Architecture of Parallel Computer Systems
- HPC Architecture -

J. Simon, C. Plessl

SoSe 18

L.079.05810
Master Course for Informatik and
Computer Engineering “Embedded Systems”,
Wirtschaftsinformatik
V2/Ü1

www.uni-paderborn.de/pc2

Organizational

- Lecturer:
  Jens Simon
  Office: O2.161
- Lecture: Monday, **16:00 – 18:15, O1.258**
- Exercise: Tuesday, **14:00 – 15:30, O1.258**

- News about Courses:
  https://pc2.uni-paderborn.de/teaching/lectures/architektur-paralleler-rechnersysteme-hpc-architectures-ss-2018/

Course Assessment

- Attendance at
  - Lectures (3 SWS)
  - Exercises (2 SWS)
- Submission of solved exercises
  - Sample solutions optionally, if provided by participants
- Examination
  - Oral Exam

Lecture Procedure

- Slides are provided immediately after the lecture on the web site of the lecture
- A script for the lecture is not available
- Lecture targets on
  - Introduction in parallel programming and programming methods
  - Overview on architectures of parallel systems
  - Different aspects of efficiency
  - Technologies from processors up to communication networks
  - Small servers as well as whole data centers
  - Performance oriented usage of HPC systems
  - ...

Exercise Procedure

- Theoretical exercises associated to the lecture
- The focus is on practical work on HPC systems of PC²
  - Send initially an email with name and IMT account to me
  - You will get limited access to some HPC-systems

About Me

- Dr. rer. nat. Jens Simon
  - Career:
    - Since 2001: Paderborn Center for Parallel Computing, PC²
    - 1999 to 2001: Konrad-Zuse Institut Berlin (ZIB)
    - 1992 to 1998: Universität Paderborn / PC²
  - Lecturer:
    - HPC–related courses
  - Research:
    - Computer systems, (specialized) processors
    - High Speed communication networks
    - Middleware for HPC-Systems
  - Services:
    - Writing proposals, procurements, …
    - Project work
    - HPC consultant
    - …

Literature

Computer architecture

- Culler, D. E.; Singh, J. P.; Gupta, A.: *Parallel computer architecture : A hardware/software approach*, 1999
- Rauber, T.; Rünger, G.: *Parallele Progammierung*, Springer, 2012
- Hwang, K.: *Advanced Computer Architecture, 1993*
- Hennessy, J.; Patterson D.: Computer Architecture – A Quantitative Approach, 1996
- Tanenbaum, A.; Computerarchitektur – Strukturen – Konzepte – Grundlagen, 2005
- Barros L.A., Hölzle U; Datacenter As A Computer, 2009
- Kaxiras S., Martonosi, M.; Computer Architecture Techniques for Power-Efficiency, 2008

Literature

Parallel programming

- Andrews, G. R.: *Multithreaded, Parallel, and Distributed Programming*, 2000
- Leopold, C.: Parallel and Distributed Computing – a survey of models, paradigms, and approaches, 2001
- Tanenbaum, A.: Moderne Betriebssysteme, 2009
- Groop, W.; Lusk, E.; Skjellum, A.: Using MPI – Portable Parallel Programming with the Message-Passing Interface, 1999
- Groop, W.; Lusk, E.; Thakur, R.: Using MPI-2 – Advanced Features of the Message-Passing Interface, 1999
- Chapman, B.; Jost, G.; van der Pas, R.: Using OpenMP – Portable Shared Memory Parallel Programming, 2007

Acknowledgement

Parts of the lecture are inspired by the book

"**Parallel Computer Architecture - A Hardware / Software Approach**" *von Culler, Singh und Gupta*

Parallel Computing: Users‘ View

Warum paralleles Rechnen?

- Die Welt ist höchst parallel – ein bewährtes Prinzip
  - Physikalische Abläufe sind „parallel“
    - Kristallwachstum, Gravitationsfelder, Chemische Reaktionen, …
  - Soziale und Arbeitsprozesse sind „parallel“
    - Ameisenkolonie, Straßenverkehr, Produktionsstätten, Finanzwirtschaft, Universitäten, politische Prozesse, …
  - Menschliches Gehirn, Sensorik, Lernverhalten sind „parallel“
    - Denken, Sinnesorgane, Evolutionsprozesse, …

- Eine Koordination der größtenteils unabhängigen Prozesse ist aber in den meisten Fällen notwendig

Das Prinzip der Parallelität bereits bei der Beschreibung der Abläufe nutzbar

Warum Parallelverarbeitung?

- Einzelprozessorsysteme bieten nicht genügend Ressourcen für viele Anwendungsbereiche
  - Trotz des rasanten Geschwindigkeitszuwachses bei PCs.
- Sogenannte „Grand-Challenge“ Anwendungen benötigen bereits heute um einige Größenordnungen mehr Rechenleistung als die eines einzelnen PCs.
  - Klimaveränderung, Bioinformatik, Astrophysik, …
- Kopplung verschiedener Methoden für das Auffinden einer besseren Lösung
  - Kooperative Systeme
- Höhere Anforderungen an Sicherheit und Verfügbarkeit
  - Redundante Systeme

Einsatzgebiete von Hochleistungsrechnern (HPC)

- Forschung
  - Klimawandel, Astrophysik, …
- Produktentwicklung
  - Mikrochip-Entwurf, Werkstofftests, Virtuelle Prototypen, …
- Informationssysteme
  - Datenbanken, Suchmaschinen, Maschinelles Lernen, Wetterdienste, …
- Virtuelle Umgebungen
  - Fahrzeugsimulationen, Architekturplanungen, …
- Gesundheitswesen
  - Medikamentenentwicklung, Genomanalyse, …
- Finanzdienstleistungen
  - Fonds- u. Risikoanalysen, High-Frequency-Trading, …
- …

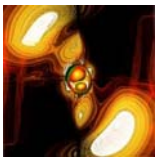

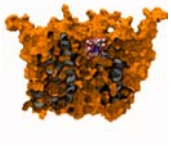

HPC in der Forschung

- Numerische Simulation
  - dritte Säule in der Forschung, neben Theorie und Experiment
  - sehr rechenintensiv und teilweise mit sehr hohem Speicherbedarf
  - zur Untersuchung von sehr langsam oder sehr schnell ablaufenden Prozessen
  - ohne störende äußere Einflüsse
  - zur Vermeidung gefährlicher Experimente
  - Nutzung unterschiedlicher Skalen
    - Z.B. Physik: Astrophysik bis hin zur Quantenmechanik

