Hauptseminar
Ausgewählte Kapitel der Systemsoftware: Multicore- und Manycore-Systeme

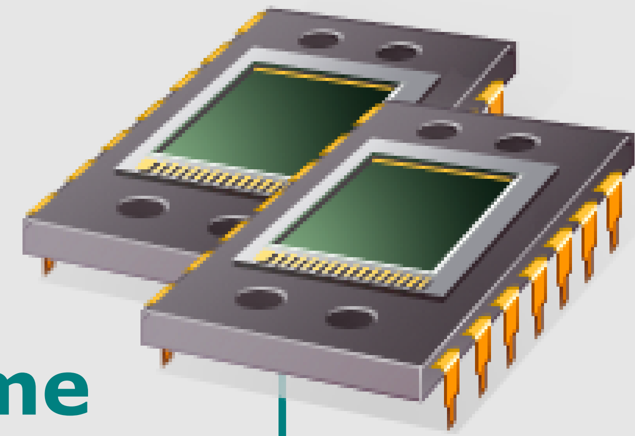

Herausforderungen von Tausendundeinem Kern

Glaubt man den Voraussagen einiger Experten, so werden innerhalb von zehn Jahren bis zu 1000 Prozessorkerne in einer CPU untergebracht sein. Dieser Vortrag wird die Herausforderungen bei der Hard- und Softwareentwicklung solcher Systeme erläutern, sowie die derzeit diskutierten Lösungsansätze vorstellen.

Vortragender: Alexander Münch
<Alexander.Muench@informatik.stud.uni-erlangen.de>

30. April 2009

Gliederung

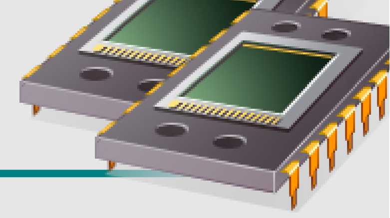

- Einführung
- Theoretischer Hintergrund
- Hardwareentwicklung
- Softwareentwicklung
  - Message Passing Interface
  - Open Multi-Processing
  - Threading Building Blocks
- Fazit
- Live-Beispiel

Warum Parallelität?

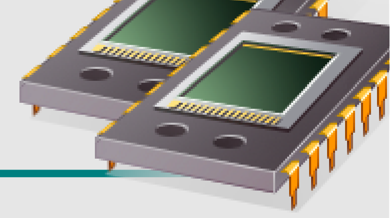

- bisher:
  Performance-Steigerung durch Taktsteigerung
- hoher Energieverbrauch, da exponentiell gegenüber der Leistung
- weiteres Problem:
  zu große Wärmeentwicklung
- besser:
  Untertaktung und Zusammenschluss von mehreren Prozessoren zu einer CPU

Leistung vs. Energieverbrauch

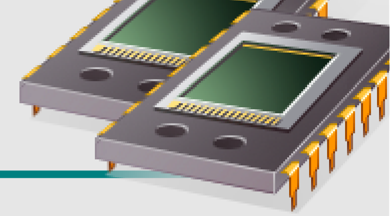

Leistung | Energieverbrauch

200%
150%
100%
50%
0%

100% 100%

Ausgangsprozessor

Leistung vs. Energieverbrauch

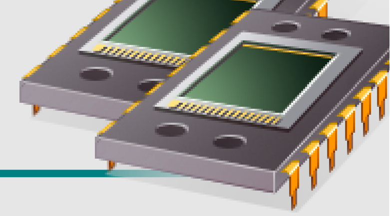

Leistung Energieverbrauch

200%
150%
100%
50%
0%

	Leistung	Energieverbrauch
Ausgangsprozessor	100%	100%
übertaktet	113%	173%

Leistung vs. Energieverbrauch

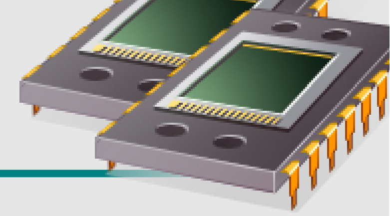

	Leistung	Energieverbrauch
Ausgangsprozessor	100%	100%
übertaktet	113%	173%
untertaktet	87%	51%

200%
150%
100%
50%
0%

Leistung vs. Energieverbrauch

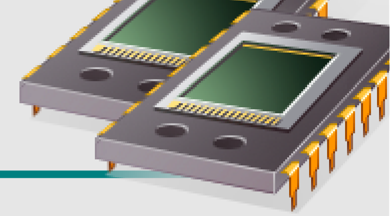

	Leistung	Energieverbrauch
Ausgangsprozessor	100%	100%
übertaktet	113%	173%
untertaktet	87%	51%
Dualcore	174%	102%

