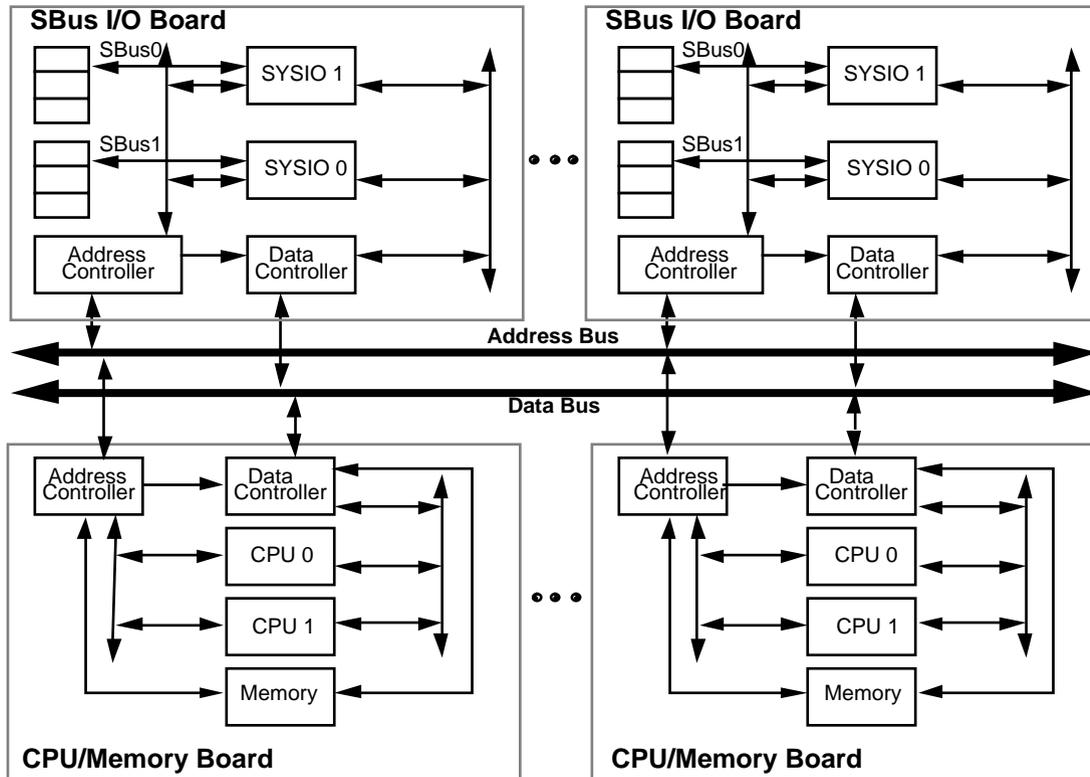
- ◆ Kein Kopieren der Daten vom Benutzer in den Kernadreßraum
- ◆ Kein Interessenkonflikt zwischen Seitenadressierung und E/A Puffern
- ◆ Wesentliche Reduktion der Systemaufrufe (kein read/write)
- ◆ Angabe von Zugriffsstrategien
(NORMAL, RANDOM, SEQUENTIAL, WILLNEED, DONTNEED)
- ◆ Einfaches Adressierung der Daten innerhalb der Datei über Adreßpointer
- ◆ Mehrere Prozesse können (ohne Kohärenzproblem) auf der gleichen Datei arbeiten.

D SUN Enterprise X000

- Einsatz am RRZE/IMMD
 - ◆ cssun: Enterprise 4000
8 CPUs, 8 GByte
 - ◆ faui40: Enterprise 4000
4 CPUs, 1 GByte
 - ◆ faui09: Enterprise 3000
4 CPUs, 1 GByte
 - ◆ faui01: Enterprise 3000
2 CPU, 512 MByte



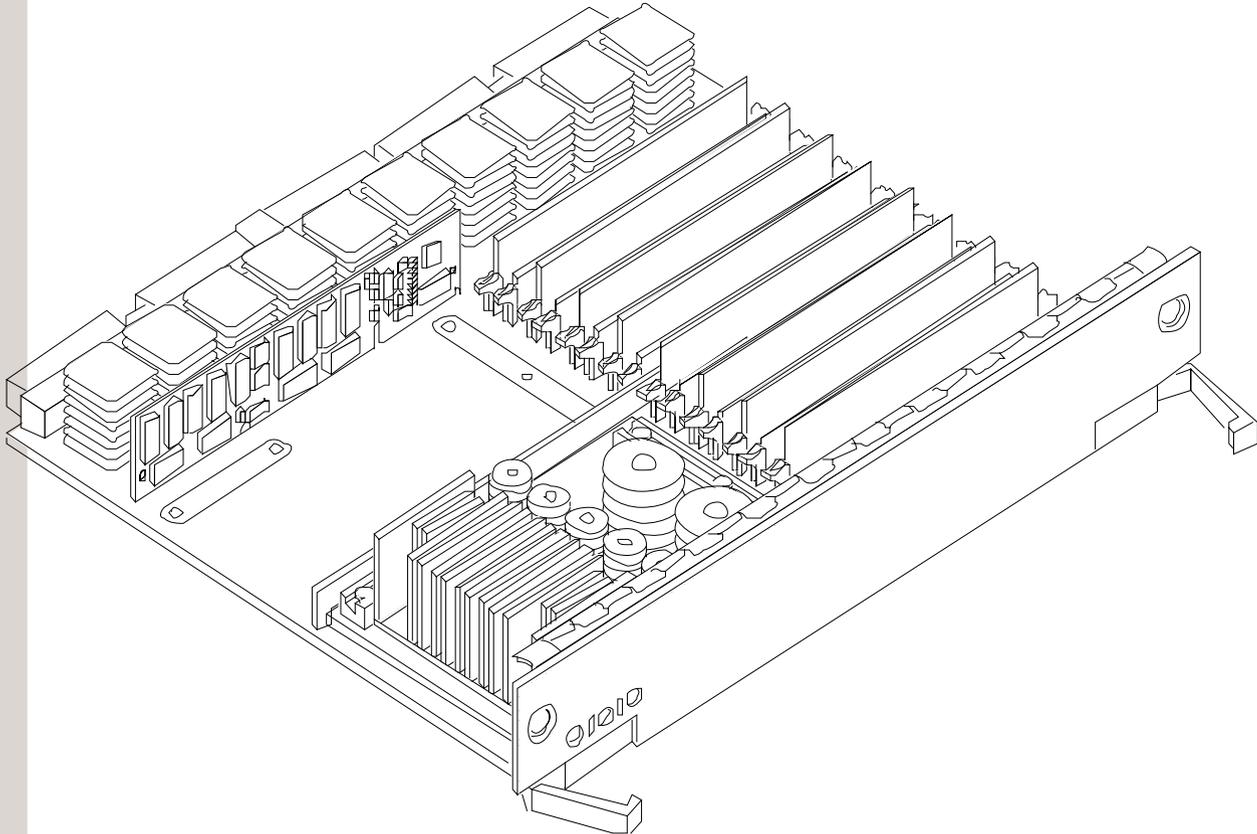
D.1 Systemarchitektur



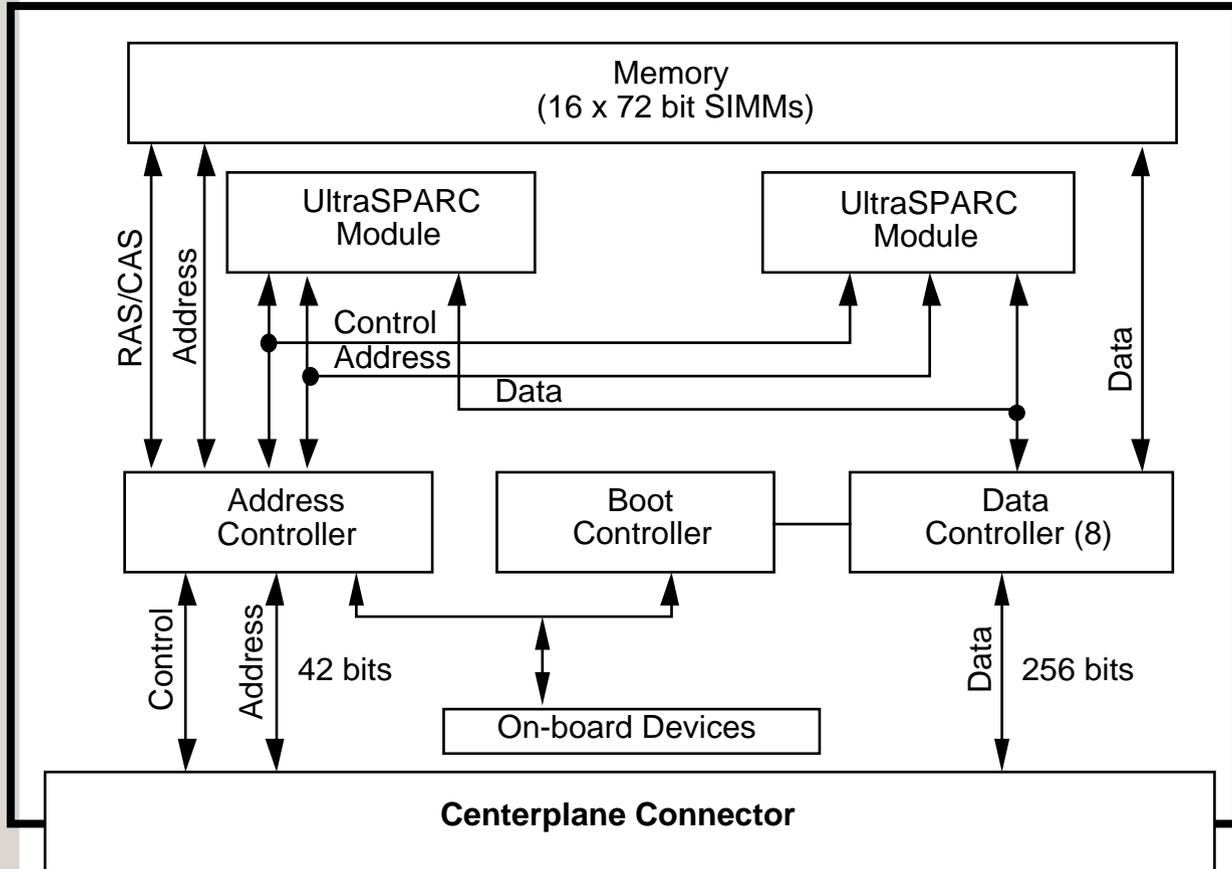
1 Gigaplane Bus

- Sehr schneller (mit 83.3/100 MHz getakteter) und breiter (256 Bits) Bus auf der *Centerplane*.
- Kann eine vollständige Cacheline (64 Bytes) in 2 Zyklen transferieren, das ist eine Datentransferrate von 2.672 GB/s.
- Kein Multiplexen von Adressen und Daten, kein Arbitrierungs-overhead, daher extrem niedrige Latenzzeit.
- “Packet-switched” Architektur ermöglicht hohen Durchsatz.
- Die elektrischen Eigenschaften limitieren den Bus auf 16 Anschlüsse. Deshalb wird innerhalb der einzelnen Boards über den standard UPA (*Ultra Port Architecture*) Bus weiterverzweigt.