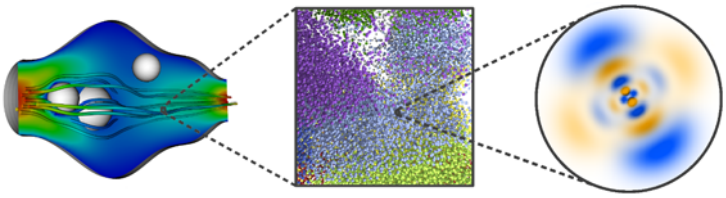

Kontinuumsmethode Molekulardynamik Quantenmechanik

Founding Visions of Computational Science

Abel Prize Winner

The „third“ leg quotation (1986)
„During its spectacular rise, the computational has joined the theoretical and experimental branches of science, and is rapidly approaching its two older sisters in importance and intellectual respectability.“
Peter D. Lax, in *J. Stat. Phys.*, 43:749-756

The computer as a „scientific instrument“

The „Grand Challenge“ quotation (1989)
„A few areas with both extreme difficulties and extraordinary rewards for success should be labelled as the “Grand Challenges of Computational Sciences”. [They] should define opportunities to open up vast new domains of scientific research, domains that are in accessible to traditional experimental or theoretical models of investigation.”
Kenneth G. Wilson, in *Future Generation Computer Systems*, 5:171-189

Nobel Prize Winner

How HPC fits into Scientific Computing

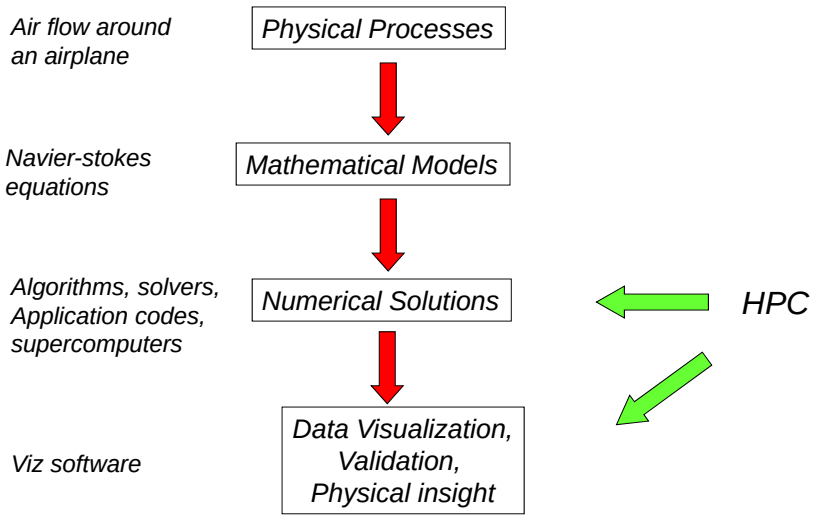

Performance: Key Factor for HPC

- Numerical Simulation do need number crunching

- FLOPS, or Flop/s: FLoating-point Operations Per Second
  - MFLOPS: MegaFLOPS, 10^6 flops, mobile devices
  - GFLOPS: GigaFLOPS, 10^9 flops, home PC
  - TFLOPS: TeraFLOPS, 10^{12} flops, fast servers
  - PFLOPS: PetaFLOPS, 10^{15} flops, class of today's supercomputers (http://www.top500.org)
  - EFLOPS: ExaFLOPS, 10^{18} flops, supercomputers by > 2020
- MIPS: Mega Instructions per Second
  - Fix-point or logical operations
  - Equal to frequency of processor in MegaHertz (if only 1 IPS)
  - von Neumann computer had 0.00083 MIPS

Most Powerful Supercomputer since 06/2016

- Name: TaihuLight
- Place: Nat. Supercomputing Center Wuxi, China
- Vendor: Sunway
- Purpose: earth system modelling, weather forecast, life sciences, Big Data analysis

- LINPACK: 93.01 Petaflops
- Peak Performance 125.4 PFlop/s
- Racks: 40 (XXL form factor)
- Nodes: 40,960
- Processor: Sunway 260C
- Cores 10,649,600
- Memory: 1,25 PiB
- Interconnect: InfiniBand
- Floor Space: 604 m²
- Power consumption: 15.4 MWatt
- OS: Raise OS (Linux)
- Price: ca. 238 Mio.€

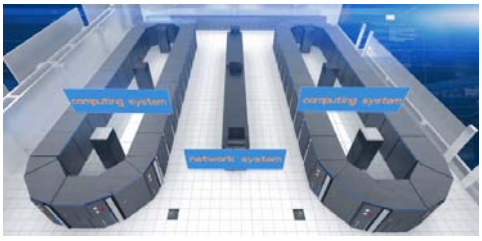

Source: top500.org

The Chinese-designed Processor

- ShenWei architecture 26010
  - 64-bit RISC
  - 4 clusters each with 64 SIMD vector processors (CPE) and 1 Management Processor (MPE)
  - CPE executes up to 8 DP floating point operation per cycle
  - 1.45 GHz
  - Scratchpad memory 64 kiB data and 16 kiB instructions (no copy of data in memory needed)
  - 4 x 128-bit channels DDR3 @ 2133 MHz
  - Network on a chip, no HW for traditional cache coherency

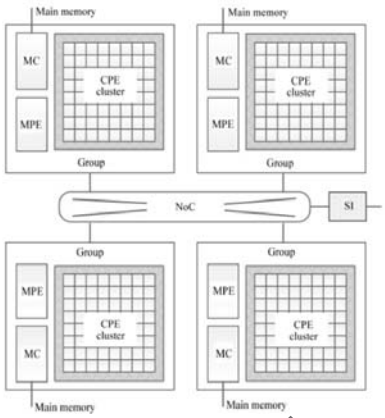

Performance Metrics

- Theoretical peak performance R_{theor}
  - maximum FLOPS a machine can reach in theory.
    - Clock_rate * no_cores * no_FPU/CORE * INST/CLOCK
    - 3 GHz, 16 cores, 4 FPU/CORE, 2 INST/CLOCK
      → $R_{theor} = 3*10^9 * 16 * 4 * 2 = 384$ GFLOPS
- Real performance R_{real}
  - FLOPS for specific operations, e.g. vector multiplication
- Sustained performance $R_{sustained}$
  - performance on an application, e.g. CFD

