Parallele Programmiermodelle I

Stefan Lang

Interdisziplinäres Zentrum für Wissenschaftliches Rechnen
Universität Heidelberg
INF 368, Raum 532
D-69120 Heidelberg
phone: 06221/54-8264
email: Stefan.Lang@iwr.uni-heidelberg.de

WS 13/14

Parallele Programmiermodelle I

Kommunikation über gemeinsamen Speicher

- Kritischer Abschnitt
- Wechselseitiger Ausschluss: Petersons Algorithmus
- OpenMP
- Barriere – Synchronization aller Prozeße
- Semaphore

Kritischer Abschnitt

Was ist ein kritischer Abschnitt?

Wir betrachten folgende Situation:

- Anwendung besteht aus P nebenläufigen Prozessen, diese werden also zeitgleich bearbeitet
- von einem Prozeß ausgeführte Anweisungen werden in zusammenhängende Gruppen eingeteilt
  - kritische Abschnitte
  - unkritische Abschnitte
- kritischer Abschnitt: Folge von Anweisungen, welche lesend oder schreibend auf *gemeinsame Variable* zugreift.
- Anweisungen eines kritischen Abschnitts dürfen nicht gleichzeitig von zwei oder mehr Prozessen bearbeitet werden

$\rightarrow$ man sagt nur ein Prozeß darf sich im kritischen Abschnitt befinden

Wechselseitiger Ausschluß

2 Arten der Synchronisation sind unterscheidbar

- Bedingungssynchronisation
- Wechselseitiger Ausschluss

Wechselseitiger Ausschluss besteht aus *Eingangsprotokoll* und *Ausgangsprotokoll*:

Programm (Einführung wechselseitiger Ausschluss)

```
parallel critical-section
{
    process Π [int p ∈ {0, ..., P − 1}]
    {
        while (1)
        {
            Eingangsprotokoll;
            kritischer Abschnitt;
            Ausgangsprotokoll;
            unkritischer Abschnitt;
        }
    }
}
```

Wechselseitiger Ausschluß

Folgende Kriterien sollen erfüllt werden:

1. *Wechselseitiger Ausschluss*. Höchstens ein Prozess führt den kritischen Abschnitt zu einer Zeit aus.
2. *Verklemmungsfreiheit*. Falls zwei oder mehr Prozesse versuchen in den kritischen Abschnitt einzutreten muss es genau einer nach endlicher Zeit auch schaffen.
3. *Keine unnötige Verzögerung*. Will ein Prozess in den kritischen Abschnitt eintreten während alle anderen ihre unkritischen Abschnitte bearbeiten so darf er nicht am Eintreten gehindert werden.
4. *Schließliches Eintreten*. Will ein Prozess in den kritischen Abschnitt eintreten so muss er dies nach endlicher Wartezeit auch dürfen (dazu nimmt man an, daß jeder den kritischen Abschnitt auch wieder verlässt).

Petersons Algorithmus: Eine Softwarelösung

Wir betrachten zunächst nur zwei Prozesse und entwickeln die Lösung schrittweise . . .

Erster Versuch: Warte bis der andere *nicht* drin ist

int *in1*=0, *in2*=0; // 1=drin

Π_1:	Π_2:
while (*in2*) ;	**while** (*in1*) ;
in1=1;	*in2*=1;
krit. Abschnitt;	krit. Abschnitt;

- Es werden keine Maschinenbefehle benötigt
- Problem: Lesen und Schreiben ist nicht atomar

Petersons Algorithmus: Zweite Variante

Erst besetzen, dann testen

int *in1*=0, *in2*=0;

Π_1:	Π_2:
in1=1;	*in2*=1;
while (*in2*) ;	**while** (*in1*) ;
krit. Abschnitt;	krit. Abschnitt;

Problem: Verklemmung möglich

Petersons Algorithmus: Dritte Variante

Löse Verklemmung durch Auswahl eines Prozesses

Programm (Petersons Algorithmus für zwei Prozesse)

```
parallel Peterson-2
{
    int in1=0, in2=0, last=1;

    process Π1
    {
        while (1) {
            in1=1;
            last=1;
            while (in2 ∧ last==1) ;
            krit. Abschnitt;
            in1=0;
            unkrit. Abschnitt;
        }
    }

    process Π2
    {
        while (1) {
            in2=1;
            last=2;
            while (in1 ∧ last==2) ;
            krit. Abschnitt;
            in2=0;
            unkrit. Abschnitt;
        }
    }
}
```

Konsistenzmodelle

Bisherige Beispiele basieren auf dem Prinzip der *Sequentiellen Konsistenz*:

1. *Lese- und Schreiboperationen werden in Programmordnung beendet*
2. *diese Reihenfolge ist für alle Prozessoren konsistent sichtbar*

Hier erwartet man, dass $a = 1$ gedruckt wird:

```
int a = 0,flag=0;                  // wichtig!
process Π1                         process Π2
    ...                                ...
    a = 1;
    flag=1;                            while (flag==0) ;
                                       print a ;
```

Hier erwartet man, dass nur für einen die **if**-Bedingung wahr wird:

```
int a = 0, b = 0;                  // wichtig!
process Π1                         process Π2
    ...                                ...
    a = 1;                             b = 1;
    if (b == 0) ...                    if (a == 0) ...
```

Konsistenzmodelle

Warum keine sequentielle Konsistenz?

- *Umordnen von Anweisungen*: Optimierende Compiler können Operationen aus Effizienzgründen umordnen. Das erste Beispiel funktioniert dann nicht mehr!
- *Out-of-order execution*: z. B. Lesezugriffe sollen langsame Schreibzugriffe (invalidate) überholen können (solange es nicht die selbe Speicherstelle ist). Das zweite Beispiel funktioniert dann nicht mehr!

Total store ordering: Lesezugriff darf Schreibzugriff überholen

Weak consistency: Alle Zugriffe dürfen einander überholen

Reihenfolge kann durch spezielle Maschinenbefehle erzwungen werden, z. B. *fence*: alle Speicherzugriffe beenden bevor ein neuer gestartet wird.

