

Esercitazioni di Calcolo Parallelo

Paolo Avogadro

DISCo, Università di Milano-Bicocca
U14, Id&aLab T36
paolo.avogadro@unimib.it
Aula Lezione T014 (o WEBEX),
edificio U14

- Mercoledì' 14:30-16:30
- Giovedì" 10:30-12:30

Intro: openMP

- **openMP** = **open** specifications for **M**ulti **P**rocessing
- **openMP** standard nato nel 1997 per il FORTRAN e portato poi a C/C++
- **openMP** e' una **API** per ambienti **multi-thread** a **memoria condivisa**
- **openMP** definisce:
 - direttive per il compilatore
 - una libreria di funzioni a runtime
 - variabili d'ambiente
- per la **gioia** di grandi e piccini, openMP e' uno **standard** non una **implementazione**, per questo le implementazioni (per esempio GNU e Intel) possono avere dei comportamenti differenti.
- **openMP** lascia al programmatore il controllo dell'esistenza di **deadlock** e comportamenti **non-deterministici**
- **openMP** non definisce particolari standard di I/O

Un sito di riferimento: <https://computing.llnl.gov/tutorials/openMP/#PRIVATE>

da MPI a openMPI

Usiamo ora MPI come paragone per poter capire cosa sia openMP

- Grossolanamente parlando l'idea dove nasce e': **MPI** ↔ **memoria non condivisa** (p.es tanti computer connessi in una rete locale)
- con la medesima grossolanita': **openMP** ↔ **memoria condivisa** (p.es una cpu multi-core)

Nel caso di **MPI**, non esistendo una memoria condivisa, si deve definire un protocollo di comunicazione tra processi. **openMP** viene invece pensato per un ambiente dove la **comunicazione** tra varie unita' di calcolo avviene **accedendo alla memoria condivisa**, servono quindi dei protocolli per definire questi accessi.

- ricordiamo che **MPI** si basa (prevalentemente) su una logica **SPMD** (un solo codice gira ed elabora dati differenti)
- anche **openMP** segue il paradigma **SPMD** in cui pero' e' essenziale il concetto di **work sharing** in cui i singoli thread eseguono parti differenti del lavoro.

Un paragone introduttivo tra MPI e openMP:

MPI
tante CPU girano **sempre**
i **processi** necessitano di un **protocollo** per comunicare
il codice va **progettato** parallelo

openMP
utilizzo CPU/core solo alla **bisogna**
i **thread** accedono alla stessa **memoria**
parallelizzazione progressiva

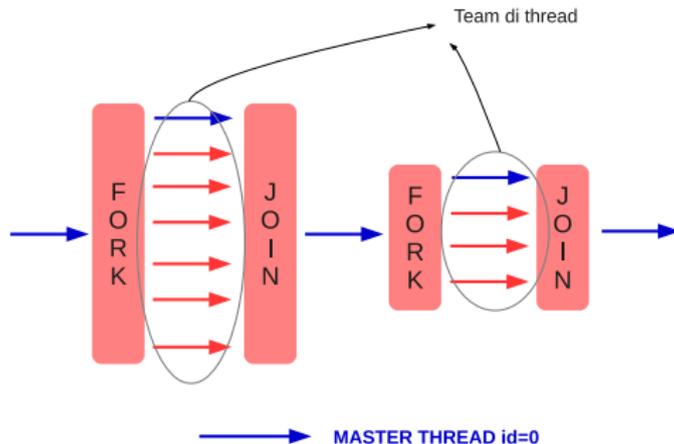
Cos'è un thread? (differenze rispetto ad un processo)

- (ricordi di MPI...) un **processo** è un'istanza di esecuzione del programma (ergo: un processo fa girare tutto un codice)
- un **thread** (o **instruction stream**) è la più piccola unità di calcolo che può essere gestita dal sistema (un thread spesso fa girare solo una **piccola** parte di un codice)
- in **alcune parti** di un **processo** possono girare vari **thread** (non è vero il contrario)
- i thread di un processo possono **condividere la memoria** assegnata al processo.
- invece processi differenti, in genere, non condividono* le risorse.

*alcune risorse possono essere condivise tra processi differenti, per esempio la memoria di massa. E come abbiamo visto MPI può girare anche su un sistema multi-core con memoria condivisa.

L'idea di **openMP** e' che:

- il codice gira su una macchina con molte "cpu/core" con memoria condivisa
- la parte seriale di codice non ha senso che venga fatta girare su tutte le cpu! (**economia**)
- esiste un **master** thread che fa girare il codice
- al momento della **bisogna** (per esempio quando c'e' un ciclo `for` che puo' beneficiare della parallelizzazione) si inserisce l'apposito costrutto di **openMP**.
- a questo punto c'e'un **fork**: dal **master thread** si crea un **team** di thread che eseguono il calcolo parallelo (in realta' si ha concorrenza/concurrency, ovvero *parallelismo potenziale*).
<http://tutorials.jenkov.com/java-concurrency/concurrency-vs-parallelism.html>
- alla fine della sessione parallela tutti i thread tranne il master cessano di esistere e il calcolo riprende in modo seriale, questo viene chiamato una: **join** (dove vi e' una barriera implicita).