Das Philosophenproblem

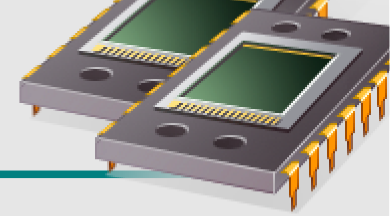

- 5 Philosophen sitzen am runden Tisch
- 5 Teller, dazwischen 5 Gabeln
- ein Philosoph kann entweder denken oder essen

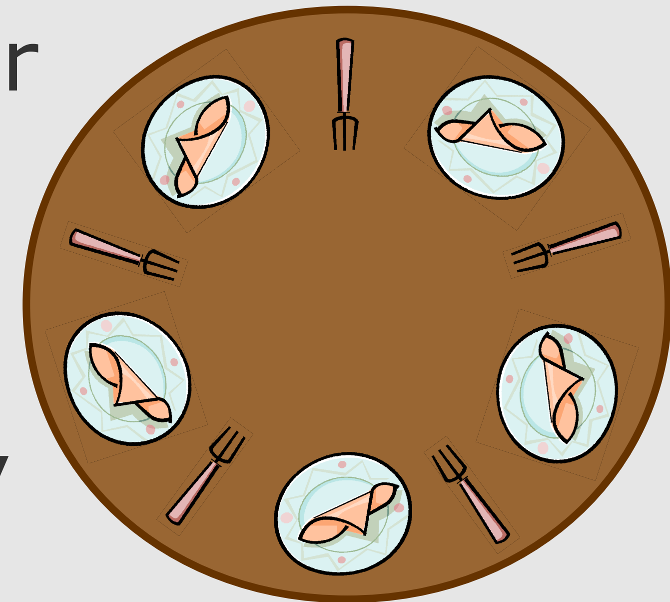

- Will ein Philosoph essen,
  - nimmt er erst die linke Gabel,
  - dann die rechte Gabel,
  - isst, legt anschließend beide Gabeln zurück und denkt wieder.
- Was, wenn alle gleichzeitig essen wollen?

Philosophenproblem - übertragen

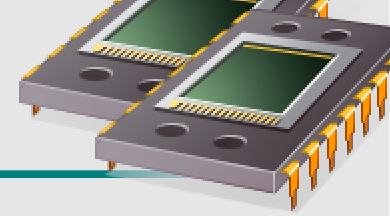

Betriebssystem

Scheduler

Ready-Liste

Core 1

Core 2

Quad-Core CPU

Core 3

Core 4

Amdahlsches Gesetz

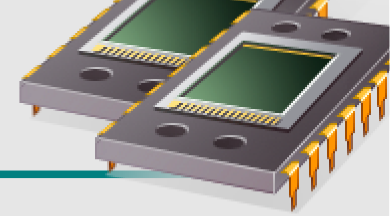

- Gene Amdahl, 1967:
- Sei P der Anteil an parallelem Code
- und (1-P) der Anteil an seriellem Code in einem Programm,
- so ist die mögliche Beschleunigung S eines Programms bei N Prozessoren

$$S = \frac{1}{(1-P) + \frac{P}{N}}$$

Amdahlsches Gesetz - grafisch

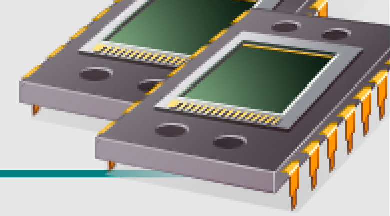

Geschwindigkeitsbeschleunigung

12x
10x
8x
6x
4x
2x
0x

1 2 4 8 16 32 64 128 256

Anzahl Prozessorkerne

- P=50%
- P=60%
- P=75%
- P=90%
- P=92%

Gustafsons Gesetz

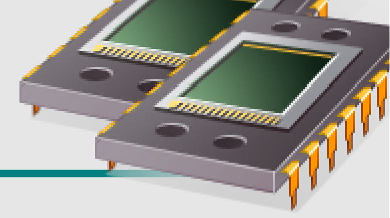

- John Gustafson, 1988:
- Sei P der Anteil an parallelem Code
- und (1-P) der Anteil an seriellem Code in einem Programm,
- so ist die mögliche Beschleunigung S eines Programms bei N Prozessoren