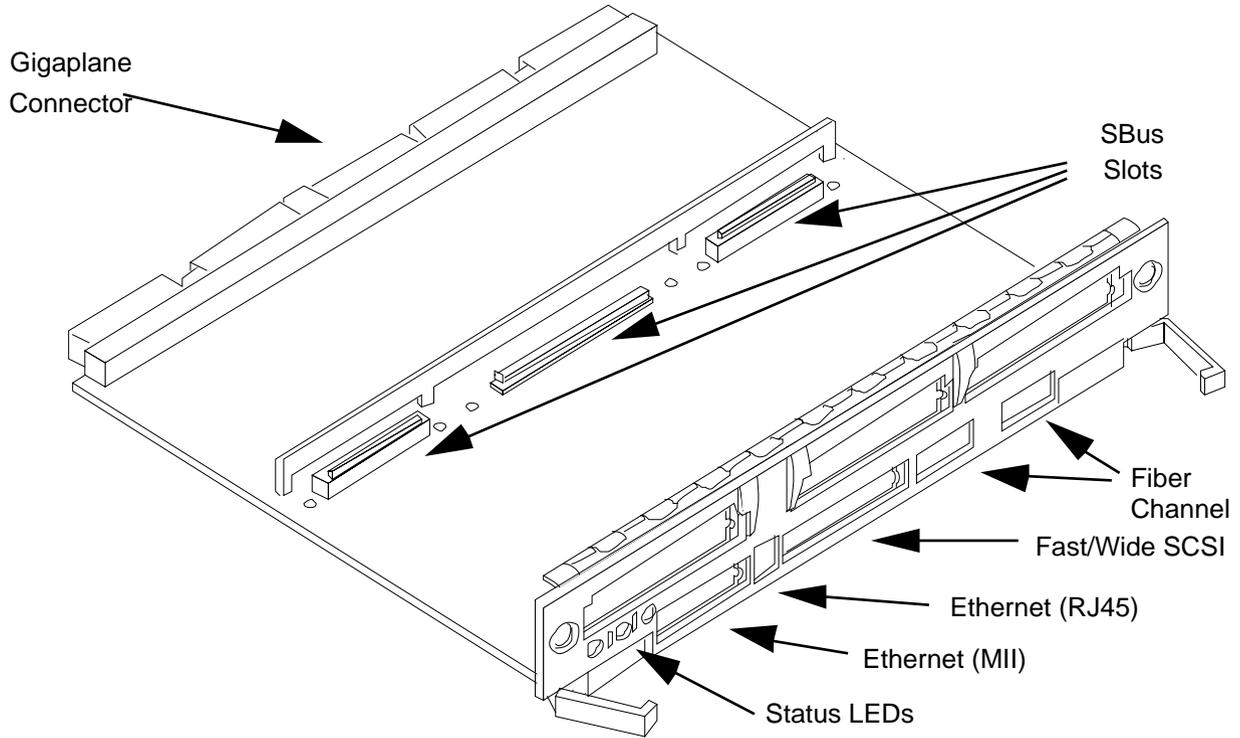
2 CPU/Memory Modul



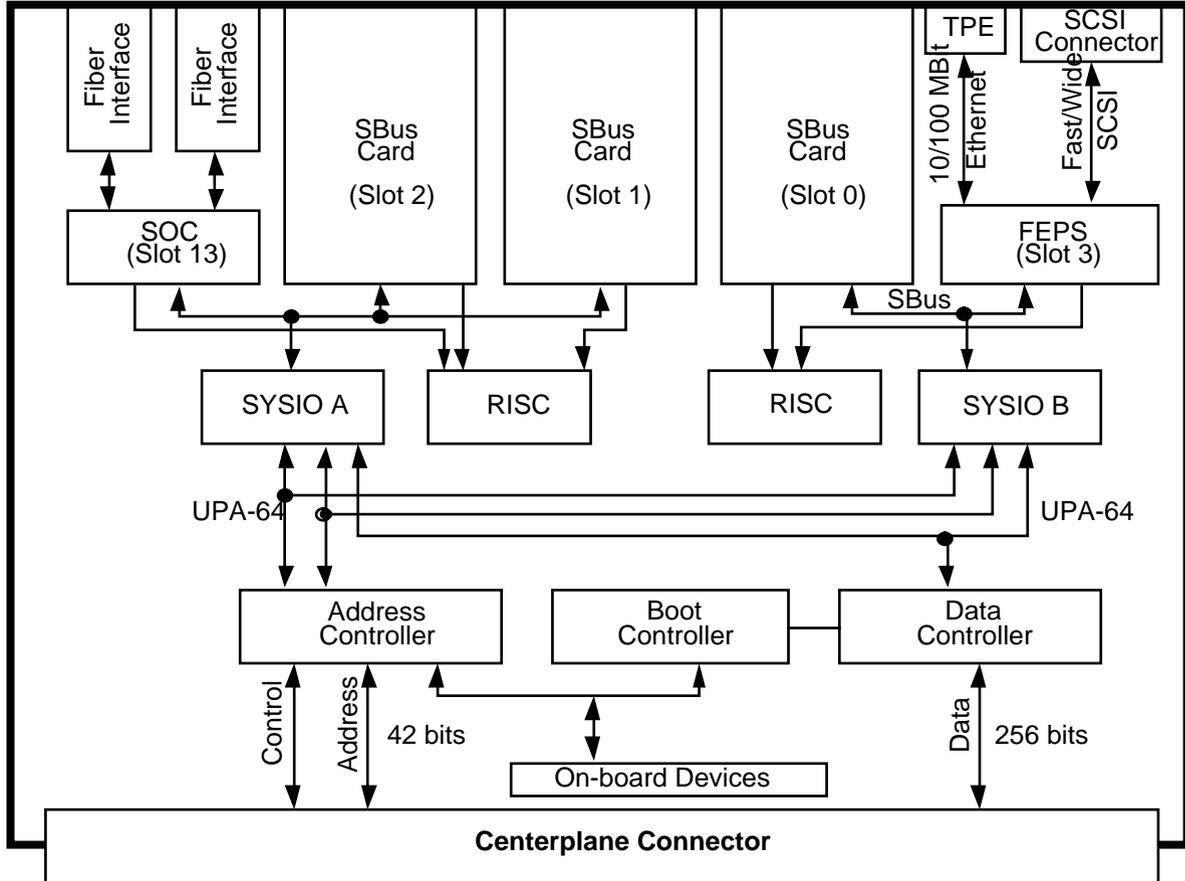
2 CPU/Memory Module (2)



3 I/O Board



3 I/OBoard (2)



E Pthreads

E.1 Grundlagen

- Der Name steht für POSIX Threads.
POSIX = Portable Operating System Interface)
- Verabschiedet im Juni 1995 als POSIX Standard 1003.1c
 - ◆ Leider ist der Standard nicht im Netz erreichbar, sondern muß für viel Geld bei IEEE erworben werden. Pthreads sind standardisiert und laufen deshalb unter fast jedem OS.
 - ◆ Pthreads sind unter fast jedem OS verfügbar.
- Bücher zur Vorlesung
 - ◆ “Pthreads Programming”. O'REILLY *Nutshell* Buch
 - ◆ “Threadtime, The Multithreaded Programming Guide”, Prentice Hall

1 Prozeßmodell

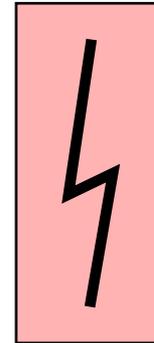
■ Der einfädige (single-threaded) Prozeß

Program "hello.c"

```
#include <stdio.h>
main()
{
    printf("hello PPS\n");
}
```

```
$ cc -o hello hello.c
$ ./hello
```

Process

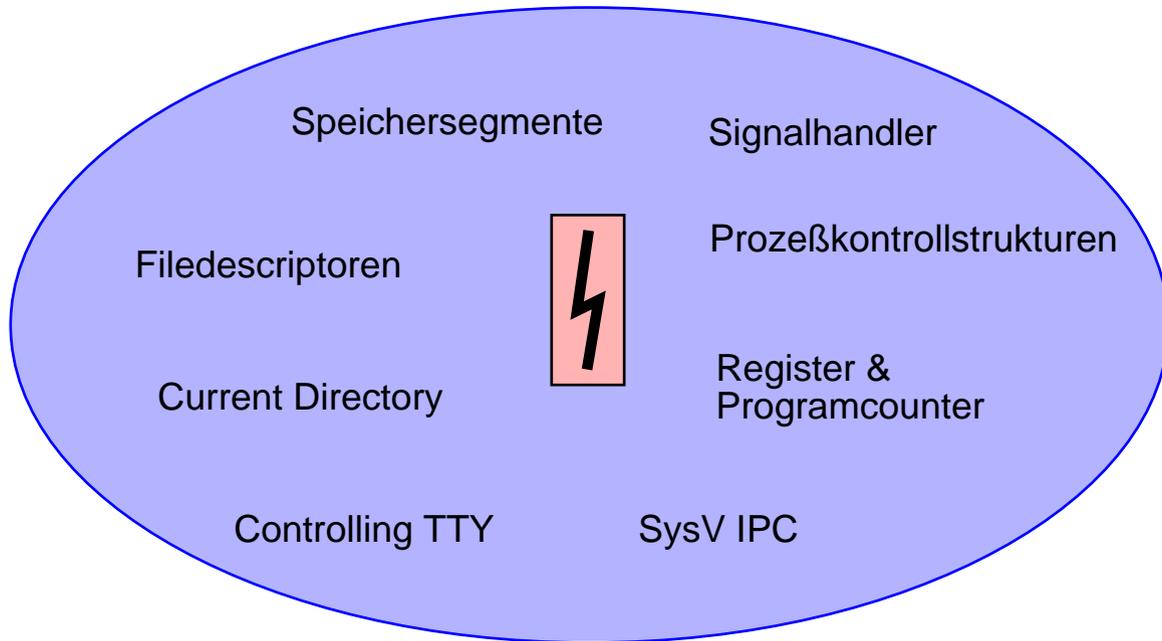


 = Ein Thread

◆ Ein Prozeß ist die Instanz eines Programmes in Ausführung.

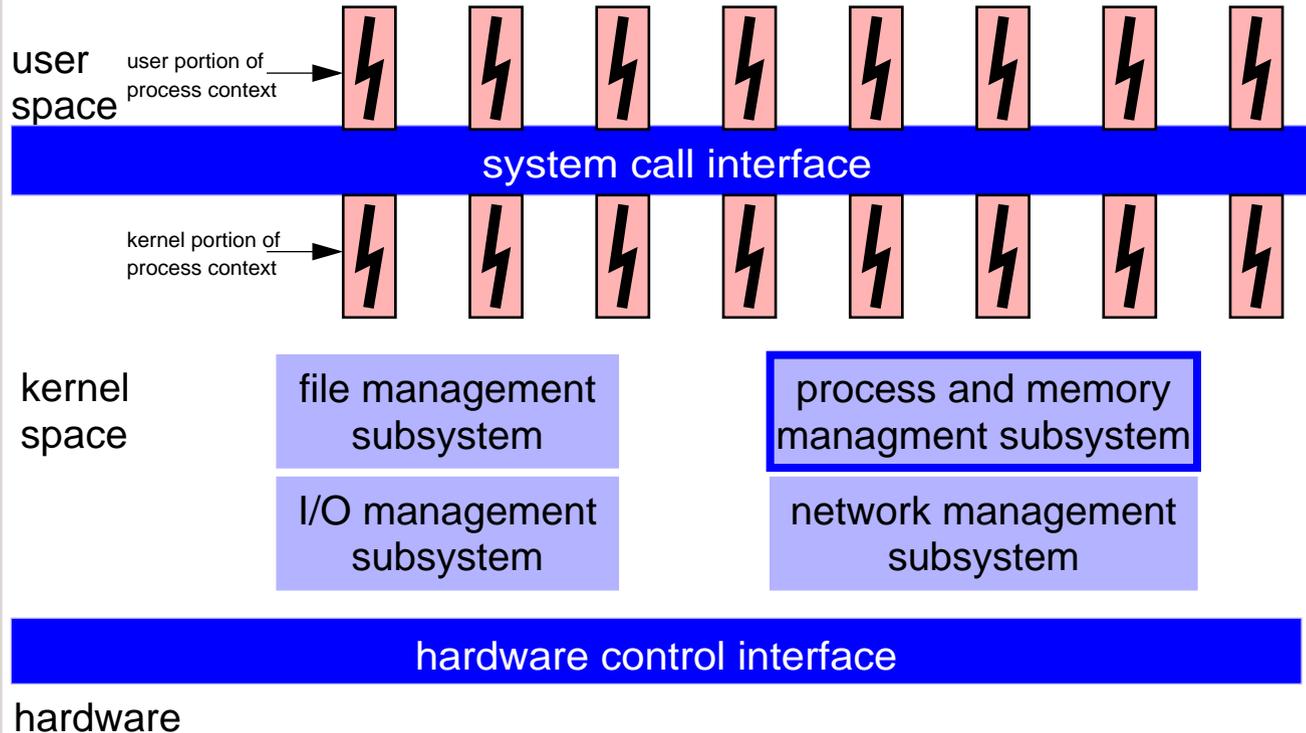
1 Prozeßmodell (2)

- Aufbau eines UNIX Prozesses:



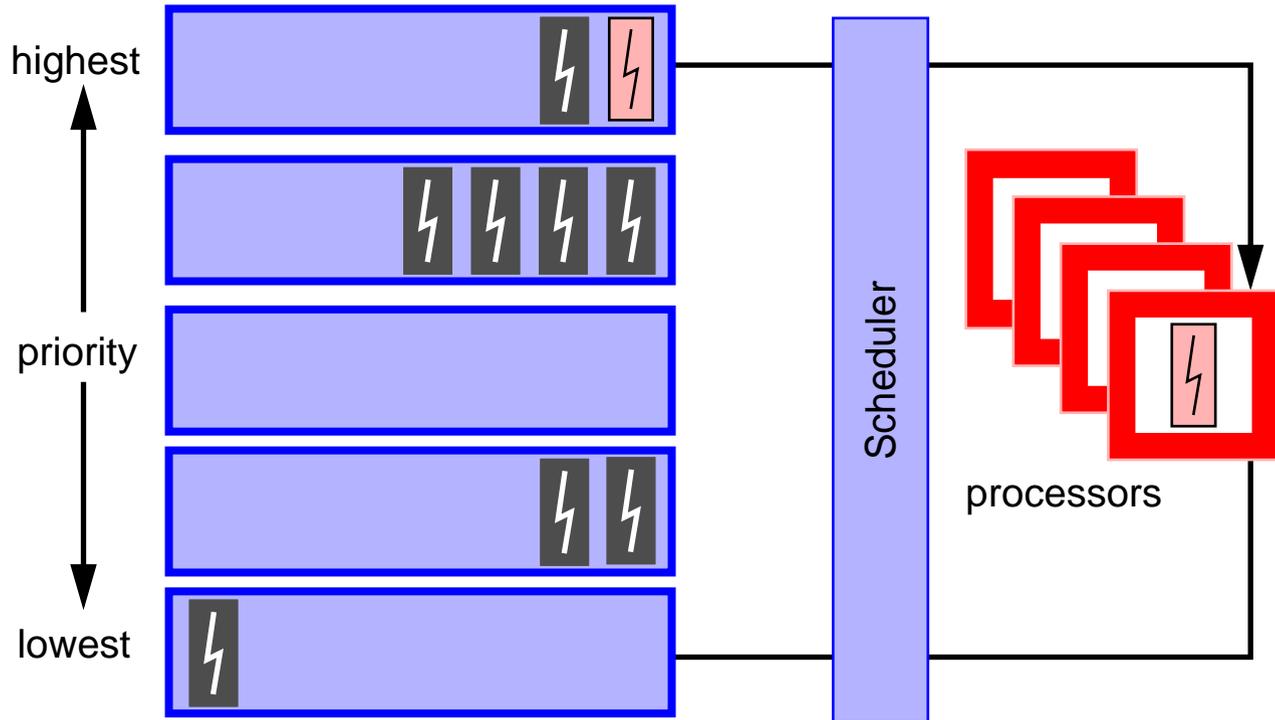
1 Prozeßmodell (3)