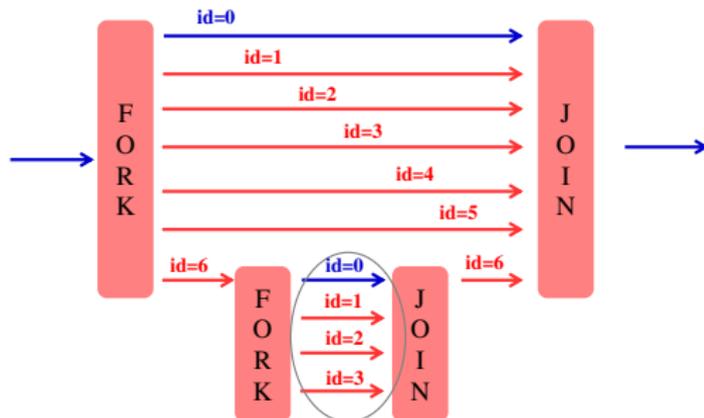


Fork: parallelismo innestato

- E' possibile fare creare un **nuovo team** da un thread di una regione parallela
- Attenzione pero': questo comportamento di default e' **spento** (non avviene nessun fork aggiuntivo se si chiama un costrutto parallelo in un costrutto parallelo).
- per **accendere** il nested parallelism si puo' settare una variabile d'ambiente: `OMP_NESTED = true`
- oppure usare la seguente funzione a runtime: `omp_set_nested(1)`

Nested Parallelism

MASTER THREAD id=0



- **parallel region**: parte di codice dove puo' agire piu' di un thread
- una regione parallela e' considerata **attiva** se vi agisce piu' di un thread (se c'e' solo il thread master, la regione non e' attiva).
- a tutti i thread viene assegnato un numero intero di identificazione progressivo chiamato **id** (e' il cugino del rank di MPI)
- il **master** thread ha **id=0**
- tutti i comandi (**statement**) in una regione parallela sono eseguiti da **tutti** i thread nella regione parallela
- quando **tutti** i thread hanno completato il loro compito si arriva alla fine della regione parallela: c'e' un **JOIN**.
- Con un **JOIN** tutti i thread **tranne** il master cessano di esistere.

Per compilare e fare girare un codice

- Per un codice in C serve un header iniziale: `#include <omp.h>`
- e' possibile (**NON NECESSARIO**), definire delle variabili d'ambiente, che contengano, per esempio il numero di thread che si vuole fare "creare" di default al momento dei **fork**.
- al momento della compilazione con `gcc` si deve usare la flag: `-fopenmp`, per esempio:
`gcc -fopenmp miocodice.c -o miocodice.x`
- per il compilatore `icc`: `icc -qopenmp miocodice.c -o miocodice.x`
- la flag con il compilatore `pg` e': `pgcc -mp miocodice.c -o miocodice.x`
- il codice ottenuto, viene poi lanciato semplicemente con `./miocodice.x` (non si ha una modalita' di lancio particolare, come invece c'era in MPI).

Ciao Mondo!

Il primo codice openMP:

```
#include <omp.h> // header necessario per openMP
#include <stdio.h>
void main()
{
    #pragma omp parallel num_threads(5) // COSTRUTTO parallelo di openMP: c'e' il FORK
    {
        int id; // NON METTERE la GRAFFA sulla linea di #pragma
        id = omp_get_thread_num(); // definisco intero per l'id
        printf("Ciao Mondo, sono il thread (%d)\n", id ); // funzione INTRINSECA di openMP
    } // fine regione parallela JOIN
    printf(" Ricioo Mondo\n" ); // Quante volte verra' scritto "Ricioo"?
}
```

- # pragma omp sta per *pragmatic information* del tipo **openMP** e serve al compilatore che, nel momento della compilazione, sa di dover fare qualcosa (descritto nel seguito della riga).
- la **direttiva** parallel dice al compilatore di fare un **FORK** e creare un team di thread (in questo caso, la clausola (clause) num_threads(5) definisce che i thread di **questa** regione parallela devono essere 5).
- Ci possono essere comandi #pragma diversi da quelli omp, in altri ambiti.
- **Occhio**: se si apre la parentesi graffa che definisce il costrutto parallelo sulla stessa linea di #pragma omp parallel si ottiene un **errore**
- **Altro occhio**: se si dimentica di usare la clausola parallel, il fork **non** avviene e c'e' solo il master thread.

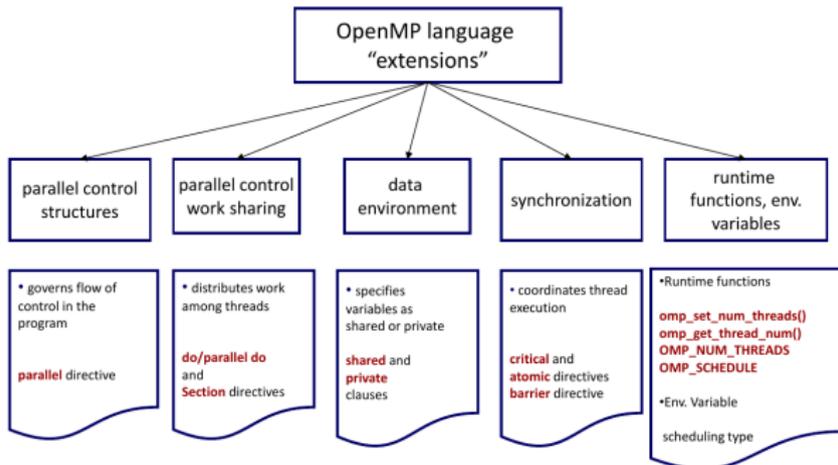
Le direttive

- i comandi sono Case sensitive (in C)
- si può specificare un **solo** nome della direttiva (p.es. `parallel`, `for`,...) (**in realtà** in alcuni casi si hanno delle scorciatoie p.es.: `parallel for` sulla stessa riga è valido)
- dopo il nome della direttiva si possono aggiungere delle *clausole* (p.es. `shared(i)` identifica che la variabile `i` è `shared`, vedremo poi il significato)
- ogni direttiva si applica al più ad un blocco strutturato; in un blocco strutturato c'è un solo ingresso e una sola uscita, p.es. non si può entrare/uscire con `goto!` (ma si può uscire con un `exit()` in C o `stop` per il FORTRAN).
- se la direttiva è lunga si può **andare a capo** con `\` e continuare la direttiva.