Diese Operationen werden eingefügt,

- bei annotieren von Variablen („Synchronisationsvariable“)
- bei parallelen Anweisungen (z. B. FORALL in HPF)
- vom Programmierer der Synchronisationsprimitive (z. B. Semaphore)

Peterson für P Prozesse

Idee: Jeder durchläuft $P-1$ Stufen, Jeweils der letzte auf einer Stufe ankommende muss warten

Variablen:

- $in[i]$: Stufe $\in \{1,\ldots,P-1\}$ (!), die Π_i erreicht hat
- $last[j]$: Nummer des Prozesses der zuletzt auf Stufe j ankam

Programm (Petersons Algorithmus für P Prozesse)

```
parallel Peterson-P
{
    const int P=8;
    int in[P] = {0[P]};
    int last[P] = {0[P]};
    ...
}
```

Peterson für P Prozesse

Programm (Petersons Algorithmus für P Prozesse cont.)

```
parallel Peterson-P cont.
{
    process Π [int i ∈ {0, ..., P − 1}]
    {
        int j,k;
        while (1)
        {
            for (j=1; j ≤ P − 1; j++)                    // durchlaufe Stufen
            {
                in[i] = j;                               // ich bin auf Stufe j
                last[j] = i;                             // ich bin der letzte auf Stufe j
                for (k = 0; k < P; k++)                  // teste alle anderen
                    if (k ≠ i)
                        while (in[k]≥in[i] ∧ last[j]==i) ;
            }
            kritischer Abschnitt;
            in[i] = 0;                                   // Ausgangsprotokoll
            unkritischer Abschnitt;
        }
    }
}
```

- $O(P^2)$ Tests notwendig für Eintritt
- Strategie ist fair, wer als erstes kommt darf als erster rein

Hardware Locks

Hardwareoperationen zur Realisierung des wechselseitigen Ausschlusses:

- *test-and-set*: Überprüfe ob eine Speicherstelle den Wert 0 hat, wenn ja schreibe den Inhalt eines Registers in die Speicherstelle (als unteilbare Operation).
- *fetch-and-increment*: Hole den Inhalt einer Speicherstelle in ein Register und erhöhe den Inhalt der Speicherstelle um eins (als unteilbare Operation).
- *atomic-swap*: Vertausche den Inhalt eines Registers mit dem Inhalt einer Speicherstelle in einer unteilbaren Operation.

In allen Maschinenbefehlen muß ein Lesezugriff gefolgt von einem Schreibzugriff ohne Unterbrechung durchgeführt werden!

Hardware Locks

Ziel: Maschinenbefehl und Cache-Kohärenz Modell stellt alleiniges Eintreten in den kritischen Abschnitt sicher und erzeugt geringen Verkehr auf dem Verbindungsnetzwerk

Programm (Spin Lock)

```
parallel spin–lock
{
    const int P = 8;                    // Anzahl Prozesse
    int lock=0;                         // Variable zur Absicherung

    process Π [int p ∈ {0, ..., P − 1}]
    {
        ...
        while ( atomic − −swap(& lock)) ;
        ...                             // kritischer Abschnitt
        lock = 0;
        ...
    }
}
```

Hardware Locks

Was passiert im System?

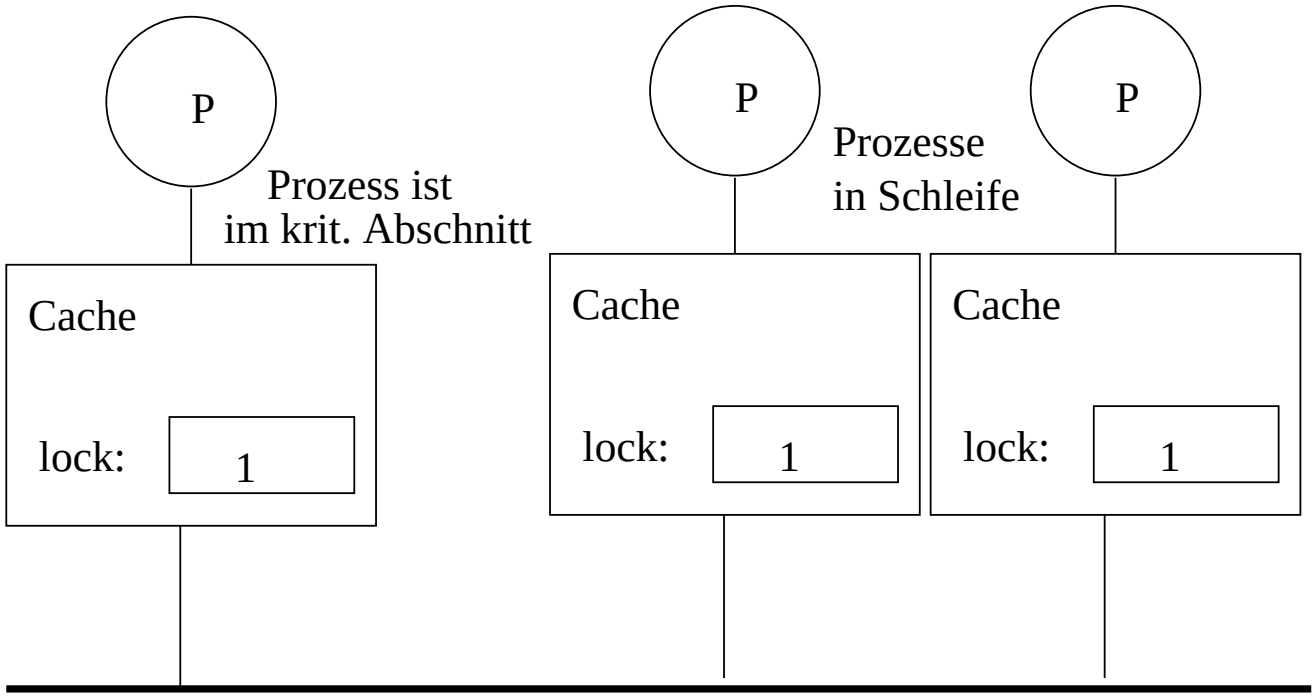

Die beiden wartenden Prozesse erzeugen hohen Busverkehr

Hardware Locks

Ablauf bei MESI Protokoll:Variable *lock* ist 0 und ist in keinem der Caches

- Prozess Π_0 führt die $atomic - swap$–Operation aus

$\rightarrow$ Lesezugriff führt zu read miss, Block wird aus dem Speicher geholt und bekommt den Zustand E (wir legen MESI zugrunde).

$\rightarrow$ Nachfolgendes Schreiben ohne weiteren Buszugriff, Zustand von E nach M.

- anderer Prozess Π_1 führt $atomic - swap$–Operation aus

$\rightarrow$ Read miss führt zum Zurückschreiben des Blockes durch Π_0, der Zustand beider Kopien ist nun, nach dem Lesezugriff, S.