$R_{sustained} << R_{real} << R_{theor}$

Not uncommon: $R_{sustained} < 10\%$ *of* R_{theor}

	TaihuLight #1	Tianhe-2 #2	ORNL Titan #5
Peak Performance	125.4 PFLOPS Node=256 CPEs + 4 MPEs Supernode= 256 nodes System= 160 Supernodes Cores=260*256*160=10M	54.9 PFLOPS CPU=6.75 PFLOPS Phi=48.14 PFLOPS	27 PFLOPS CPU=2.6 PFLOPS GPU=25.5 PFLOPS
HPL Linpack	93 PFlop/s	30.65 PFlop/s	17.6 PFlop/s
HPL % Peak	74.13%	55.83%	65.19%
HPCG Benchmark	0.371 PFlop/s	0.58 PFlop/s	0.322 PFlop/s
HPCG % Peak	0.30%	1.1%	1.2%
Compute Nodes	40,960	16,000	18,688
Node	256 CPEs + 4 MPEs	2 x Intel Xeon + 3 x Intel Phi	1 x AMD + 1 x GPU
Sockets	40,960 processors	32,000 Xeon + 48,000 Phi	18,688 AMD + 18,688 GPU
Node Peak Performance	3.06 TFlop/s CPE: 8 flop/core/cycle 1.45GHz*8*256 = 2.969 TFlop/s	3.43 TFlop/s 2 x 0.2112 TFlop/s + 3 x 1.003 TFlop/s	1.45 TFlop/s 0.141 TFlop/s + 1.31. TFlop/s

2nd Most Powerful Supercomputer 06/2013

- Name: Tianhe-2 (“MilkyWay-2”)
- Place: Guangzhou, China
- Vendor: National University of Defense Technology, Guangzhou, China
- Purpose: Research and Education

Source: top500.org

- LINPACK: 33.86 PFlop/s
- Floor Space: 720 m²
- Racks: 162 (125 compute, 13 Arch switches, 24 storage)
- Nodes: 16,000 (2 CPU sockets, 3 Xeon-Phi cards, 64 GiB)
- Sockets: 32,000 Intel Ivy Bridge Xeon,2.2GHz and 48,000 Xeon Phi
- Cores 3,120,000
- Memory: 1.4 PB (1024 TB CPU, 384 TB Xeon PHI)
- Power consumption: 17.8 MWatt (24 MWatt incl. cooling)
- OS: Kylin Linux

Fastest European Supercomputer 11/2014

- "Piz Daint", Cray XC50 with upgrade path from XC40
- CSCS, Swiss
- 19.59 PetaFLOP/s Linpack performance (25.32 PFlop/s peak)
- 5,320 nodes, each with one Intel E5-2690v3 + nVIDIA P100
  and 1,256 nodes, each with two Intel E5-2695v4
- Aries Dragonfly network topology (3 x 14 Gbit/s interconnect)

- In total
  - 361,760 cores
  - 332 TByte main memory
  - 2.27 MWatt power consumption
  - Floorspace ca. 100 m²
  - Investment: > 40 Mio. Franken

Source: CSCS

Fastest German Supercomputer 11/2015

- "Hazel Hen", Cray XC40
- HLRS, Stuttgart
- 5,64 PetaFLOP/s Linpack performance (7.4 PFlop/s peak)
- 7,712 nodes, each with two Intel E5-2680v3 12C 2.5GHz
- Aries Dragonfly network topology (3 x 14 Gbit/s interconnect)
- total
  - 185,088 CPU-cores
  - 964 TByte main memory
  - 3.615 MWatt power consumption
  - Floorspace ca. 150 m²
  - Investment: > €60 Mio.

Source: HLRS

European Top500-List 11/2017

Rank	Site	System	Cores	RMAX (PFLOP/s)	RPEAK (PFLOP/s)	POWER[MW]
3	CSCS, Switzerland	Cray XC40/50	361,760	**19.59**	25.32	1.31
14	CINECA, Italy	Intel Xeon Phi	314,384	**7.47**	15.37	?
15	Meteo Office, UK	Cray XC40	241,920	**6.76**	8.12	?
19	HLRS, Germany	Cray XC40	185,088	**5.64**	7.40	3.62
21	Total Exploration Production, France	SGI ICE X	220,800	**5.28**	6.71	4.15
22	FZJ, Germany	IBM BlueGene/Q	458,752	**5.00**	5.87	2.30
23	CEA, France	Bull Sequana	208,896	**4.96**	9.35	1.24
27	ECMWF, UK	Cray XC40	126,468	**3.94**	4.25	1.9
28	ECMWF, UK	Cray XC40	126,468	**3.94**	4.25	1.9
29	FZJ, Germany	T-Platforms/Dell	155,150	**3.78**	6.5	1.34
37	Exploration & Production, Italy	IBM iDataPlex	72,000	**3.18**	4.60	1.23
42	DKRZ, Germany	Bullx DLC 720	99,072	**3.01**	3.96	1.27
44	LRZ, Germany	IBM iDataPlex	147,456	**2.89**	3.18	3.42

J. Si

Paderborn Center for Parallel Computing

Supercomputer wird zum Mobiltelefon

- Rechenleistung zur Lösung eines Gleichungssystems (Linpack-Benchmark)

1979: Cray 1 und Fortran

- 3.4 MFlop/s
- $5 - $9 Mio.
- 5.25 t
- 115 kW

32 Jahre

1 : 38 →
12.000 : 1 →
40.000 : 1 →
25.000 : 1 →

2012: Galaxy S3 mit Android 4.1.2 und Java

- 130 MFlop/s
- $600
- 133 g
- ca. 5 Watt

Wird dieses immer so weitergehen?