Esempio della struttura di una direttiva:

INTESTAZIONE **NOME della DIRETTIVA** **Clausole...**
`#pragma omp parallel shared(i) private (j)`

Alla fine della direttiva si deve **andare a capo!!!!!!!** (senza `;` in C)



Alcune routine (funzioni) a runtime di openMP

Alcune utili funzioni definite da *openMP* (queste **non** vanno messe dopo un `#pragma`):

- `int omp_get_num_threads();` restituisce il numero di thread nel team (equivalente alla **size** di MPI nella regione parallela)
- `int omp_get_thread_num();` la funzione restituisce l'id del thread chiamante (sotto forma di int) (equivalente del **rank** per i processi di MPI), per esempio: `myID=omp_get_thread_num();`
I thread sono identificati da un **id** che va da 0 (per il **Master**) a N-1 (N =numero thread della regione parallela).
- `double omp_get_wtime();` wall time, per esempio: `t1 = omp_get_wtime();`
- `void omp_set_num_threads();` definisce il numero di thread nei successivi costrutti paralleli (a meno che, nel frattempo, intervengano altre specificazioni sul numero di thread).
- `int omp_get_num_procs();` trova il numero di CPU presente nella macchina
- `int omp_in_parallel();` restituisce un valore intero che e' 0 se **non** siamo in una regione parallela **attiva**. Restituisce invece 1 se viene chiamato dall'interno di una regione parallela **attiva**.

Alcune routine (funzioni) a runtime di openMP

Alcune utili funzioni definite da *openMP* (queste **non** vanno messe dopo un `#pragma`):

- `int omp_get_num_threads();` restituisce il numero di thread nel team (equivalente alla `size` di MPI nella regione parallela)
- `int omp_get_thread_num();` la funzione restituisce l'**id** del thread chiamante (sotto forma di `int`) (equivalente del **rank** per i processi di MPI), per esempio: `myID=omp_get_thread_num();`
I thread sono identificati da un **id** che va da 0 (per il **Master**) a N-1 (N =numero thread della regione parallela).
- `double omp_get_wtime();` wall time, per esempio: `t1 = omp_get_wtime();`
- `void omp_set_num_threads();` definisce il numero di thread nei successivi costrutti paralleli (a meno che, nel frattempo, intervengano altre specificazioni sul numero di thread).
- `int omp_get_num_procs();` trova il numero di CPU presente nella macchina
- `int omp_in_parallel();` restituisce un valore intero che e' 0 se non siamo in una regione parallela **attiva**. Restituisce invece 1 se viene chiamato dall'interno di una regione parallela **attiva**.

Alcune routine (funzioni) a runtime di openMP

Alcune utili funzioni definite da *openMP* (queste **non** vanno messe dopo un `#pragma`):

- `int omp_get_num_threads();` restituisce il numero di thread nel team (equivalente alla `size` di MPI nella regione parallela)
- `int omp_get_thread_num();` la funzione restituisce l'id del thread chiamante (sotto forma di `int`) (equivalente del `rank` per i processi di MPI), per esempio: `myID=omp_get_thread_num();`
I thread sono identificati da un `id` che va da 0 (per il `Master`) a `N-1` (`N` = numero thread della regione parallela).
- `double omp_get_wtime();` **wall time, per esempio:** `t1 = omp_get_wtime();`
- `void omp_set_num_threads();` definisce il numero di thread nei successivi costrutti paralleli (a meno che, nel frattempo, intervengano altre specificazioni sul numero di thread).
- `int omp_get_num_procs();` trova il numero di CPU presente nella macchina
- `int omp_in_parallel(),` restituisce un valore intero che e' 0 se non siamo in una regione parallela **attiva**. Restituisce invece 1 se viene chiamato dall'interno di una regione parallela **attiva**.

Alcune routine (funzioni) a runtime di openMP

Alcune utili funzioni definite da *openMP* (queste **non** vanno messe dopo un `#pragma`):

- `int omp_get_num_threads()`; restituisce il numero di thread nel team (equivalente alla `size` di MPI nella regione parallela)
- `int omp_get_thread_num()`; la funzione restituisce l'id del thread chiamante (sotto forma di `int`) (equivalente del `rank` per i processi di MPI), per esempio: `myID=omp_get_thread_num()`; i thread sono identificati da un `id` che va da 0 (per il **Master**) a N-1 (N =numero thread della regione parallela).
- `double omp_get_wtime()`; wall time, per esempio: `t1 = omp_get_wtime()`;
- `void omp_set_num_threads()`; definisce il numero di thread nei successivi costrutti paralleli (a meno che, nel frattempo, intervengano altre specificazioni sul numero di thread).
- `int omp_get_num_procs()`; trova il numero di CPU presente nella macchina
- `int omp_in_parallel()`, restituisce un valore intero che e' 0 se **non** siamo in una regione parallela **attiva**. Restituisce invece 1 se viene chiamato dall'interno di una regione parallela **attiva**.

Alcune routine (funzioni) a runtime di openMP

Alcune utili funzioni definite da *openMP* (queste **non** vanno messe dopo un `#pragma`):

- `int omp_get_num_threads()`; restituisce il numero di thread nel team (equivalente alla `size` di MPI nella regione parallela)
- `int omp_get_thread_num()`; la funzione restituisce l'id del thread chiamante (sotto forma di `int`) (equivalente del `rank` per i processi di MPI), per esempio: `myID=omp_get_thread_num()`; i thread sono identificati da un `id` che va da 0 (per il **Master**) a `N-1` (`N` = numero thread della regione parallela).
- `double omp_get_wtime()`; wall time, per esempio: `t1 = omp_get_wtime()`;
- `void omp_set_num_threads()`; definisce il numero di thread nei successivi costrutti paralleli (a meno che, nel frattempo, intervengano altre specificazioni sul numero di thread).
- `int omp_get_num_procs()`; trova il numero di CPU presente nella macchina
- `int omp_in_parallel()`, restituisce un valore intero che e' 0 se **non** siamo in una regione parallela **attiva**. Restituisce invece 1 se viene chiamato dall'interno di una regione parallela **attiva**.

