

# 4. Parallelprogrammierung

ALDaBi Praktikum

# Inhalt

- Einführung in Parallelität
- OpenMP
- Bemerkungen zur P-Aufgabe

# Einführung in Parallelität

Folien z.T. aus VL „Programmierung von Hardwarebeschleunigern“  
von Alexander Reinefeld und Thomas Steinke, WS09

David Weese  
© 2010/11

Johannes Röhr / René Rahn  
WS 2015/16

# Voraussetzungen

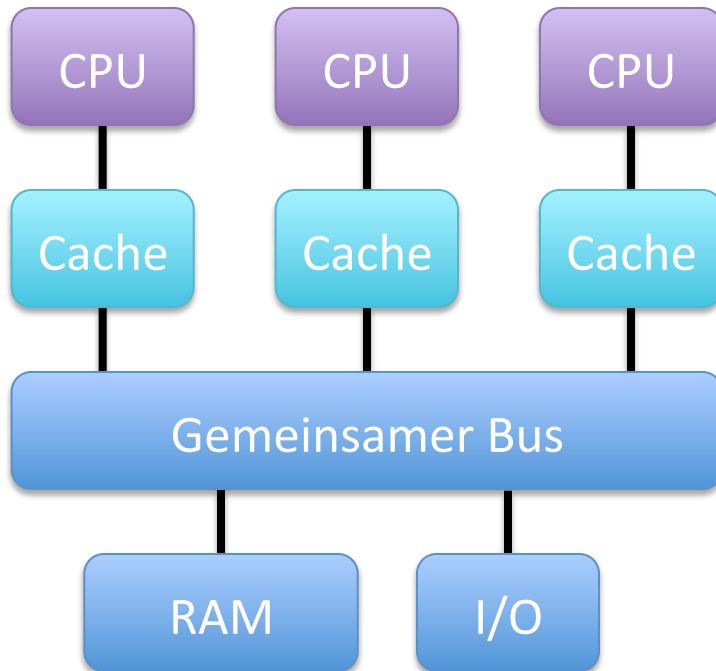
- Es werden Mechanismen benötigt, um
  - Parallelität zu erzeugen
  - Prozesse voneinander unterscheiden zu können
  - zwischen Prozessen kommunizieren zu können
- Für die Formulierung paralleler Programme:
  - Datenparallele Programmiermodelle
    - HPF
  - Kontrollparallele Programmiermodelle
    - MPI, OpenMP, CUDA
  - Beides
    - VHDL, MitrionC

# Parallelprogrammierung durch ...


- Direkten Zugriff auf das Netzwerk eines Clusters
  - Effizient, aber nicht portabel
- Unterprogrammibliotheken
  - Beispiele: PThreads, fork(), MPI, ...
- Erweiterung einer Programmiersprache durch Compiler-Direktiven
  - Beispiel: OpenMP
- Eigenständige parallele Programmiersprache
  - Großer Aufwand: Einarbeitung, neue Compiler, etc.
  - Beispiele: OCCAM, parallele Fortran-Varianten (HPF), MitrionC, ...

# Parallele Plattformen

Gemeinsamer Speicher  
(shared memory)



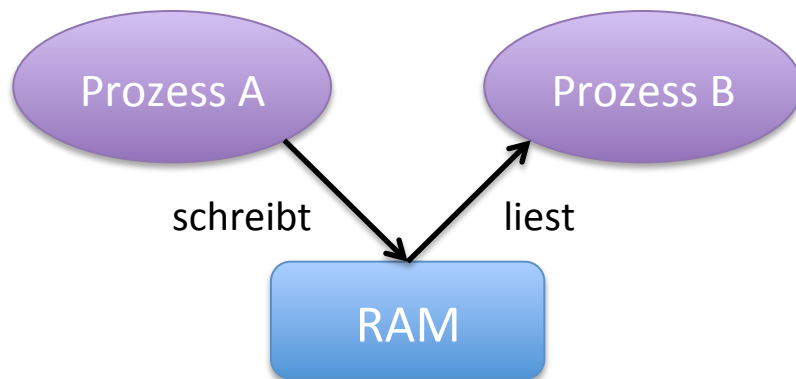
Verteilter Speicher  
(distributed memory)



# Prozesskommunikation ...


## Gemeinsamer Speicher (shared memory)

- ... über gemeinsamen Speicherbereich
  - Schreiben/Lesen im RAM
  - Synchronisation über gegenseitigen Ausschluss