- Schreibzugriff von Π_1 invalidiert Kopie von Π_0 und Zustand in Π_1 ist M.
- $atomic - swap$ gibt 1 in Π_1 und kritischer Abschnitt wird von Π_1 nicht betreten.
- Führen beide Prozesse die $atomic - swap$–Operation gleichzeitig aus entscheidet letztendlich der Bus wer gewinnt.
- Angenommen Cache C_0 von Prozessor P_0 als auch C_1 haben je eine Kopie des Cache–Blockes im Zustand S vor Ausführung der $atomic - swap$–Operation
- Beide lesen zunächst den Wert 0 aus der Variable *lock*.
- Beim nachfolgenden Schreibzugriff konkurrieren beide um den Bus um eine invalidate Meldung zu platzieren.
- Der Gewinner setzt seine Kopie in Zustand M, Verlierer seine in den Zustand I. Die Cache–Logik des Verlierers findet beim Schreiben den Zustand I vor und muss den $atomic - swap$–Befehl veranlassen doch den Wert 1 zurückzuliefern (der atomic-swap–Befehl ist zu dieser Zeit ja noch nicht beendet).

Verbessertes Lock

Idee: Mache keinen Schreibzugriff solange der kritische Abschnitt besetzt ist

Programm (Verbesserter Spin Lock)

```
parallel improved–spin–lock
{
    const int P = 8;                    // Anzahl Prozesse
    int lock=0;                         // Variable zur Absicherung

    process Π [int p ∈ {0, ..., P − 1}] {
        ...
        while (1)
            if (lock==0)
                if (read − and − set(& lock)==0 )
                    break;
        ...                             // kritischer Abschnitt
        lock = 0;
        ...
    }
}
```

Verbessertes Lock

1. Problem: Strategie gewährleistet keine Fairness
2. Situation mit drei Prozessen: Zwei wechseln sich immer ab, der dritte kommt nie rein
3. Aufwand falls P Prozesse gleichzeitg eintreten wollen: $O(P^2)$, Zuweisung $lock = 0$ bedingt P Bustransaktionen für Cache Block Kopien
4. Lösung ist ein Queuing Lock: Bei Austritt aus dem kritischen Abschnitt wählt der Prozess seinen Nachfolger aus

Ticketalgorithmus:

- Fairness mit Hardware-Lock
- Idee: Vor dem Anstellen an der Schlange zieht man eine Nummer. Der mit der kleinsten Nummer kommt als nächster dran.

Ticketalgorithmus

Programm (Ticket Algorithmus für P Prozesse)

```
parallel Ticket
{
    const int P=8;
    int number=0;
    int next=0;

    process Π [int i ∈ {0, ..., P − 1}]
    {
        int mynumber;
        while (1)
        {
            [mynumber=number; number=number+1;]
            while (mynumber≠next) ;
            kritischer Abschnitt;
            next = next+1;
            unkritischer Abschnitt;
        }
    }
}
```

Ticketalgorithmus

1. Fairness basiert darauf, daß Ziehen der Zahl nicht lange dauert. Möglichkeit einer Kollision ist kurz.
2. Geht auch bei Überlauf der Zähler, (MAXINT>P)
3. Inkrementieren von *next* geht ohne Synchronisation, da dies immer nur einer machen kann

Bedingter kritischer Abschnitt

- Erzeuger-Verbraucher Problem:
  - m Prozesse P_i (Erzeuger) erzeugen Aufträge, die von n anderen Prozessen C_j (Verbraucher) abgearbeitet werden sollen.
  - Die Prozesse kommunizieren über eine zentrale Warteschlange (WS) mit k Plätzen.
  - Ist die WS voll müssen die Erzeuger warten, ist die WS leer müssen die Verbraucher warten.
- Problem: Wartende dürfen den (exklusiven) Zugriff auf die WS nicht blockieren!
- Kritischer Abschnitt (Manipulation der WS) darf nur Betreten werden *wenn* WS nicht voll (für Erzeuger), bzw. nicht leer (für Verbraucher) ist.
- Idee: Probeweises Betreten und busy-wait:

Bedingter kritischer Abschnitt

Programm (Erzeuger–Verbraucher Problem mit aktivem Warten)

```
parallel producer-consumer-busy-wait
{
    const int m = 8; n = 6; k = 10;
    int orders=0;
    process P [int 0 ≤ i < m]
    {
        while (1) {
            produziere Auftrag;
            CSenter;
            while (orders==k){
                CSexit;
                CSenter;
            }
            speichere Auftrag;
            orders=orders+1;
            CSexit;

        }
    }
}
```

```
process C [int 0 ≤ j < n]
{
    while (1) {

        CSenter;
        while (orders==0){
            CSexit;
            CSenter;
        }
        lese Auftrag;
        orders=orders-1;
        CSexit;
        bearbeite Auftrag;
    }
}
```

Bedingter kritischer Abschnitt

- Ständiges Betreten und Verlassen des kritischen Abschnittes ist ineffizient wenn mehrere Warten (Trick vom verbesserten Lock hilft nicht)
- (Praktische) Abhilfe: Zufällige Verzögerung zwischen *CSenter*/*CSexit*, *exponential back-off*.

OpenMP (Open Multi Processing) I: Ansatz

OpenMP ist ein paralleles Programmiermodell auf
der Grundlage der folgenden Annahmen:

- ein Prozeß besteht aus mehreren Threads (Fäden)
- alle Threads teilen die gleichen Statusvariablen des Programms
- jeder Thread kann zusätzliche private Variablen besitzen
- Threads können auf unterschiedlichen Prozessoren laufen
- Es gibt Mechanismen zur Synchronization und zum Sperren

OpenMP II

Was ist OpenMP?