$$S = N - (1 - P)(N - 1)$$

Gustafsons Gesetz - grafisch

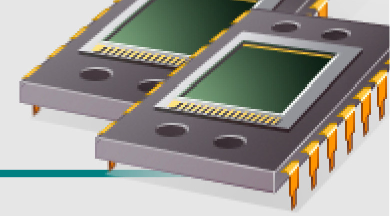

Geschwindigkeitsbeschleunigung

250x
200x
150x
100x
50x
0x

1 2 4 8 16 32 64 128 256

Anzahl Prozessorkerne

P=50%
P=60%
P=75%
P=90%
P=92%

Amdahl vs. Gustafson

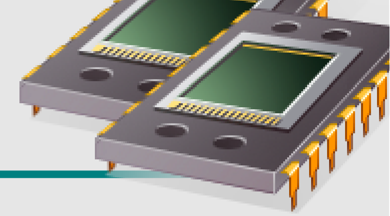

- Amdahl betrachtet den Performance-Gewinn bei konstanter Datenmenge
- Gustafson geht von konstantem Zeitbedarf aus und füttert das Programm mit mehr Daten

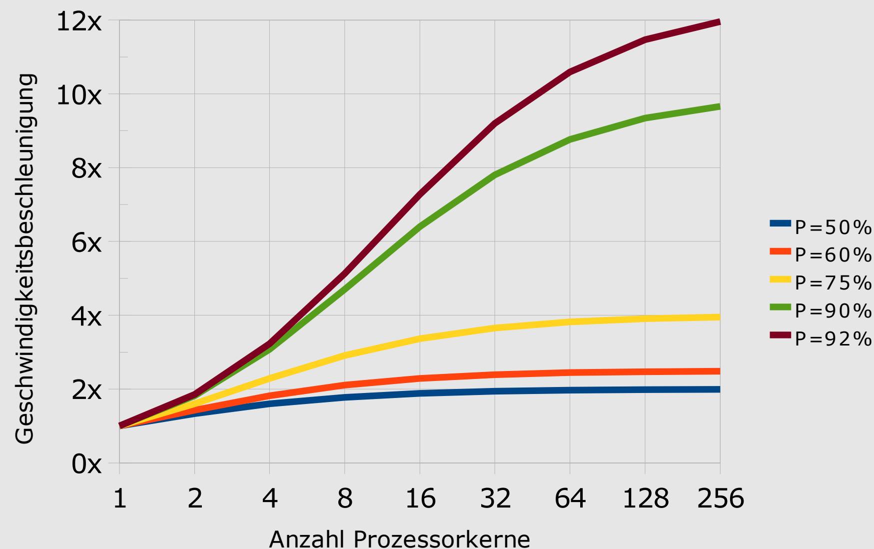

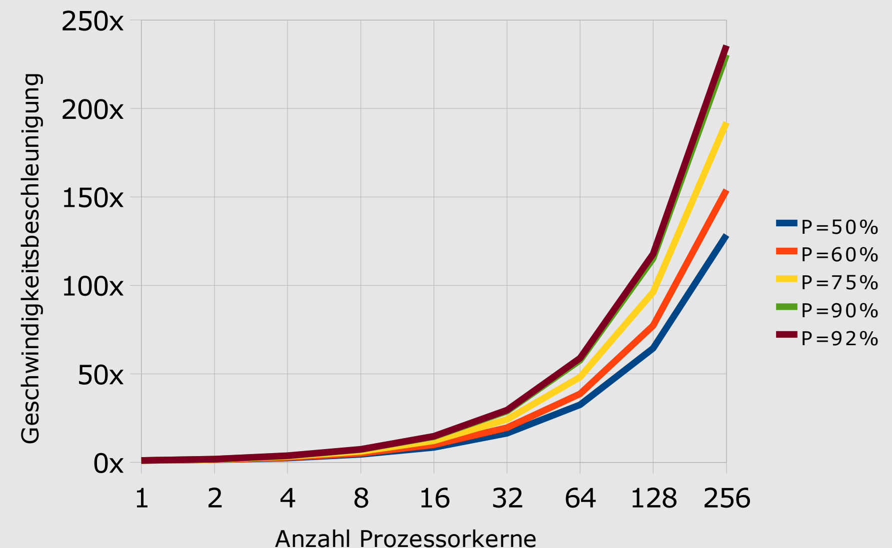

Symmetrische vs. asymmetrische Mehrkernprozessoren

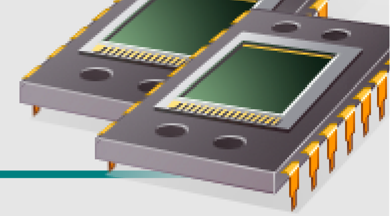

- symmetrischer Mehrkernprozessor:
  alle Cores sind vom selben Typ
- asymmetrischer Mehrkernprozessor:
  es werden Cores unterschiedlichen Typs verbaut
- Vorteile von Asymmetrie:
  Einsparung von Chip-Fläche und Vermeidung unnötiger Wärmeentwicklung
- hauptsächlich symmetrische Mehrkernprozessoren im Umlauf
- bekannter asymmetrischer Vertreter:
  IBM Cell-Prozessor (PLAYSTATION 3)

