2.2 Multiprozessoren

2.2.1 Grundlagen

2.2.1.1 Klassifikation von Multiprozessoren

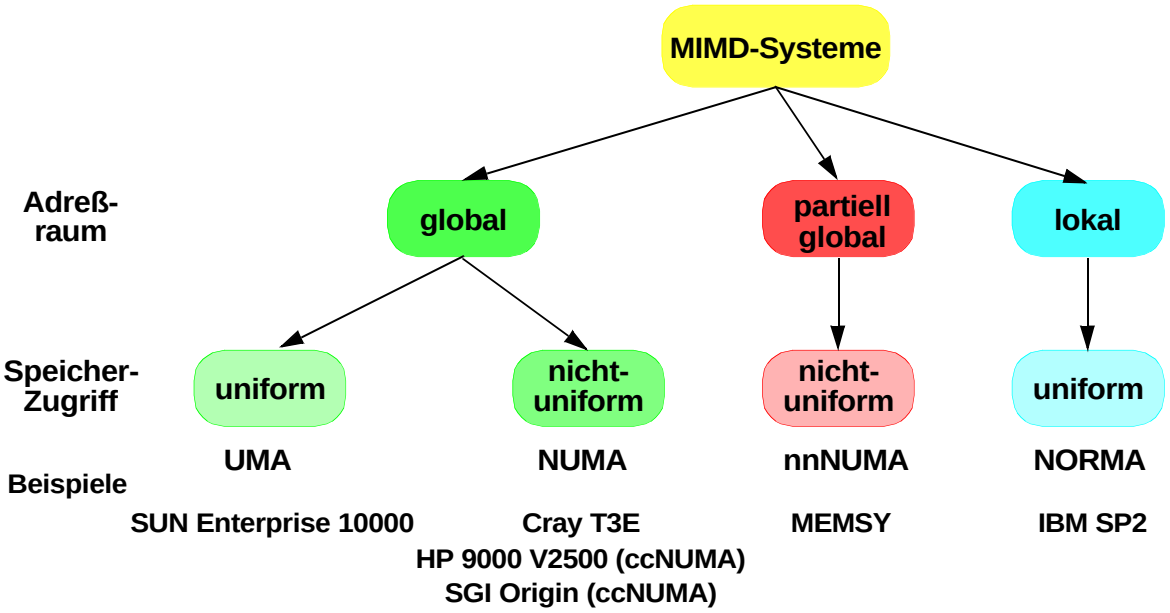

2.2.1.2 Beispiele

- UMA: Sun Enterprise 10000; Prozessor UltraSparc II

  http://www.sun.com/servers/highend/10000/

  - Prozessor und Pufferspeicher

Ultra Sparc II			
	Ebene 1		Ebene 2
	Datenspeicher	Befehlsspeicher	
on chip	ja	ja	nein
Adressierung	virtuell	physikalisch	physikalisch
Markierung	physikalisch	physikalisch	physikalisch
Größe	16KB	16 KB	0,5 - 16 MB
Indexbreite	7 Bit	6 Bit	14 - 18 Bit
Zeilenzahl	256	256	8192 - 262144
Zeilenlänge	32 Byte	32 Byte	64 Byte
Assoziativität	1	2	1
write-on-hit	write-through	(nicht beschreibbar)	write-back
write-on-miss	nonallocating	(nicht beschreibbar)	allocating
Kohärenz	konsistent mit L2	konsistent mit L2	MOESI
	Keine Konsistenz zwischen Daten- und Befehlsspeicher		

Pufferspeicher bei Multiprozessoren: Sun Enterprise 10000

- **Board**

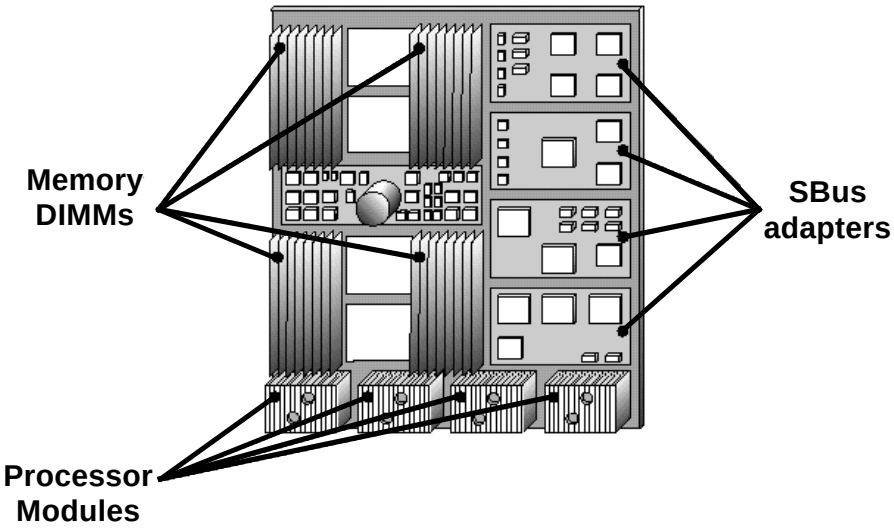

Pufferspeicher bei Multiprozessoren: Sun Enterprise 10000

- **Gesamtstruktur**
  Vollständig kohärent

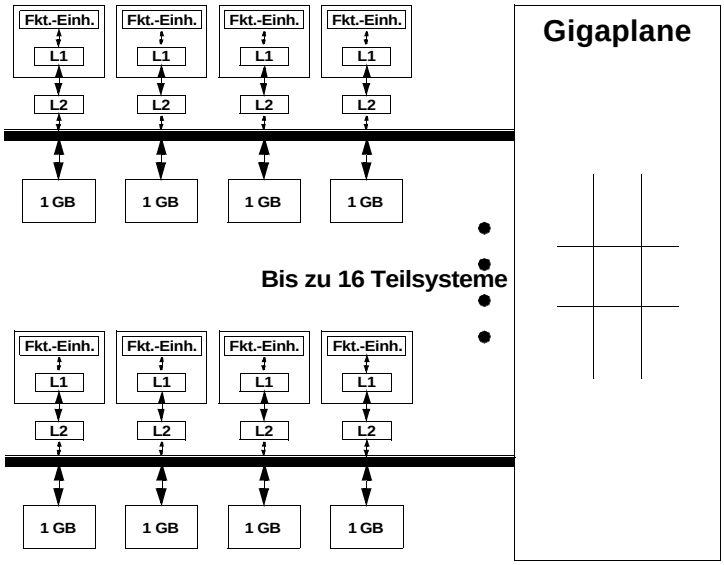

Pufferspeicher bei Multiprozessoren: Sun Enterprise 10000

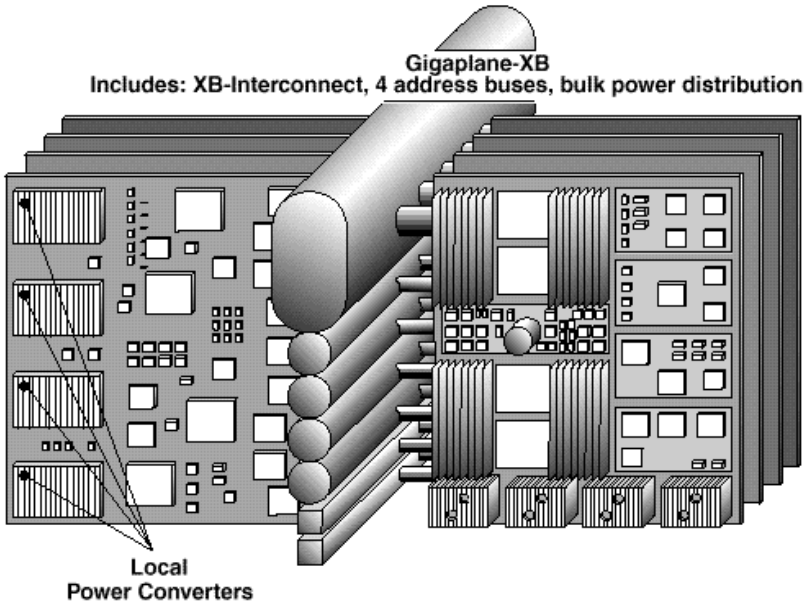

Pufferspeicher bei Multiprozessoren: Cray T3E

- **NUMA: Cray T3E; Prozessor Alpha 21264**

  http://www.sgi.com/t3e/

  - **Prozessor und Pufferspeicher**

Alpha 21264			
	Ebene 1		Ebene 2
	Datenspeicher	Befehlsspeicher	
on chip	ja	ja	ja
Adressierung	virtuell	virtuell	physikalisch
Markierung	physikalisch	physikalisch	physikalisch
Größe	8 KB	8 KB	96 KB
Indexbreite			
Zeilenzahl	256	256	512
Zeilenlänge	32 Byte	32 Byte	64 Byte
Assoziativität	1	1	3
write-on-hit	write-back	write-back	write-back
write-on-miss	allocating	allocating	allocating
Kohärenz	lokal	lokal	lokal