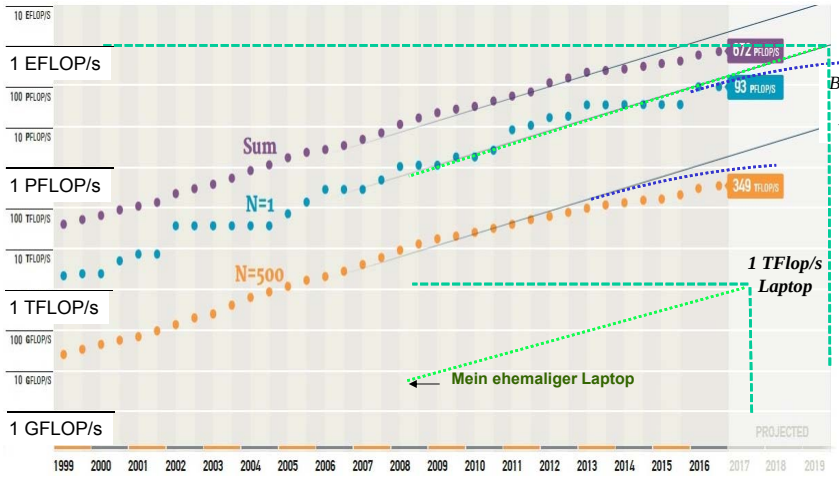

Shrinking Transistors

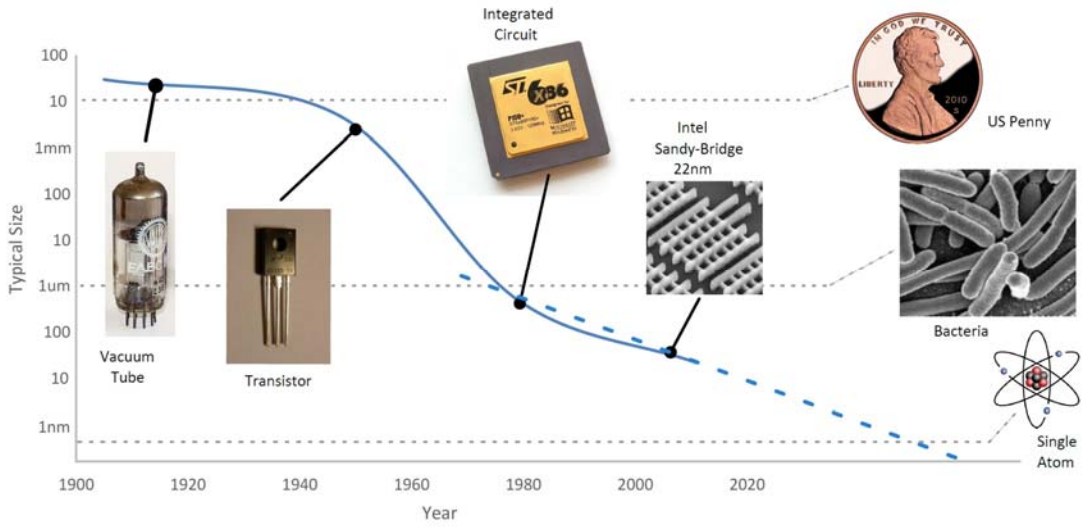

Transistors Won't Shrink Beyond 2021

Year of Production	2015	2017	2019	2021	2024	2027	2030
Device technology naming	P70M56	P48M36	P42M24	P32M20	P24M12 G1	P24M12 G2	P24M12 G3
"Node Range" labeling (nm)	16/14	11/10	8/7	6/5	4/3	3/2.5	2/1.5
Device structure options	finFET FDSOI	finFET FDSOI	finFET LGAA	finFET LGAA VGAA	VGAA M3D	VGAA M3D	VGAA M3D
			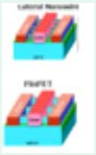		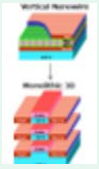	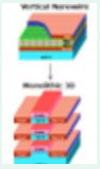	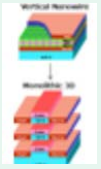

Source: International Technology Roadmap for Semiconductors

Der Weg zum optimalen Supercomputer

Das Vorbild

- Rechenleistung des Gehirns angenommen als 100 TFlop/s (H. Moravec) oder auch 10 PFlop/s (R. Kurzweil)
- Speicherleistung der Synapsen ca. 2 Petabyte
- Gehirn: ca. 1,4 kg Gewicht, 20 Milliarden Nervenzellen, 15 – 20 Watt chemische Leistungsaufnahme

Trotz der rasanten Entwicklung von Technik und Wissenschaft (im Wesentlichen exponentielles Wachstum) noch keine derart effiziente Maschine in Aussicht.

Beispiel: LHC Computing Grid

Beschleunigerring, Kollision unterschiedlicher Elementarteilchen für Higgs-Boson Nachweis

- Large Hadron Collider (LHC) im CERN liefert Messdaten („Events“)
- >140 Rechenzentren in 33 Ländern
- > 100.000 Prozessor-Cores für die Analyse der Messdaten im CERN
- > 140 PetaBytes Speicherkapazität im CERN ($140 \cdot 10^{15}$ Byte)
- Mehrebenenstruktur
  - Tier-0: CERN: Rohdaten
  - Tier-1: vorberechnete Daten
  - Tier-2: Datenverteilung und zentrale Rechenkapazitäten
  - Tier-3: lokale Rechenzentren
  - Tier-4: PCs der Wissenschaftler

Simon, CERN 2006

Beispiel: Google Data Center

- 45 Container, jeder mit
  - Ca. 1 000 Server
  - 250 kW Stromverbrauch
- ~ 4 bis 5 kW pro “Rack”

Quelle: Google™

Google Server-Knoten (Stand 2010)

- 2 Prozessoren
- Proprietäre double-wide DIMMs
- einzelner Lüfter pro Knoten (im Netzteil)
- nur 12 Volt Stromversorgung zum Knoten
- 12 Volt USV (Batterie)
- Verkabelung nur von der Frontseite

Parallel Programming: Basics

Programmierung von Parallelrechnern

- Speichermodelle
  - Gemeinsamer Speicher
  - Verteilter Speicher
- Programmiermethoden
  - Speichergekoppelt
  - Nachrichtengekoppelt
- Programmierkonzepte / Programmiersprachen
  - Annotierung sequentieller Programme (OpenMP)
  - Mehrere Ausführungsfäden - Threads (PThreads)
  - Expliziter Nachrichtenaustausch - Message-Passing (MPI)
  - ...