Transaktionaler Speicher

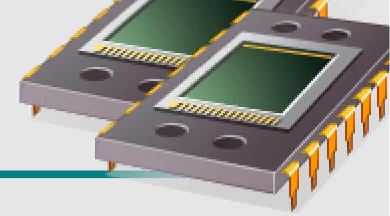

- Problem bei mehreren Prozessoren: konkurrierende Zugriffe auf gemeinsamen Speicher
- Idee aus Datenbanktechnik übernehmen: Transaktionen
- Speicher bietet Instruktionen für „begin transaction“ und „commit transaction“
- Änderungen werden semantisch atomar ausgeführt und sind erst für andere sichtbar, wenn komplett
- Hardware entscheidet, welche Zugriffe parallel ausgeführt werden können

Parallelität mittels Software

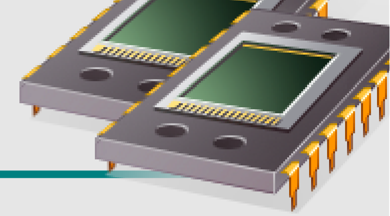

- Parallelisierbare Probleme
- Parallelität über das Betriebssystem
- andere Ansätze
  - Message Passing Interface
  - Open Multi-Processing
  - Threading Building Blocks
- Vergleich der Ansätze

Parallelisierbare Probleme

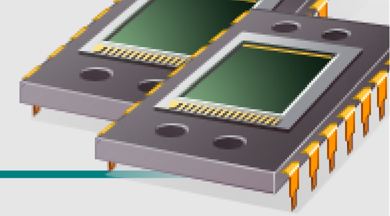

- Mehr Kerne muss nicht unbedingt einen Performance-Gewinn bedeuten!
- Probleme und ihre Lösungsalgorithmen müssen parallelisierbar sein
- interaktive Prozesse sind das größtenteils nicht
- parallele Algorithmen, z.B. Filter-operationen auf Grafik-/Video-Daten versprechen große Performance-Gewinne

Parallelität über das Betriebssystem

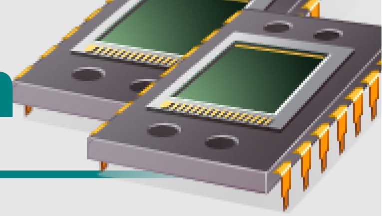

- das Betriebssystem nutzt mehrere Prozessoren automatisch aus: Prozesse und Threads werden parallel ausgeführt
- Problem: ein Prozess mit CPU-Burst lastet einen Kern 100% aus, die restlichen Kerne führen trotzdem nur den Idle-Thread aus
- Lösung: der Programmierer muss seine Anwendung so gestalten, dass sie ihre Arbeit mittels mehrerer Threads erledigt

Parallelität über das Betriebssystem

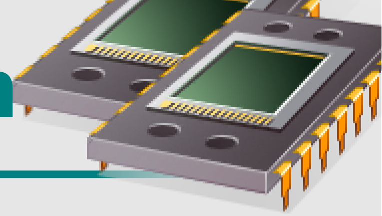

- Erstellen von Prozessen und Threads durch Systemcalls
  - Linux: fork(), pthread_create()
  - Windows: CreateProcess(), CreateThread()
- Nachteile
  - Code wird unübersichtlich
  - Programmierer muss sich genau überlegen, welche Threads auf welche Daten zugreifen und geeignete Synchronisierung durchführen

Message Passing Interface (MPI)

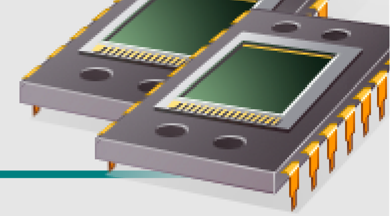

- Standard, der eine Programmierschnittstelle definiert
- Ziel: Nachrichtenaustausch zwischen Prozessen
- Es gibt einen Hauptprozess.
- MPI_Send(), MPI_Recv():
  Senden und Empfangen von Nachrichten (blockierend)
- MPI_Isend(), MPI_Irecv(), MPI_Test() (nicht-blockierend)