Pufferspeicher bei Multiprozessoren: Cray T3E

- **Knoten**

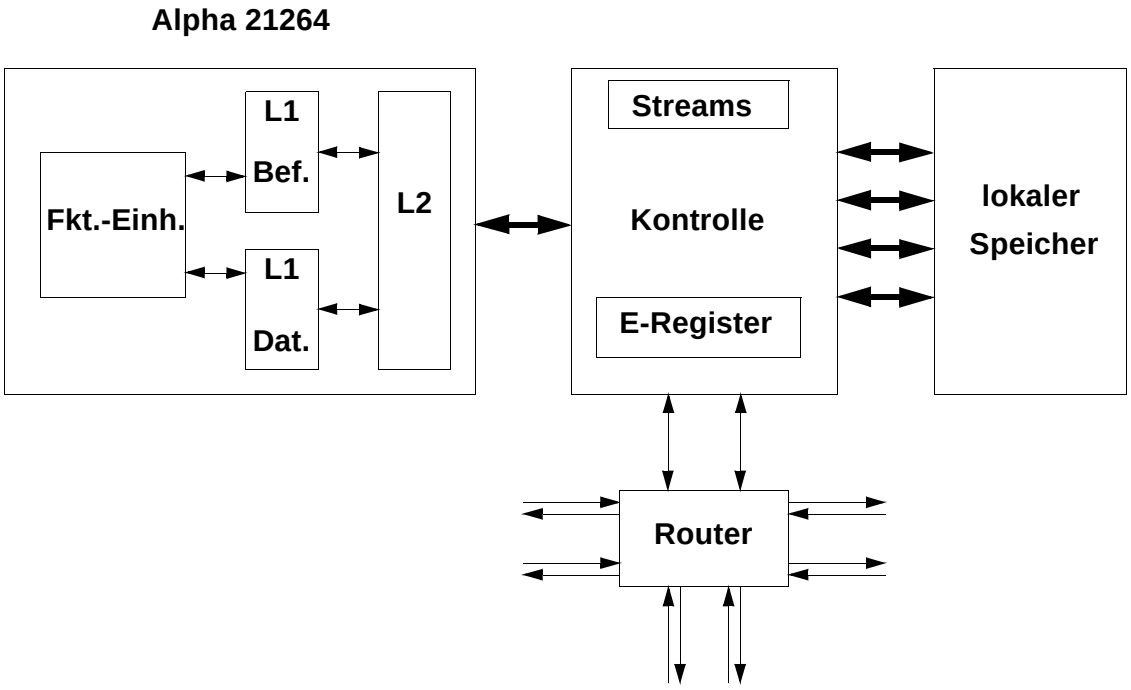

Pufferspeicher bei Multiprozessoren: Cray T3E

- **Gesamtstruktur**
  Lokale Kohärenz zwischen Prozessor-Cache und lokalem Speicher bei Lesen oder Schreiben mit Hilfe der E-Register

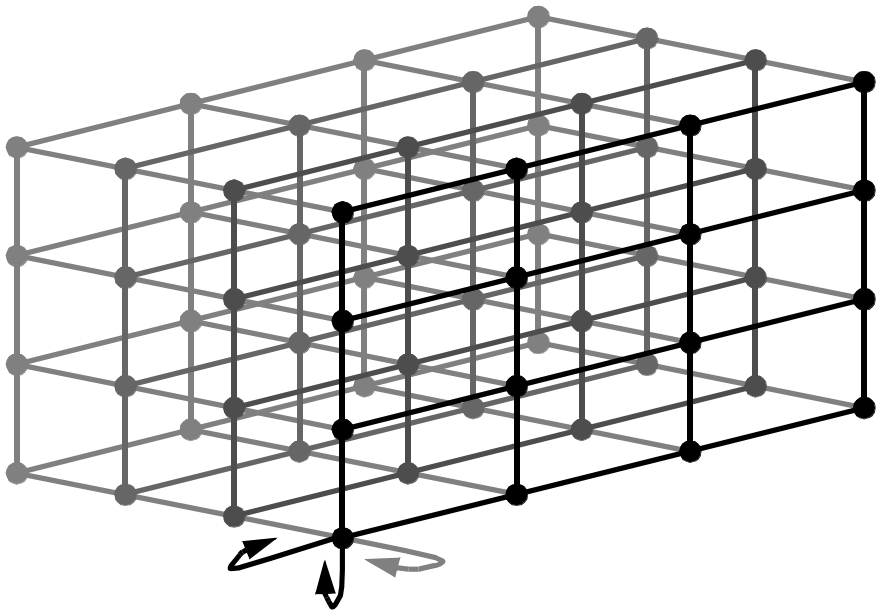

Pufferspeicher bei Multiprozessoren: HP 9000 V

- **NUMA: HP 9000 V; Prozessor PA-8500**

  http://datacentersolutions.hp.com/vclass_servers_index_html

  - **Prozessor und Pufferspeicher**

PA 8500		
	Ebene 1	
	Datenspeicher	Befehlsspeicher
on chip	ja	ja
Adressierung	virtuell	virtuell
Markierung	---	---
Größe	1 MB	0,5 MB
Indexbreite	14	13
Zeilenzahl	16364	8192
Zeilenlänge	16 Byte	16 Byte
Assoziativität	4	4
write-on-hit	write-back/through	nicht beschreibbar
write-on-miss	nonallocating	nicht beschreibbar
Kohärenz	---	---
	Keine Konsistenz zwischen Daten- und Befehlsspeicher	