Alcune routine (funzioni) a runtime di openMP

Alcune utili funzioni definite da *openMP* (queste **non** vanno messe dopo un `#pragma`):

- `int omp_get_num_threads()`; restituisce il numero di thread nel team (equivalente alla `size` di MPI nella regione parallela)
- `int omp_get_thread_num()`; la funzione restituisce l'id del thread chiamante (sotto forma di `int`) (equivalente del `rank` per i processi di MPI), per esempio: `myID=omp_get_thread_num()`; i thread sono identificati da un `id` che va da 0 (per il **Master**) a `N-1` (`N` =numero thread della regione parallela).
- `double omp_get_wtime()`; wall time, per esempio: `t1 = omp_get_wtime()`;
- `void omp_set_num_threads()`; definisce il numero di thread nei successivi costrutti paralleli (a meno che, nel frattempo, intervengano altre specificazioni sul numero di thread).
- `int omp_get_num_procs()`; trova il numero di CPU presente nella macchina
- `int omp_in_parallel()`, restituisce un valore intero che e' 0 se **non** siamo in una regione parallela **attiva**. Restituisce invece 1 se viene chiamato dall'interno di una regione parallela **attiva**.

Alcune routine (funzioni) a runtime di openMP

Alcune utili funzioni definite da *openMP* (queste **non** vanno messe dopo un `#pragma`):

- `int omp_get_num_threads();` restituisce il numero di thread nel team (equivalente alla **size** di MPI nella regione parallela)
- `int omp_get_thread_num();` la funzione restituisce l'**id** del thread chiamante (sotto forma di int) (equivalente del **rank** per i processi di MPI), per esempio: `mioID=omp_get_thread_num();`
I thread sono identificati da un **id** che va da 0 (per il **Master**) a N-1 (N =numero thread della regione parallela).
- `double omp_get_wtime();` **wall time**, per esempio: `t1 = omp_get_wtime();`
- `void omp_set_num_threads();` definisce il numero di thread nei successivi costrutti paralleli (a meno che, nel frattempo, intervengano altre specificazioni sul numero di thread).
- `int omp_get_num_procs();` trova il numero di CPU presente nella macchina
- `int omp_in_parallel(),` restituisce un valore intero che e' 0 se **non** siamo in una regione parallela **attiva**. Restituisce invece 1 se viene chiamato dall'interno di una regione parallela **attiva**.

Quanti thread?

Ci sono vari modi di definire il numero di thread in un blocco parallelo, per esempio:

```
omp_set_num_threads(4); // <= si definisce il numero prima del blocco
//.... altro codice
#pragma omp parallel
{
    int ID = omp_get_thread_num();
    printf("Io sono: %d", ID);
}
```

Oppure si puo' definire al momento della creazione della direttiva:

```
int vaiParallelo = 0;
#pragma omp parallel if (vaiParallelo == 1) num_threads( 8) shared (var_b) default ( none)
{ // per fare si che num_threads( 8) venga preso, meglio mettere vaiParallelo=1;
    int ID = omp_get_thread_num();
    printf("Io sono: %d", ID);
}
```

Il numero di thread e' determinato con la seguente gerarchia (1 = piu' importante ... 4 = meno importante) :

- 1 valutazione della clausola `if` con di seguito il valore all'interno della clausola `num_threads()`
- 2 Utilizzo della funzione `omp_set_num_threads()` (prima del blocco parallelo)
- 3 il valore della variabile d'ambiente `OMP_NUM_THREAD` (settata precedentemente)
- 4 default della implementazione (numero di core di un nodo)

Come comunicano i thread? Data sharing

Quando c'è una sessione parallela bisogna definire come vengono gestite le risorse (le variabili, gli array...). In particolare è importante sapere **quale** thread ha accesso a **quale** risorsa, vediamo alcune **clauseole**:

- `private (i)` **ogni** thread ha la propria versione privata della variabile `i`, indipendente da tutte le altre copie (la variabile `i` non dà luogo a race condition). La variabile è **inizializzata** secondo l'inizializzazione standard (come nel main). **Domanda**: può essere un puntatore? Certo! ma questo significa che sarà generato un nuovo puntatore per ognuno dei thread che andrà quindi inizializzato correttamente.
- `shared (v,u)` indica che **tutti i thread** della regione parallela accedono agli stessi oggetti `v` e `u` (**Attenzione** può causare race condition!). Gli oggetti sono condivisi con il resto del codice.
- `firstprivate (i)` è identico a `private` ma il valore di `i` è inizializzato con l'ultimo valore posseduto prima del costrutto parallelo (ergo del master thread).
- `default (shared)` significa che le variabili esterne diventano `shared` nel costrutto parallelo (è il default per un costrutto parallelo).
- `default (private)` indica che tutte le variabili, array sono `private` all'interno del costrutto
- Esiste anche `default (none)`: richiede di specificare per ogni variabile il suo attributo di data sharing: è una buona pratica di programmazione!
- `lastprivate (j)` all'uscita dalla regione parallela (JOIN) la variabile viene aggiornata per il master thread (che continua ad esistere) con l'ultimo valore della regione parallela (spiegata più approfonditamente nel seguito).

Come comunicano i thread? Data sharing

Quando c'è una sessione parallela bisogna definire come vengono gestite le risorse (le variabili, gli array...). In particolare è importante sapere **quale** thread ha accesso a **quale** risorsa, vediamo alcune **clausole**:

- `private (i)` ogni thread ha la propria versione privata della variabile `i`, indipendente da tutte le altre copie (la variabile `i` non dà luogo a race condition). La variabile è inizializzata secondo l'inizializzazione standard (come nel main). **Domanda:** può essere un puntatore? Certo! ma questo significa che sarà generato un nuovo puntatore per ognuno dei thread che andrà quindi inizializzato correttamente.
- `shared (v,u)` indica che **tutti i thread** della regione parallela accedono agli stessi oggetti `v` e `u` (**Attenzione** può causare race condition!). Gli oggetti sono condivisi con il resto del codice.
- `firstprivate (i)` è identico a `private` ma il valore di `i` è inizializzato con l'ultimo valore posseduto prima del costrutto parallelo (ergo del master thread).
- `default (shared)` significa che le variabili esterne diventano `shared` nel costrutto parallelo (è il default per un costrutto parallelo).
- `default (private)` indica che tutte le variabili, array sono `private` all'interno del costrutto
- Esiste anche `default (none)`: richiede di specificare per ogni variabile il suo attributo di data sharing: è una buona pratica di programmazione!
- `lastprivate (j)` all'uscita dalla regione parallela (JOIN) la variabile viene aggiornata per il master thread (che continua ad esistere) con l'ultimo valore della regione parallela (spiegata più approfonditamente nel seguito).