- API (application programming interface) um multi-threaded Anwendungen zu schreiben
  - Compilerdirektiven and Bibliotheksfunktionen
  - standardisiert für C und Fortran
- neuer Standard unter stetiger Weiterentwicklung
- wichtiges Modell, da viele wichtige Firmen partizipieren
- Parallelisierungsprozeß unter OpenMP
  - Programm wird in Stufen parallelisiert
  - Startpunkt ist die serielle Version, welche in vielen Fällen unverändert erhalten bleibt
  - Parallelismus ist nicht direkt codiert, sondern wird mit Direktiven beeinflußt

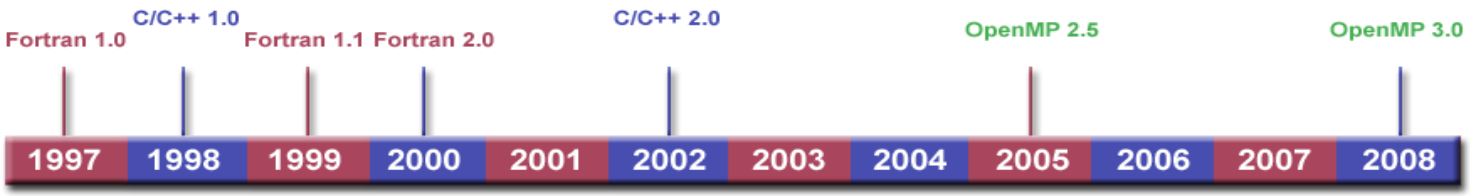

OpenMP Beispiel I

Hello World:

- das ursprüngliche Programm bleibt erhalten
- Ausführung beim Setzen einer Umgebungsvariable:

```
void main(void)
{
#pragma omp parallel
  {
     printf(„Hallo Welt\n“);
  }
}
```

```
(~): export OMP_NUM_THREADS=4
(~): ./hello-openmp
Hallo Welt
Hallo Welt
Hallo Welt
Hallo Welt
```

OpenMP Beispiel II

Parallele Regionen (Blöcke)

- bei Verwendung der Compilerdirektive `#pragma omg parallel` wird der folgende Block parallel ausgeführt
- dazu wird eine Menge von Threads gestartet
  - die Threadanzahl hängt von der Umgebungsvariable `OMP_NUM_THREADS` ab, die kann vom Programm geändert werden
  - man spricht von fork-join Parallelismus
- nachdem alle Threads abgearbeitet sind, werden diese terminiert oder verbleiben wartend

Kontrollfluß in Block 1 Kontrollfluß in Block 2

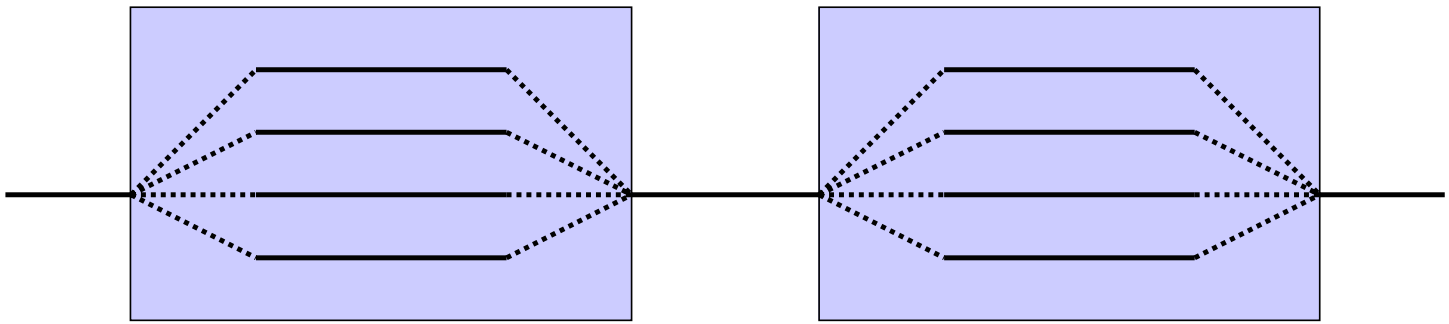

OpenMP Beispiel III

- primärer Einsatzbereich von OpenMP ist das Parallelisieren von Schleifen
- **#pragma omp parallel for**
- i-loop will be executed simultaneously by `OMP_NUM_THREADS` threads

Matrix-Matrix Multiplikation

```
#pragma omp parallel for
for (i = 0; i < M; i++)
  for (j = 0; j < N; j++)
    for (k = 0; k < K; k++)
      C[i,j] = A[i,k] * B[k,j];
```

OpenMP Beispiel IV

Laufzeitbedingungen

- falls mehrere Threads die selbe Variable lesen und schreiben, können Inkonsistenzen entstehen
- dies ist mit den bekannten Inkonsistenzen in Shared-Memory Architekturen vergleichbar

Beispiel: Skalarprodukt

```
sum = 0.0;
#pragma omp parallel for
for (i = 0; i < N; i++)
      sum = sum + x[i] * y[i];
```

OpenMP Beispiel V

Lösung 1: Locking

- Um die Addition bei Summenbildung abzusichern kann man diese als atomar oder kritisch deklarieren
- Nachteil: das ist ineffizient, weil die Threads nicht mehr parallel arbeiten können

```
sum = 0.0;
#pragma omp parallel for
for (i = 0; i < N; i++)
#pragma omp critical
{
      sum = sum + x[i] * y[i];
}
```

OpenMP Beispiel VI

Lösung 2: Privat Variablen

- in parallelen Regionen können bestimmte Variablen als privat deklariert werden
- dies kann man noch kompakter schreiben

```
sum = 0.0;
#pragma omp parallel private(local_sum)
{
  local_sum = 0.0;
#pragma omp parallel for
  for (i = 0; i < N; i++)
    local_sum = local_sum + x[i] * y[i];

#pragma omp critical
  { sum = sum + local_sum; }
}
```

OpenMP Beispiel VII

Lösung 3: Reduktionsvariablen

- solche Fälle sind typisch, man kann kritische Variable als Reduktionsvariable deklarieren
- innerhalb von Threads werden diese als privat generiert und dann mit einer geeigneten Operation am Schleifenende verbunden (synchronisiert)

```
sum = 0.0;
#pragma omp parallel for reduction (+ : sum)
for (i = 0; i < N; i++)
     sum = sum + x[i] * y[i];
```

OpenMP Pragmas I

- directives (in C):
  - **#pragma omp clauses** . . .
  - are ignored by non-OpenMP compilers
- parallel regions (blocks):
  - **#pragma omp parallel**
  - following block ({. . .}) is executed in parallel
- variable scoping
  - **#pragma omp private(. . .) shared(. . .) reduction(. . .) firstprivate(. . .) lastprivate(. . .)**
  - defines which variable are used together and which are used as copies in each thread
  - **shared is default value**