Pufferspeicher bei Multiprozessoren: HP 9000 V

- **Gesamtstruktur**
  Vollständig kohärent

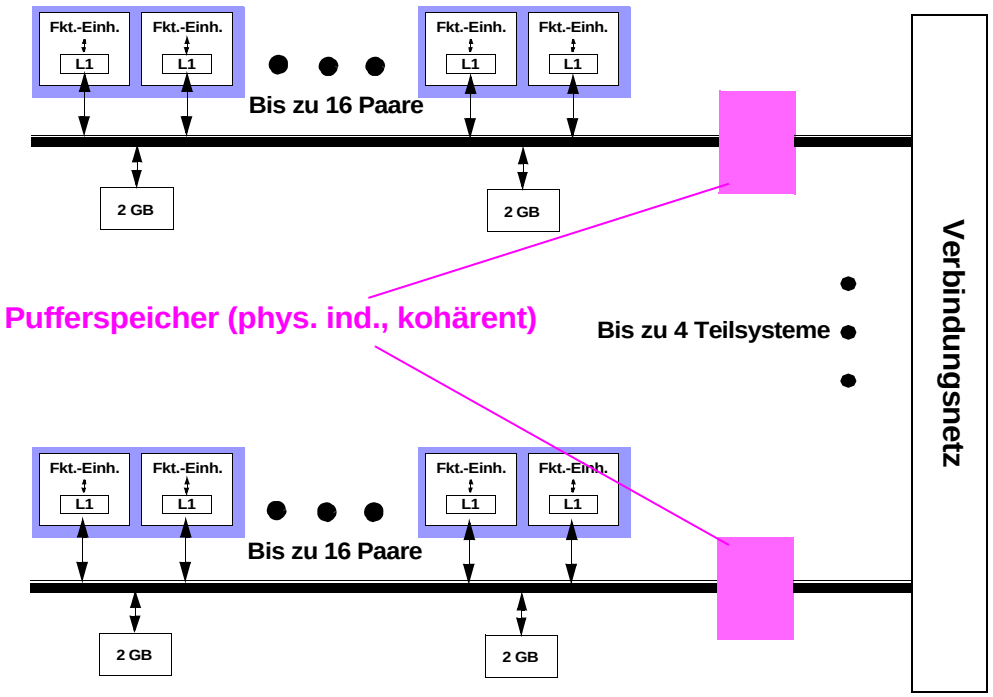

Pufferspeicher bei Multiprozessoren: HP 9000 V

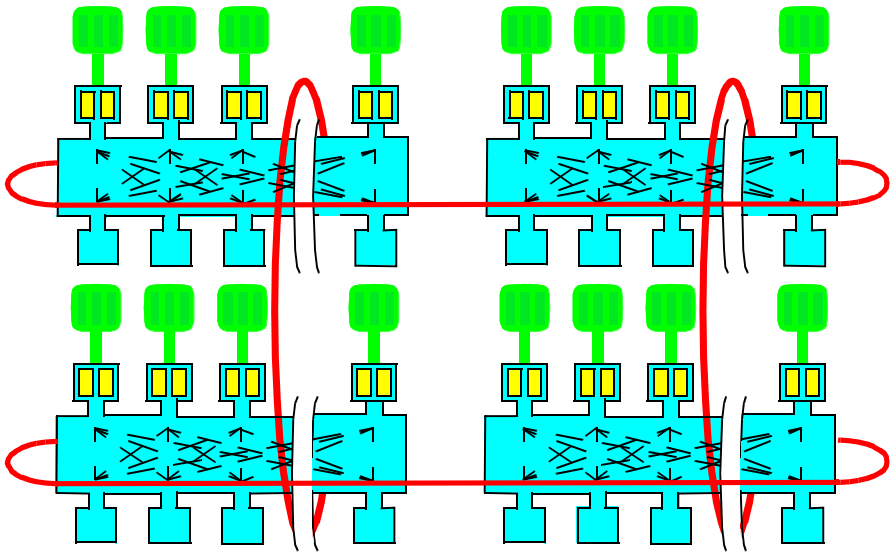

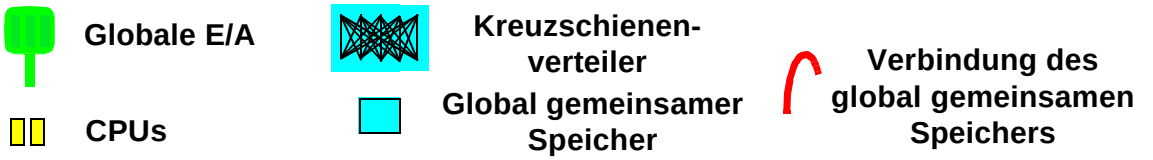

Pufferspeicher bei Multiprozessoren: SGI Origin

ccNUMA: SGI Origin; Prozessor MIPS R10000

http://www.sgi.com/origin/2000/index.html

Prozessor und Pufferspeicher

MIPS R10000			
	Ebene 1		Ebene 2
	Datenspeicher	Befehlsspeicher	
on chip	ja	ja	nein
Adressierung	virtuell	virtuell	physikalisch
Markierung	physikalisch	physikalisch	physikalisch
Größe	32 KB	32 KB	0,5 - 16 MB
Indexbreite	9 Bit	8 Bit	12 - 17 Bit
Zeilenzahl	512	256	4096/2048 - 131072/65536
Zeilenlänge	32 Bytes	64 Bytes	64/128 Bytes
Assoziativität	2	2	2
write-on-hit	write-back	write-back	write-back
write-on-miss	allocating	allocating	allocating
Snooping	Systembus	Systembus	Systembus
Kohärenz	konsistent mit L2	konsistent mit L2	MESI-ähnlich

Pufferspeicher bei Multiprozessoren: SGI Origin

- **Knoten**

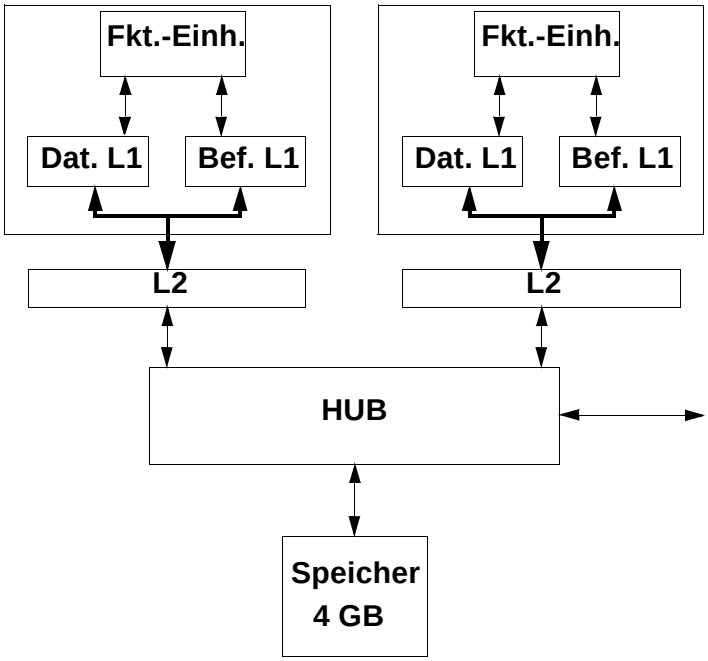

Pufferspeicher bei Multiprozessoren: SGI Origin

- **Gesamtstruktur**
  Vollständig kohärent

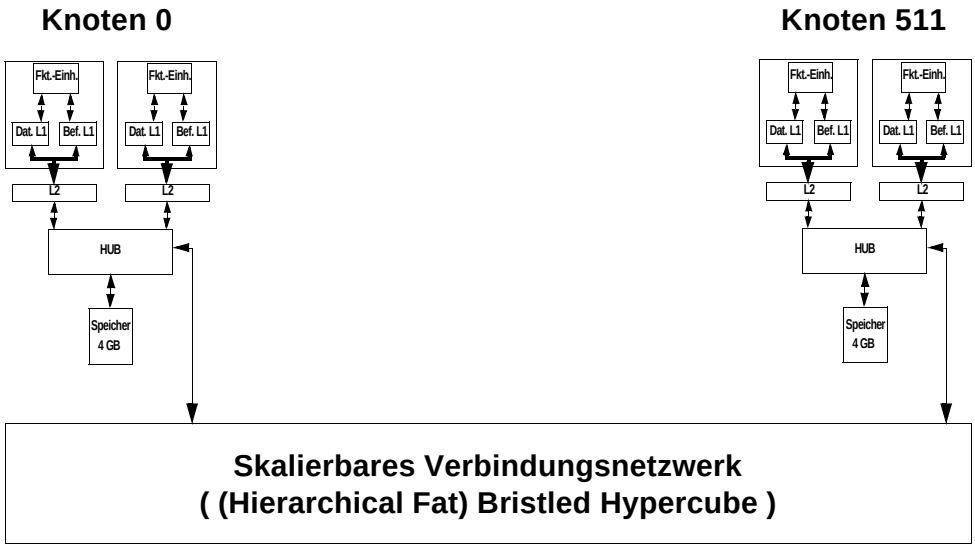

Pufferspeicher bei Multiprozessoren: SGI Origin

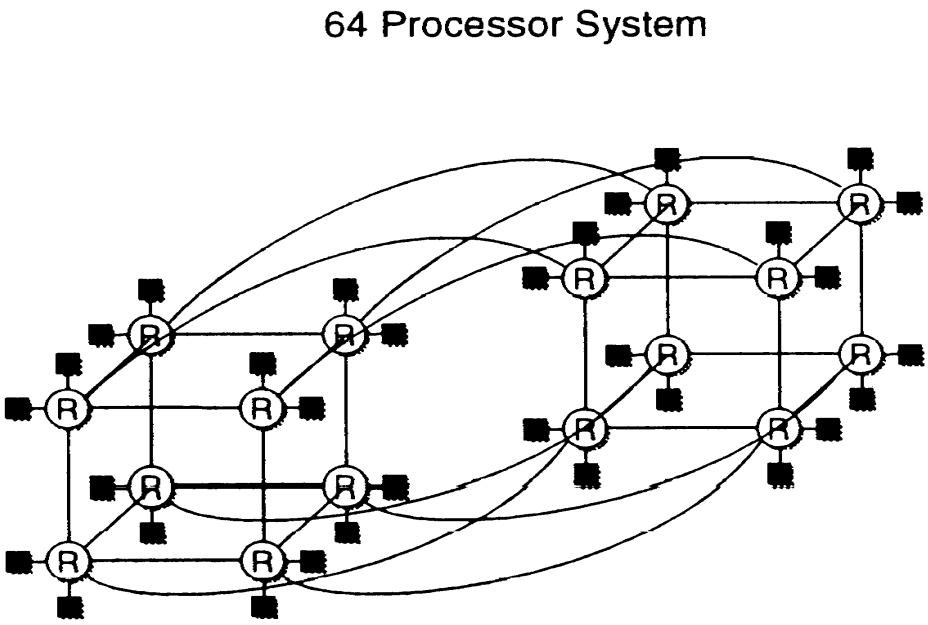

Pufferspeicher bei Multiprozessoren: Memsy

- **nnNUMA: Memsy; Prozessor Motorola MC8100MC/8204**

  http://www4.informatik.uni-erlangen.de/Projects/MEMSY/

- **Prozessor und Pufferspeicher**

MC88100/MC88204		
	Ebene 1	
	Datenspeicher	Befehlsspeicher
on chip	nein	nein
Adressierung	virtuell	virtuell
Markierung	physikalisch	physikalisch
Größe	64 KB	64 KB
Indexbreite	10 Bit	10 Bit
Zeilenzahl	1024	1024
Zeilenlänge	16 Byte	16 Byte
Assoziativität	4	4
write-on-hit	write-back/ through	write-back/ through
write-on-miss	allocating	allocating
Snooping	Systembus	Systembus