■ Betriebssystem-Architektur für das Prozeßmodell



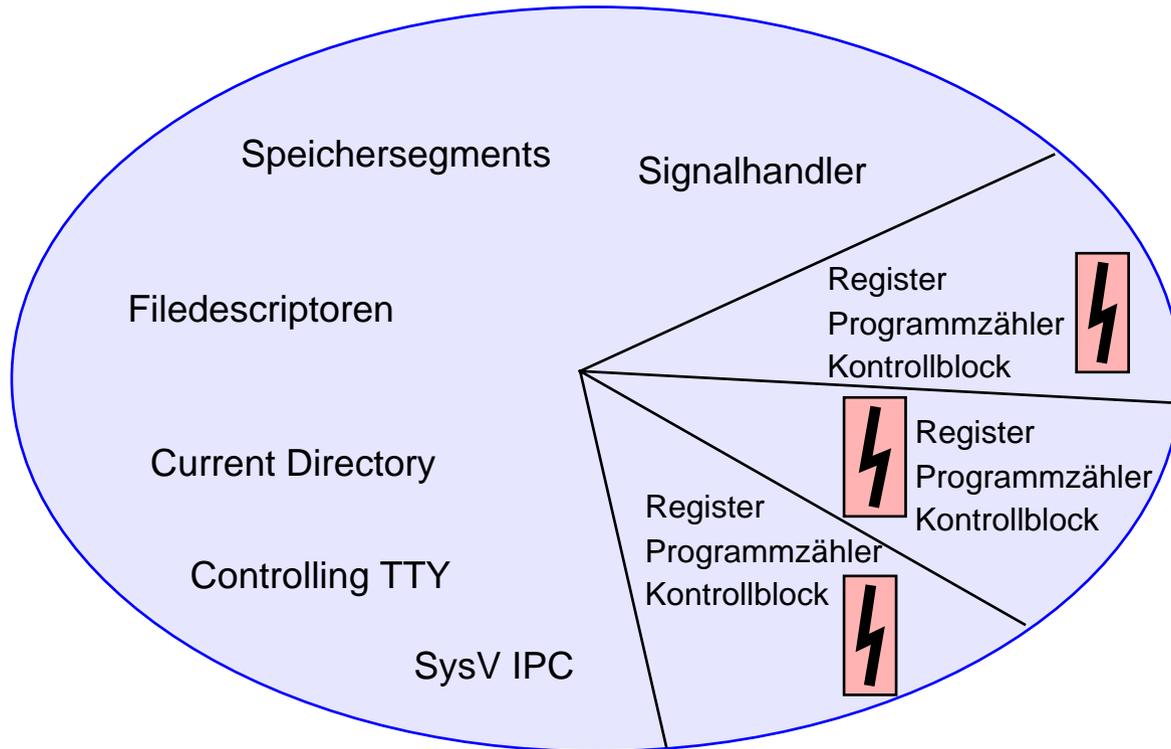
1 Prozeßmodell

■ Scheduling



2 Threadmodell

- Aufspaltung eines Prozesses in mehrere Threads

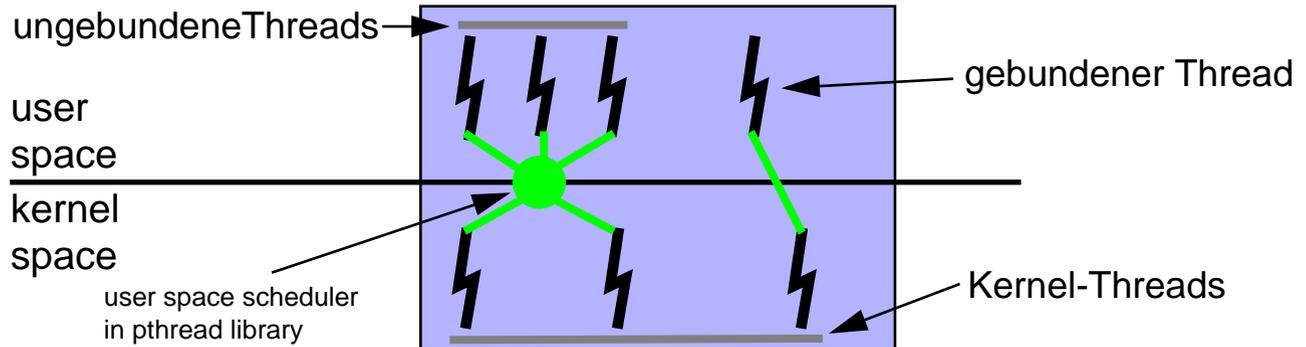


2 Threadmodell (2)

- Der Einsatz von Threads anstelle von Prozessen ist aus folgenden Gründen sinnvoll:
 - ◆ Die Prozeßerzeugung durch `fork()` ist sehr zeitaufwendig, da ein neuer Prozeßkontext angelegt werden muß.
 - ◆ Ein neuer Thread verbraucht weniger Systemressourcen als ein neuer Prozeß.
 - ◆ Der Scheduler kann wesentlich schneller zwischen zwei Threads eines Prozesses umschalten, da die gleichen Prozeßressourcen (insbesondere der gleiche Adreßraum) verwendet werden.
 - Bessere Antwortzeiten (Beispiel: Apache vs. Netscape Web-Server)
 - ◆ SysV-IPC Mechanismen sind kompliziert, nicht an Prozesse gebunden (sie bleiben nach Prozeßende bestehen) und langsam (da ein Kernelaufruf getätigt werden muß).

2 Threadmodell (3)

■ Gebundene und Ungebundene User-Threads



- ◆ Gebundene User-Threads werden direkt an Kernel-Threads gebunden. Aus Sicht der gebundenen User-Threads stellen Kernel-Threads virtuelle Prozessoren dar. Die Kernel-Threads konkurrieren mit allen Kernel-Threads des Systems um die verfügbaren physikalischen Prozessoren.
- ◆ Ein ungebundener User-Thread kann von jedem Kernel-Thread eines Prozesses ausgeführt werden. Ungebundene User-Threads konkurrieren um die Kernel-Threads des Prozesses. Die Zuweisung erfolgt durch die Thread-Bibliothek (Pthreads Library).

2 Threadmodell (4)

■ Many-to-One (M x 1)

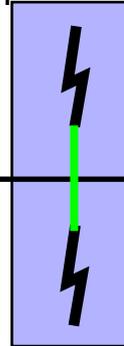
 = user space scheduler
linked in from
pthread library

user
space

kernel
space

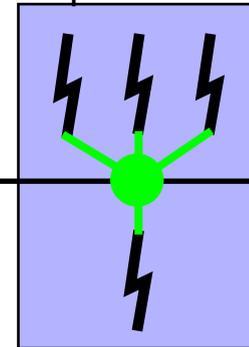
single-threaded

process



multithreaded

process



Vorteile:

- Schnelle Thread Management Operationen
- Sparsamer Gebrauch von Systemressourcen
- Nebenläufiges Programmiermodell, das ohne Modifikation auch auf mehreren Prozessoren ablaufen kann (1 x 1, M x n Modell)

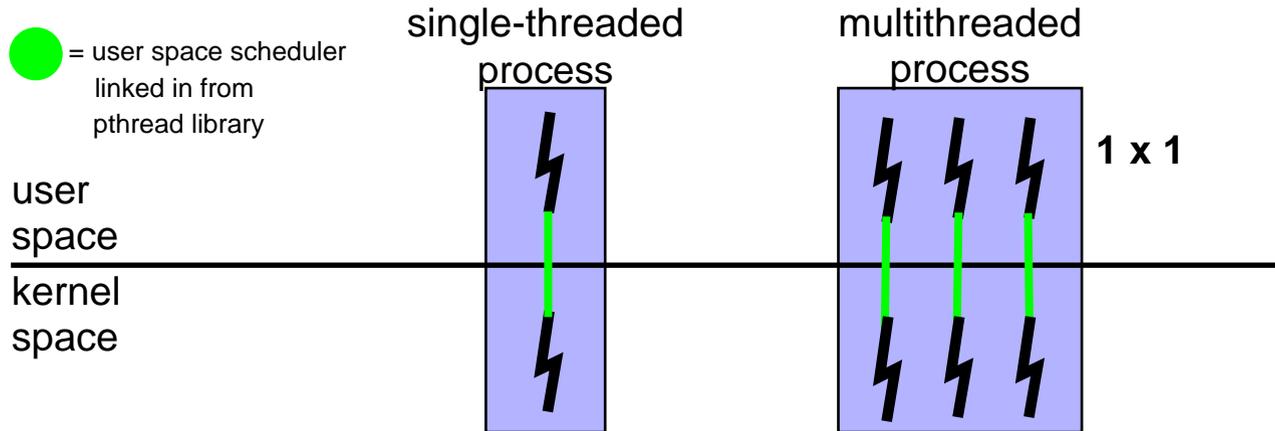
Nachteile:

- Keine echte Parallelität
- Verklemmung in Systemaufrufen möglich!
- Signalbehandlung ist kritisch
- Profiling einzelner Threads nicht möglich
- Debugging einzelner Threads nicht möglich

2 Threadmodell (5)

■ One-to-One (1 x 1)

● = user space scheduler
linked in from
pthread library



Vorteile:

- Echte parallele Ausführung der Threads im Multiprozessor möglich
- Profiling einzelner Threads möglich
- Debugging einzelner Threads möglich

Nachteile:

- Aufwendige Threadverwaltung im OS-Kern
- Hoher Verbrauch an Systemressourcen

2 Threadmodell (6)

■ Many-to-Many (M x N)

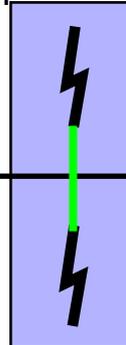
 = user space scheduler
linked in from
pthread library

user
space

kernel
space

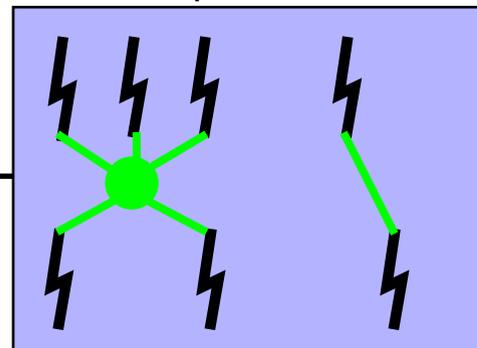
single-threaded

process



multithreaded

process



M x N

Vorteile:

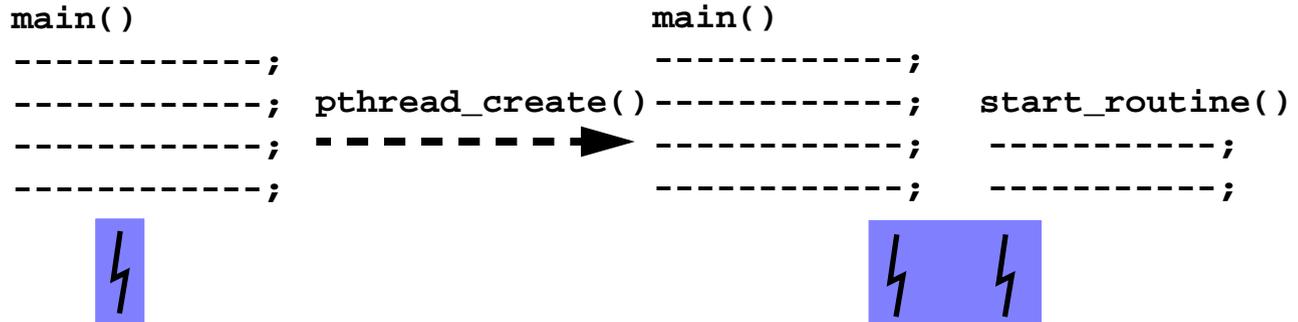
- Flexibles Modell
- Effiziente parallele Ausführung
- Verklemmung an Systemaufrufen kann durch Nachstarten von Kernel-Threads aufgelöst werden.

Nachteile:

- Scheduling auf zwei Ebenen (User- und Kernel-Ebene) steigert die Komplexität.
- Profiling und Debugging ungebundener Threads ist kritisch.

E.2 Basic Pthread Management

1 Erzeugung



- ◆ Ein neuer Thread kann durch

```
pthread_create(pthread_t *thread,
               const pthread_attr_t *attr,
               void *(*start_routine)(void *),
               void *arg)
```

erzeugt werden. Der erzeugte Thread führt als erstes die Funktion `start_routine(arg)` auf. `thread` kann vom Vaterthread als *Handle* auf den erzeugten Thread verwendet werden.

2 Thread-Attribute

◆ Über das `attr` Argument können die Attribute des erzeugten Threads modifiziert werden. Ist `attr == NULL`, werden die Standardattribute gesetzt.

- Initialisieren des Attribut-Objekts:

```
ret_val = pthread_attr_init (&attr);
```

- Setzen der Stack-Größe

```
ret_val = pthread_attr_setstacksize(&attr, stacksize);
```

- Lesen der Stack-Größe

```
ret_val = pthread_attr_getstacksize(&attr, &stacksize)
```

◆ Es gibt noch weitere Parameter (Stackadresse, Joinable/Detached, ...).

→ `man pthread_create`

3 Terminierung

■ Selbst-Terminierung:

- ◆ Ein Thread kann sich durch `void pthread_exit(void *retval)` beenden. Dies geschieht automatisch, wenn der Thread aus der Funktion `start_routine` zurückspringt.

■ Warten auf die Terminierung eines Thread

- ◆ Mit der Funktion

`pthread_join(pthread_t thread, void **retvalp)`

kann der Vaterthread auf die Beendigung eines erzeugten Threads warten. `thread` ist dabei der durch den Aufruf von `pthread_create` erzeugte Handle.

Über `retvalp` wird der Exitstatus des Threads zurückgeliefert. Interessiert der Status nicht, kann als `retvalp` auch `NULL` übergeben werden.

4 Rückgabewerte

- ◆ Die Pthread Funktionen weichen von ihrer Aufrufsemantik von den Standard Kernaufrufen ab. Zwar wird bei einem erfolgreichen Aufruf auch 0 zurückgeliefert, im Fehlerfall wird aber auf die Verwendung von `errno` verzichtet und der Fehlercode direkt zurückgeliefert.
 - ◆ Die anderen Systemaufrufe setzen immer noch die `errno` Variable. Die Fehlerwerte der Pthreads Funktionen lassen sich über `perror()` oder `strerror()` als Fehlermeldung ausgeben.
 - ◆ Da `errno` für jeden Thread verschieden sein muß, ist es normalerweise keine Variable mehr, sondern wird über ein `#define` auf einen Funktionsaufruf abgebildet.
- Setzen des Parallelitätsgrades in SUN Solaris 2.5/6
- ◆ Unter Solaris muß der Parallelitätsgrad (Anzahl der Kernelthreads im M x N Modell) über `thr_setconcurrency(n)` konfiguriert werden.
 - ◆ Das Defaultverhalten ist, daß nur **ein** Kernelthread läuft.

5 Beispiel zur Thread-Erzeugung

■ Beispiel 1: Multiplikation Matrix mit Vektor

```
#include <stdio.h>
#include <pthread.h>
double a[100][100], b[100], c[100];

main() {
    pthread_t tids[100];
    ...
    for (i = 0; i < 100; i++)
        pthread_create(&tids[i], NULL, mult, (void *)(&c[i]));
    for (i = 0; i < 100; i++)
        pthread_join(tids[i], NULL);
    ...
}
```

5 Beispiel zur Thread-Erzeugung (2)

◆ Multiplikationsfunktion `mult()`

```
void *mult(void *cp){
    int j, i = (double *)cp - c;
    double sum = 0;

    for (j = 0; j < 100; j++)
        sum += a[i][j] * b[j];
    c[i] = sum;
    return 0;
}
```

5 Beispiel zur Thread-Erzeugung (3)

- Ergebnisse: 1000x1000 Matrix, `mult` k -fach wiederholt

k	Anzahl der Prozessoren ($nproc$)				
	–	1	2	3	4
1	0.6	1.1	0.8	0.8	0.8
2	0.9	1.3	0.9	0.8	0.8
10	2.9	3.4	2.0	1.4	1.2
100	26.3	26.7	13.3	9.2	7.1

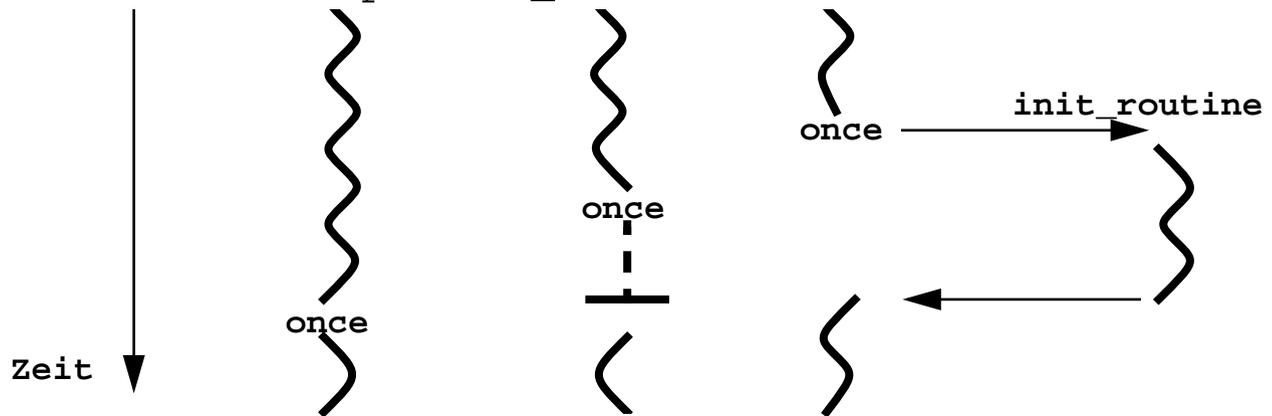
- => Laufzeit setzt sich ungefähr folgendermaßen zusammen:
 - 0.3s Initialisierung,
 - 0.4s Starten und Beenden von 1000 Threads,
 - ($k \times 0.26s$) / $nproc$ reine Rechenzeit.