OpenMP Pragmas II

- synchronization
  - **#pragma omp atomic, critical, ordered, barrier, flush**
  - essential for program correctness
- parallel loops (work-sharing)
  - **#pragma omp parallel for**
  - following **for** is parallelized
  - type of distribution can be determined with **schedule** clause
  - e.g. **schedule(dynamic,4)**: each thread is assigned four loop iterations (1. . .4, 5. . .8) and new ones, as soon as a thread is ready
  - other variant are **static, guided** and **runtime**

OpenMP Run Time Environment I

run time environment

- processor count
  - **omp_get_num_procs()**
- thread count
  - **omp_set_num_thread(int)**
  - **omp_get_num_thread()**
    same as envrionment variable **OMP_NUM_THREADS**
  - **omp_get_thread_num()**

OpenMP Run Time Environment II

run time environment

- dynamic mode: Is in different blocks a different number of threads allowed?
  - **omp_set_dynamic(), omp_get_dynamic()**
  - equal to **OMP_DYNAMIC (TRUE / FALSE)**
- nesting: Are in parallel regions new thread teams allowed? (nested threads)
  - **omp_set_nested(), omp_get_nested()**
  - equal to **OMP_NESTED (TRUE / FALSE)**

OpenMP in Practise: Matrix-Vector Product

```
#pragma omp parallel for default(none) \
            private(i,j,sum) shared(m,n,a,b,c)
for (i=0; i<m; i++)
{
   sum = 0.0;
   for (j=0; j<n; j++)
     sum += b[i][j]*c[j];
   a[i] = sum;
}
```

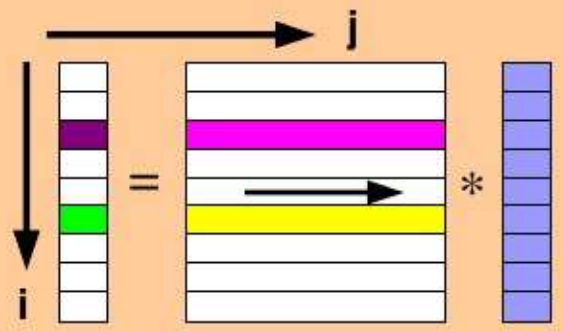

TID = 0

```
for (i=0,1,2,3,4)
 i = 0
sum =    b[i=0][j]*c[j]
  a[0] = sum
 i = 1
sum =    b[i=1][j]*c[j]
  a[1] = sum
```

TID = 1

```
for (i=5,6,7,8,9)
 i = 5
sum =    b[i=5][j]*c[j]
  a[5] = sum
 i = 6
sum =    b[i=6][j]*c[j]
  a[6] = sum
```

... etc ...

openmp.org

OpenMP in Practise: Scaling behaviour in MFLOPs

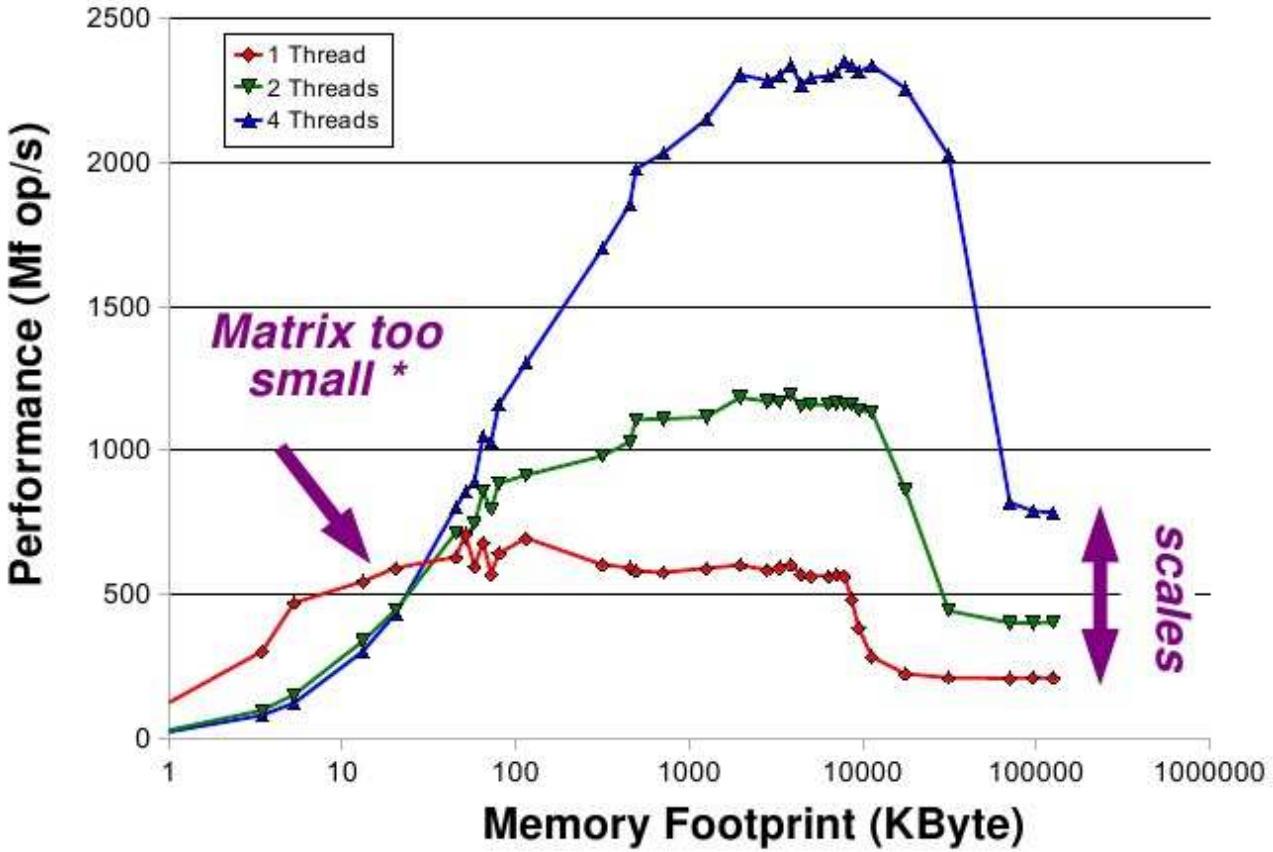

*) With the IF-clause in OpenMP this performance degradation can be avoided

openmp.org

OpenMP in Practise: IF-Clause

if (scalar expression)