Pufferspeicher bei Multiprozessoren: Memsy

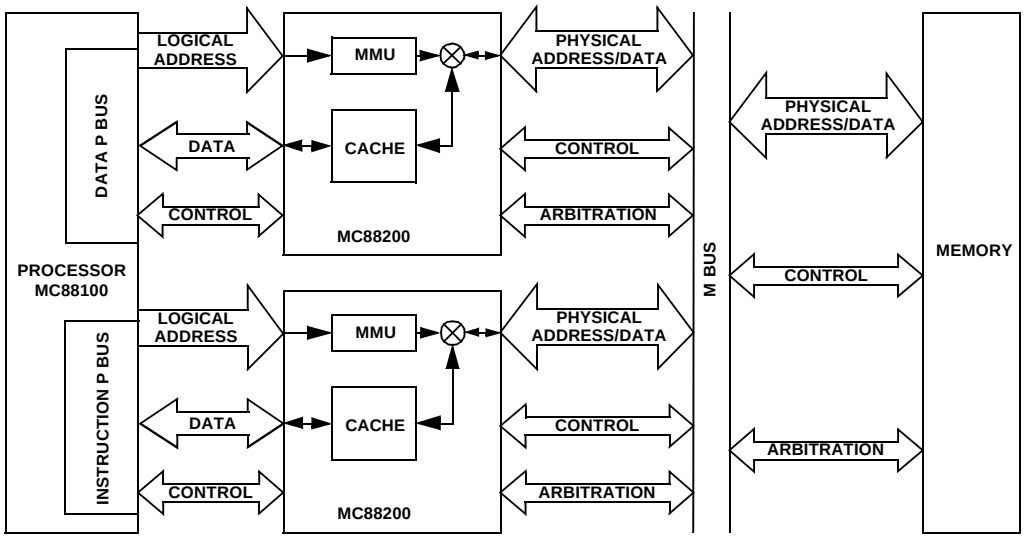

Pufferspeicher bei Multiprozessoren: Memsy

- Knoten

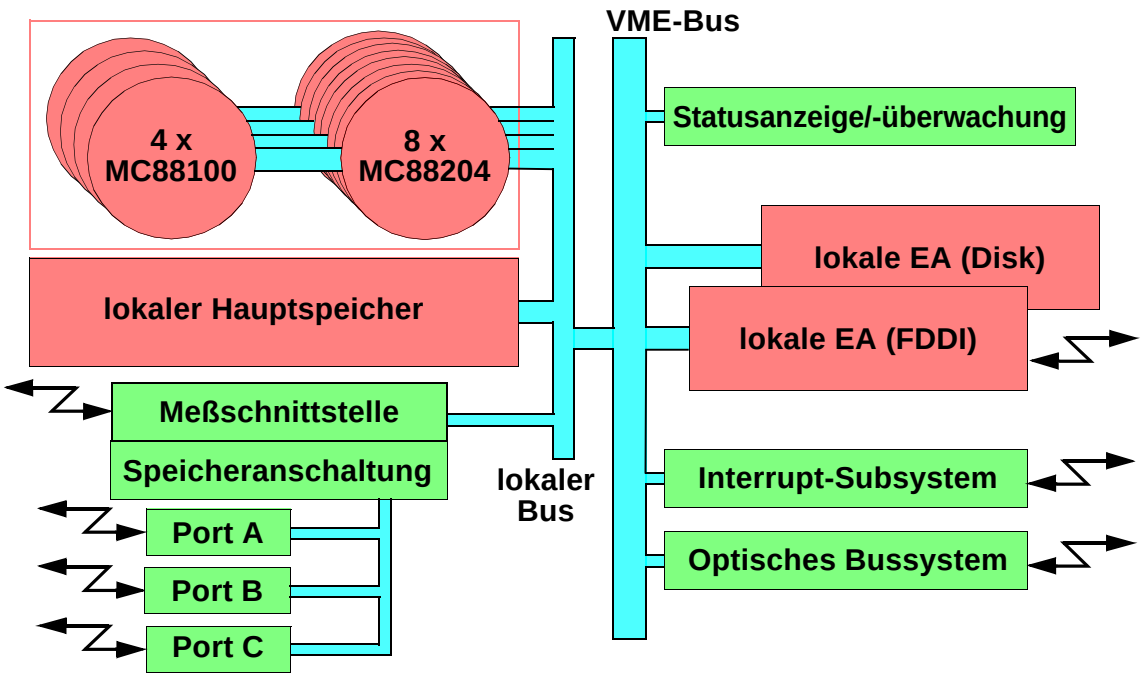

Pufferspeicher bei Multiprozessoren: Memsy

- **Gesamtstruktur**
  Cache-Kohärenz nur lokal!