Speichermodell für „Shared-Memory“ Programme

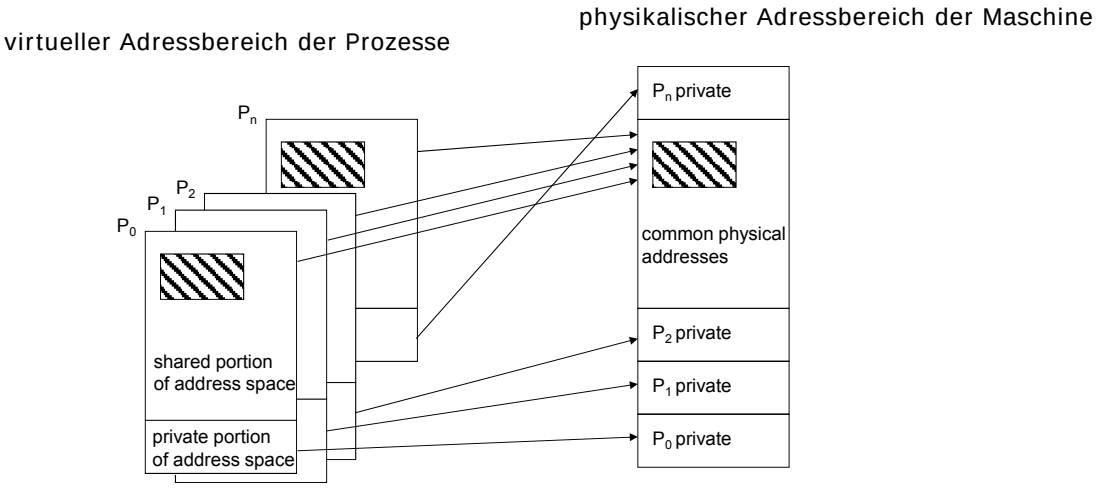

Speichermodell für „Message-Passing“ Programme

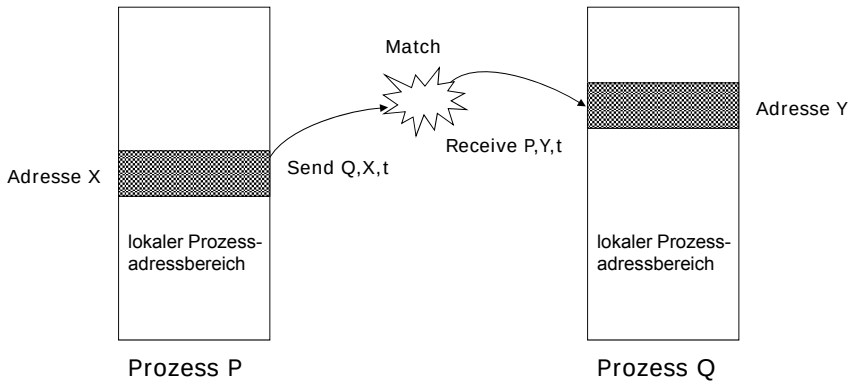

Programmiermethoden

- Nachrichtengekoppelte Multiprozessorsysteme
  - Prozesse kommunizieren mittels expliziten Nachrichtenaustausch
    Prozess$_1$: *send(x);* Prozess$_2$: *receive(x);*
  - Standards: MPI-1 und MPI-2

- Speichergekoppelte Multiprozessorsysteme
  - Zugriff auf gemeinsame Variablen *y = x*; oder
    shmem_get/shmem_put;
  - Synchronisation notwendig *lock(mutex_x); ...*
    unlock(mutex_x);
  - Nutzung von Multithreading: leichtgewichtige Prozesse
  - POSIX-Threads als Standard (PThreads)
  - durchgängiges Konzept für Workstations, Multiprozessor-Workstations (SMPs) und für die großen verteilten Multiprozessorsysteme aller Arten

Programmierkonzepte

- POSIX Threads
  - Gemeinsamer Speicher und Threads

- OpenMP
  - Erweiterung der Programmiersprachen C/C++ und Fortran

- Message Passing Interface (MPI)
  - Standardisierter Nachrichtenaustausch

- PGAS
  - Partitioned Global Address Space

Threads (Ausführungsfäden)

- Im Shared-Memory-Modell laufen mehrere Tasks (Threads), oftmals mit unterschiedlichen Funktionalitäten parallel ab. Die Tasks kommunizieren untereinander durch Schreiben und Lesen auf einem gemeinsamen Speicher.

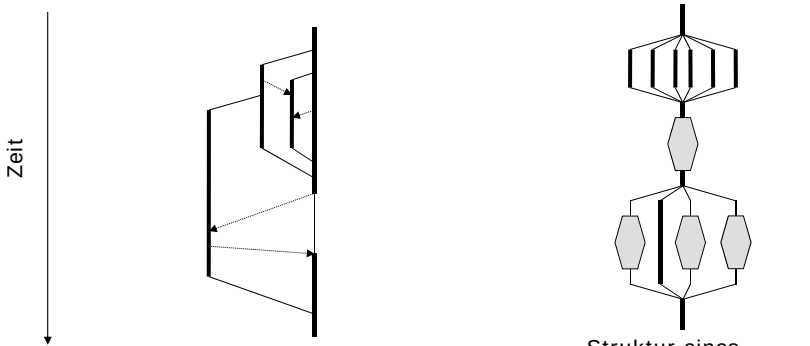

Struktur eines Multi-Threading-Programms

Struktur eines OpenMP-Programms

PThreads

- PThreads ist ein POSIX-Standard (Portable Operating System Interface for UNIX) für Threads.
- Bietet Funktionen zur Verwaltung von Threads.
- Schnittstelle zu vielen sequentiellen Programmiersprachen.
- Besteht aus einer Bibliothek und Header-Dateien
  - *Header-Datei* *#include <pthread.h>*
  - Bibliothek *libpthread.a*
- Compiler-Aufruf

```
gcc –pthread file.c        # GNU Compiler, Linux
icl /pthreads file.c       # Intel Compiler, Windows
```

PThread-Bibliothek

- Erzeugen eines POSIX Threads
  int ***pthread_create*** *(pthread_t *thread_id,*
  *const pthread_attr_t *attributes,*
  *void *(*thread_function)(void *),*
  *void *arguments);*
- Terminieren eines POSIX Threads
  – nach dem Rückkehr aus der Funktion
  – durch Aufruf der Rückkehrfunktion
  int ***pthread_exit*** *(void *status);*
- Warten auf Terminierung eines Threads
  int ***pthread_join*** *(pthread_t thread, void **status_ptr);*
- Rückgabe der Identität des Threads
  pthread_t ***pthread_self*** *();*
- Vergleich von Thread-Ids
  int ***pthread*** *(pthread_t t1, pthread_t t2);*