Message Passing Interface (MPI)

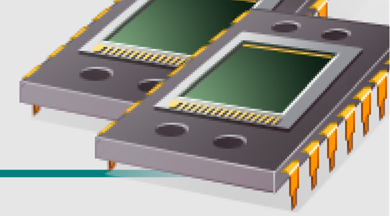

- Nachricht an alle: MPI_Bcast()
- Hauptprozess „sammelt“ Daten von allen anderen Prozessen: MPI_Gather(), MPI_Reduce()
- Jeder Prozess sendet seine Daten an alle anderen Prozesse: MPI_Allgather()
- Der Hauptprozess sendet an alle Prozesse eine Nachricht: MPI_Scatter()

Message Passing Interface (MPI)

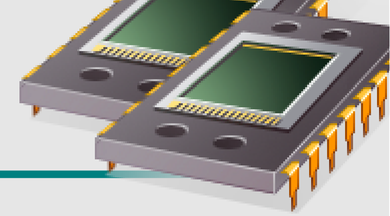

- MPI eignet sich besonders für Supercomputer, wo es keinen gemeinsamen Speicher gibt
- Performance-Gewinn durch exklusiven Zugriff auf den Speicher
- ggf. können die Prozesse sogar räumlich getrennt sein: z.B. Kommunikation über TCP/IP
- theoretisch auch für shared-memory Systeme geeignet, aber wegen dem zusätzlichen Overhead nicht rentabel

Open Multi-Processing (OpenMP)

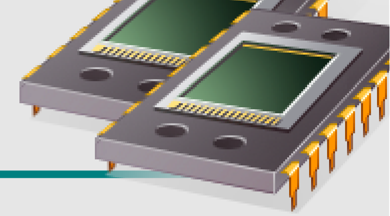

- Programmierschnittstelle für C/C++- und Fortran-Compiler
- Umfang
  - Compilerdirektiven
  - Bibliotheksfunktionen
  - Umgebungsvariablen
- Parallelität wird zur Übersetzung durch den Compiler erzeugt
- Auszeichnung paralleler Abschnitte im Code mittels Compilerdirektiven

Open Multi-Processing (OpenMP)

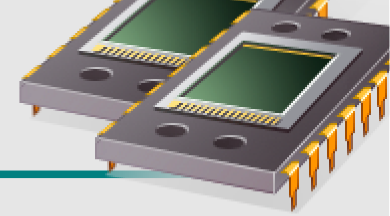

- zu Beginn: initialer Thread
- Erreicht die Ausführung einen parallelen Abschnitt, erzeugt er zusätzliche Threads.
- Master-Thread und Team
- Am Ende des parallelen Abschnitts läuft nur der Master-Thread weiter.

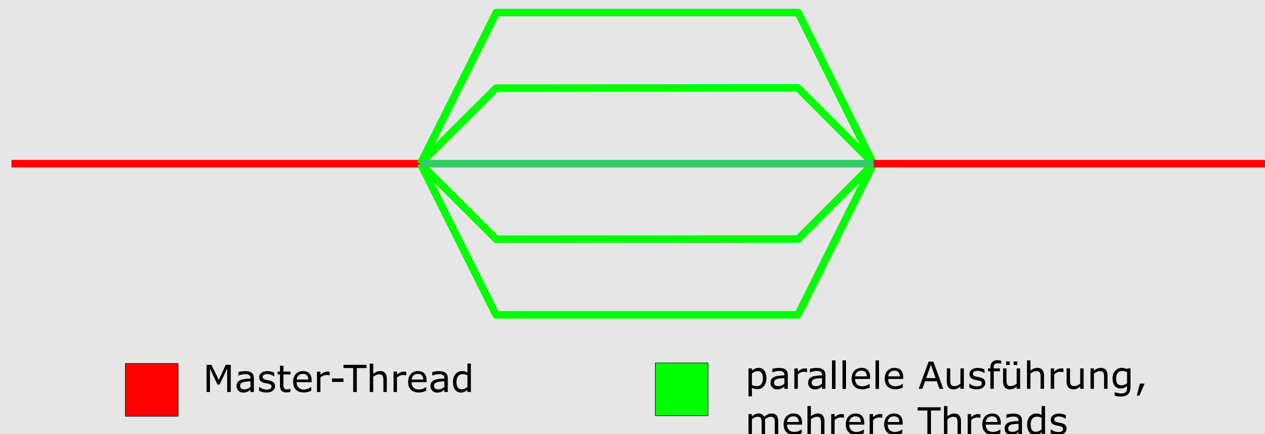

OpenMP: parallele for-Schleife

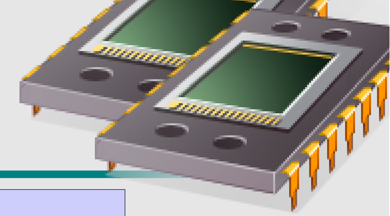

```
void main(int argc, char** argv)
{
  double a[3][3], b[3][3], c[3][3];
  int i, j, k;
  double sum;


  for(int i = 0; i < 3; i++)
  {
    for(j = 0; j < 3; j++) {
      sum = 0;
      for(k = 0; k < 3; k++)
        sum += a[i][k] * b[k][j];
      c[i][j] = sum;
    }
  }
}
```