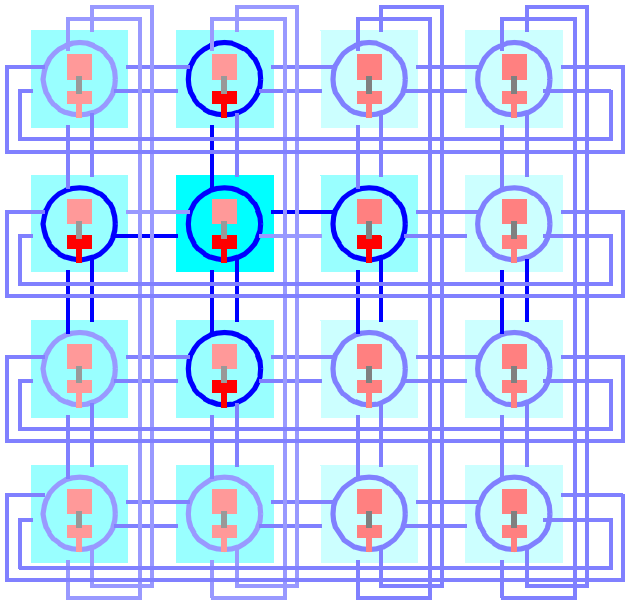

Pufferspeicher bei Multiprozessoren: Memsy

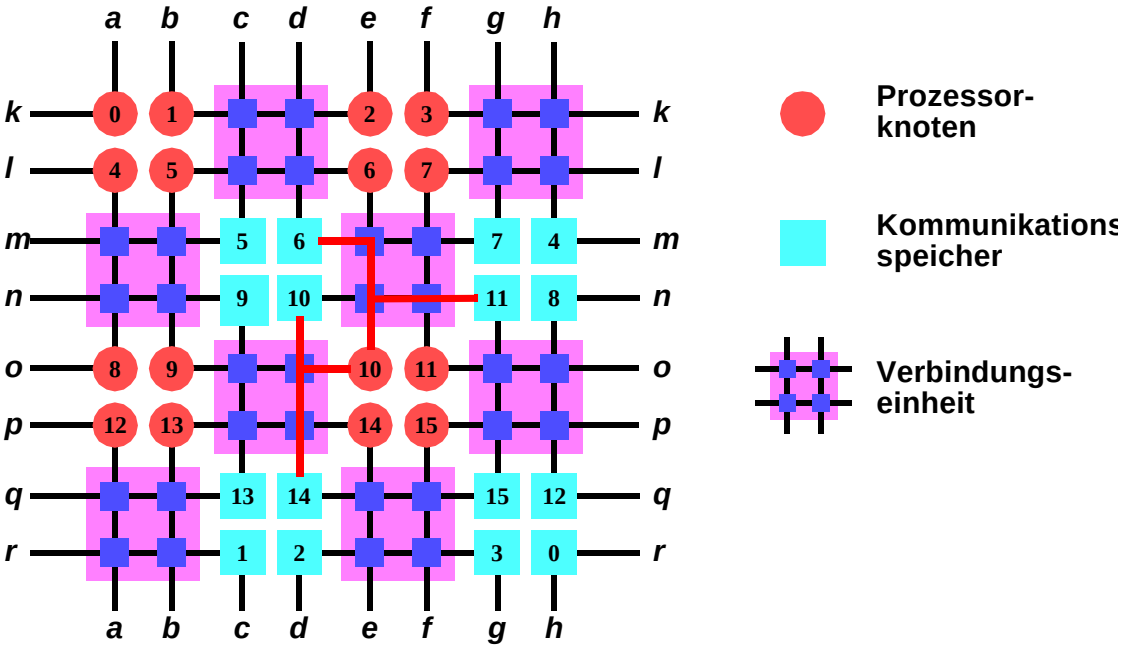

Pufferspeicher bei Multiprozessoren: Memsy

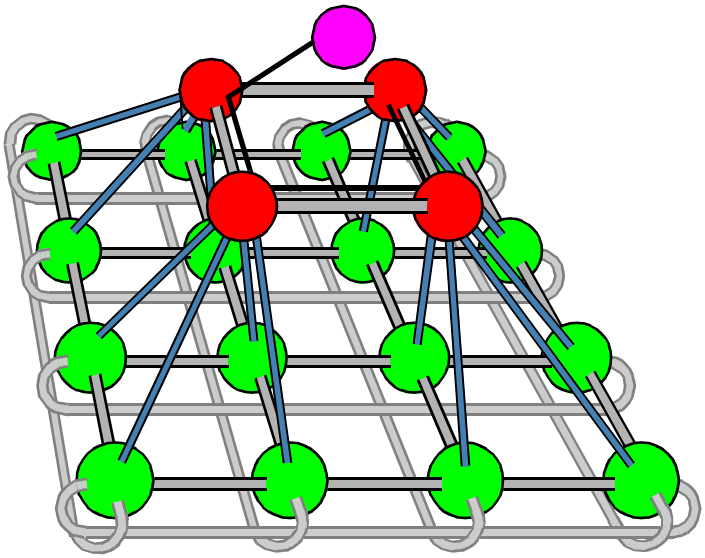

Speicherkopplung ider Ebene

Speicherkopplung zwischen den Ebenen

Gemeinsamer Bus zwischen B- und C-Ebene

Pufferspeicher bei Multiprozessoren: MESI-Protokoll

2.2.2 Das MESI-Protokoll

❑ Zustände für Ebene E_i

Zustand der Pufferzeile	M (Modified)	E (Exclusive)	S (Shared)	I (Invalid)
Pufferzeile gültig?	ja	ja	ja	nein
Inhalt in E_{i+1}	veraltet	aktuell	aktuell	---
Kopien in E_i's anderer Prozessoren?	nein	nein	vielleicht	vielleicht

Pufferspeicher bei Multiprozessoren: MESI-Protokoll

❑ **Entscheidungstabelle für Zustandsübergänge**

Operation	read		write			snoop hit
wt/wb	write through	write back	write through		write back	
allocating/ nonallocating			allocating	nonallo-cating	allocating	
M	nicht möglich	M	nicht möglich	nicht möglich	M	S/I + store
E	nicht möglich	E	nicht möglich	nicht möglich	M	S/I
S	S	S	S	S	E	S/I
I	Zeile füllen + S	Zeile füllen + E	Zeile füllen +S	I	Zeile füllen + E	I

Pufferspeicher bei Multiprozessoren: Spinlocks und Barrieren

2.2.3 Implementierung von Spinlocks und Barrieren

Literatur

Mellor-Crummey, J. M.; Scott, M. L.: Algorithms for Scalable Synchronization on Shared-Memory Multiprocesors. ACM Transactions on Computer Systems, Vol. 9, No. 1, February 1991, pp.21-65.

❑ **Für UMA und NUMA Architekturen sind zwei Klassen von Koordinierungsmechanismen bedeutsam:**

- ◆ **Blockierende Koordinierung**
- ◆ **Koordinierung durch aktives Warten**

Bedeutsam bei kurzen kritischen Abschnitten, zwei Ausprägungen

- **Spinlocks**

  Zur Erzielung gegenseitigen Ausschlusses
- **Barrieren (barriers)**

  Zur Koordinierung des Übergangs von parallelen in serielle Phasen

Probleme

- **Bei großen Prozessorzahlen entstehen leicht ‘hot spots’**

Pufferspeicher bei Multiprozessoren: Spinlocks

- **Untersuchungen von Agarwal und Cherian an Benchmarkprogrammen:**
  - **In Systemen mit Cache-Kohärenz ist mehr als die Hälfte der Fehlzugriffe durch Spinlocks bedingt**
  - **Werden Spinlock-Variable nur im Arbeitsspeicher geführt, erzeugen die Spinlocks nahezu die Hälfte des Datentransports zwischen CPU und Arbeitsspeicher**

Folgerung: Entwicklung geeigneter Algorithmen

2.2.4 Spinlocks

- **Teste-und-setze als atomare Aktion verfügbar**
- **Bei alleiniger Führung der Variablen im Arbeitsspeicher Belastung der Übertragungswege durch wartende Fäden**
- **Bei Caches mit Kohärenz häufige Invalidierungen der Variablen und damit Rückfall auf das vorige Problem**
- **Bei Caches ohne automatische Kohärenz zusätzlicher Aufwand um für die Spinlock-Variable Kohärenz zu sichern**
- **Verbesserung durch Erhöhen der Zeit bis zur nächsten Überprüfung, falls letzte Überprüfung negativ**

Pufferspeicher bei Multiprozessoren: Spinlocks

```
import java.awt.*;

class Lock {
  Scheduler scheduler;
  int value;
  public Lock(Scheduler scheduler) {
    value = 0; this.scheduler = scheduler;
  }
  private int testAndSet() {
    scheduler.beginOfAtomic();
      int old = value; value = 1;
    scheduler.endOfAtomic();
    return old;
  }
```

Pufferspeicher bei Multiprozessoren: Spinlocks

```
  public void acquire() {
    int delay = 1;
    while (testAndSet() != 0) {
      scheduler.system.updateSyncState(scheduler.myPid(),
                                       new String("D: " + delay),
                                       Color.red);
      scheduler.sleep(delay);
      delay = 2 * delay;
    }
    scheduler.system.updateSyncState(scheduler.myPid(),
                                     Color.green);
  }

  public void release() {
    value = 0;
    scheduler.system.updateSyncState(scheduler.myPid(),
                                     Color.white);
  }
}
```


Pufferspeicher bei Multiprozessoren: Spinlocks

```
}

import java.awt.*;

public class UserThread extends SimProcess {
  String    name = null;
  Lock lock;
  public UserThread(String f_name, Scheduler f_scheduler,
                    int f_nodeNumber) {
    super(f_name, f_scheduler, f_nodeNumber);
    name = f_name;
    lock = ((Spinlock)(scheduler.system)).lock;
  }
  public void runProcess() {
    for (int i = 0; i < 5; i++) {
      lock.acquire();
        scheduler.system.updateSyncState(scheduler.myPid(),
                                         new String("" + i));
        scheduler.sleep(2000);
      lock.release();
      scheduler.sleep(5000);
    }
  }
}
```

Pufferspeicher bei Multiprozessoren: Ticket-Lock

- Weitere Überlegungen
  - Verlängerung der Verzögerung muß begrenzt werden
  - test-and-test_and_set

    Dadurch im wesentlichen nur während des aktiven Wartens nur Leseaufrufe

- Ticket-Lock
  - Idee: Thread, der kritischen Abschnitt betreten will, bekommt ein Ticket. Tickets werden fortlaufend numeriert. Es wird jeweils nächste Nummer aufgerufen (durch Setzen eines entsprechenden Zählers).
  - Vorteil: Während des aktiven Wartens keine Schreibaufrufe und damit keine durch Konsistenzerhaltung bedingten Invalidierungen. FIFO-Abarbeitung (kein Aushungern).
  - Voraussetzung: Atomare fetch_and_increment-Operation
  - Schwierigkeiten: Hot Spots durch Pollen der Anzeige für das aufgerufene Ticket

Pufferspeicher bei Multiprozessoren: Ticket-Lock

```
class TicketLock implements Lock {
  Scheduler scheduler;
  int nextTicket, nowServing;

  public TicketLock(Scheduler scheduler) {
    nextTicket = 0;
    nowServing = 0;
    this.scheduler = scheduler;
  }
  private int fetchAndIncrement(){
    scheduler.beginOfAtomic();
      int old;
      old = nextTicket++;
    scheduler.endOfAtomic();
    return old;
  }
```