Example: POSIX Threads

```
                                                    /* Interface to the PThread-Library */
#include <pthread.h>
...
                                                    /* Definiton of a threaded routine */
void *routine(void *arg) {
  printf("Hello World!\n");
  pthread_exit ((void *) 0);
}
...
int main() {
                                                    /* Definition of required variables */
  pthread_t          thread;
  pthread_attr_t     attr = NULL;
  ...
                                                     /* Thread creation */
  err = pthread_create (&thread, attr, routine, (void *)arg);
  if (err) {
    printf ("FEHLER! pthread_create() : %d\n", err);
    exit(-1);
  }
}
```

PThread-Bibliothek

- Mutex Variablen
  - *int* ***pthread_mutex_init*** *(mutex, attr);*
  - *int* ***pthread_mutex_destroy*** *(mutex);*
  - *int* ***pthread_mutexattr_init*** *(attr);*
  - *int* ***pthread_mutexattr_destroy*** *(attr);*
  - *int* ***pthread_mutex_lock*** *(mutex);*
  - *int* ***pthread_mutex_trylock*** *(mutex);*
  - *int* ***pthread_mutex_unlock*** *(mutex);*
- Condition Variablen
  - *int* ***pthread_cond_init*** *(cond, attr);*
  - *int* ***pthread_cond_destroy*** *(cond);*
  - *int* ***pthread_condattr_init*** *(attr);*
  - *int* ***pthread_condattr_destry*** *(attr);*
  - *int* ***pthread_cond_wait*** *(cond, mutex);*
  - *int* ***pthread_cond_signal*** *(cond);*
  - *int* ***pthread_cond_broadcast*** *(cond);*

PThreads: Join

```
1  #include <pthread.h>
2  #include <stdio.h>
3  #define NUM_THREADS 3
4  ...
5  /* Thread-Routine */
6  void *routine (void *arg) {
7    sleep(1);
8    printf("Thread Nummer: %d.\n", arg);
9    pthread_exit ((void *) 0);
10 }
11 ...
12 int main() {
13    /* define Mutex-variables */
14    pthread_t       thread[NUM_THREADS];
15    pthread_attr_t  attr;
16    int             i, status, err;
17
18    /* set detach status to JOINABLE */
19    pthread_attr_init (&attr);
20    pthread_attr_setdetachstate (&attr,
21          PTHREAD_CREATE_JOINABLE);
22 /* Start all threads */
23    for(i=0; i < NUM_THREADS; i++) {
24     err = pthread_create (&thread[i], &attr,
25                           routine, (void *) (i+1));
26     if (err) printf("(main) ERROR - Creation failed...\n");
27    }
28
29    ...
30    /* Join with previously startet threads */
31    for(i=0; i < NUM_THREADS; i++) {
32     err = pthread_join (thread[i], (void **)&status);
33     if (err) printf("(main) ERROR - No join...\n");
34    }
35    printf( "All threads are successfully executed!\n");
36 }
```

Thread Synchronization is Essential

- Lost Update Problem
  - Concurrent writes
  - Dirty read

Example:

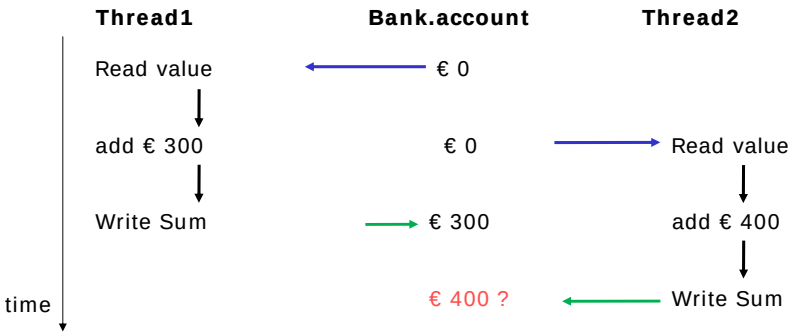

Mutex unter POSIX Threads

Mutex hat zwei grundlegende Funktionen.

- Lock:
  - ist Mutex frei, dann belegt der Thread den Mutex
  - ist Mutex belegt, dann blockiert der Thread bis der Mutex frei wird
- Unlock:
  - gibt Mutex frei

- Initialisierung

  int ***pthread_mutex_init*** *(pthread_mutex_t *mut,*
  *const pthread_mutexattr_t *attr);*

- Destruktion

  int ***pthread_mutex_destroy*** *(pthread_mutex_t *mut);*

Mutex

- *Lock*
  *int **pthread_mutex_lock** (pthread_mutex_t *mut);*
  – falls Mutex frei, belege den Mutex
  – falls Mutex belegt, warte bis Mutex frei wird

- *Unlock*
  *int **pthread_mutex_unlock** (pthread_mutex_t *mut);*
  – Mutex freigeben (falls Thread auf Lock wartet, belege den Mutex mit dem Lock eines wartenden Threads)

- Mutex Test
  *int **pthread_mutex_trylock** (pthread_mutex_t *mut);*
  – falls Mutex frei, belege den Mutex, andernfalls gebe Wert *EBUSY* zurück

PThreads: Mutex

```
1  #include <pthread.h>
2
3  /* define Mutex-variable */
4  pthread_mutex_t      mutex_sum =
5              PTHREAD_MUTEX_INITIALIZER;
6  int                  sum = 100;
7
8  void *minus (void *arg) {
9    int i = 0;
10
11   for(i=0; i < 1000000; i++) {
12     pthread_mutex_lock (&mutex_sum);
13     random();
14     sum = sum - 1;
15     pthread_mutex_unlock (&mutex_sum);
16   }
17 }
18
19 void *plus (void *arg) {
20   int i = 0;
21
22   for(i=0; i < 1000000; i++) {
23     pthread_mutex_lock (&mutex_sum);
24     random();
25     sum = sum + 1;
26     pthread_mutex_unlock (&mutex_sum);
27   }
28 }
```

```
29 int main() {
30   // Definition der Variablen
31   pthread_t       thread[2];
32   pthread_attr_t  attr;
33   int             i, status, err;
34
35   pthread_attr_init (&attr);
36   pthread_attr_setdetachstate (&attr,
37         PTHREAD_CREATE_JOINABLE);
38
39   /* start threads */
40   pthread_create (&thread[0], &attr, minus,
41                                (void *) NULL);
42   pthread_create (&thread[1], &attr, plus,
43                                (void *) NULL);
44   /* Warte auf beide Threads */
45   for(i=0; i < 2; i++) {
46     err = pthread_join (thread[i], (void **)&status);
47     if (err) printf("No join...\n");
48   }
49   printf("Summe : %d\n",sum);
50 }
```

Conditions

Mutex synchronisiert den Zugriff von Threads auf Daten, aber wie können Threads über sich ändernde Daten informiert werden?