- ✔ ***Only execute in parallel if expression evaluates to true***
- ✔ ***Otherwise, execute serially***

```
#pragma omp parallel if (n > some_threshold) \
        shared(n,x,y) private(i)
  {
    #pragma omp for
     for (i=0; i<n; i++)
        x[i] += y[i];
  } /*-- End of parallel region --*/
```

openmp.org

OpenMP in Practise: More Elaborate Example

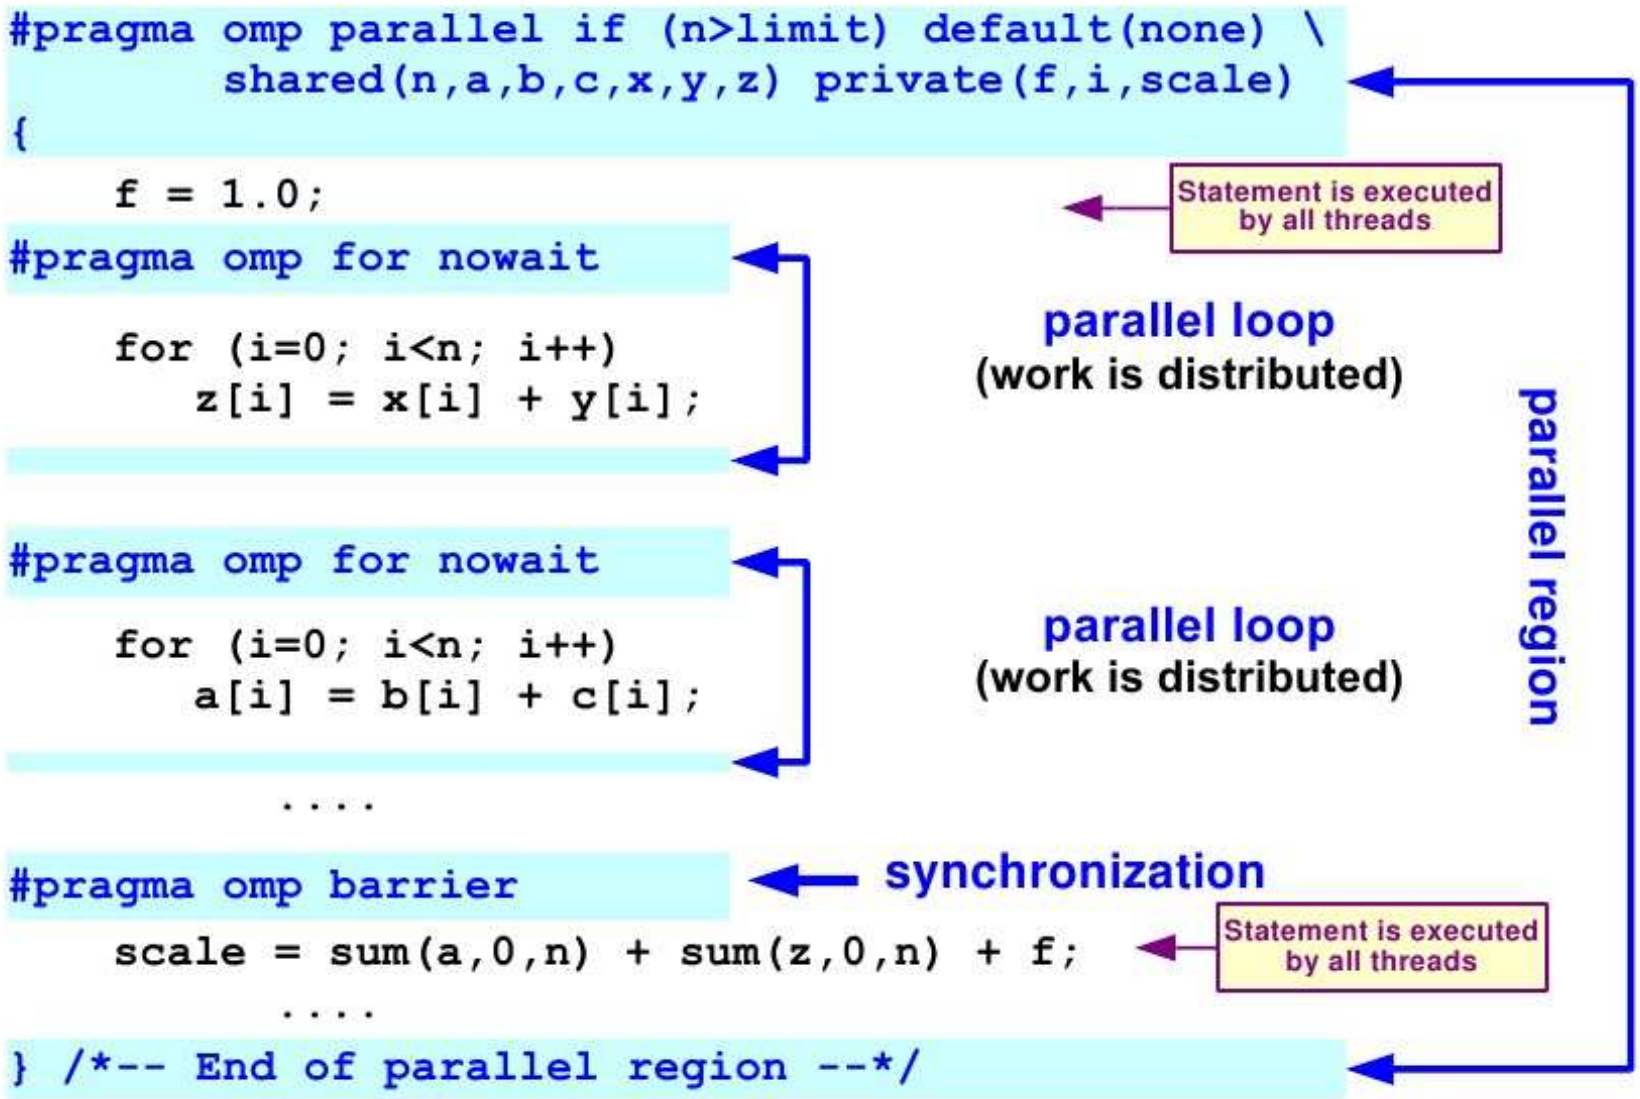

openmp.org

OpenMP in Practise: OpenMP Summary

Directives

- Parallel region
- Worksharing constructs
- Tasking
- Synchronization
- Data-sharing attributes