Pufferspeicher bei Multiprozessoren: Ticket-Lock

```
  public void acquire() {
    int myTicket = fetchAndIncrement();
    while (myTicket != nowServing) {
      scheduler.system.updateSyncState(scheduler.myPid(),
                                       Color.red);
      scheduler.sleep((myTicket - nowServing) * 100);
    }
    scheduler.system.updateSyncState(scheduler.myPid(),
                                     Color.green);
  }

  public void release() {
    nowServing++;
    scheduler.system.updateSyncState(scheduler.myPid(),
                                     Color.white);
  }
}
```


Pufferspeicher bei Multiprozessoren: Array-Based Queuing Lock

- **Array-Based Queuing Lock**
  - **Idee: Jedem Thread eine eigene Spinvariable zuordnen, z. B. aus einem Vektor von Spinvariablen.**
  - **Vorteil: Skaliert deutlich besser als die beiden vorangehenden. Bei Cache-Kohärenz auch besser als TicketLock, ohne Cache-Kohärenz ist bei NUMA-Architekturen TicketLock vorzuziehen. Erzwingt FIFO-Abarbeitung.**
  - **Voraussetzung: Atomare fetchAndIncrement-Operation zur Zuteilung der Spinvariablen.**

    Atomare fetchAndAdd-Operation zur Vermeidung von Überlaufproblemen bei dem Zähler, der für die Zuordnung der Spinvariablen benötigt wird.
  - **Schwierigkeiten: Pro Lockvariable für ihre Verwaltung benötigter Speicherplatz proportional zur Zahl der Threads.**

Pufferspeicher bei Multiprozessoren: Array-Based Queuing Lock

```
class ArrayBasedQueuingLock implements Lock {
  static int MUSTWAIT = 1;
  static int HASLOCK = 2;
  Scheduler scheduler;
  int slots[] = new int[Spinlock.NUMBEROFPROCESSES];
  int myPlace[] = new int[Spinlock.NUMBEROFPROCESSES];
  int nextSlot;

  public ArrayBasedQueuingLock(Scheduler scheduler) {
    nextSlot = 0; slots[0] = HASLOCK;
    for (int i = 1; i < Spinlock.NUMBEROFPROCESSES; i++) {
      slots[i] = MUSTWAIT;
    }
    this.scheduler = scheduler;
  }
```


Pufferspeicher bei Multiprozessoren: Array-Based Queuing Lock

```
  private int fetchAndIncrement(){
    scheduler.beginOfAtomic();
      int old = nextSlot++;
    scheduler.endOfAtomic();
    return old;
  }

  private void atomicAdd(int x) {
    scheduler.beginOfAtomic();
      nextSlot += x;
    scheduler.endOfAtomic();
    return;
  }
```

Pufferspeicher bei Multiprozessoren: Array-Based Queuing Lock

```
public void acquire() {
  myPlace[scheduler.myPid()] = fetchAndIncrement();
  if (myPlace[scheduler.myPid()] == Spinlock.NUMBEROFPROCESSES){
    atomicAdd(-Spinlock.NUMBEROFPROCESSES);
  }
  myPlace[scheduler.myPid()]
    = myPlace[scheduler.myPid()] % Spinlock.NUMBEROFPROCESSES;
  while (slots[myPlace[scheduler.myPid()]] == MUSTWAIT) {
    scheduler.system
             .updateSyncState(scheduler.myPid(),
                              "Slot: " + myPlace[scheduler.myPid()],
                                         Color.red);
    scheduler.schedule();
  }
  scheduler.system.updateSyncState(scheduler.myPid(),
                                   Color.green);
  slots[myPlace[scheduler.myPid()]] = MUSTWAIT;
}
```


Pufferspeicher bei Multiprozessoren: Array-Based Queuing Lock

```
public void release() {
  slots[(myPlace[scheduler.myPid()] + 1)
        % Spinlock.NUMBEROFPROCESSES]
    = HASLOCK;
  scheduler.system.updateSyncState(scheduler.myPid(),
                                   Color.white);
}
}
```

Pufferspeicher bei Multiprozessoren: List-Based Queuing Lock

- List-Based Queuing Lock
  - Idee: Anforderungen werden in verketteter Liste geführt. Für blockierte Prozesse wird jeweils ihre zugeordnete Zustandsinformation in einem Listenelement geführt, das in seinem lokalen Speicher liegt.

    Bei Freigabe wird jeweils der eigene Zustand und der des nächsten Wartenden verändert.
  - Vorteil: - Garantiert FIFO-Abarbeitung
    - Wartet aktiv an lokalen Variablen
    - Beansprucht wenig Speicherplatz (1 Wort pro Knoten unabhängig von der Zahl der Lockvariablen)
    - Arbeitet gleich gut für Systeme mit und ohne Cachekohärenz
  - Voraussetzung: Atomare fetch_and_Store- sowie compare_and_Swap-Operation
  - Vorteile: Bestes bekanntes Verfahren
  - Anmerkung: Durch etwas kompliziertere Realisierung der nachfolgenden release-Operation kann auf atomare compare_and_Swap-Operation verzichtet werden

Pufferspeicher bei Multiprozessoren: List-Based Queuing Lock

```
import java.awt.*;

class QueueNode {
  int next;
  boolean locked;
  public QueueNode() {
    next = -1; locked = false;
  }
}

class ListBasedQueuingLock implements Lock {
  Scheduler scheduler;
  QueueNode[] queueNodes
     = new QueueNode[Spinlock.NUMBEROFPROCESSES];
  QueueNode tail;

  public ListBasedQueuingLock(Scheduler scheduler) {
    tail = new QueueNode();
    for (int i = 0; i < Spinlock.NUMBEROFPROCESSES; i++) {
      queueNodes[i] = new QueueNode();
    }
    this.scheduler = scheduler;
  }
```

Pufferspeicher bei Multiprozessoren: List-Based Queuing Lock

```
private int fetchAndStore(QueueNode memory, int value){
  scheduler.beginOfAtomic();
    int old = memory.next;
    memory.next = value;
  scheduler.endOfAtomic();
  return old;
}

private boolean compareAndSwap(QueueNode memory,
                               int value1, int value2) {
  boolean result = false;
  scheduler.beginOfAtomic();
    if (result = (memory.next == value1)) {
      memory.next = value2;
    }
  scheduler.endOfAtomic();
  return result;
}
```


Pufferspeicher bei Multiprozessoren: List-Based Queuing Lock

```
public void acquire() {
  queueNodes[scheduler.myPid()].next = -1;
  int predecessor = fetchAndStore(tail, scheduler.myPid());
  if (predecessor >= 0) {
    queueNodes[scheduler.myPid()].locked = true;
    queueNodes[predecessor].next = scheduler.myPid();
    while (queueNodes[scheduler.myPid()].locked) {
      scheduler.system.updateSyncState(scheduler.myPid(),
                                       getQueue(),
                                       Color.red);
      scheduler.schedule();
    }
  }
  scheduler.system.updateSyncState(scheduler.myPid(),
                                   getQueue(),
                                   Color.green);
}
```

```
  public void release() {
    if (queueNodes[scheduler.myPid()].next < 0) {
      if (compareAndSwap(tail, scheduler.myPid(), -1)) {
        return;
      }
      while (queueNodes[scheduler.myPid()].next < 0)
        scheduler.schedule();
    }
    queueNodes[queueNodes[scheduler.myPid()].next].locked = false;
    queueNodes[scheduler.myPid()].next = -1;
    scheduler.system.updateSyncState(scheduler.myPid(),
                                     Color.white);
  }
```



```
  String getQueue() {
    int i, root;

    String result2 = new String();
    root = -1;
    for (i = 0; i < Spinlock.NUMBEROFPROCESSES; i++) {
      if (!queueNodes[i].locked && queueNodes[i].next >= 0) {
        root = i;
        break;
      }
    }
    if (root < 0) root = tail.next;
    while (root >= 0) {
      result2 = result2 + root + " ";
      root = queueNodes[root].next;
    }
    return result2;
  }

}
```

Pufferspeicher bei Multiprozessoren: List-Based Queuing Lock

- Messungen an einer 'Sequent Symmetry' nach Mellor-Crummey und Scott

  - UMA-Multiprozessor mit bis zu 30 Prozessoren
  - Prozessor: Intel 80386 (16 MHz)
    64 kB Cache, 2-fach assoziativ
    Kohärenz durch snooping
    write-through, falls Inhalt der Pufferzeile auch in anderen Pufferspeichern,
    sonst write-back
  - Atomarer Befehl: fetch_and_store mit 1, 2 oder 4 Byte