## Verteilter Speicher (distributed memory)

- ... über Nachrichtenaustausch (message passing)
  - Senden/Empfangen von Nachrichten
  - Nur lokale (private) Variablen



# Begriffe

- Prozess
  - Besteht aus eigenem Adressraum
    - Für Stack, Heap, Programmcode, ...
    - Ist dadurch vor anderen Prozessen geschützt
  - Kann Ressourcen reservieren
  - Hat einen oder mehrere Threads, die den Code ausführen
  - Beispiel:
    - Programm
- Thread
  - Gehören zu einem Prozess
  - Bestehen aus eigenem Stack und CPU-Registerzustand
  - Haben den Adressraum des zugehörigen Prozesses
    - Threads desselben Prozesses sind nicht voreinander geschützt
  - Beispiel:
    - Auf mehrere Threads verteilte for-Schleife eines Programms

# Fallstricke

- Race Conditions

- Situationen, in denen das „Wettrennen“ (race) der Prozesse beim Zugriff auf gemeinsame Ressourcen Auswirkungen auf das Ergebnis eines Programmlaufs hat
- Beispiel: 2 Threads schreiben in dieselbe Speicherstelle

- Lösung

- Synchronisation

- **Mutex** (Mutual Exclusion)

- kann von mehreren Threads verlangt werden (lock), aber nur einer besitzt sie bis er sie freigibt (unlock)

- **Semaphore**


- kann von mehreren Threads verlangt werden, ist aber immer nur in Besitz von höchstens k Threads
- Mutex ist Semaphore mit  $k=1$

- **Barrier**

- Eine Gruppe von Threads hält solange an einer Barriere an, bis alle angekommen sind, danach laufen alle weiter

# Fallstricke (II)

- Bei unpassender Synchronisation entstehen:
  - Verklemmung (dead locks)
    - Threads warten gegenseitig auf die Ressourcen der anderen
  - Aushungern (starvation)
    - Resource wechselt (unfairerweise) nur innerhalb einer Gruppe von Threads
    - Threads außerhalb der Gruppe erhalten die Resource nie
- Beispiel:
  - Philosophenproblem
    - Philosophen essen und denken
    - Zum Essen braucht jeder 2 Gabeln
    - Jeder kann gleichzeitig nur eine Gabel aufheben
  - Verklemmung
    - Jeder nimmt die linke Gabel auf und wartet auf die rechte
  - Lösung
    - Eine Mutex für den ganzen Tisch zum Prüfen und Aufnehmen zweier Gabeln



# OPEN MULTI-PROCESSING

Folien z.T. aus VL „Parallele Programmierung“ von Nicolas Maillard und Marcus Ritt, TU Berlin

David Weese  
© 2010/11

Johannes Röhr / René Rahn  
WS 2015/16

# Verfügbarkeit

Compiler	OpenMP Unterstützung	Compiler Schalter
g++	GCC 4.2: OpenMP 2.5 GCC 4.4: OpenMP 3.0 (Pool-Recher: GCC 4.7.2 )	<b>-fopenmp</b>
Visual C++	VS 2005-2013: OpenMP 2.0	<b>/openmp</b> In der IDE*
Intel C++	V9: OpenMP 2.5 V11: OpenMP 3.0	Windows: <b>/Qopenmp</b> Linux: <b>-openmp</b>
Sun Studio	V12: OpenMP 2.5 V12 U1: OpenMP 3.0	<b>-xopenmp</b>