6 Identifikation

- Ein Thread kann seinen Thread-Handle über `pthread_t pthread_self(void)` erfragen.
- Es ist nicht garantiert, daß man Thread-Handles mit `==` auf Gleichheit überprüfen kann.
 - Die Funktion `pthread_equal(pthread_t t1, pthread_t t2)` liefert `TRUE` zurück, wenn die beiden Threads identisch sind.

7 Initialisierungen

- Initialisierungen dürfen häufig nur genau einmal durchgeführt werden.
- Die Pthread Bibliothek erleichtert diese Aufgabenstellung mit der `pthread_once()` Funktion.
- Die übergebene Funktion wird genau einmal vom dem Thread ausgeführt, der das erste Mal `pthread_once` aufruft.
- Arbeitet gerade ein Thread die Initialisierungsfunktion ab, blockieren alle anderen Threads im `pthread_once` Aufruf.



7 Initialisierungen (2)

- Syntax:

```
pthread_once(pthread_once_t *once_block,  
             void (*init_routine)(void))
```

- Der `once_block` wird von der Pthreads Bibliothek zur Speicherung von Statusinformation benötigt. Er muß *statisch* mit `PTHREAD_ONCE_INIT` initialisiert werden.
- Leider kann der Initialisierungsfunktion kein Argument mitgegeben werden.

8 Threadlokale globale Variablen

- Threadlokale Variablen sind normalerweise nur Variablen, die auf dem Programmstack abgelegt wurden.
- Es ist manchmal wünschenswert, threadspezifische Variablen zu verwenden, die unabhängig von der Aufrufhierarchie (Stack) sind.
- Threadlokale Variablen werden durch globale *Keys* implementiert. Jedem Key kann ein Wert zugewiesen werden, der threadlokal gespeichert wird.

◆ Ein Key kann mit der Funktion

```
pthread_key_create(pthread_key_t *key,  
                  void (*destructor)(void *))
```

angelegt werden. Dieser Aufruf bewirkt folgendes:

- Das System legt Speicherplatz für den Wert des Keys an.
- Außerdem kann dem System eine Funktion mitgeteilt werden, die beim Überschreiben und Löschen eines Wertes aufgerufen werden soll. Hierdurch lassen sich auch komplizierte Strukturen als Wert speichern.

8 Threadlokale globale Variablen (2)

- ◆ Soll ein Wert an einen Key zugewiesen werden, ist `pthread_setspecific(pthread_key_t key, void *value)` aufzurufen. Hierbei wird der Wert `value` unter dem Key `key` gespeichert.
- ◆ Der gespeicherte Wert kann mit `void *pthread_getspecific(pthread_key_t key)` abgefragt werden.
- ◆ Wird ein globaler Key nicht mehr benötigt, sollte `pthread_key_delete(pthread_t key)` aufgerufen werden.

E.3 Synchronisation

- Da die einzelnen Threads gleichzeitig ablaufen, kann es zu ungewollten Effekten beim Zugriff auf den Speichern kommen (sogenannte *Race Conditions*).

Beispiel: Erhöhung eines Zählers

```
int var;
void *incr(void *arg) {
    int i;
    for (i = 0; i < 10000; i++)
        var++;
    return NULL;
}
.....
pthread_create(&son1, NULL, incr, NULL);
pthread_create(&son2, NULL, incr, NULL);
pthread_join(son1, NULL);
pthread_join(son2, NULL);
printf("Result: %d\n", var);
```

E.3 Synchronisation (2)

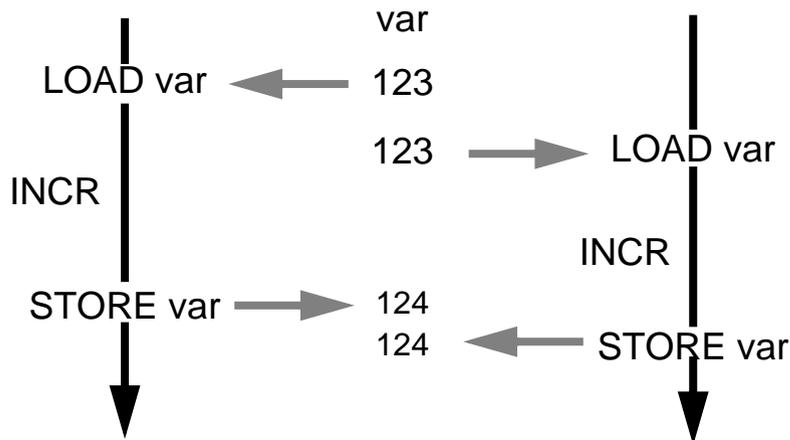
- Dreimaliges Aufrufen des Programms auf einer SUN ergab folgende Werte:

Result: 13950

Result: 13881

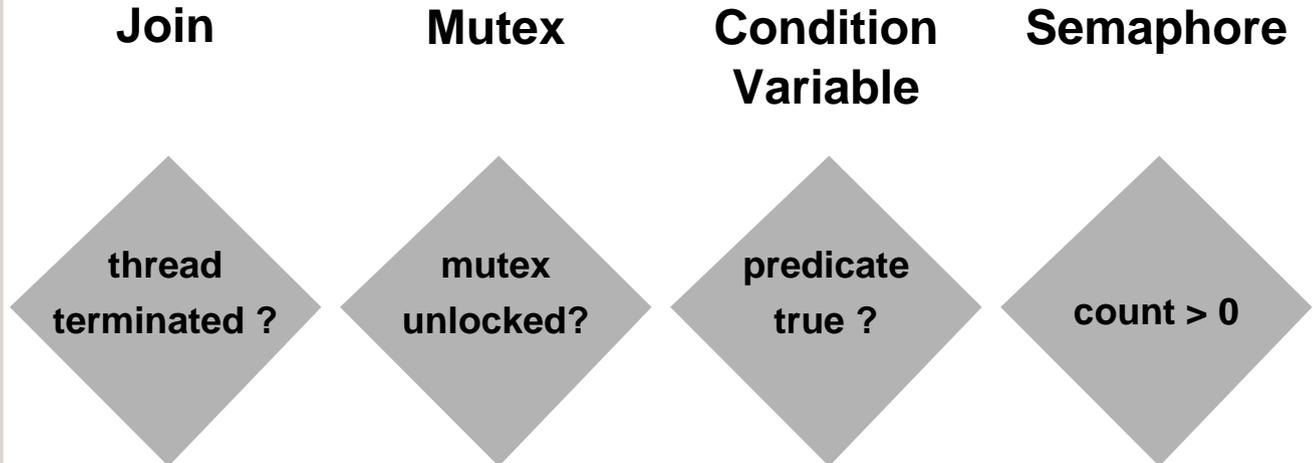
Result: 13638

Ursache für dieses Verhalten: Die `var++` Anweisung besteht aus einer Lese- und einer Schreiboperation. Versucht der zweite Thread zwischen diesen beiden Operationen, den Zähler zu erhöhen, geht ein `var++` verloren:



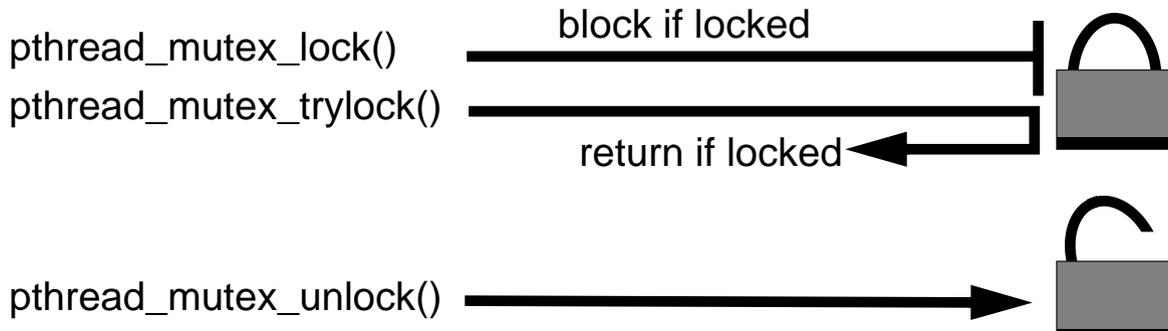
E.3 Synchronisation (3)

1 Mechanismen zur Thread-Koordination



2 Mutex

- Programmabschnitte, in denen sich zu einem Zeitpunkt nur ein Thread befinden darf, werden als *critical Section* bezeichnet.
Beispiel: Erhöhung eines Zählers
- Der Pthread Standard bietet die Möglichkeit, kritische Abschnitte durch einen *Mutex* zu sperren.
In einem gesperrten Bereich kann sich höchstens ein Thread aufhalten. Will zusätzlich ein zweiter Thread den Bereich betreten, muß dieser solange warten, bis der erste Thread den Bereich “entriegelt” hat.
- Ein Mutex ist also mit einem Türschloß vergleichbar.



2 Mutex (2)

■ Erzeugen eines Mutexes:

- ◆ Beim Kompilieren (statisch), durch

```
pthread_mutex_t lock = PTHREAD_MUTEX_INITIALIZER;
```

- ◆ Beim Programmlauf (dynamisch), durch

```
pthread_mutex_init(pthread_mutex_t *mutex,  
                  pthread_mutexattr_t *attr)
```

`mutex` muß auf einen gültigen Speicherbereich zeigen.

- ◆ Beim dynamischen Aufruf können wie bei der Erzeugung von Threads Attribute gesetzt werden. Für einen Standardmutex kann dieses Argument `NULL` sein.

■ Vernichten eines Mutexes:

- ◆ Wird ein Mutex nicht mehr benötigt, kann dies dem System mit

```
pthread_mutex_destroy()
```

 mitgeteilt werden.

Die Pthread Bibliothek kann dann die zugeordneten Ressourcen freigeben.

2 Mutex (3)

- Ein Mutex kann durch `pthread_mutex_lock(pthread_mutex_t *mutex)` verriegelt werden. Nach diesem Aufruf ist sichergestellt, daß der aktuelle Thread als einziges den Mutex belegt hat.
- Nach dem kritischen Codeabschnitt kann mit `pthread_mutex_unlock(pthread_mutex_t *mutex)` der Mutex entriegelt werden.
- Soll nicht die erfolgreiche Verriegelung abgewartet werden, kann `pthread_mutex_trylock(pthread_mutex_t *mutex)` verwendet werden. Diese Funktion liefert einen Fehler (**EBUSY**) zurück, wenn der Mutex durch einen anderen Thread belegt ist.

2 Mutex (4)

■ Beispiel:

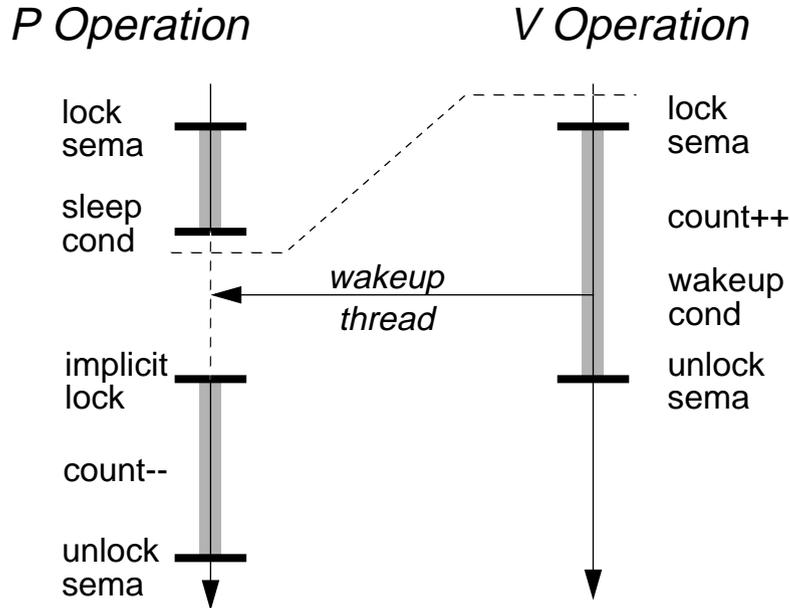
```
int var;
pthread_mutex_t varlock = PTHREAD_MUTEX_INITIALIZER;
...
for (i = 0; i < 10000; i++) {
    pthread_mutex_lock(&varlock);
    var++;
    pthread_mutex_unlock(&varlock);
}
```

3 Condition-Variablen

- Häufig muß ein Programm auf das Eintreffen bestimmter Ereignisse warten. Dieses Warten sollte nicht aktiv geschehen (*polling*), da sonst wertvolle Rechenzeit ungenutzt bleibt.
- Stattdessen sollte es eine Möglichkeit geben, daß sich Threads “schlafen legen” (*sleep*). Wenn ein anderer Thread feststellt, daß das gewünschte Ereignis eingetroffen ist, kann der schlafende Thread geweckt werden (*wakeup*).
- Normalerweise bezieht sich das Ereignis auf eine Struktur, die durch ein Mutex gelockt werden muß. Deshalb muß der Sleep-Aufruf den Mutex automatisch freigeben. Nach dem Wakeup muß dann ein implizites Lock durchgeführt werden.
- Im Prinzip ist die Idee der Condition-Variablen identisch mit dem `sleep()`/`wakeup()` Mechanismus, der im UNIX Kern verwendet wird. Allerdings wird dort anstelle der Mutexe ein `splhi()` Aufruf verwendet, der die Interrupts sperrt.

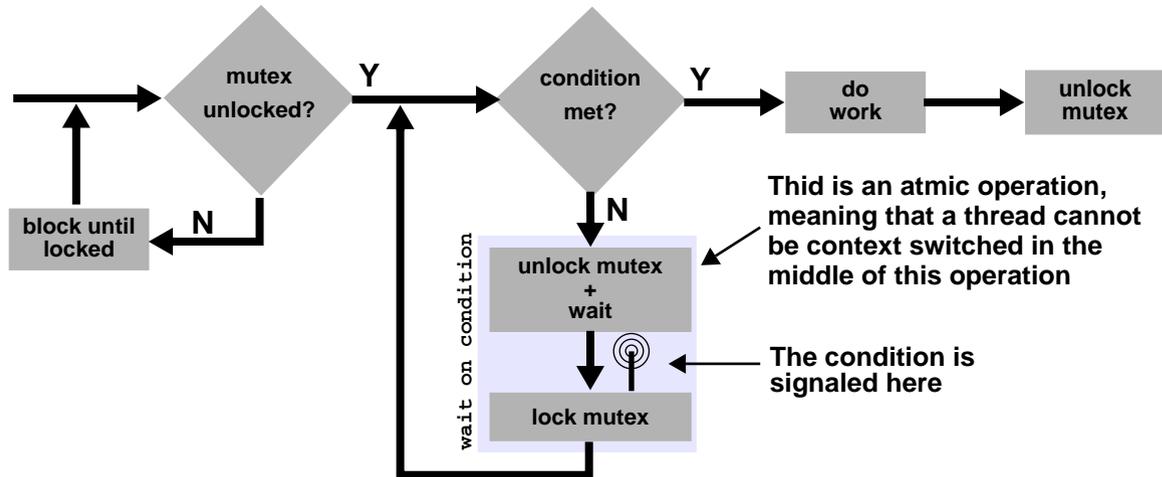
3 Condition-Variablen (2)

- Beispiel: P/V Semaphore.
Die kritische Struktur ist der Zähler. Das Ereignis, auf das gewartet werden muß, ist "count > 0".