Pufferspeicher bei Multiprozessoren: List-Based Queuing Lock

- Ausführungszeiten verschiedener Spinlock-Implementierungen

Kritischer Abschnitt leer

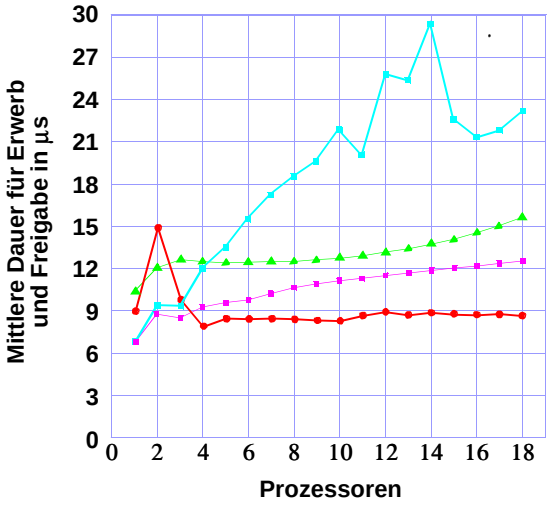

Kritischer Abschnitt 6,48 µs

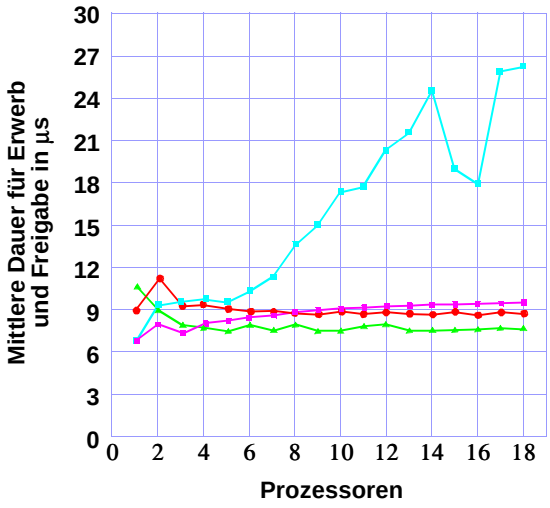

test & test & test
test & set, exp.
array based
list-based queuing

2.2.5 Barrieren

❑ Zentralisierte Barrieren

- ◆ An einer zentralen Variablen, die die noch ausstehenden Prozesse zählt, warten ankommende Threads aktiv bis der letzte ankommt.

  Der letzte leitet durch Umsetzen einer Booleschen Variablen die nächste Runde ein.
- ◆ Schwierigkeiten: Bei Parallelrechnern ohne Cachekohärenz entsteht starke Busbelastung durch die vorzeitig angekommenen Threads, da dann die Zählvariable nicht im Pufferspeicher eingelagert werden darf.


```
class Process extends Thread {
  private Scheduler scheduler;
  private Barrier barrier;
  private int round = 0;
  public Process(Scheduler scheduler, String name,
                 Barrier barrier) {
    this.scheduler = scheduler; setName(name);
    this.barrier = barrier;
  }
  private void println(String string) {
    scheduler.system.tmp.println(string);
    System.out.println(string);
  }

  public void run () {
    scheduler.schedule();
    println("Process " + getName() + " started");
    scheduler.sleep(1000);
    for (round = 0; round < 3; round++) {
      println(getName() + ": begin of round " + round);
      scheduler.sleep((scheduler.myPid() + 1) * 10000);
      barrier.join();
    }
    scheduler.eliminateThread(this);
  }
}
```

Pufferspeicher bei Multiprozessoren: Zentralisierte Barrieren

```
class Barrier {
  Scheduler scheduler;
  boolean localSense[] = new boolean[Scheduler.NUMBEROFTHREADS];
  boolean sense = true;
  int numberOfThreads;
  int count;

  public Barrier(Scheduler scheduler, int numberOfThreads) {
    count = this.numberOfThreads = numberOfThreads;
    for (int i = 0; i < Scheduler.NUMBEROFTHREADS; i++) {
      localSense[i] = true;
    }
    this.scheduler = scheduler;
  }
```


Pufferspeicher bei Multiprozessoren: Zentralisierte Barrieren

```
  private int fetchAndDecrement(){
    scheduler.beginOfAtomic();
      int old = count--;
    scheduler.endOfAtomic();
    return old;
  }

  public void join() {
    localSense[scheduler.myPid()] = !localSense[scheduler.myPid()];
    System.out.println(scheduler.myPid() + ": count = " + count);
    if (fetchAndDecrement() == 1) {
      count = numberOfThreads;
      sense = localSense[scheduler.myPid()];
    } else {
      scheduler.system.updateSyncState(scheduler.myPid(),
                                       Color.red);
      while (sense != localSense[scheduler.myPid()])
        scheduler.schedule();
    }
    scheduler.system.updateSyncState(scheduler.myPid(),
                                     Color.green);
  }
}
```

- **Dissemination Barrier**
  - **Idee: Baumartige Anordnung der Koordinierung. In der k-ten Runde koordinieren sich Prozessor i mit Prozessor (i + 2^k) % P (P ist die Zahl der beteiligten Threads)**

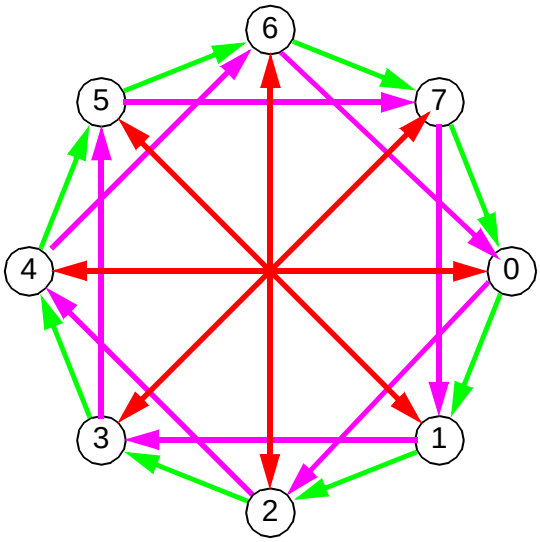

  - **Vorteil: Reduktion der Zugriffe zu nicht-lokalen Speicherorten; jeder Prozessor wartet aktiv an eigenen, statisch festlegbaren Variablen.**


```
class Flag {
  private boolean flag;
  public Flag(boolean f) {
    flag = f;
  }
  public boolean getValue() {
    return flag;
  }
  public void setValue(boolean f) {
    flag = f;
  }
}

class Flags {
  public Flag myFlags[][], partnerFlags[][];
  public Flags(int rounds) {
    myFlags = new Flag[2][rounds];
    partnerFlags = new Flag[2][rounds];
    for (int r = 0; r < 2; r++)
      for (int k = 0; k < 3; k++)
        myFlags[r][k] = new Flag(false);
  }
}
```

```
class Barrier {
  Scheduler scheduler;
  int parity[] = new int[100]; boolean sense[] = new boolean[100];
  Flags localFlags[] = new Flags[100];
  Flags allnodes[] = new Flags[100];
  int numberOfThreads, rounds = 0;

  public Barrier(Scheduler scheduler, int numberOfThreads) {
    int tmp = numberOfThreads * 2 - 1;
    while ((tmp = tmp / 2) > 0) rounds++;
    for (int i = 0; i < numberOfThreads; i++) {
      allnodes[i] = new Flags(); parity[i] = 0;
      sense[i] = true; localFlags[i] = allnodes[i];
    } // tmp = ceiling(ld numberOfThreads)
    for (int i = 0; i < numberOfThreads; i++) {
      for (int j = 0; j < numberOfThreads; j++) {
        for (int k = 0; k < rounds; k++) {
          if (j == (i+(int)(Math.pow(2,k)+0.1)) % numberOfThreads)
            for (int r = 0; r < 2; r++) {
              allnodes[i].partnerFlags[r][k]
                = allnodes[j].myFlags[r][k];
          }
        }
      }
    }
    this.scheduler = scheduler;
  }
```



```
  public void join() {
    int myPid = scheduler.myPid();
    for (int round = 0; round < rounds; round++) {
      localFlags[myPid]
        .partnerFlags[parity[myPid]][round]
        .setValue(sense[myPid]);
      do {
       scheduler.schedule();
      } while (localFlags[myPid]
                 .myFlags[parity[myPid]][round]
                 .getValue()
               != sense[myPid]);
    }
    if (parity[myPid] == 1) {
      sense[myPid] = !sense[myPid];
    }
    parity[myPid] = 1 - parity[myPid];
  }
}
```