Eingabe:
a, b sind 3x3-Matrizen

Ausgabe:
c als 3x3-Matrix, die das Matrizenprodukt a*b enthält

Variable, die das Skalarprodukt halten wird

Für jede Zeile, ...

für jede Spalte, ...

berechne das Skalarprodukt ...

und speichere es in der Ergebnismatrix.

OpenMP: parallele for-Schleife

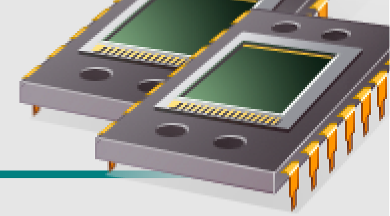

```
#include <omp.h>

void main(int argc, char** argv)
{
   double a[3][3], b[3][3], c[3][3];
   int i, j, k;
   double sum;

   #pragma omp parallel for private(sum)
   for(int i = 0; i < 3; i++)
   {
      for(j = 0; j < 3; j++) {
        sum = 0;
        for(k = 0; k < 3; k++)
          sum += a[i][k] * b[k][j];
        c[i][j] = sum;
      }
   }
}
```

Einbinden der notwendigen Definitionen für den Compiler

#pragma omp
Es folgt eine OpenMP-Anweisung.

parallel
Ein paralleler Abschnitt beginnt: Master-Thread erzeugt Team von mehreren Threads.

for
Die nächste for-Schleife wird parallel ausgeführt. Die Zähler-variable i ist automatisch privat.

private(sum)
sum ist ebenfalls privat, d.h. jeder Thread hat seine eigene Kopie.

OpenMP: weitere Konstrukte

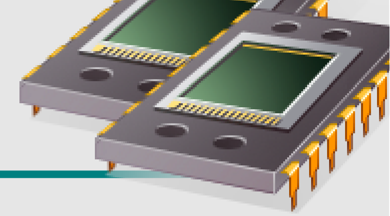

- sections: verschiedene Codeblöcke parallel ausführen
- barrier: an einer Barriere ist ein Synchronisationspunkt. Alle Threads warten dort, bis alle anderen auch an dieser Stelle angelangt sind
- single/master: ein Abschnitt wird nur einmalig/nur vom Master-Thread ausgeführt
- atomic: atomares Ausführen von Operationen

Threading Building Blocks (TBB)

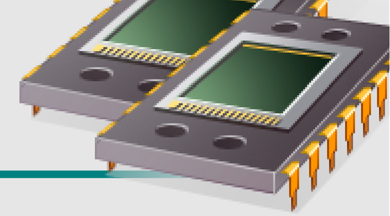

- von Intel entwickeltes freies Framework
- an die STL angelehnt:
  - Container
  - Algorithmen
  - Funktionsobjekte: „Funktor"
- Task-Scheduler koordiniert die Zuordnung von Tasks auf Threads

TBB: Range

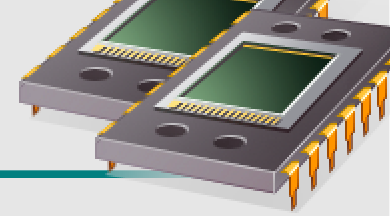

- Abstraktion eines Wertebereichs
- mathematisch mit einem Intervall zu vergleichen, aber beliebige Datentypen möglich
- für Parallelisierung wichtig: Range sollte teilbar sein
- „Partitionskonstruktor"

TBB: Range - Beispiel

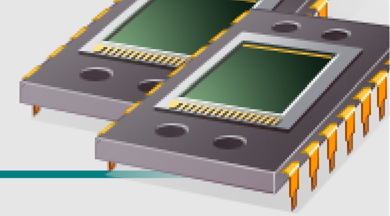

```
struct MyIntRange
{
  int from, to;

  bool empty() const { return (from == to); }
  int size() const { return to - from; }
  int begin() const { return from; }
  int end() const { return to; }

  bool is_divisible() const {
    return (size() > 10);
  }

  MyIntRange(int x1, int x2) {
    from = x1; to = x2;
  }

  MyIntRange(MyIntRange& r, split) {
    int middle = (r.from + r.to) / 2;
    from = r.from; to = middle;
    r.from = middle;
  }
};
```

Variablen, die Anfang und Ende des Bereichs halten

Primitive Methoden für Bereich leer? Größe des Bereichs? Anfang? Ende?