- Beispiel: Status-Variable (an/aus, voll/leer)

Einfache Lösung:

- kontinuierliche Abfrage einer Variable (Polling)
- Polling verschwendet aber Prozessorressourcen!

Besserer Ansatz:

- über eine Kondition gesteuerter Zugriff auf einen Mutex
- Thread blockiert bis Kondition erfüllt ist

Lösung: Condition-Variable

Condition Variable (1)

- Initialisierung
  int ***pthread_cond_init*** *(pthread_cond_t *cond, pthread_condattr_t *attr);*
- Destruktion
  int ***pthread_cond_destroy*** *(pthread_cond_t *cond);*
- Warten
  int ***pthread_cond_wait*** *(pthread_cond_t *cond, pthread_mutex_t *mut);*
  - blockierendes Warten mit Freigabe des Mutex
- Signalisierung
  int ***pthread_cond_signal*** *(pthread_cond_t *cond);*
  - mindestens einen Thread singalisieren/aufwecken und nachfolgende Mutex-Aquirierung

Condition Variable (2)

- Broadcast Signalisierung
  int ***pthread_cond_broadcast*** *(pthread_cond_t *cond);*
  – alle Threads signalisieren mit nachfolgender Mutex-Aquirierung

- Warten mit Time-Out
  int ***pthread_cond_timedwait*** *(pthread_cond_t *cond, pthread_mutex_t *mut, const struct timespec *abstime);*
  – identisch zu *pthread_cond_wait()*, mit Zeitschranke
  – Rückgabe von *ETIMEDOUT* falls Zeitschranke überschritten
  struct timespec to { time_t tv_sec; long tv_nsec; };

- Erzeugen / Entfernen
  int ***pthread_cond_init*** *(pthread_cond_t *cond, pthread_condattr_t *attr);*
  – oder statisch, *phtread_cond_t cond =* ***PTHREAD_COND_INITIALIZER****;*
  int ***pthread_cond_destroy*** *(pthread_cond_t *cond);*

Condition: Anmerkungen

- eine Condition-Variable ist immer in Verbindung mit einem Mutex zu nutzen
- entsprechender Mutex muss vor Aufruf von *pthread_cond_wait()* belegt sein
- Konditionen werden signalisiert
- Warten mehrere Threads auf eine Kondition, dann muss *pthread_condition_broadcast()* anstatt p*thread_condition_signal()* genutzt werden
- Konditionen werden nicht „gespeichert“, d.h. *pthread_cond_wait()* **muss vor** dem entsprechenden p*thread_condition_signal()* aufgerufen werden

Beispiel: Condition Variable (1)

```
1  #include <pthread.h>
2  #define NUM_THREADS 3
3
4  pthread_mutex_t mutex;
5  pthread_cond_t  cond;
6
7  /* Eine Kondition für jeden Thread */
8  /*     0 : starten                  */
9  /*     1 : stoppen                  */
10 int flag[NUM_THREADS];
11
12 void *work (void *arg) {
13   int id = (int) arg;
14   int sum, i;
15
16   /* Mutex Variable sperren */
17   pthread_mutex_lock (&mutex);
```

```
18 /* In einer Schleife wird jetzt geprüft, ob der Thread laufen darf  */
19   while (flag[id]) {
20     printf("(thread %d) Muss noch warten...\n", id);
21     pthread_cond_wait (&cond, &mutex);
22   }
23
24   pthread_mutex_unlock (&mutex);
25
26   printf("(thread %d) Jetzt geht's los!\n", id);
27
28 /* Hier würde im Normalfall die eigentliche       */
29 /* Threadfunktion stehen; eine Schleife tut's auch. */
30   for(i=0; i < 10000; i++) {
31     sum = sum + (int) (100*random());
32   }
33
34   pthread_exit (NULL);
35 }
```

mutex koordiniert den Zugriff auf Variable *flag*

main Funktion auf der folgenden Folie

Beispiel: Condition Variable(2)

```
37 int main() {
38 /* Definition der Variablen */
39  pthread_t       thread[NUM_THREADS];
40  pthread_attr_t attr;
41
42  int i, status, err;
43
44   for(i=0; i < NUM_THREADS; i++)
45     flag[i] = 1;      /* Status „Thread-Stop“ */
46
47   pthread_attr_init (&attr);
48   pthread_attr_setdetachstate (&attr,
49         PTHREAD_CREATE_JOINABLE);
50
51  pthread_mutex_init (&mutex, NULL);
52  pthread_cond_init (&cond, NULL);
53
54  for(i=0; i < NUM_THREADS; i++) {
55         pthread_create (&thread[i], &attr,
56           work, (void *) i);
57   }
58 /* Alle Threads sind hochgefahren und warten */
```

```
59   printf("(main) Sende das Signal\n");
60 /* Sende das Signal, dass die Threads starten können */
61   pthread_mutex_lock (&mutex);
62   for(i=0; i < NUM_THREADS; i++)
63         flag[i] = 0;
64
65 /* Wecke sie auf */
66   pthread_cond_broadcast (&cond);
67   pthread_mutex_unlock (&mutex);
68
69   /* Warte auf alle Threads */
70   for(i=0; i < NUM_THREADS; i++) {
71     err = pthread_join (thread[i], (void **)&status);
72       if (err) printf("(main) ERROR - No join...\n");
73   }
74
75 /* Aufräumen */
76   pthread_attr_destroy (&attr);
77   pthread_mutex_destroy (&mutex);
78   pthread_cond_destroy (&cond);
79
80   pthread_exit (NULL);
81 }
```

Condition Variable

Achtung

- Signale werden nicht gespeichert
  - Falls kein Thread im *Condition-Wait*, dann gilt ein zu dem Zeitpunkt gesendetes Signal als verloren
  - Threads können somit verhungern, falls auf ein Signal gewartet wird das nicht mehr gesendet wird
- Lock und Unlock müssen richtig gesetzt werden
  - ansonsten eine Verklemmung im Programm möglich