Come comunicano i thread? Data sharing

Quando c'è una sessione parallela bisogna definire come vengono gestite le risorse (le variabili, gli array...). In particolare è importante sapere **quale** thread ha accesso a **quale** risorsa, vediamo alcune **clauseole**:

- `private (i)` ogni thread ha la propria versione privata della variabile `i`, indipendente da tutte le altre copie (la variabile `i` non dà luogo a race condition). La variabile è **inizializzata** secondo l'inizializzazione standard (come nel main). **Domanda**: può essere un puntatore? Certo! ma questo significa che sarà generato un nuovo puntatore per ognuno dei thread che andrà quindi **inizializzato** correttamente.
- `shared (v,u)` indica che **tutti i thread** della regione parallela accedono agli stessi oggetti `v` e `u` (**Attenzione** può causare race condition!). Gli oggetti sono **condivisi** con il resto del codice.
- `firstprivate (i)` è identico a `private` ma il valore di `i` è **inizializzato** con l'ultimo valore posseduto prima del costrutto parallelo (ergo del master thread).
- `default (shared)` significa che le variabili esterne diventano `shared` nel costrutto parallelo (è il default per un costrutto parallelo).
- `default (private)` indica che tutte le variabili, array sono `private` all'interno del costrutto
- Esiste anche `default (none)`: richiede di specificare per ogni variabile il suo attributo di data sharing: è una buona **pratica** di programmazione!
- `lastprivate (j)` all'uscita dalla regione parallela (JOIN) la variabile viene aggiornata per il master thread (che continua ad esistere) con l'ultimo valore della regione parallela (spiegata più approfonditamente nel seguito).

Come comunicano i thread? Data sharing

Quando c'è una sessione parallela bisogna definire come vengono gestite le risorse (le variabili, gli array...). In particolare è importante sapere **quale** thread ha accesso a **quale** risorsa, vediamo alcune **clauseole**:

- `private (i)` ogni thread ha la propria versione privata della variabile `i`, indipendente da tutte le altre copie (la variabile `i` non dà luogo a race condition). La variabile è inizializzata secondo l'inizializzazione standard (come nel main). **Domanda:** può essere un puntatore? Certo! ma questo significa che sarà generato un nuovo puntatore per ognuno dei thread che andrà quindi inizializzato correttamente.
- `shared (v,u)` indica che **tutti i thread** della regione parallela accedono agli stessi oggetti `v` e `u` (**Attenzione** può causare race condition!). Gli oggetti sono condivisi con il resto del codice.
- `firstprivate (i)` è identico a `private` ma il valore di `i` è inizializzato con l'ultimo valore posseduto prima del costrutto parallelo (ergo del master thread).
- `default (shared)` significa che le variabili esterne diventano `shared` nel costrutto parallelo (è il default per un costrutto parallelo).
- `default (private)` indica che tutte le variabili, array sono `private` all'interno del costrutto
- Esiste anche `default (none)`: richiede di specificare per ogni variabile il suo attributo di data sharing: è una **buona pratica** di programmazione!
- `lastprivate (j)` all'uscita dalla regione parallela (JOIN) la variabile viene aggiornata per il master thread (che continua ad esistere) con l'ultimo valore della regione parallela (spiegata più approfonditamente nel seguito).

Come comunicano i thread? Data sharing

Quando c'è una sessione parallela bisogna definire come vengono gestite le risorse (le variabili, gli array...). In particolare è importante sapere **quale** thread ha accesso a **quale** risorsa, vediamo alcune **clausole**:

- `private (i)` ogni thread ha la propria versione privata della variabile `i`, indipendente da tutte le altre copie (la variabile `i` non dà luogo a race condition). La variabile è inizializzata secondo l'inizializzazione standard (come nel main). **Domanda:** può essere un puntatore? Certo! ma questo significa che sarà generato un nuovo puntatore per ognuno dei thread che andrà quindi inizializzato correttamente.
- `shared (v,u)` indica che **tutti i thread** della regione parallela accedono agli stessi oggetti `v` e `u` (**Attenzione** può causare race condition!). Gli oggetti sono condivisi con il resto del codice.
- `firstprivate (i)` è identico a `private` ma il valore di `i` è inizializzato con l'ultimo valore posseduto prima del costrutto parallelo (ergo del master thread).
- `default (shared)` significa che le variabili esterne diventano `shared` nel costrutto parallelo (è il default per un costrutto parallelo).
- **default (private)** indica che **tutte le variabili, array sono private** all'interno del costrutto
- Esiste anche `default (none)`: richiede di specificare per ogni variabile il suo attributo di data sharing: è una **buona pratica** di programmazione!
- `lastprivate (j)` all'uscita dalla regione parallela (JOIN) la variabile viene aggiornata per il master thread (che continua ad esistere) con l'ultimo valore della regione parallela (spiegata più approfonditamente nel seguito).