Runtime environment

- Number of threads
- Thread ID
- Dynamic thread adjustment
- Nested parallelism
- Schedule
- Active levels
- Thread limit
- Nesting level
- Ancestor thread
- Team size
- Wallclock timer
- Locking

Environment variables

- Number of threads
- Scheduling type
- Dynamic thread adjustment
- Nested parallelism
- Stacksize
- Idle threads
- Active levels
- Thread limit

openmp.org

OpenMP in Practise: Locking Mechanism

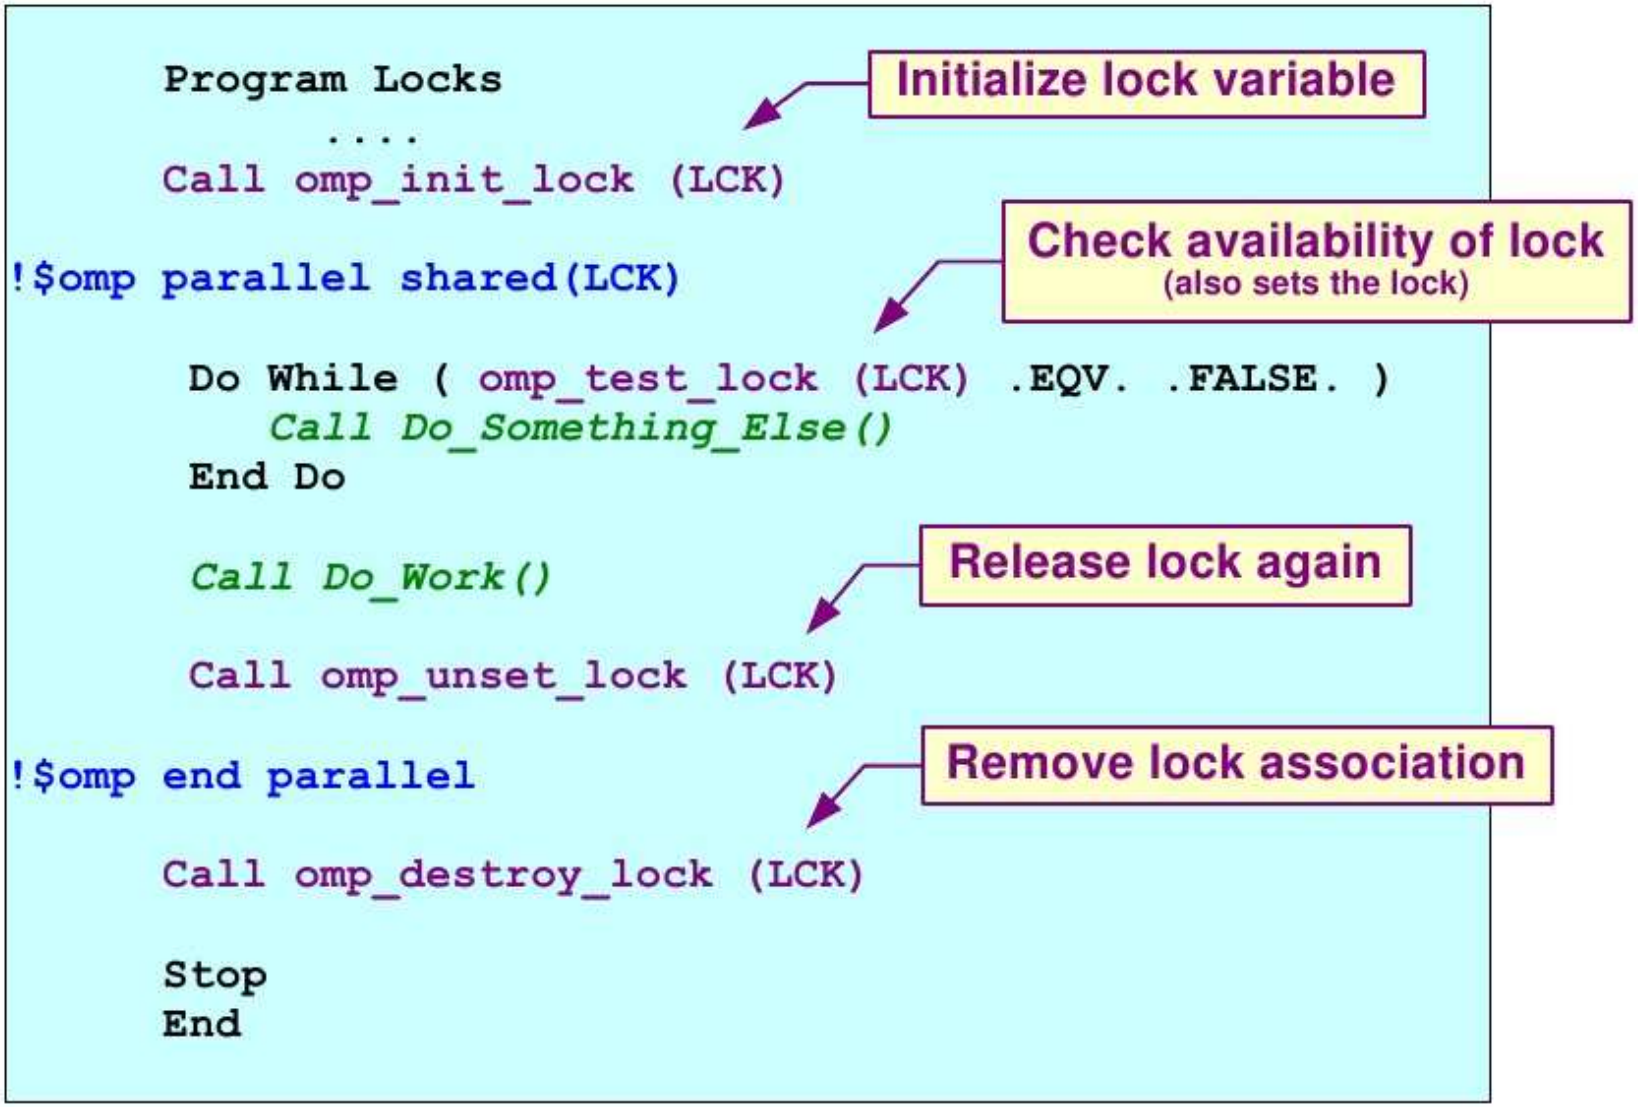

openmp.org

OpenMP in Practise: Scheduling I

schedule (static | dynamic | guided | auto [, chunk])
schedule (runtime)

static [, chunk]