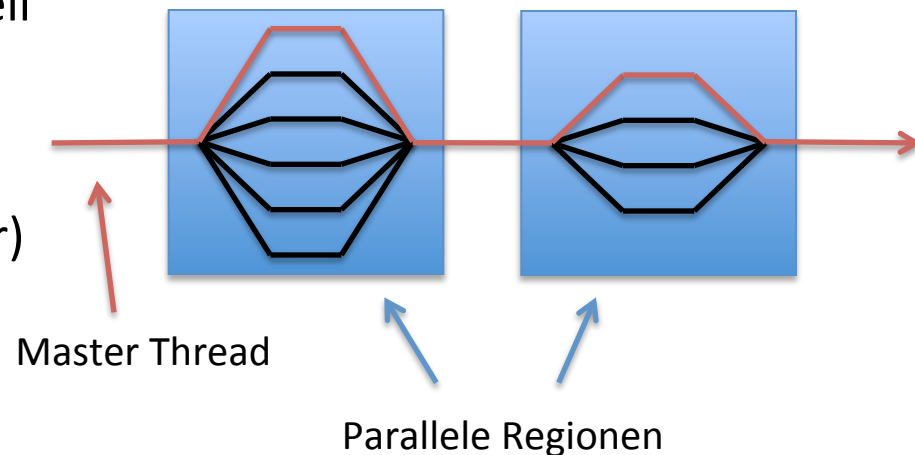
- OpenMP aktivieren in Visual Studio 2005 oder später:
  - Öffne Properties des Projektes und gehe zu:  
Configuration Properties -> C/C++ -> Language
  - Setze OpenMP Support auf yes
- Achtung:
  - Visual Studio 2005 **Express Edition** unterstützt kein OpenMP, obwohl der Schalter existiert

# Einführung

- OpenMP stellt eine Programmierschnittstelle (API) für C/C++ (und Fortran) zur Verfügung
  - Erweiterung der Programmiersprache durch #pragma-Direktiven
    - Eine Direktive besteht aus einem Namen und einer Klauselliste:  
#pragma omp directive [clause list]
  - Bibliotheksfunktionen
    - #include <omp.h>
- Nur für Plattformen mit gemeinsamen Speicher (shared memory)
- Nützliche Links
  - OpenMP Homepage - <http://www.openmp.org/>
  - OpenMP Tutorial - <http://computing.llnl.gov/tutorials/openMP/>
  - Kurzübersicht - <http://www.openmp.org/mp-documents/OpenMP3.0-SummarySpec.pdf>

# Programmiermodell

- Parallelität lässt sich schrittweise erzeugen
  - Ein serielles Programm wird zu einem parallelen
  - Serielle Version weiterhin nutzbar
- Direktive **parallel** startet ein Team
  - Aktueller Thread ist Master
  - Alle Threads bearbeiten den folgenden Abschnitt
- Direktive **for** teilt Iterationen auf Team-Mitglieder auf
  - Jeder Thread bearbeitet einen Teil
- Ende des parallelen Blocks
  - Implizite Synchronisation (barrier)
  - Nur Master läuft weiter



# OpenMP Beispiel

- Einfaches Beispielprogramm in OpenMP:

```
#include <stdio>
#include <omp.h>

int main(int, char*[ ])
{
    #pragma omp parallel
    printf("Hello, world.\n");

    return 0;
}
```

- Ausgabe auf Intel Core 2 Duo:

```
Hello, world.
Hello, world.
```

# OpenMP Beispiel (II)

- Unterscheidung der Threads:

```
#include <stdio>
#include <omp.h>

int main(int, char*[])
{
    #pragma omp parallel
    printf("I'm thread %i of %i.\n",
        omp_get_thread_num(),
        omp_get_num_threads());

    return 0;
}
```

- Ausgabe:

```
I'm thread 0 of 2.
I'm thread 1 of 2.
```

# Von seriell zu parallel

- Serielles Programm:

```
double A[10000];  
for (int i = 0; i < 10000; ++i)  
    A[i] = langwierige_berechnung(i);
```

- Parallelisiert mit OpenMP:

```
double A[10000];  
#pragma omp parallel for  
for (int i = 0; i < 10000; ++i)  
    A[i] = langwierige_berechnung(i);
```

- Serielle Version weiterhin nutzbar
  - `#pragma omp` wird ignoriert von Compilern ohne OpenMP-Unterstützung

# Direktiven

- Parallele Regionen
  - `omp parallel`
- Klauseln zur Definition gemeinsamer und privater Daten
  - `omp shared, private, ...`
- Aufteilung von Schleifen
  - `omp for`
- Synchronisation
  - `omp atomic, critical, barrier, ...`
- Bibliotheksfunktionen und Umgebungsvariablen
  - `omp_set_num_threads(), omp_set_lock(), ...`
  - `OMP_SCHEDULE, OMP_NUM_THREADS, ...`

# parallel

- Parallele Ausführung mit **parallel**
  - Folgender Block wird von allen Threads parallel ausgeführt
  - Programmierer verteilt die Arbeit
    - Entweder manuell
    - Oder mit weiteren Direktiven, bspw. for, sections, ...

```
double A[10000];
int cnt = omp_get_num_threads();
#pragma omp parallel
{
    int id = omp_get_thread_num();
    int i_start = 10000 * id / cnt;
    int i_end = 10000 * (id+1) / cnt;
    langwierige_berechnung(A, i_start, i_end);
}
```