Come comunicano i thread? Data sharing

Quando c'è una sessione parallela bisogna definire come vengono gestite le risorse (le variabili, gli array...). In particolare è importante sapere **quale** thread ha accesso a **quale** risorsa, vediamo alcune **clausole**:

- `private (i)` ogni thread ha la propria versione privata della variabile `i`, indipendente da tutte le altre copie (la variabile `i` non dà luogo a race condition). La variabile è inizializzata secondo l'inizializzazione standard (come nel `main`). **Domanda:** può essere un puntatore? Certo! ma questo significa che sarà generato un nuovo puntatore per ognuno dei thread che andrà quindi inizializzato correttamente.
- `shared (v,u)` indica che **tutti i thread** della regione parallela accedono agli stessi oggetti `v` e `u` (**Attenzione** può causare race condition!). Gli oggetti sono condivisi con il resto del codice.
- `firstprivate (i)` è identico a `private` ma il valore di `i` è inizializzato con l'ultimo valore posseduto prima del costrutto parallelo (ergo del master thread).
- `default (shared)` significa che le variabili esterne diventano `shared` nel costrutto parallelo (è il default per un costrutto parallelo).
- `default (private)` indica che tutte le variabili, array sono `private` all'interno del costrutto
- **Esiste anche `default (none)`: richiede di specificare per ogni variabile il suo attributo di data sharing: è una buona pratica di programmazione!**
- `lastprivate (j)` all'uscita dalla regione parallela (JOIN) la variabile viene aggiornata per il master thread (che continua ad esistere) con l'ultimo valore della regione parallela (spiegata più approfonditamente nel seguito).

Come comunicano i thread? Data sharing

Quando c'è una sessione parallela bisogna definire come vengono gestite le risorse (le variabili, gli array...). In particolare è importante sapere **quale** thread ha accesso a **quale** risorsa, vediamo alcune **clausole**:

- `private (i)` ogni thread ha la propria versione privata della variabile `i`, indipendente da tutte le altre copie (la variabile `i` non dà luogo a race condition). La variabile è inizializzata secondo l'inizializzazione standard (come nel main). **Domanda:** può essere un puntatore? Certo! ma questo significa che sarà generato un nuovo puntatore per ognuno dei thread che andrà quindi inizializzato correttamente.
- `shared (v,u)` indica che **tutti i thread** della regione parallela accedono agli stessi oggetti `v` e `u` (**Attenzione** può causare race condition!). Gli oggetti sono condivisi con il resto del codice.
- `firstprivate (i)` è identico a `private` ma il valore di `i` è inizializzato con l'ultimo valore posseduto prima del costrutto parallelo (ergo del master thread).
- `default (shared)` significa che le variabili esterne diventano `shared` nel costrutto parallelo (è il default per un costrutto parallelo).
- `default (private)` indica che tutte le variabili, array sono `private` all'interno del costrutto
- Esiste anche `default (none)`: richiede di specificare per ogni variabile il suo attributo di data sharing: è una **buona pratica** di programmazione!
- `lastprivate (j)` all'uscita dalla regione parallela (JOIN) la variabile viene aggiornata per il master thread (che continua ad esistere) con l'ultimo valore della regione parallela (spiegata più approfonditamente nel seguito).

Come comunicano i thread? Data sharing

Quando c'è una sessione parallela bisogna definire come vengono gestite le risorse (le variabili, gli array...). In particolare è importante sapere **quale** thread ha accesso a **quale** risorsa, vediamo alcune **clausole**:

- `private (i)` **ogni** thread ha la propria versione privata della variabile `i`, indipendente da tutte le altre copie (la variabile `i` non dà luogo a race condition). La variabile è **inizializzata** secondo l'inizializzazione standard (come nel main). **Domanda**: può essere un puntatore? Certo! ma questo significa che sarà generato un nuovo puntatore per ognuno dei thread che andrà quindi inizializzato correttamente.
- `shared (v,u)` indica che **tutti i thread** della regione parallela accedono agli stessi oggetti `v` e `u` (**Attenzione** può causare race condition!). Gli oggetti sono condivisi con il resto del codice.
- `firstprivate (i)` è identico a `private` ma il valore di `i` è inizializzato con l'ultimo valore posseduto prima del costrutto parallelo (ergo del master thread).
- `default (shared)` significa che le variabili esterne diventano `shared` nel costrutto parallelo (è il default per un costrutto parallelo).
- `default (private)` indica che tutte le variabili, array sono `private` all'interno del costrutto
- Esiste anche `default (none)`: richiede di specificare per ogni variabile il suo attributo di data sharing: è una **buona pratica** di programmazione!
- `lastprivate (j)` all'uscita dalla regione parallela (JOIN) la variabile viene aggiornata per il master thread (che continua ad esistere) con l'ultimo valore della regione parallela (spiegata più approfonditamente nel seguito).

E se non dico nulla?

Attenzione

- 1 Le variabili definite **prima** del costrutto `parallel` sono **automaticamente shared**
- 2 Le variabili definite all'**interno** del costrutto `parallel` sono **automaticamente private**

Attenzione

- costrutti differenti (p.es. `foreach`, `seq`, `task`) definiscono in modo diverso dal costrutto `parallel` quali sono le caratteristiche di **default** delle variabili all'interno della loro regione.

E se non dico nulla?

Attenzione

- 1 le variabili definite **prima** del costrutto `parallel` sono **automaticamente shared**
- 2 Le variabili definite all'**interno** del costrutto `parallel` sono **automaticamente private**

Attenzione

- costrutti differenti (p.es. `foreach`, `seq`, `task`) definiscono in modo diverso dal costrutto `parallel` quali sono le caratteristiche di **default** delle variabili all'interno della loro regione.

E se non dico nulla?