3 Condition-Variablen (3)

- Wenn mehr als ein Thread eine P-Operation durchführen kann, muß nach jedem *Wakeup* die Bedingung neu getestet werden und gegebenenfalls wieder ein *Sleep* durchgeführt werden.



This is an atomic operation, meaning that a thread cannot be context switched in the middle of this operation

The condition is signaled here

```
lock associated mutex
while (predicate is not true)
    wait on condition variable
do work
unlock associated mutex
```

3 Condition-Variablen (4)

■ Erzeugen einer Condition-Variablen

◆ Eine Condition-Variable wird ähnlich wie ein Mutex erzeugt:

◆ Statisch durch

```
pthread_cond_t cond = PTHREAD_COND_INITIALIZER;
```

◆ Dynamisch mit

```
pthread_cond_init(pthread_cond_t *cond,  
                  const pthread_condattr_t *attr)
```

◆ Wie bei der Mutexerzeugung können wieder Attribute angegeben werden. Sollen die Standardattribute verwendet werden, kann `NULL` verwendet werden.

■ Vernichten einer Condition-Variablen

◆ Mit der Funktion

```
pthread_cond_destroy(pthread_cond_t *cond)
```

kann dem System mitgeteilt werden, daß diese Condition-Variable nicht mehr verwendet wird.

3 Condition-Variablen (5)

■ Synchronisation (1):

◆ Mit

```
pthread_cond_wait(pthread_cond_t *cond,  
                  pthread_mutex_t *mutex)
```

kann sich ein Thread auf der Condition-Variablen `cond` blockieren.
`mutex` gibt hierbei den Mutex an, der implizit freigegeben werden soll.

◆ Von diesem Aufruf gibt es auch eine Version mit Zeitbegrenzung:

Mit

```
pthread_cond_timedwait(pthread_cond_t *cond,  
                        pthread_mutex_t *mutex,  
                        const struct timespec *abstime)
```

kann ein Zeitpunkt angegeben werden, zu dem der Aufruf mit einem Fehler
(**ETIMEDOUT**) abgebrochen wird.

3 Condition-Variablen (6)

■ Synchronisation (2):

◆ Das Eintreffen eines Ereignisses kann durch `pthread_cond_signal(pthread_cond_t *cond)` signalisiert werden. Das System weckt hierbei höchstens einen Thread auf (abhängig von der Schedulingpriorität).

◆ Sollen alle Threads aufgeweckt werden, die sich an der Condition-Variablen blockiert haben, ist dies mit `pthread_cond_broadcast(pthread_cond_t *cond)` möglich.

◆ Beispiel in Pseudo-Code:

```
lock associated mutex
set predicate to true
signale condition variable (wake-up one or all)
unlock associated mutex
```

3 Condition-Variablen (7)

■ Beispiel

- ◆ s soll eine P/V Semaphore implementiert werden.

```
typedef struct {
    pthread_mutex_t mutex;
    pthread_cond_t cond;
    int count;
} mysem_t;
```

- ◆ Initialisierung:

```
void mysem_init(mysem_t *ms, int init) {
    pthread_mutex_init(&ms->mutex, NULL);
    pthread_cond_init(&ms->cond, NULL);
    ms->count = init;
}
```

Resourcenfreigabe

```
void mysem_destroy(mysem_t *ms) {
    pthread_mutex_destroy(&ms->mutex);
    pthread_cond_destroy(&ms->cond);
}
```

3 Condition-Variablen (8)

◆ P Operation:

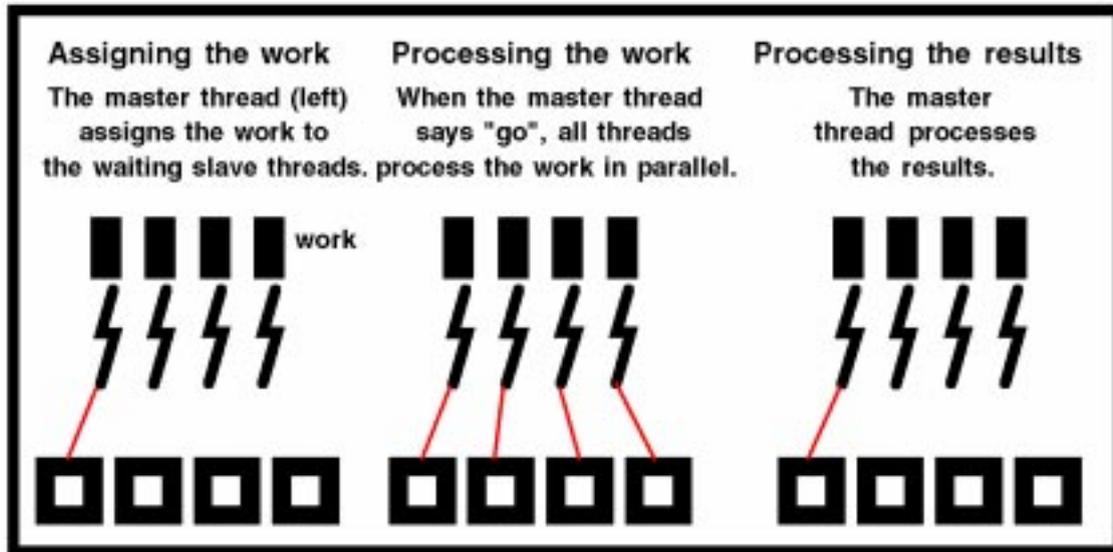
```
void mysem_p(mysem_t *ms) {
    pthread_mutex_lock(&ms->mutex);
    while (ms->count <= 0) {
        pthread_cond_wait(&ms->cond,
                          &ms->mutex);
    }
    ms->count--;
    pthread_mutex_unlock(&ms->mutex);
}
```

◆ V Operation:

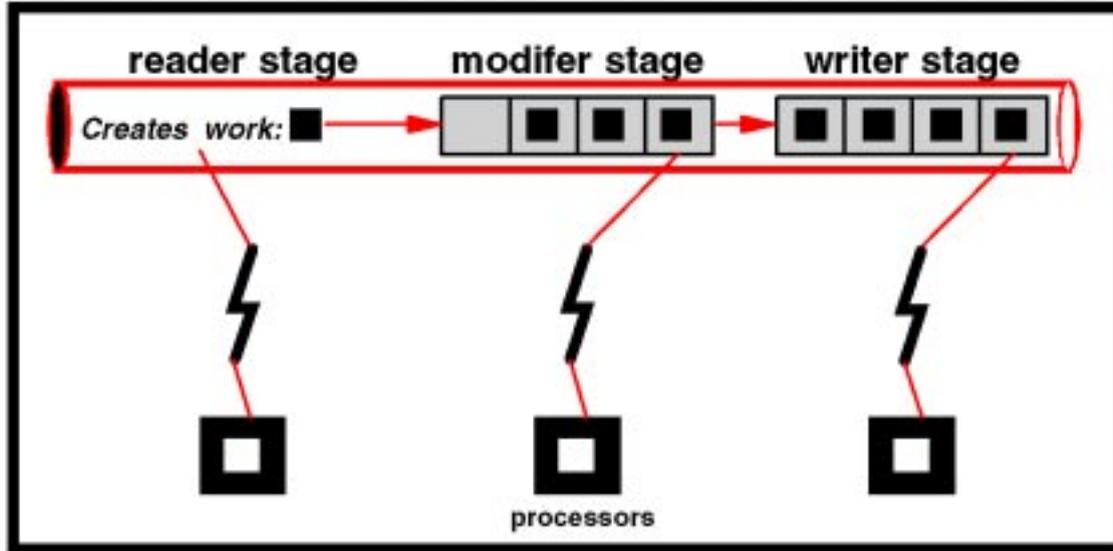
```
void mysem_v(mysem_t *ms) {
    pthread_mutex_lock(&ms->mutex);
    ms->count++;
    pthread_cond_signal(&ms->cond);
    pthread_mutex_unlock(&ms->mutex);
}
```

E.4 Parallelisierungsmodelle

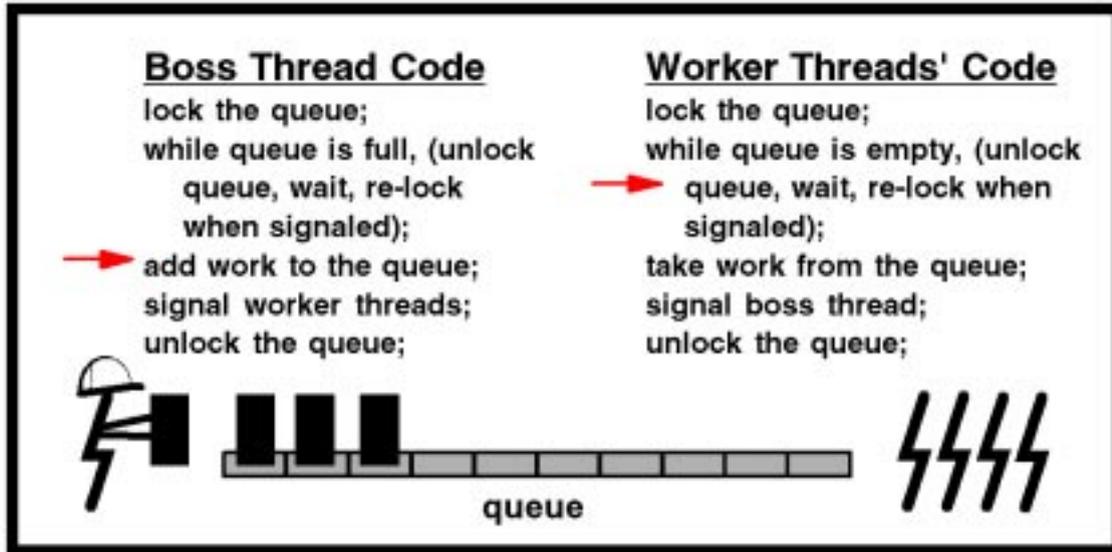
1 Master-Slave Modell



2 Pipeline Modell



3 Boss-Worker Modell



E.5 Attribute

- Bei einigen Pthread Aufrufen (`pthread_create`, `pthread_mutex_init`, `pthread_cond_init`) kann eine Attributstruktur als Parameter spezifiziert werden, mit dem das neue Objekt konfiguriert wird.
- Das Erzeugen/Setzen/Abfragen von Attributen geschieht immer nach dem gleichen Schema:
 - ◆ Initialisierung der Attributstruktur.
 - ◆ Abfragen oder Setzen der gewünschten Werte.
 - ◆ Erzeugung des neuen Objektes unter Benutzung eines Zeiger auf die Attributstruktur als Parameter.
 - ◆ Gegebenenfalls Freigabe der Attributstruktur.

E.5 Attribute (2)

- Initialisieren der Attributstruktur:

```
pthread_XXXattr_init(pthread_XXXattr_t *attr)
```

- Auslesen eines einzelnes Attributs:

```
pthread_XXXattr_getATTR(pthread_XXXattr_t *attr,  
                          ATTRTYP *pointer)
```

- Setzen eines einzelnes Attributs:

```
pthread_XXXattr_setATTR(pthread_XXXattr_t *attr,  
                          ATTRTYP value)
```

- Freigeben eines einzelnes Attributs:

```
pthread_XXXattr_destroy(pthread_XXXattr_t *attr)
```

- Attributierbare Objekte: XXX:

- Threads: XXX = "" (Leerstring)
- Mutex: XXX = "mutex"
- Conditional: XXX = "cond"

E.6 Thread Scheduling

1 Festlegung des Thread-Modells (1 x 1, M x 1, M x N)

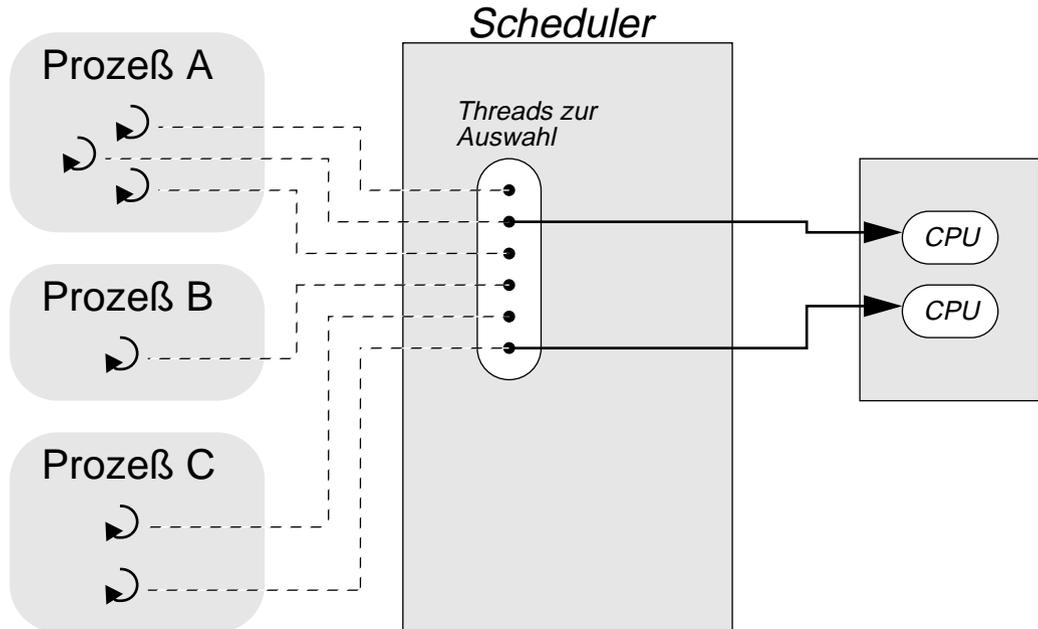
- Das Modell für die Bindung an die Kernel-Threads wird durch den Scheduling-Scope festgelegt. Der gewünschte Scope für einen Thread kann durch ein Threadattribut der Funktion `pthread_create` mitgeteilt werden:

`ATTR=scope, ATTRTYP=int`

- ◆ `PTHREAD_SCOPE_SYSTEM`: Die Schedulingstrategie soll für alle laufenden Threads des Systems (also aus allen Prozessen) gelten.
Es handelt sich hier um einen gebundenen Thread (1 x 1 Modell).
- ◆ `PTHREAD_SCOPE_PROCESS`: Die Schedulingstrategie soll nur für die Threads eines Prozesses gelten. Zwischen den Prozessen wird mit dem standard Systemscheduler umgeschaltet.
Es handelt sich hier um einen ungebundenen Thread (M x 1, M x N Modell)