# for

- Aufteilung von Schleifeniteration mit **for**
  - OpenMP teilt Iterationen den einzelnen Threads zu
  - Nur for-Schleifen mit bestimmter Syntax

```
double A[elemente];  
#pragma omp parallel  
#pragma omp for  
for (int i = 0; i < 10000; ++i)  
    A[i] = langwierige_berechnung(i);
```

- Seit OpenMP 3.0 sind auch Iterator-Schleifen parallelisierbar:

```
vector<int> v(10000);  
typedef vector<int>::iterator iter;  
#pragma omp parallel  
#pragma omp for  
for (iter i = v.begin(); i < v.end(); ++i)  
    langwierige_berechnung(*i);
```

# for (II)

- Einschränkungen
  - Nur ganzzahlige Schleifenvariablen (mit oder ohne Vorzeichen)
  - Test nur mit <, <=, >, >=
  - Schleifenvariable verändern: nur einfache Ausdrücke
    - Operatoren ++, --, +, +=, -=
  - Obere und untere Grenze unabhängig von Schleifendurchlauf
    - Ausdrücke sind möglich
- Automatische Synchronisation nach **for** mit Barriere
  - kann mit **nowait** unterdrückt werden
    - Kurzform:
  - `#pragma omp parallel for`

# for (III)

- Verschiedene Arten, den Indexraum auf Threads zu verteilen
- Auswahl erfolgt mit **schedule**
  - `schedule(static[,k])`
    - Indexraum wird in Blöcke der Größe  $k$  zerlegt und den Threads **reihum** zugewiesen
    - $k=1$ : 012012012.....0
    - $k=5$ : 000001111122222000001111122222...00000
  - `schedule(dynamic[,k])`
    - Indexraum wird in Blöcke der Größe  $k$  zerlegt und den Threads **nach Bedarf** zugewiesen
  - `schedule(guided[,k])`
    - Indexraum wird in Blöcke **proportional zur Restarbeit** auf Threads aufgeteilt und nach Bedarf zugewiesen;  $k$  = minimale Iterationszahl
  - `schedule(auto)`
    - Implementierungs-spezifisch (Standard, wenn keine Angabe)
  - `schedule(runtime)`
    - Entscheidung zur Laufzeit (`omp_set_schedule`, `omp_get_schedule`, `OMP_SCHEDULE`)

# Klauseln

- Festlegen der Anzahl der Threads:

```
double A[10000];  
#pragma omp parallel for num_threads(4)  
for (int i = 0; i < 10000; ++i)  
    A[i] = langwierige_berechnung(i);
```

- Alternativ ginge auch `omp_set_num_threads(4);`
- Oder über Umgebungsvariable `export OMP_NUM_THREADS=4`

- Bedingte Parallelisierung:

```
double A[elemente];  
#pragma omp parallel for if (elemente > 100)  
for (int i = 0; i < elemente; ++i)  
    A[i] = langwierige_berechnung(i);
```

# Mehrdimensionale Schleifen

- Zusammenfassung von Schleifen
  - for-Direktive wirkt nur auf nächste Schleife
  - **collapse(k)** kombiniert Indexraum der folgenden k Schleifen
- Beispiel: Matrixmultiplikation

```
#pragma omp parallel for collapse(3)
for (int i = 0; i < dim1; ++i)
    for (int j = 0; j < dim2; ++j)
        for (int k = 0; k < dim3; ++k)
            C[i][j] = A[i][k]*B[k][j];
```

# sections

- Parallelisierung ohne Schleifen mit Abschnitten
  - Jedem Abschnitt wird ein Thread zugewiesen
  - Nur statische Parallelität möglich: Abschnitt gilt für ganzes Team

```
#pragma omp parallel
#pragma omp sections
{
    #pragma omp section
    arbeit1();
    #pragma omp section
    arbeit2();
    #pragma omp section
    arbeit3();
}
```