- *Distribute iterations in blocks of size "chunk" over the threads in a round-robin fashion*
- *In absence of "chunk", each thread executes approx. N/P chunks for a loop of length N and P threads*
  - *Details are implementation def ned*
- *Under certain conditions, the assignment of iterations to threads is the same across multiple loops in the same parallel region*

openmp.org

OpenMP in Practise: Scheduling II

dynamic [, chunk]

- ✔ *Fixed portions of work; size is controlled by the value of chunk*
- ✔ *When a thread f nishes, it starts on the next portion of work*

guided [, chunk]

- ✔ *Same dynamic behavior as "dynamic", but size of the portion of work decreases exponentially*

auto

- ✔ *The compiler (or runtime system) decides what is best to use; choice could be implementation dependent*

runtime

- ✔ *Iteration scheduling scheme is set at runtime through environment variable OMP_SCHEDULE*

openmp.org

OpenMP in Practise: Scheduling III

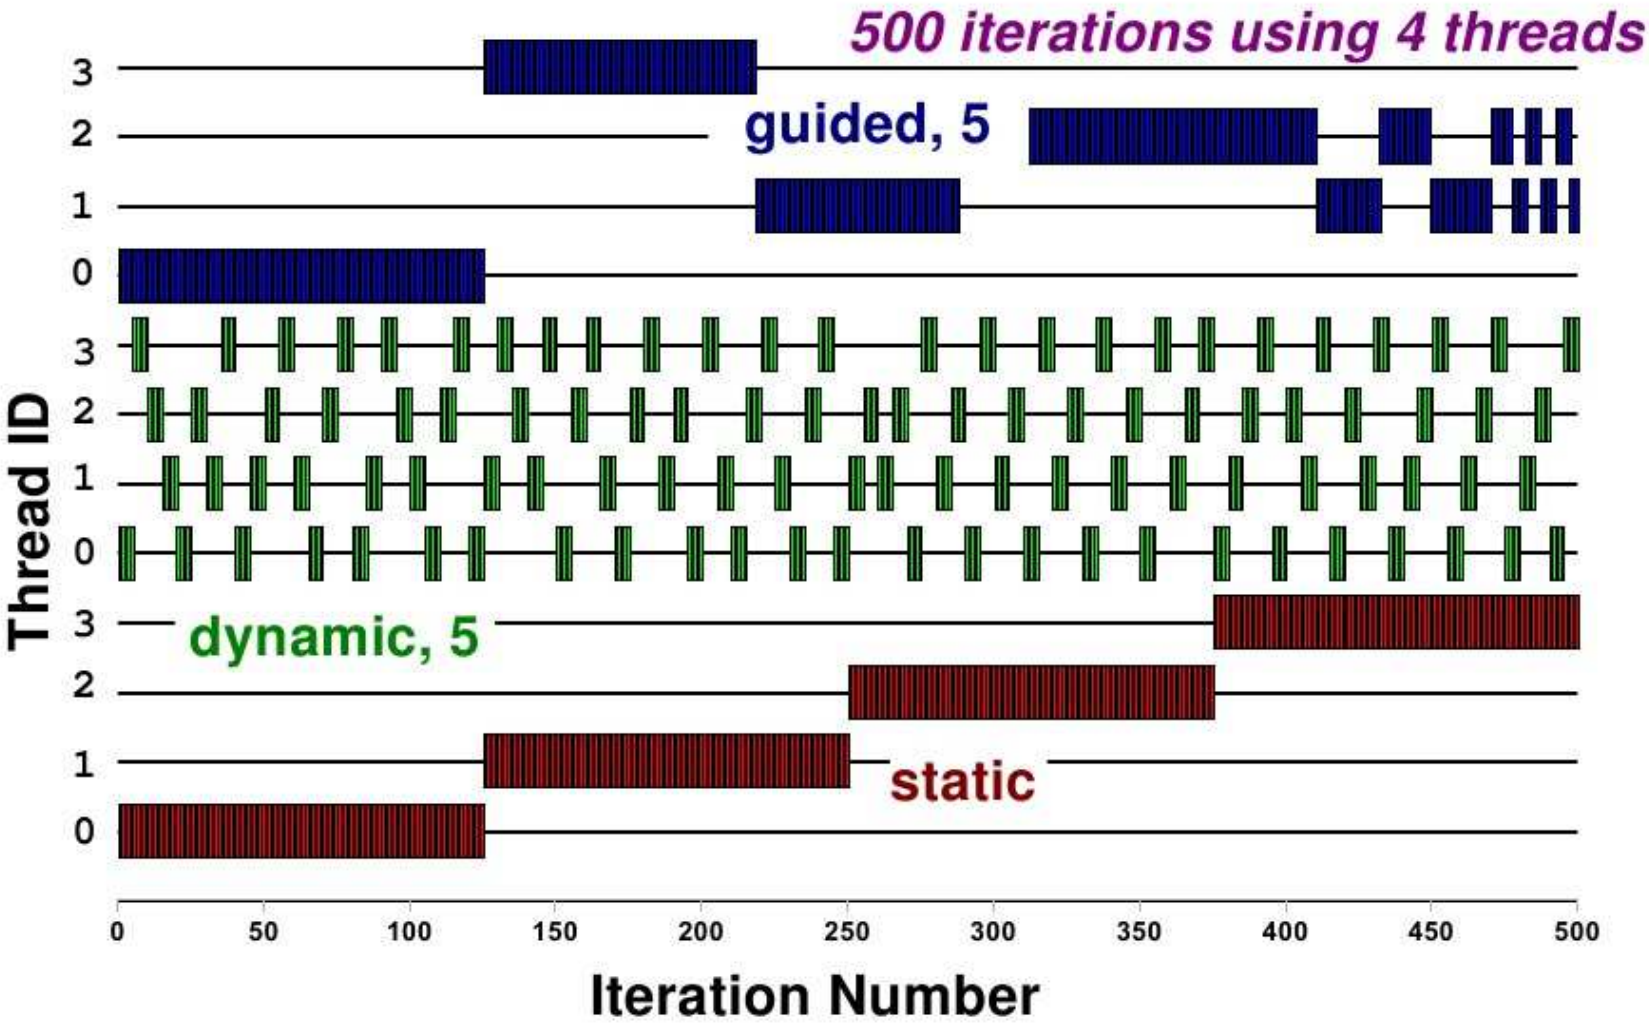

openmp.org