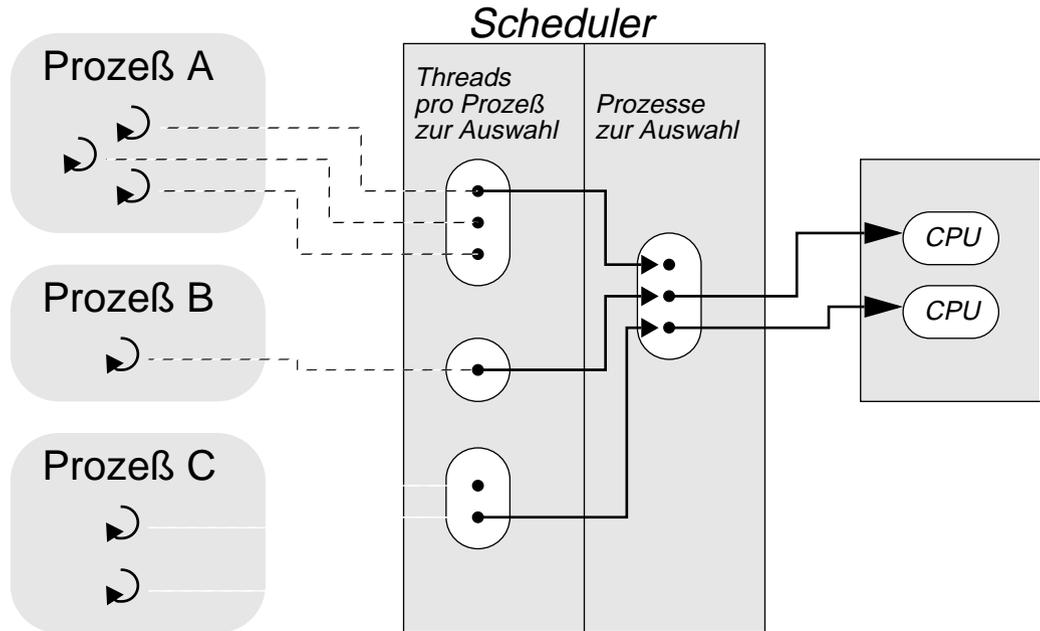
1 Scheduling Scope (2)

■ Beispiel für System-Scope



1 Scheduling Scope (3)

■ Beispiel für Prozeß-Scope (M x 1)



2 Scheduling Strategie

- Die gewünschte Scheduling Strategie für einen Thread kann durch ein Threadattribut der Funktion `pthread_create` mitgeteilt werden:

`ATTR=schedpolicy, ATTRTYP=int`

- ◆ `SCHED_FIFO`: Ein Thread läuft bis er stirbt oder sich blockiert. Wenn er, nachdem er sich blockiert hat, weiterlaufen kann, wird er am Ende der Queue für seine Priorität eingehängt.
Dieser Attributwert ist nur für gebundene Threads anwendbar und für Echtzeitanwendungen vorgesehen (In Solaris nicht implementiert).
- ◆ `SCHED_RR`: Ähnlich wie `SCHED_FIFO`, allerdings wird der Thread auf jeden Fall nach Ablauf eines festen Quantum unterbrochen.
Dieser Attributwert ist nur für gebundene Threads anwendbar und für Echtzeitanwendungen vorgesehen (In Solaris nicht implementiert).
- ◆ `SCHED_OTHER`: Eine beliebige Strategie. Dies ist die Standardeinstellung!
Dieser Attributwert ist nur für Threads im Time-Sharing Betrieb anwendbar.

3 Threadpriorität

- Die gewünschte Priorität eines **ungebundenen Threads** kann durch ein Attribut der Funktion `pthread_create` mitgeteilt werden:

`ATTR=schedparam, ATTRTYP=struct sched_param`

Die Struktur wird auch beim `set` Aufruf als Pointer übergeben!

Die verwendeten Parameter sind abhängig von der eingestellten Schedulingstrategie. POSIX.1b erzwingt genau ein Attribut für `sched_param`:

```
struct sched_param {  
    int sched_priority;  
};
```

Um den Bereich abzufragen, in dem `sched_priority` gültig ist, können die POSIX.1b Aufrufe

```
sched_get_priority_max(int schedpolicy)
```

```
sched_get_priority_min(int schedpolicy)
```

verwendet werden.

- Die Priorität von **gebundenen Threads** kann durch einen Systemaufruf `prctl()` geändert werden.

4 Scheduling Parameter

- Die Schedulingparameter von laufenden ungebundenen Threads können nachträglich angepaßt werden. Dies geschieht über

```
pthread_getschedparam(pthread_t thread,  
                      int *policy,  
                      struct sched_param *param)
```

und

```
pthread_setschedparam(pthread_t thread,  
                      int policy,  
                      struct sched_param *param)
```

- `policy` und `param` entsprechen den Parametern, wie sie bei den Threadattributen werden (`policy`: `SCHED_FIFO`, `SCHED_RR`, `SCHED_OTHER`, `param`: `sched_priority`).

5 Vererbung von Scheduling Parametern

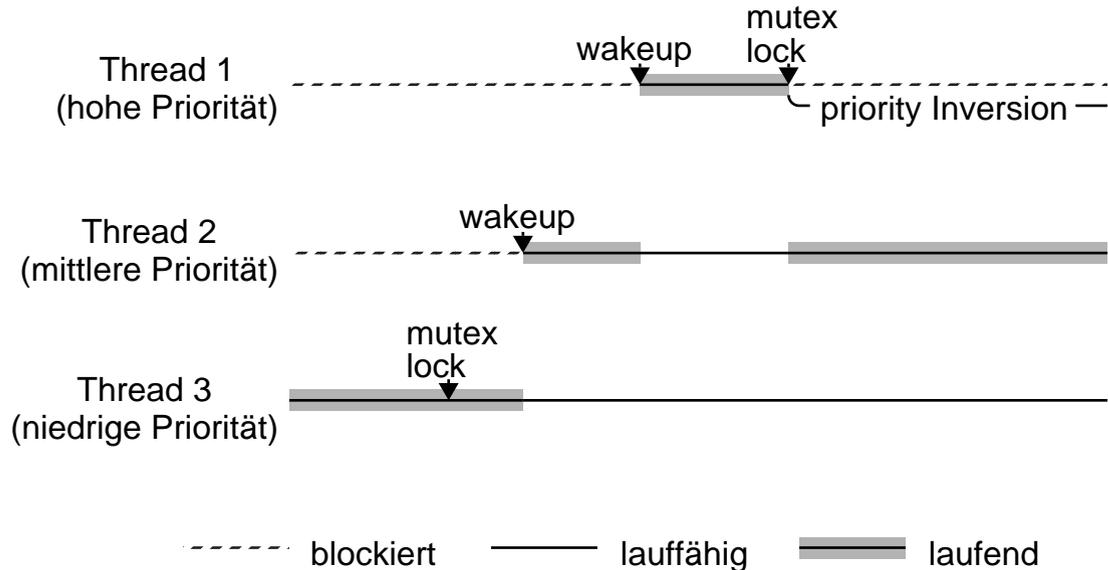
- Ein Attribut kann festlegen, ob die Schedulingparameter aus der Attributstruktur übernommen werden sollen, oder ob diese ignoriert werden und die Parameter vom Vaterthread kopiert werden sollen.
ATTR=`inheritsched`, ATTRTYP=`int`
 - ◆ `PTHREAD_INHERIT_SCHED`: Kopiere die Parameter vom Vaterthread
 - ◆ `PTHREAD_EXPLICIT_SCHED`: Übernehme die Parameter aus dem Prozeßattributobjekt.

6 Priority Inversion

- Über die Mutexattribute lassen sich Strategien zur Vermeidung von *Priority Inversion* konfigurieren. Außerdem ist einstellbar, daß Mutexe auch über Prozeßgrenzen hinweg funktionieren sollen.
- Priority Inversion bedeutet, daß ein Thread mit hoher Priorität nicht arbeiten kann, weil ein anderer mit niedriger Priorität eine Resource hält.
- Dies kann in Realtime-Anwendungen zu drastischen Problemen führen.

6 Priority Inversion (2)

■ Beispiel:



6 Priority Inversion (2)

■ Strategie 1: Priority Ceiling

- ◆ Hier wird jedem Mutex eine eigene Priorität zugeordnet. Wenn ein Thread einen kritischen Abschnitt betritt und einen Mutex lockt, bekommt er automatisch die Priorität zugeteilt. Beim Unlock des Mutex wird seine alte Priorität restauriert.
- ◆ Diese Strategie ist verwendbar, wenn die Konstante `_POSIX_THREAD_PRIO_PROTECT` definiert ist.
- ◆ Priority Ceiling wird gewählt, indem das Attribut `ATTR=protocol`, `ATTRTYPE=int` in den Mutexattributen auf `PTHREAD_PRIO_PROTECT` gesetzt wird.
Der Attributwert `PTHREAD_PRIO_NONE` schaltet Priority Ceiling wieder ab.
- ◆ Die Priorität des Mutexes sollte so hoch gewählt werden, wie das Maximum der Prioritäten aller Threads, die den Mutex belegen können.
- ◆ Die Priorität des Mutexes ist mit dem Attribut `ATTR=prioceiling`, `ATTRTYPE=int` einstellbar.

6 Priority Inversion (3)

■ Strategie 2: Priority Inheritance

- ◆ Hier wird die Priorität des Threads, der den Mutex belegt hat, dynamisch so verändert, daß sie immer so groß ist wie das Maximum der Prioritäten aller Threads, die auf den Mutex warten.
- ◆ Diese Strategie ist verwendbar, wenn die Konstante `_POSIX_THREAD_PRIO_INHERIT` definiert ist.
- ◆ Priority Inheritance wird gewählt, indem das Attribut `ATTR=protocol`, `ATTRTYPE=int` in den Mutexattributen auf `PTHREAD_PRIO_INHERIT` gesetzt wird.

7 Entkopplung von Threads (detached threads)

- Mit `pthread_detach(pthread_t thread)` kann der Pthread-Bibliothek mitgeteilt werden, daß der Exitstatus des Threads `thread` nicht gespeichert werden soll.
 - Automatische Freigabe aller Thread-Ressourcen.
 - Ein `pthread_join` ist nicht mehr möglich.
 - Die ID eines Thread kann nach seiner Terminierung für einen neuen Thread wiederverwendet werden! Falls unklar ist, ob ein entkoppelter Thread schon terminiert ist, darf seine Handle nicht mehr verwendet werden.
- Die Entkopplung kann auch direkt über ein Attribut beim Aufruf von `pthread_create` geschehen.
 - ◆ `ATTR=detachstate, ATTRTYP=int`
 - `PTHREAD_CREATE_JOINABLE`: Auf diesen Thread kann ein `join()` durchgeführt werden, d.h., das System muß sich den "Exitstatus" merken.
 - `PTHREAD_CREATE_DETACHED`: Dieser Thread soll völlig unabhängig vom Vaterthread laufen.

7 Entkopplung von Threads (2)

- Soll ein Server für jede Anfrage einen neuen Thread starten (ala *inetd*), ist es nicht sinnvoll, daß der erzeugt Thread noch Verbindung zu seinem Vaterthread hat.
- Beispiel – Server Applikation:

```
main() {  
    ...  
    for (;;) {  
        pthread_t worker;  
        req = malloc(sizeof *req);  
        wait_for_request(&req);  
        pthread_create(&worker, NULL,  
                      process, req);  
        pthread_detach(worker);  
    }  
}
```

E.7 UNIX Interaktion

- UNIX kennt traditionell nur Prozesse als Aktivitätsträger, die alle einen eigenen Adreßraum besitzen. Daraus resultieren eine Reihe von Problemen bezüglich Threads:
 - ◆ Können sich mehrere Threads gleichzeitig in einer Bibliotheksfunktion befinden?
 - ◆ Was passiert, wenn eine Cancellation geschieht, während der Thread eine Bibliotheksfunktion abarbeitet?
 - ◆ UNIX Signale: Wenn ein Prozeß ein Signal empfängt, welche Folgen entstehen für die Threads?
 - ◆ Was passiert bei *fork()*, *exec()* und *exit()*?
 - ◆ Gibt es eine Synchronisation über Prozeßgrenzen hinweg?
 - ◆ Was passiert, wenn eine Funktion einen Systemaufruf tätigt, der sich blockiert?

1 Bibliotheksaufrufe

- Durch die Verwendung von Threads kann es passieren, daß sich mehrere Aktivitätsträger gleichzeitig in einer Funktion befinden. Wenn die Funktion Datenstrukturen manipuliert, kann es zu Fehlern kommen, wenn diese nicht mit Mutexen oder anderen Locks versehen wurden.
- Funktionen, die so gesichert wurden, nennt man (*multi-*) *thread-safe* (*MT-safe*) oder *reentrant*.
- Alle POSIX-Funktionen sind MT-safe, bis auf zwei Klassen von Ausnahmen:
 - ◆ Funktionen, deren Spezifikation dies nicht zuläßt.
 - ◆ Funktionen, die aus Geschwindigkeitsgründen nicht mit Locks versehen wurden.

1 Bibliotheksaufrufe (2)

- Funktionen, die von ihrer Spezifikation nicht threadsafe gemacht werden können, sind solche, die Daten in einen statischen Puffer hinterlegen und häufig einen Zeiger auf sie zurückliefern. Dies sind zum Beispiel `rand()`, `getpw*()`, `ctime()`, `strtok()`...
- Für viele dieser Funktionen spezifiziert der Pthread Standard ein zweites Interface, bei dem der Puffer über zusätzliche Parameter übergeben werden kann. Diese Funktionen enden alle auf `_r` (wie `reentrant`).

- Beispiel:

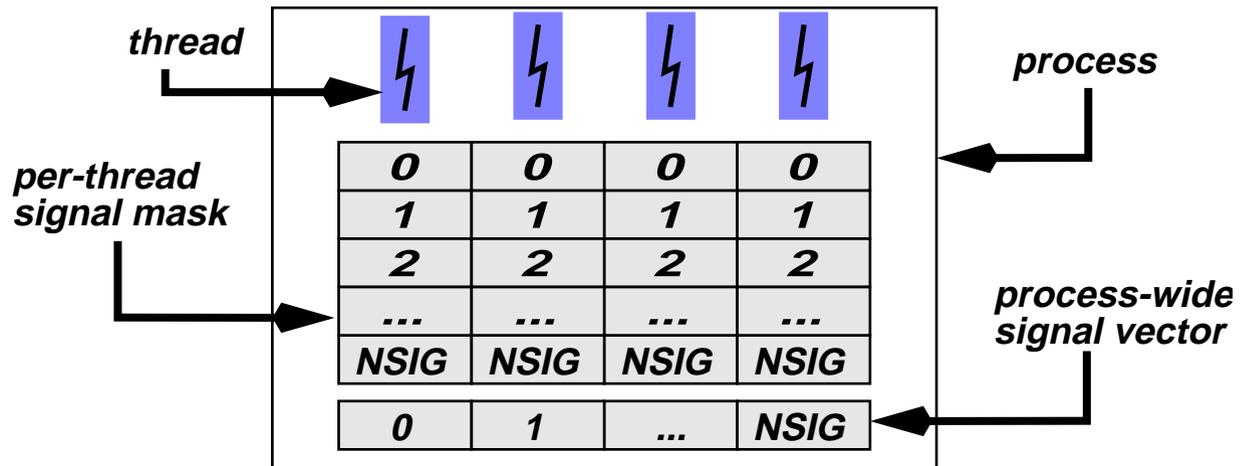
```
char *ctime_r(const time_t *clock,  
              char *buf, int buflen)
```

1 Bibliotheksaufrufe (3)

- Die Standard-IO Funktionen `getc/getchar/putc/putchar` wurden zwar threadsafe gemacht, es existiert aber noch eine Variante, bei der auf das Lock verzichtet wird.
- Diese Funktionen enden auf `_unlocked`. Sie eignen sich vor allem dann, wenn sie für eine Zeitlang häufig hintereinander aufgerufen werden. In diesem Fall ist es sinnvoll, vor dem ersten Aufruf das `FILE` zu locken, die Aufrufe durchzuführen, und danach ein `Unlock` aufzurufen.
- Die `FILE`-Struktur kann mit `flockfile(FILE *stream)`, `funlockfile(FILE *stream)` und (nicht blockierend) mit `ftrylockfile(FILE *stream)` gesperrt und freigegeben werden.