# sections (II)

- Rekursionen sind mit **sections** sehr einfach parallelisierbar
  - Beispiel: Quicksort mit verschachtelten Teams:

```
void quicksort(int a[], int l, int r)
{
    if (l < r)
    {
        int i = partition(a, l, r);
        #pragma omp parallel sections
        {
            #pragma omp section
            quicksort(a, l, i - 1);
            #pragma omp section
            quicksort(a, i + 1, r);
        }
    }
}
```

# task

- Parallelisierung ohne Schleifen mit Tasks (OpenMP 3.0)
  - Jeder Task wird (reihum) einem Thread zugewiesen
  - Unterschied zu sections
    - Definition eines Tasks an beliebiger Stelle von beliebigem Thread im Team
    - Ein Thread im Team führt den Task aus

```
void quicksort(int a[], int l, int r)
{
    if (l < r)
    {
        int i = partition(a, l, r);
        #pragma omp task
        quicksort(a, l, i - 1);
        quicksort(a, i + 1, r);
    }
}
```

```
int main()
{
    #pragma omp parallel
    {
        #pragma omp single
        quicksort(a, 1, 99);
    }
}
```

# Synchronisation

- Block der nur von einem / dem Master Thread im Team ausgeführt werden soll
  - `#pragma omp single / #pragma omp master`
  - Beispiel: Datei einlesen, Textausgabe auf der Konsole
- Block der von jedem Thread einzeln (seriell) ausgeführt werden soll
  - `#pragma omp critical`
  - Analog zur Mutex, entspricht dem Bereich zwischen lock und unlock
  - Beispiel: Zugriff auf gemeinsame Datenstruktur / Resource
- Atomares Schreiben (“kleiner kritischer Abschnitt”)
  - `#pragma omp atomic`
  - Beispiel: Inkrementieren eines globalen Zählers
- Synchronisation aller Threads mit Barriere
  - `#pragma omp barrier`

# SpeicherklauseIn für Variablen

- **shared**
  - Daten sind für alle Threads sichtbar/änderbar. Standard in Schleifen.
- **private**
  - Jeder Thread hat eigene Kopie. Daten werden nicht initialisiert. Sind außerhalb des parallelen Abschnitts nicht bekannt.
- **firstprivate**
  - private Daten. Initialisierung mit letztem Wert vor parallelem Abschnitt
- **lastprivate**
  - private Daten. Der Thread, der die letzte Iteration ausführt, übergibt den Wert aus dem parallelen Abschnitt an das Hauptprogramm.
- **threadprivate**
  - globale Daten, die im parallelen Programmabschnitt jedoch als privat behandelt werden. Der globale Wert wird über den parallelen Abschnitt hinweg bewahrt.
- **reduction**
  - private Daten, werden am Ende auf einen globalen Wert zusammengefasst.

# BEMERKUNGEN ZUR P-AUFGABE

David Weese  
© 2010/11

Johannes Röhr / René Rahn  
WS 2015/16

# Bemerkungen zu Aufgabe 4

- Aufgabenstellung
  - Neighborhood Generation (w, t, S)
  - Einfachste Lösung -> Rekursive Funktion die alle Strings der Länge w enumeriert und anhand (w, t, S) Nachbarschaft bestimmt
  - Parallelisieren!

```
void genNeighborhood(std::string query,
                    const ScoreMatrix &matrix,
                    unsigned wordSize,
                    int threshold)
{
    // Iteriere alle überlappenden Wörter
    // Bestimme Nachbarschaft rekursiv.
    // Gebe Nachbarschaft aus
}
```

# Bemerkungen zu Aufgabe 4 (II)


- Score-Matrizen
  - Blosum
  - PAM
- a4\_util.h -> Helferfunktionen zum Einlesen der Scoring-Matrix.

```
#include <iostream>
#include "../material/material_a4/a4_util.h"

void genNeighborhood(std::string query,
                    const ScoreMatrix &matrix,
                    unsigned wordSize,
                    int threshold)
{ ... }

int main(int argc, const char** argv) {
    ...
    genNeighborhood(...);
    return 0;
}
```

# Bemerkungen zu Aufgabe 5

- Aufgabe 5 ist die Weihnachtsaufgabe
  - Ausgabe: 14.12.2015
  - Abgabe: 25.1.2016

6 Wochen
- Thema: Read Mapping
  - Deutlich mehr Aufwand als bisherige Aufgaben
- Kein Tutorium dazu in diesem Jahr
  - Besuch der P-VL am 14.12.2015 zu empfehlen
  - Zusatztutorial am 4.1.2016 bei Bedarf