Wechselseitiger Ausschluss und Synchronisation

- Mutex
  - Das Mutex wird verwendet für den wechselseitigen Ausschluss.
  - Der Konstruktor von *mutex* initialisiert das binäre Semaphor automatisch auf *unlocked*.
  - Mit *lock* versucht man in den kritischen Abschnitt einzutreten, mit *unlock* verlässt man diesen.
- Condition Variable
  - Eine Condition Variable ist immer mit mindestens einem Mutex verbunden.
  - Die Wait Operation gibt das Mutex frei und blockiert die Aktivität. Die Wait Operation kann nicht unterbrochen werden.
  - Die Signal Operation hat nur eine Auswirkung, falls mindestens eine Aktivität blockiert ist: in diesem Falle wird mindestens eine Aktivität aufgeweckt.
  - Die Broadcast Operation funktioniert wie Signal außer, dass alle blockierten Aktivitäten aufgeweckt werden.
  - Sobald eine auf Wait blockierte Aktivität aufgeweckt wird, so wird von dieser erneut die Lock Operation auf dem Mutex ausgeführt und fährt anschließend mit seiner Arbeit fort.

Was ist OpenMP?

OpenMP (*Open Multi Processing*) ist

- ein Standard für die Realisierung des Shared-Memory Programmiermodells
- compiler-basiert
- eine Erweiterung bestehender Programmiersprachen durch
  - Direktiven für den Compiler
  - einige wenige Bibliotheksroutinen
  - Umgebungsvariablen (z.B. Anzahl Prozesse, Umgebungsvariablen)

Möglichkeiten von OpenMP

OpenMP bietet

- Portabilität auf Shared-Memory Architekturen
- Skalierbarkeit
- inkrementelle Parallelisierung
- Unterstützung der Daten-Parallelisierung
- Erweiterungen für FORTRAN und C/C++

Geschichte von OpenMP

OpenMP

- entwickelte sich aus Erweiterungen bestehender Programmiersprachen einzelner Hersteller
- wurde mit dem Ziel der Vereinheitlichung / Portabilität entwickelt
- ist ein Standard sein 1997
- wurde von Cray, SGI, Digital Equipment Corporation, IBM, Intel usw. entwickelt und wird von vielen (allen) Hard- und Softwarefirmen unterstützt.

Quellen zu OpenMP

- R. Chandra et al.: Parallel Programming in OpenMP, Academic Press 2001
- Chapman, B.; Jost, G.; van der Pas, R.: Using OpenMP – Portable Shared Memory Parallel Programming, 2007
- http://www.openmp.org
- Intel Compiler (Free Tools for Students)
  - icc –openmp file.c # Linux x86 and Linux x86-64
  - icl /Qopenmp file.c # Windows
- GCC Compiler ab Version 4.2
  - gcc –fopenmp file.c

OpenMP Programming Modell

- OpenMP basiert auf dem Shared-Memory Modell
- Die Arbeitslast wird zwischen Threads verteilt
  - Variablen können
    - gemeinsam (shared) für alle Threads sein
    - für jeden Thread dupliziert werden (private Nutzung)
  - Threads kommunizieren durch gemeinsame Variablen
- Unbeabsichtigt gemeinsam genutzte Variablen können zu sogenannten *race conditions* führen:
  - *race condition*: Das Ergebnis des Programms ändert sich, wenn sich das Laufzeitverhalten (scheduling) der Threads ändert
- *Kontrolle von „race conditions“* durch
  - Synchronisierung, um Datenkonflikte zu vermeiden
- Nachlässige Verwendung von Synchronisierungsanweisungen kann zu *deadlocks* führen

Umgebungsvariablen

- *OMP_NUM_THREADS*
  - gibt die Anzahl der Threads während des Programmlaufs an
  - ist die dynamische Anpassung der Anzahl der Threads aktiviert, so gibt sie die Zahl maximal verfügbarer Threads an
  - *setenv OMP_NUM_THREADS 4*

- *OMP_SCHEDULE*
  - betrifft nur die for-Schleife und parallelen *for* Direktiven die den Scheduling Type *RUNTIME* haben
  - setzt den Scheduling Typ und die chunk size aller Schleifen
  - *setenv OMP_SCHEDULE “GUIDED, 4“*

OpenMP Direktiven

- *#pragma* Direktiven
- Format:
  #pragma omp directive_name [clause [[,] [clause], ..]
- Unterscheidung von Gross- und Kleinbuchstaben
- bedingte Compilation
  #ifdef ***_OPENMP***
  block
  #endif
- Include-File für Bibliotheksroutinen:
  #include <***omp.h***>

OpenMP Laufzeitbibliothek

- Benutzerfunktionen der Laufzeitbibliothek
  - Anzahl der Threads
    numthreads = ***omp_get_num_threads****();*
  - Identifikation eines Threads
    myid = ***omp_get_thread_num****();*
- Systemfunktionen der Laufzeitbibliothek
  - Thread-Verwaltung
    - starten, halten, stoppen, ...
  - Thread-Steuerung
    - Scheduling, ...
  - ...

Parallele Region

- Block des Programms, der durch mehrere Threads parallel ausgeführt werden soll. Jeder Thread führt denselben Code aus

- C/C++:
  #pragma **omp parallel** [clause [clause] ..] *new line*
  structured block

- *Clause kann eine der folgenden sein:*
  - *private (list)*
  - *shared (list)*
  - *reduction (operator,list)* - *Reduktion auf den* Variablen
  - *schedule (type [, chunk])* - Aufteilung der Iterationen auf Threads
  - *nowait* - Thread nicht am Schleifenende synch

Fork-and-Join-Modell (1)

- *Fork-Join* Modell dient der parallelen Ausführung

- Beginn der Ausführung mit einem einzigen Prozess (*master process*)

- paralleles Konstrukt geht aus Master Prozess hervor
  - Start:
    Master Thread erzeugt Team von *Threads*
  - Abschluss:
    Die Threads des Teams werden synchronisiert (implizite Barriere)

- Nur der Master Thread fährt mit der Ausführung fort

Example: OpenMP „hello“

```
#include <stdio.h>

# ifdef _OPENMP
#  include <omp.h>
# endif

int main(int argc, char** argv)
{
  int myid, numthreads;

  myid = -1; numthreads = 0;
#pragma omp parallel private(myid)
  {
# ifdef _OPENMP

    myid = omp_get_thread_num();
    numthreads = omp_get_num_threads();
# endif
    printf("hello, world says thread %d of %d threads.\n", myid, numthreads);

    /* end omp parallel */
  }
  return 0;
}
```