

4. Parallelprogrammierung

ALDaBi Praktikum

©David Weese

Kathrin Trappe
René Rahn

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

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
- Unterprogrammbibliotheken
 - 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

- Philosophenproblem:
 - Philosophen essen und denken
 - Zum Essen braucht jeder 2 Gabeln
 - Jeder kann gleichzeitig nur eine Gabel aufheben
 - Jeder nimmt die linke Gabel auf und wartet auf die rechte
- 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



Fallstricke (II)

- 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

OPEN MULTI-PROCESSING

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

Verfügbarkeit

Compiler	OpenMP Unterstützung	Compiler Schalter
g++	GCC 4.2: OpenMP 2.5 GCC 4.4: OpenMP 3.0	-fopenmp
Visual C++	VS 2005-2010: OpenMP 2.0	/openmp In der IDE*
Intel C++	V9: OpenMP 2.5 V11: OpenMP 3.0	Windows: /Qopenmp Linux: -openmp
Sun Studio	V12: OpenMP 2.5 V12 U1: OpenMP 3.0	-xopenmp


- 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)`
 - Implementierung-spezifisch (Standard, wenn keine Angabe)
 - `schedule(runtime)`
 - Entscheidung zur Laufzeit (`omp_set_schedule`, `omp_get_schedule`, `OMP_SCHEDULE`)

for (IV)

- 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];
```

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);
```

sections

- Parallelisierung ohne Schleifen mit Abschnitten
 - Jedem Arbeitspaket 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 [read | write | update | capture]`
 - Beispiel: Inkrementieren eines globalen Zählers
- Synchronisation aller Threads mit Barriere
 - `#pragma omp barrier`

Speicherklauseln für Variablen

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

BEMERKUNGEN ZUR P-AUFGABE

Bemerkungen zu Aufgabe 3

- Typischer Fehler:
 - Traceback bevorzugt Gaps in Sequenz x:
ababa- x
 | | | |
-babab y
 - gefordert war, Gaps in y zu bevorzugen:
-ababa x
 | | | |
babab- y

Bemerkungen zu Aufgabe 3 (II)

- Mögliche Verbesserungen:
 - Auf die Traceback-Matrix kann auch verzichtet werden
 - Traceback-Matrix speichert Richtung, aus der das Maximum kam
 - Alternativ kann man die Richtung des Traceback während des Zurückverfolgens berechnet werden
 - Auch In der Linearisierung der Matrix haben benachbarte Zellen gleichbleibende relative Abstände

```
for(int y = 1; y < yLen; ++y)
  for(int x = 1; x < xLen; ++x)
  {
    int posD = (y-1) * xLen + x-1;
    int posV = (y-1) * xLen + x;
    int posH = y * xLen + x-1;
    int pos = y * xLen + x;
  }
```



```
for(int y = 1; y < yLen; ++y)
  for(int x = 1; x < xLen; ++x)
  {
    int pos = y * xLen + x;
    int posV = pos - xLen;
    int posD = posV - 1;
    int posH = pos - 1
  }
```

- Noch schneller ist, ganz auf Multiplikation zu verzichten

Hinweise zu Aufgabe 4

- Was passiert, wenn der Text einfach nur in nichtüberlappende Teile zerlegt wird?
 - Matches, die halb in beiden Teilen liegen, werden nicht gefunden
- | | | | |
|------|------|---------|---|
| what | ever | whateve | r |
|------|------|---------|---|
- Wie muss der Text aufgeteilt werden, damit
 - Alle Matches gefunden werden
 - Keine Matches doppelt ausgegeben werden
 - Wie verhindert man, dass 2 Threads gleichzeitig den `vector` mit Matches beschreiben
 - Mit der Aufgabe sollte über das Wochenende begonnen werden
 - Auftretende Fragen/Probleme können so im Tutorium am Dienstag besprochen werden

Code Review I

- Wann?
 - 11.12.2012 (Dienstag)
 - Zwischen 10:00 Uhr und 17:00 Uhr
- Wo?
 - Gruppe 1 – 9 in Raum 018 (René Rahn)
 - Gruppe 10 – 18 in Raum 010 (Kathrin Trappe)
- Was?
 - Aufgaben P1 – P4