2 Signale

- Um kompatibel zu UNIX zu bleiben, spezifizierten die Pthread Entwickler, daß Signale sich auf ganze Prozesse beziehen. Ein Signalhandler gilt also für alle Threads, es kann der standard POSIX Aufruf *sigaction()* verwendet werden.
- Allerdings erlaubt der Pthread Standard jedem Thread, Signale auszumaskieren. Dies erlaubt den Benutzer, die Aufgaben des Signalhandlings an einzelne Threads zu verteilen.



2 Signale (2)

- Die Art, Signale zu maskieren, entspricht der Technik, die POSIX für Prozesse spezifiziert hat:
 - ◆ Es gibt eine Signalmaske die alle Signale enthält.
 - ◆ Diese kann gelesen/verändert/gesetzt werden.
- Setzen der Threadsignalmaske (analog zu `sigprocmask`):

```
int pthread_sigmask(int how, const sigset_t *set,
                    sigset_t *oset)
```
- Wenn `oset` gesetzt ist, wird hier die alte Maske hinterlegt.
- Ist `set` gesetzt, wird die aktuelle Maske verändert. `how` gibt an, in welcher Weise dies geschehen soll:
 - ◆ `SIG_BLOCK`: die Maske wird zu der aktuellen Maske hinzugefügt.
 - ◆ `SIG_UNBLOCK`: die Maske wird von der aktuellen entfernt.
 - ◆ `SIG_SETMASK`: die Maske wird übernommen.

2 Signale (3)

- Beim Eintreffen eines Signals wählt das System einen Thread aus, der den Signalhandler aufruft.
 - ◆ Wenn das Signal eindeutig einem Thread zugeordnet werden kann (z.B. bei Exceptions (`SEGV...`)), wird dieser Thread verwendet.
 - ◆ Andernfalls wird ein beliebiger Thread ausgewählt, der das Signal nicht blockiert hat.
- Es ist auch möglich, ein Signal direkt an einen Thread des gleichen Prozesses zu schicken:
`pthread_kill(pthread_t thread, int sig)`
thread ist durch `pthread_create` oder `pthread_self` erhaltene Threadkontrollblock.

2 Signale (4)

- Für einen Signalhandler gelten einige Einschränkungen: Er darf nur Funktionen aufrufen, die *asynchronous signal-safe* sind. Das bedeutet, daß die Funktion gefahrlos unterbrochen werden kann, ohne daß Inkonsistenzen oder Deadlocks eintreten. Async signal-safe ist somit eine Einschränkung von MT-safe.
- Der Standard führt eine Reihe von Funktionen auf, die signal-safe sein müssen. Dies sind praktisch nur Kernaufrufe.
- *Keine* der Pthread Funktionen muß signal-safe sein! Das bedeutet, daß in einem Signalhandler keine Mutexe oder ähnliches verwendet werden dürfen.

2 Signale (5)

- Diese Einschränkung ist nicht ganz so schlimm, wie sie sich zuerst anhört. Man löst das Problem dadurch, indem man einen Thread startet, der nur für die Annahme des gewünschten Signals zuständig ist. Alle Threads maskieren dieses Signal aus.
- Dieser Thread ruft die POSIX Standardfunktion `sigwait()` auf, die solange wartet, bis ein Signal eintrifft, und dann zurückkehrt:

```
int sigwait(const sigset_t *set, int *sig)
```

`set` gibt an, auf welche Signale gewartet werden soll. In `sig` wird bei Eintreffen die Signalnummer gespeichert.

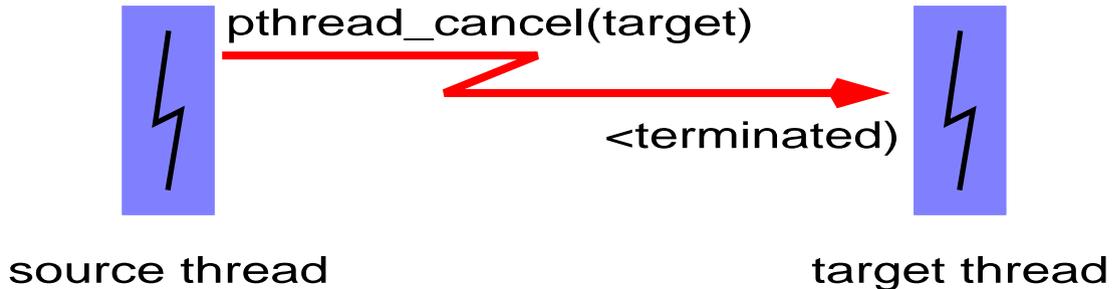
2 Signale (6)

■ Beispiel: SIGCHLD Handler

```
sigset_t chldset;
pthread_t chldthr;
...
void *chldhand(void *arg) {
    int sig;
    for (;;) {
        sigwait(&chldset, &sig);
        waitpid()
        ...
    }
    ...
    sigemptyset(&chldset);
    sigaddset(&chldset, SIGCHLD);
    pthread_sigmask(SIG_BLOCK, &chldset, NULL);
    pthread_create(&chldthr, NULL, chldhand, NULL);
}
```

3 Abbruch eines Threads

- Manche Probleme erfordern die Möglichkeit, laufende Threads abubrechen (sogenannte *Thread Cancellation*).
Beispiel: Falls ein Thread in einem Suchalgorithmus erfolgreich war, ist es nicht mehr nötig, daß alle andern Threads weitersuchen.



- Ein Thread kann mit `pthread_cancel(pthread_t thread)` versuchen, den durch `thread` beschriebenen Thread abubrechen.

3 Abbruch eines Threads (2)

- Der Pthread Standard ermöglicht drei Arten, mit denen ein Thread auf eine Abbruchaufforderung reagieren kann:
 - ◆ Er kann sie ignorieren (`PTHREAD_CANCEL_DISABLE`)
 - ◆ Er kann sofort abbrechen.
(`PTHREAD_CANCEL_ENABLE` + `PTHREAD_CANCEL_ASYNCHRONOUS`)
 - ◆ Er kann sich die Aufforderung merken und beim nächsten Cancellation-Point abbrechen.
(`PTHREAD_CANCEL_ENABLE` + `PTHREAD_CANCEL_DEFERRED`)Dies ist standardmäßig eingestellt.

Cancelstate	Canceltype
<code>PTHREAD_CANCEL_ENABLE</code>	<code>PTHREAD_CANCEL_ASYNCHRONOUS</code> oder <code>PTHREAD_CANCEL_DEFERRED</code>
<code>PTHREAD_CANCEL_DISABLE</code>	-----

3 Abbruch eines Threads (3)

- Der Empfang von Cancelversuchen kann mit `pthread_setcancelstate(int state, int *oldstate)` ein- und ausgeschaltet werden. (ähnlich wie die Signalmaske)
Gültige Werte für `state` sind die vordefinierten Werte:

- ◆ `PTHREAD_CANCEL_ENABLE`
- ◆ `PTHREAD_CANCEL_DISABLE`

- Ob ein Cancelversuch sofort wirksam wird oder erst an einem Cancellation-Point, ist mit `pthread_setcanceltype(int type, int *oldtype)`

konfigurierbar.

Auch hier gibt es zwei vordefinierte Werte:

- ◆ `PTHREAD_CANCEL_ASYNCHRONOUS`
- ◆ `PTHREAD_CANCEL_DEFERRED`

3 Abbruch eines Threads (4)

- Da ein Thread wichtige Ressourcen belegt haben kann (z.B. Mutexe), ist es aber meist sinnvoll, ihn nur an bestimmten Stellen im Programm abbrechen zu lassen. Diese Stellen werden *Cancellation-Points* genannt.
- Ein Cancellation-Point kann durch den Aufruf von `void pthread_testcancel(void)` markiert werden. Zusätzlich sind folgende Aufrufe automatisch gültige Cancellation-Points:
 - ◆ `pthread_cond_[timed]wait`
 - ◆ `pthread_join`
 - ◆ Systemfunktionen, die längere Zeit warten können, dürfen (und müssen teilweise) auch Cancellation-Points sein.

3 Abbruch eines Threads (5)

■ Beispiel:

```
/* make shute we cannot be canceled asynchronously */
type = PTHREAD_CANCEL_DEFERRED;
(void) pthread_setcanceltype(type, &oldtype);

/* do some buffer processing */
(void) pthread_mutex_lock(&write_mtx);
...
(void) pthread_mutex_unlock(&write_mtx);

/* act on cancellation requests before writing database */
pthread_testcancel();

/* don't process cancellation requests */
state = PTHREAD_CANCEL_DISABLE;
(void) pthread_setcancelstate(state, &ostate);
...
write_into_database(buffer);
...
/* restore cancelability state and type */
(void) pthread_setcancelstate(oldstate, &state);
(void) pthread_setcanceltype(oldtype, &type);
```

4 Der Cleanup Stack

- Problem: Verklemmung durch belegte Locks nach einer Cancellation

```
/* make shute we cannot be canceled asynchronously */
type = PTHREAD_CANCEL_DEFERRED;
(void) pthread_setcanceltype(type, &oldtype);

/* do some buffer processing */
(void) pthread_mutex_lock(&write_mtx);
cancel if (global_data_ptr != NULL) {
      write(fd, global_data_ptr, sizeof(global_data_ptr));
      free(global_data_ptr);
      global_data_ptr = NULL;
      (void) pthread_mutex_unlock(&write_mtx);
}
```



- ◆ Der Mutex wird durch den abgebrochenen Thread nicht freigegeben.
Ein anderer Thread, der diesen Code-Bereich durchlaufen wird, wird für immer auf die Freigabe des Mutex warten.
→ Die Anwendung verklemmt sich!

4 Der Cleanup Stack (2)

■ Problem: Inkonsistente Daten nach einer Cancellation

```
/* make shute we cannot be canceled asynchronously */
type = PTHREAD_CANCEL_ASYNCHRONOUS;
(void) pthread_setcanceltype(type, &oldtype);

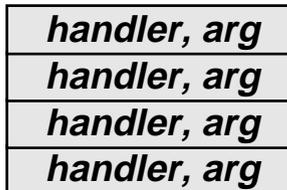
/* do some buffer processing */
(void) pthread_mutex_lock(&write_mtx);
cancel → if (global_data_ptr != NULL) {
    write(fd, global_data_ptr, sizeof(global_data_ptr));
    free(global_data_ptr);
    global_data_ptr = NULL;
(void) pthread_mutex_unlock(&write_mtx);
```

- ◆ Die Schreiboperation `write` wurde beendet. Durch den Abbruch des Threads wird aber der globale Zustand nicht mehr richtig gesetzt. Die Anwendung denkt, die Daten seien noch nicht geschrieben worden.
→ Die Daten der Anwendung werden inkonsistent!

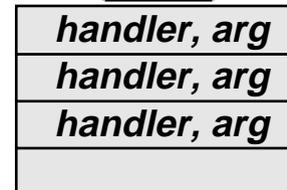
4 Der Cleanup Stack (3)

- Um die Speicherfreigabe und andere Aufräumarbeiten zu vereinfachen, hält die Pthread Bibliothek pro Thread einen sogenannten *Cleanup Stack*.
- Wenn ein Thread verstirbt (durch `pthread_exit`, Rücksprung aus der Startfunktion oder einer erfolgreichen Cancellation), werden alle Routinen aufgerufen, die auf den Stack geschoben worden sind (natürlich in LIFO Reihenfolge).
- Zu jedem Push-Aufruf muß es genau ein Pop-Aufruf geben, und zwar auf gleicher Programmblockebene. Dies erlaubt es, die beiden Funktionen als Macros zu definieren, die neue Variablen auf dem Stack anlegen.

pthread_cleanup_push(handler, arg)



pthread_cleanup_pop(execute)



4 Der Cleanup Stack (4)

- Push auf den Cleanup Stack:

```
void pthread_cleanup_push(  
                        void (*routine)(void *),  
                        void *arg)
```

Die Funktion muß vom Typ `void` sein. Das Argument `arg` wird beim Aufruf der Cleanupfunktion als Parameter übergeben.

- Pop der letzten Funktion:

```
void pthread_cleanup_pop(int execute)
```

Falls `execute` gesetzt ist, wird die gespeicherte Funktion aufgerufen.