Gibt an, ob ein Bereich weiter unterteilbar ist

Nur Bereiche größer 10 sind teilbar.

Konstruktor, der Bereich [x1, x2) erzeugt

Partitionskonstruktor

split wird von TBB definiert und unterscheidet diesen speziellen Konstruktor

Berechne Intervallmitte, ...

setze Anfang bis Mitte für den neuen Bereich ...

und verkleinere den übergebenen Bereich.

TBB: parallele for-Schleife

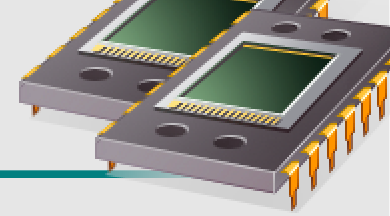

```
int numbers[100];
```

Array der Größe 100.
Eingabewerte sollen alle verdoppelt werden.

```
for(int i = 0; i < 100; i++)
  numbers[i] *= 2;
```

Für jedes Element im Array ...

verdopple den Wert.

TBB: parallele for-Schleife

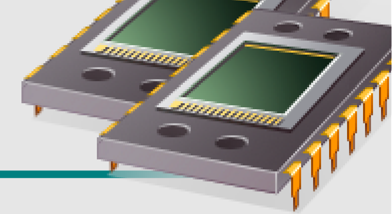

```
class DoubleInts
{
  int* const numbers;

public:
  DoubleInts(int* array) : numbers(array) {}

  void operator()
    (const blocked_range<int>& r) const
  {
    for(int i = r.begin(); i != r.end(); i++)
      numbers[i] *= 2;
  }
};

parallel_for(blocked_range<int>(0, 100),
             DoubleInts(data),
             auto_partitioner());
```

Kapselung durch Klasse

Zeiger auf das Datenfeld

Zeiger auf das Datenfeld in der Klasse speichern

Konstruktor

Funktor

TBB-vordefiniertes Template für Ranges
hier: Integer-Range

Schleifenrumpf:
Iteriere durch den Range und verdopple jedes Element darin.

Neuer Task: for-Schleife

Erzeuge Bereich [0, 100).

Klasse instanzieren und Datenfeld übergeben

TBB kümmert sich um die Partitionierung des Bereichs.

TBB: weitere Funktionen

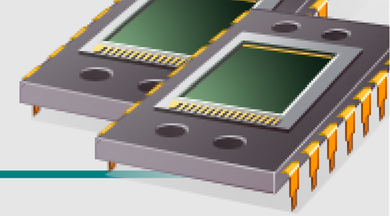

- vordefinierte Ranges von ein- bis dreidimensional
- komplexes Task-System
- Filter, Pipelines
- atomic-Template für atomare Operationen
- generische thread-safe Container:
  - Queue
  - Vector
  - HashMap

Vergleich der Ansätze

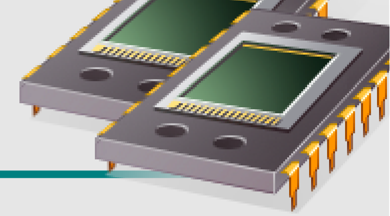

MPI

- Nachrichten basierend
- auch für Systeme ohne shared Memory
- Parallelismus auch über Rechnergrenzen hinweg, z.B. TCP/IP
- für Probleme mit viel Rechenaufwand

OpenMP

- im Compiler integriert
- nur für C/C++ und Fortran
- „einfach“ nur Compiler-direktiven einsetzen
- Code bleibt nahezu unverändert
- Debugging: „Parallel-Modus“ ausschaltbar

TBB

- Framework, an SLT angelehnt
- Kapselung
- Task-Scheduler koordiniert alle Tasks
- mehr Code zu schreiben, trotzdem bleibt der Code gut lesbar