Pufferspeicher bei Multiprozessoren: Tree-Based Barrier

- **Tree-Based Barrier**
  - **Idee**
    1. **Warten auf Rundenende in Warte(acquire)-Baum**
    2. **Start der neuen Runde signalisieren über Aufweck(wakeup)-Baum**

    d. h. die Informationen über das Erreichen bzw. Verlassen der Barriere werden in baumartigen Strukturen gesammelt bzw. verbreitet.
  - **Vorteile**
    1. **Aktives Warten nur an knotenlokalen Variablen**
    2. **Benötigter Speicherplatz proportional zur Zahl der Knoten**
    3. **Erzeugt an Maschinen ohne Broadcast das theoretische Minimum an Nachrichten**
    4. **Hat im kritischen Pfad eine Nachrichtenzahl proportional zu log(#Threads)**

Pufferspeicher bei Multiprozessoren: Tree-Based Barrier

5. **Anhand eines Ankunftsbaums mit Fanin 4 wird die Ankunft aller Prozesse an der Barriere abgewartet.**

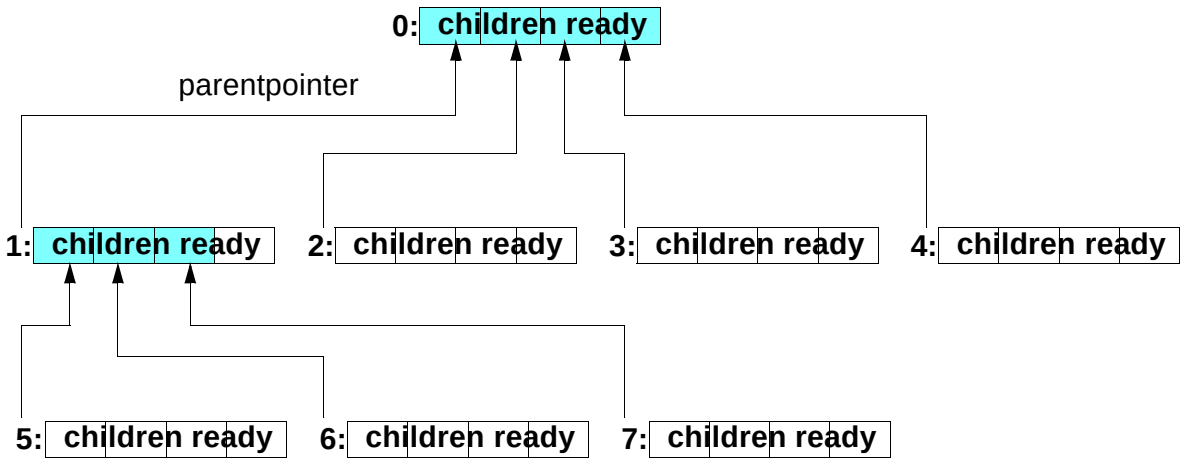

6. **Mit Hilfe eines Aufweckbaumes mit Fanout 2 wird die Erlaubnis zur Weiterarbeit erteilt.**

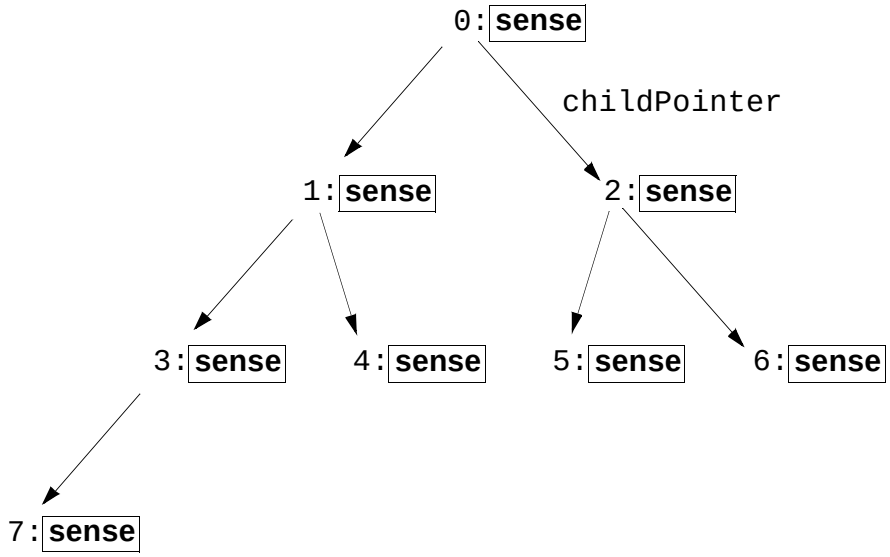


```
class Flag {
  public boolean flag;
  public Flag(boolean f) {
    flag = f;
  }
  public boolean getValue() {
    return flag;
  }
  public void setValue(boolean f) {
    flag = f;
  }
}


class TreeNode {
  public Flag parentSense;
  public Flag parentPointer;
  public Flag childPointers[] = new Flag[2];
  public Flag haveChild[] = new Flag[4];
  public Flag childNotReady[] = new Flag[4];
  public Flag dummy;
};
```

Pufferspeicher bei Multiprozessoren: Tree-Based Barrier

```
class Barrier {
  Scheduler scheduler;
  TreeNode nodes[];
  Flag sense[];       // sense[i] is local to node i
  public Barrier(Scheduler scheduler, int numberOfThreads) {
    int i, j;
    nodes = new TreeNode[numberOfThreads];
    sense = new Flag[numberOfThreads];
    for (i = 0; i < numberOfThreads; i++) {
      sense[i] = new Flag(true);
      nodes[i] = new TreeNode();
      nodes[i].parentSense = new Flag(false);
      nodes[i].dummy = new Flag(false);
    }
```


Pufferspeicher bei Multiprozessoren: Tree-Based Barrier

```
//    building acquire and wakeup tree
    for (i = 0; i < numberOfThreads; i++) {
//      build part of acquire tree
      for (j = 0; j < 4; j++) {
        nodes[i].childNotReady[j]
            = (4*i+j+1 < numberOfThreads ? new Flag(true)
                                         : new Flag(false));
        nodes[i].haveChild[j]
            = (4*i+j+1 < numberOfThreads ? new Flag(true)
                                         : new Flag(false));
      }
      nodes[i].parentPointer
        = (i == 0 ? nodes[i].dummy
                  : nodes[(i - 1) / 4].childNotReady[(i - 1) % 4]);
//      build part of wakeup tree
      if (i != 0)
      nodes[i].childPointers[0]
        = (2 * i + 1 >= numberOfThreads ? nodes[i].dummy
                                        : nodes[2 * i + 1].parentSense);
      nodes[i].childPointers[1]
        = (2 * i + 2 >= numberOfThreads ? nodes[i].dummy
                                        : nodes[2 * i + 2].parentSense);
    }
    this.scheduler = scheduler;
  }
```

Pufferspeicher bei Multiprozessoren: Tree-Based Barrier

```
  public void join() {
    int i, vpid = scheduler.myPid();
    while (nodes[vpid].childNotReady[0].flag
           || nodes[vpid].childNotReady[1].flag
           || nodes[vpid].childNotReady[2].flag
           || nodes[vpid].childNotReady[3].flag)
      scheduler.schedule();
//    prepare for next barrier
    for (i = 0; i < 4; i++) {
      nodes[vpid].childNotReady[i].flag
        = nodes[vpid].haveChild[i].flag;
    }
//    let parent know I'm ready
    nodes[vpid].parentPointer.flag = false;
//    if not root, wait until my parent signals wakeup
    if (vpid != 0) {
      while (nodes[vpid].parentSense.flag != sense[vpid].flag)
        scheduler.schedule();
    }
//    signal children in wakeup tree
    nodes[vpid].childPointers[0].flag = sense[vpid].flag;
    nodes[vpid].childPointers[1].flag = sense[vpid].flag;
    sense[vpid].flag = !sense[vpid].flag;
  }
```


Pufferspeicher bei Multiprozessoren: Tree-Based Barrier

- **Messungen an einer 'Sequent Symmetry' und einer 'Butterfly' nach Mellor-Crummey und Scott**

- **Butterfly (Hersteller: BBN)**
  - **NUMA-Multiprozessor mit bis zu 256 Prozessoren**
  - **Prozessor: Motorola MC68000 (8 MHz)**
  - **Atomarer Befehl: fetch_and_clear_then_add**
    fetch_and_clear_then_xor beide mit 2 Byte

```
int fca(int* destination, int mask, int* source) {
  int tmp;
  *destination = (*destination & mask) + *source;
  return tmp;
}
```

Pufferspeicher bei Multiprozessoren: Tree-Based Barrier

Ausführungszeiten verschiedener Barrieren-Implementierungen