4 Der Cleanup Stack (5)

```
void cleanup_func (char *ptr) {
    free(ptr);
}

...

void start_routine() {
    char *ptr
    ptr = (char *) malloc(1024);
    pthread_cleanup_push((void (*)())cleanup_func, (void *)ptr)

    /* Code to do sometingh with pointer ptr          */
    ...
    /* Finish with ptr, free() it up an remove the */
    /* Cancellation cleanup handl                    */
    pthread_cleanup_pop(0);
    free(ptr);

    pthread_exit(0);
}
```

4 Der Cleanup Stack (6)

```
void cleanup_mutex (pthread_mutex_t *lock) {
    pthread_mutex_unlock(lock);
}

void start_routine() {
    struct job_task *task;
    for ( ; ; ) {
        (void) pthread_mutex_lock(task_lock);
        pthread_cleanup_push((void (*)())cleanup_mutex,
                             (void *)task_lock)

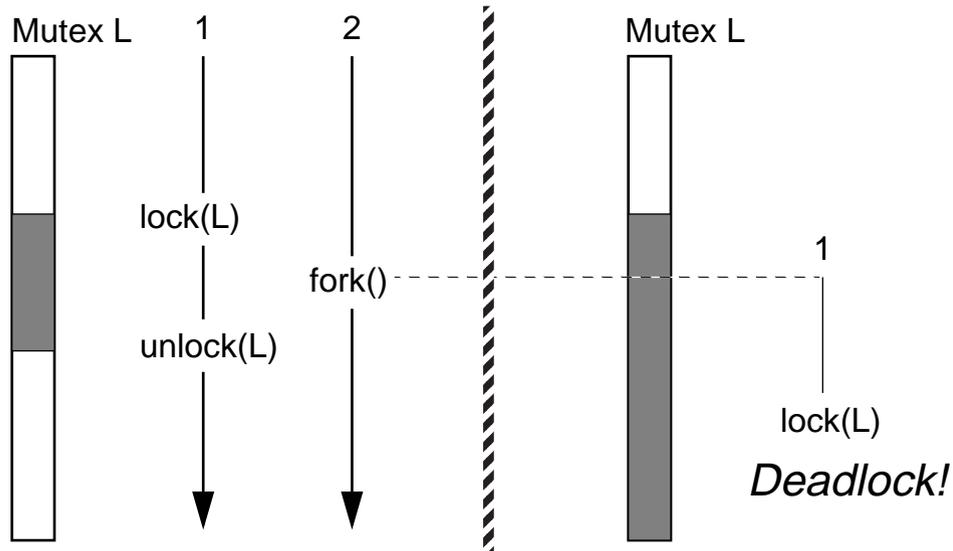
        while (task_queue_empty())
            pthread_cond_wait(task_cv, task_lock);
        pthread_cleanup_pop(0);
        task = task_dequeue();
        pthread_mutex_unlock(task_lock);
        /* Process the Task */
        ...
        free((void *)task);
    }
}
```

5 Fork/Exec/Exit

- Die Pthread Designer haben versucht, sich möglichst wenig von der Semantik der UNIX Prozesse zu entfernen.
- Ruft ein Thread in einem Programm, in dem mehrere Threads laufen, `fork()` auf, wird ein neuer Prozeß mit einem Abbild des Adreßraumes und genau einem Thread gestartet.
- Dieses führt zu zwei schwerwiegenden Problemen:
 - ◆ Der Kindprozeß erbt den Zustand aller Locks des Vaterprozesses, ohne über deren Status genaueres zu wissen.
 - ◆ Der Kindprozeß erbt den Datenbereich, also auch den von anderen Threads allozierten Speicher. Ein sauberes Freigeben der unbenötigten Bereiche ist schwierig.
- Diese Probleme sind natürlich irrelevant, wenn nach dem `fork()` direkt ein `exec()` oder `exit()` aufgerufen wird.

5 Fork/Exec/Exit (2)

- Beispiel für einen Deadlock:



5 Fork/Exec/Exit (3)

- Die Pthread Bibliothek bietet zur Lösung dieses Problems sogenannte *fork-handling Stacks* an. Diese werden bei einem `fork()` Aufruf automatisch abgearbeitet.
- Es gibt drei unterschiedliche Stacks:
 - ◆ Der *prepare-Stack*: Die Funktionen auf diesem Stack werden automatisch vor dem eigentlichen `fork()` aufgerufen.
 - ◆ Der *parent-Stack*: Der Vater des erzeugten Prozesses ruft nach dem `fork()` automatisch alle Funktionen auf diesem Stack auf.
 - ◆ Der *child-Stack*: Der erzeugte Prozeß ruft alle auf diesen Stack gelegten Funktionen auf.

5 Fork/Exec/Exit (4)

■ Die Syntax:

```
pthread_atfork(void (*prepare)(void),  
              void (*parent)(void),  
              void (*child)(void))
```

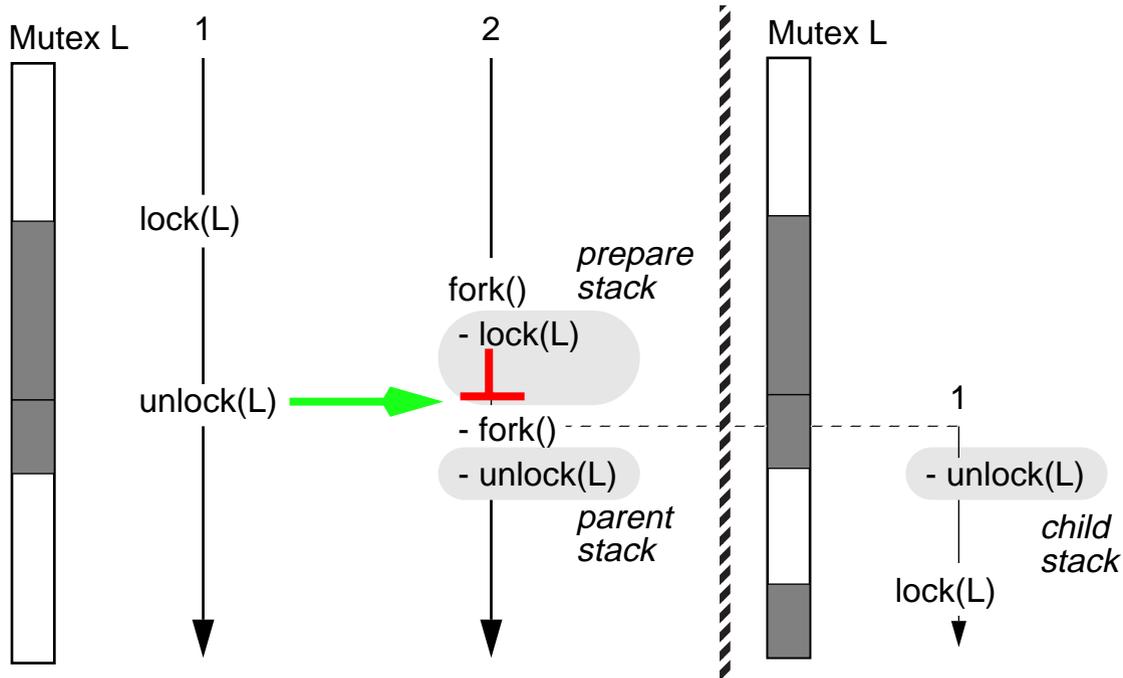
Ein Stack kann durch Angabe von `NULL` unverändert bleiben.

■ Mit dieser Funktion ist das fork-Problem leicht lösbar:

- ◆ Die Routinen auf dem prepare-Stack belegen alle Mutexe (in der richtigen Reihenfolge), die der erzeugte Prozeß benötigt.
- ◆ Die Funktionen auf dem parent- und dem child-Stack geben die Mutexe wieder frei. Zusätzlich kann die child-Funktion noch weitere Ressourcen freigeben.

5 Fork/Exec/Exit (5)

■ Vermeidung des Deadlocks:



5 Fork/Exec/Exit (6)

- Da der Pthread Standard Implementierungen zuläßt, die auf einem Monoprozessor ohne Kernunterstützung laufen, muß ein Aufruf von `exec()` und `exit()` eine automatische Terminierung aller Threads bewirken.
- Ein Aufruf von `exit()` bewirkt noch einige Aufräumaktionen (Flush aller geöffneten Files).
- Soll dies vermieden werden, kann `_exit()` aufgerufen werden. Dies ist der direkte Kernaufufruf.

6 Interprozeß-Synchronisation

- Durch das Setzen von Attributen können Mutexe und Conditionals über Prozeßgrenzen hinweg verwendet werden.
- Der Mutex/Conditional muß hierzu in einem Shared-Memory-Bereich liegen, auf den die Prozesse zugreifen können (über `mmap()` oder SysV-IPC). Weiterhin ist diese Option nur gestattet, wenn die Konstante `_POSIX_THREAD_PROCESS_SHARED` definiert ist.
- Das benötigte Attribut heißt `ATTR=pshared`, `ATTRTYPE=int`.
 - ◆ `PTHREAD_PROCESS_SHARED`: ermöglicht diese Option,
 - ◆ `PTHREAD_PROCESS_PRIVATE`: verbietet sie.

E.8 Zusammenfassung

- Threads sind ein mächtiges Hilfsmittel zur Parallelisierung eines Programmes.
- Der Vorteil des schnellen und uneingeschränkten Zugangs auf alle Prozeßressourcen (Speicher, Files) ist allerdings gleichzeitig das Hauptrisiko, da es leicht zu sehr schwer zu findende *Raceconditions* kommen kann.
- Man sollte sich immer genau überlegen, ob man auf Synchronisations- und Ausnahmebehandlungsroutinen wirklich verzichten kann.

F Übung 1

- Unter `~iwi425/PPS/streams` finden Sie die Quellen des Streams-Benchmark zur Bestimmung der Speicherbandbreite und der Rechenleistung in Abhängigkeit von der Arbeitsmenge. Arbeiten Sie auf einer unbelasteten Workstation vom Typ SUN Ultra-10 (300 MHz Ultra-SPARC Ili, 128 MB Speicher, 512 KB physical Cache, 64 entry Data-TLB)
 - ◆ Ändern Sie den Benchmark (C-Variante) derart ab, daß Sie bei einem Workingset von 32 KB (Summe aller beteiligten Cache-Zeilen) bei jedem Speicherzugriff einen TLB-Zugriffsfehler erzeugen. Vergleichen Sie Ihre Ergebnisse mit der einer TLB-freundlichen Variante.
 - ◆ Weisen Sie den Effekt des zufälligen Page-Coloring nach. Allokieren Sie im Streams Benchmark 0.5 MB Speicher und lassen die Messung durchlaufen, beenden den Prozeß aber nicht. Jetzt starten Sie mehrfach den gleichen Prozeß mit 100 MB Speicheranforderung. Heftige Auslagerung von Seiten ist die Folge. Lassen Sie jetzt den zuerst gestarteten Benchmark weiterlaufen und messen Sie den Durchsatz.

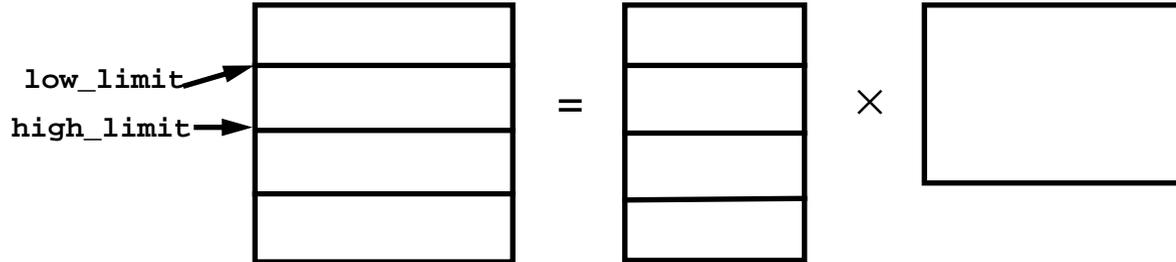
F Übung 2

- Arbeiten Sie auf einer unbelasteten Workstation vom Typ SUN Ultra-10 (300 MHz Ultra-SPARC Ili, 128 MB Speicher, 512 KB physical Cache, 64 entry Data-TLB)
- ◆ Schreiben Sie ein 2-dimensionales Feld mit Integerzahlen (Feldgröße 110 MB) in eine Datei unter `/usr/tmp`.
 - Schreiben Sie mit dem `write()` call und analysieren Sie unterschiedliche lange Puffergrößen (8190 Bytes, 8192 Bytes).
 - Allokieren Sie eine Datei von 110 MB (`open()`, `lseek()`), mappen Sie die Datei in den Adressraum (`mmap`), initialisieren Sie das Feld (z.B. alle Feldelemente auf 1) und machen sie die Änderungen persistent.
 - Summieren sie alle Element des in die Datei gespeicherten Feldes auf. Wählen Sie einen Ansatz mit `read()` und einen mit `mmap()`.

F Übung 3

- Implementieren Sie analog zur Matrix-Vektoroperation eine parallele Matrixmultiplikation mit Pthreads

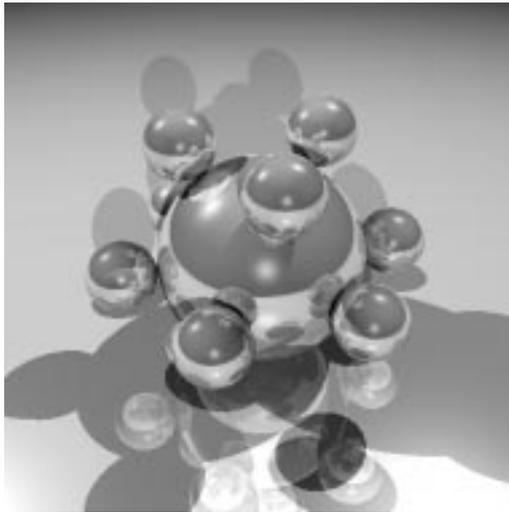
$$C[i, j] = \sum_{k=1}^s A[i, k] \cdot B[k, j]; \quad 1 \leq i \leq n, 1 \leq j \leq m$$



- ◆ Vereinfachung: Quadratische Matrizen der Größe $n \times n$; n = dimension
- ◆ Compilieren Sie mit `/opt/SUNWsprow/bin/cc -mt -lpthread`
- ◆ Variieren Sie die Zahl der Kernel-Threads.
- ◆ Messen Sie den Speedup auf dem Rechner cssun mit 1-8 Kernel-Threads in Abhängigkeit von der Matrixgröße.

F Übung 4

- Raytracer eignen sich hervorragend zur Parallelisierung, da jeder Bildpunkt unabhängig von den anderen berechnet werden kann.
- In `~iwi425/PPS/ray/` findet sich ein kleiner Raytracer, der das Bild einer einfachen Szene erzeugt.



- Start des raytracers mit `tr | /local/bin/xv -`

F Übung 4 (2)

- Parallelisieren Sie den Raytracer mit Hilfe von Pthreads.
 - ◆ Unterteilen Sie hierzu das Bild in einzelne Streifen und lassen sie die Streifen von eigenen Threads berechnen.
 - ◆ Vergessen sie nicht, in Ihr Program den Aufruf von `thr_setconcurrency(8)` einzubauen, um auf der `cssun` mit allen 8 Prozessoren rechnen zu können!
 - ◆ Warum ist die einfache Aufteilung in 8 Streifen nicht optimal? Die Rechenzeit verkürzt sich, wenn mehr Streifen und damit (Userlevel-)Threads eingesetzt werden. Was ist die optimale Anzahl von Threads?
 - ◆ Vergrößern Sie den Bildbereich, so daß ein starkes Lastungleichgewicht bei 8 Threads entsteht.
 - Implementieren Sie jetzt mit Hilfe von Thread-Cancellation eine Repartitionierung der noch nicht berechneten Streifen.
 - Lösen Sie diese Aufgabe auch durch den Einsatz von Signalen (SIGUSR1).

F Übung 5

- In dieser Aufgabe soll ein HTTP Server parallelisiert werden. Der serielle Source findet sich in `~iwi425/PPS/tinyhttp/`
- Zum Testen kann der WWW Baum des RRZE verwendet werden. Ein Aufruf wäre:

```
./tinyhttp 2345 /home/rzhome/iwi4/iwi425/PPS/wwwcip
```

Danach könnte zum Beispiel über die URL `http://cssun.rrze:12345/docs/RRZE/` auf den Server zugegriffen werden können.
- Da der Server zu langsam arbeitet, sollen die einzelnen Requests parallel von Threads abgearbeitet werden.
- Implementieren Sie den Server mit dem Boss-Worker Modell.
- Setzen Sie einen Signalhandler auf, der die Anwendung geordnet mit Cancellation terminiert.