Fazit

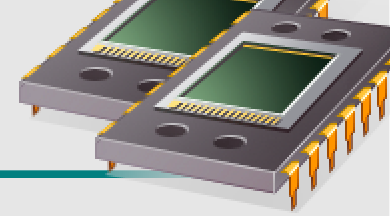

- Parallelität: Energieeinsparung, aber trotzdem ein Performance-Gewinn möglich
- unterschiedliche Ansätze für unterschiedliche Probleme:
  - MPI: Nachrichtenaustausch
  - OpenMP: Parallelität durch den Compiler
  - TBB: STL-angelehntes Framework
- alle vorgestellten Ansätze sind unabhängig von der Anzahl der Prozessorkerne
- Probleme müssen parallelisierbar sein, sonst nützen mehrere Kerne auch nichts

Live-Beispiel

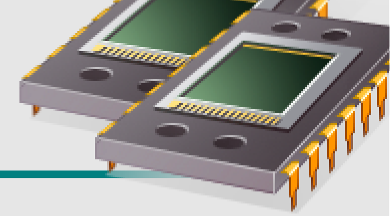

$$\pi = \int_0^1 \frac{4}{(1+x^2)}\,dx$$

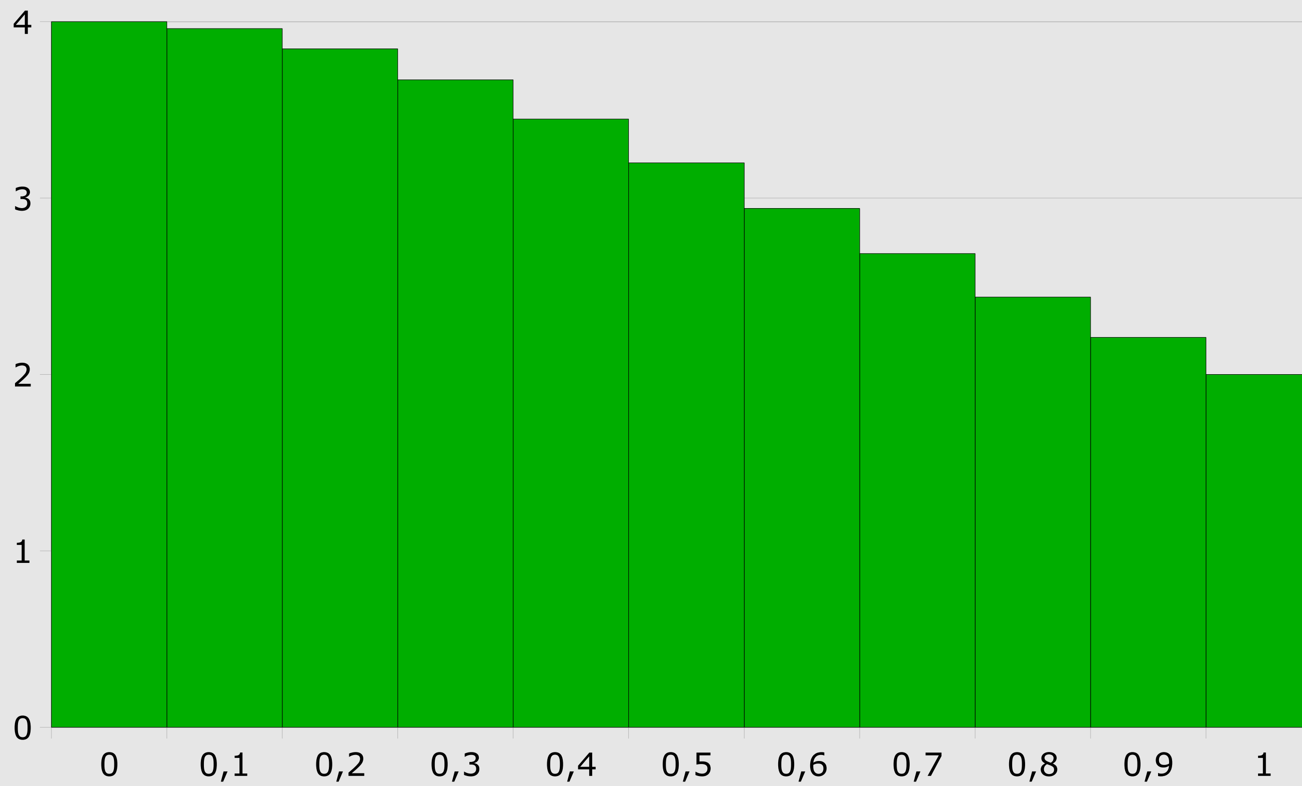

Noch Fragen?

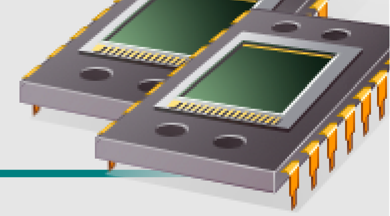

42