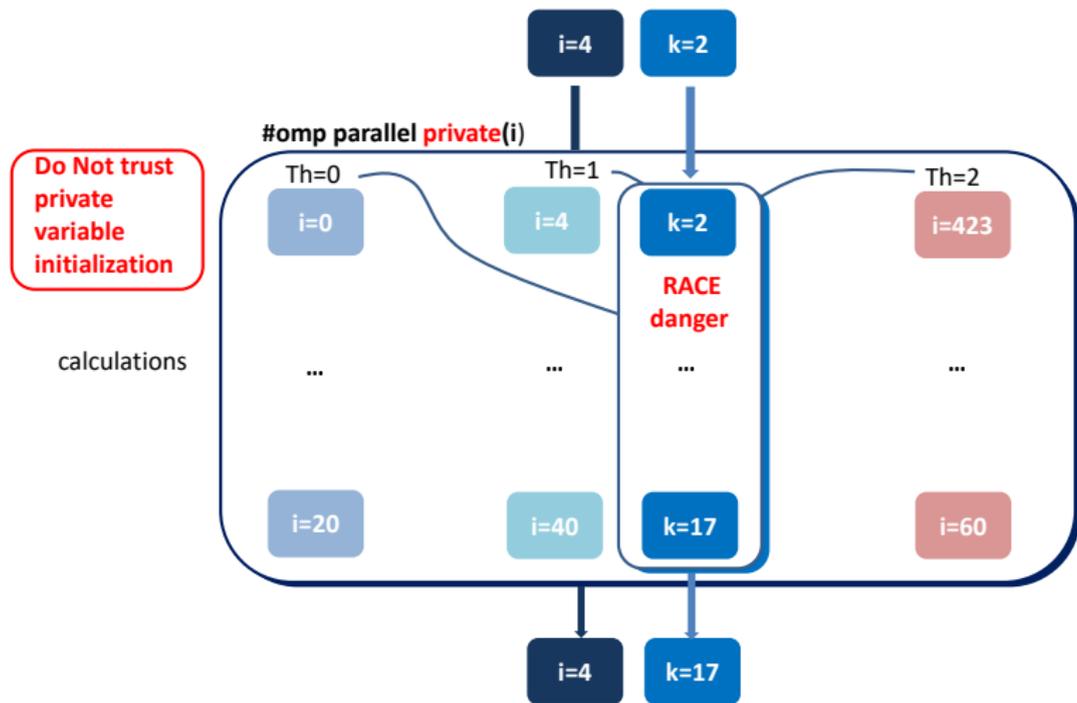
Attenzione

- 1 le variabili definite **prima** del costrutto `parallel` sono **automaticamente shared**
- 2 Le variabili definite all'**interno** del costrutto `parallel` sono **automaticamente private**

Attenzione

- costrutti differenti (p.es. `#pragma omp task`) definiscono in modo **diverso** dal costrutto `parallel` quali sono le caratteristiche di **default** delle variabili all'interno della loro regione.

Visualizziamo private e (default) shared



Esempio: shared e private di default

Cosa scrive a video il computer?

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

int main(){
    int a=5; // a viene definita PRIMA del costrutto parallel, nel costrutto parallelo e' shared
    #pragma omp parallel num_threads(3)
    {
        int id; // id e' definita dentro il costrutto e' PRIVATA di default
        id = omp_get_thread_num();
        printf("thread: %d, a=%d\n", id, a);
    }
}
```

```
thread: 0, a=5
thread: 2, a=5
thread: 1, a=5
```

Se invece avessi inserito:

```
#pragma omp parallel num_threads(3) private(a)
```

il risultato sarebbe stato:

```
thread: 1, a=0
thread: 2, a=0
thread: 0, a=0
```

Attenzione: nelle versioni piu' recenti di openMP le variabili private sono inizializzate automaticamente come lo sarebbero nel main. Nelle versioni piu' vecchie invece non sono inizializzate! Fidarsi dell'inizializzazione di una clausola private e' pericoloso!

esempio: firstprivate

Cosa scrive a video questo codice?

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

int main()
{
    int b=5;
    printf("Prima del costrutto parallelo b=%d\n", b);
    #pragma omp parallel num_threads(3) firstprivate(b)
    {
        int id;
        id = omp_get_thread_num();
        b = b+id;
        printf("thread: %d, b=%d\n", id, b);
    }
    printf("Dopo il costrutto parallelo b=%d\n", b);
}
```

Soluzione:

```
Prima del costrutto parallelo b=5
thread: 0, b=5
thread: 2, b=7
thread: 1, b=6
Dopo il costrutto parallelo b=5
```

problemi di default...

Trovare il problema:

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

int main() {
    int a=5;
    #pragma omp parallel num_threads(3) default(none)
    {
        printf("thread: %d, a=%d\n", omp_get_thread_num(), a);
    }
}
```

Soluzione:

- La variabile `a` e' dichiarata e definita prima della regione parallela.
- Se non ci fosse un `default(none)` nella regione parallela verrebbe trattata come `shared`.
- In questo caso invece la clausola `default(none)` crea problemi al compilatore: non sa come trattare `a`!
- Per risolvere il problema basta aggiungere una clausola tipo `shared(a)`, `private(a)` ... per esempio:

```
#pragma omp parallel num_threads(3) default(none) private(a)
```

- l'uso di `default(none)` e' una **buona pratica** di programmazione, perche' ci **obbliga** a dichiarare esplicitamente il possesso delle variabili

Cominciamo Bene...

Un esempio di codice volenteroso ma problematico:

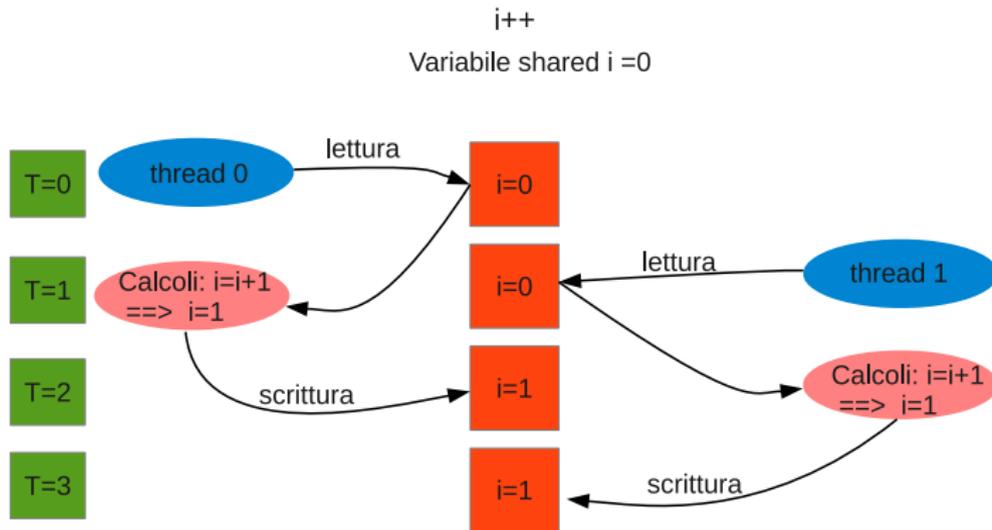
```
#include<omp.h>
#include<stdio.h>
int main()
{
    int i=0,j=0, imax=10, tanto=1000000;
    omp_set_num_threads(imax);
    #pragma omp parallel private (j)
    {
        for (j=0;j<tanto; j++) // questo serve per aumentare i problemi...
            i = i +1;
    }
    printf("teorica= %d, somma con i thread= %d \n", imax*tanto, i);
}
```

Sto utilizzando i thread, ma come?

Problemi

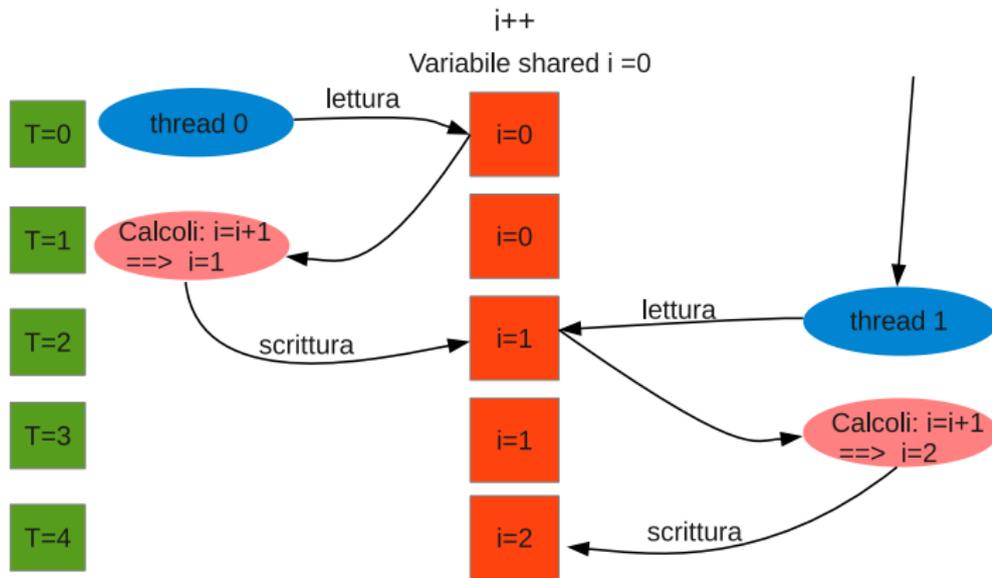
- Tutti i thread cercano di aggiornare la variabile *i*.
- la variabile *i* e' condivisa da tutti i thread: l'aggiornamento genera una **race condition**
- **Attenzione:** di solito la race condition **non sussiste** ... se eseguo in locale con una sola cpu, dato che in questo modo i thread vengono simulati e quindi eseguono uno dopo l'altro! Il ciclo su *j* e' stato messo apposta per aumentare la probabilita' che succeda.
- **Occhio:** un codice che funziona perfettamente su una macchina virtuale potrebbe essere completamente bacato!

visualizziamo una Race Condition (datarace)



Alla fine il valore della variabile i viene aggiornato dal thread 1, che **NON** tiene conto dei nuovi calcoli fatti dal thread 0.

visualizziamo una Race Condition 2



Fortunatamente, questa volta il thread 1 legge la variabile i **DOPO** che il thread 0 ha aggiornato il valore. Il risultato dipende da quando i thread accedono alla variabile

Un primo esercizio (con sincronizzazione manuale)

- **Problema:** prendere tutti i numeri da 1 a N e **sommarli** usando una ragione parallela.
- si definisca il numero di thread tramite il comando `omp_set_num_threads()`
- si ottenga l'id del singolo thread tramite `omp_get_thread_num()`
- il blocco parallelo necessita di `#pragma omp parallel`
- La somma e' **associativa**, ogni thread ne eseguirà un pezzo e metterà il risultato in un ingresso di un array condiviso (`shared`), chiamato `arr_sum`. Questo array deve poter avere tanti ingressi quanti sono i thread della regione parallela
- **Dopo** la regione parallela, il master thread fa la somma dei vari ingressi dell'array.

Un primo esercizio (lo scheletro del codice)

Sommiamo i primi numeri da 1 a N. Usare `omp_set_num_threads()` per decidere il numero dei thread, `omp_get_thread_num()` per conoscere il proprio id, e `#pragma omp parallel` per iniziare il blocco. La parte “difficile” è: suddividere il compito tra i thread correttamente!

```
#include<omp.h> // una somma inutilmente difficile dei numeri da 1 a N
#include<stdio.h>
static long N = 1000; // numero di punti da sommare
void main ()
{
  int i, sum=0;
  int numThreads = N / 10; // numero di thread usato
  //***** diciamo qui ad openMP che vogliamo numThreads
  int arr_sum[numThreads]; // array con somme parziali
  //***** facciamo partire il blocco parallelo
  {
    int par , arr; // partenza e arrivo
    //***** chiediamo a openMP l'id del chiamante, chiamiamolo "me"
    //***** calcoliamo quanti punti sono calcolati da ogni thread
    int local_sum=0 // azzeriamo la somma locale da calcolare
    //***** calcoliamo il punto di partenza della somma (funzione dell'id)
    //***** calcoliamo il punto di arrivo della somma (funzione dell'id)
    for (i= par; i< arr; i++){
      local_sum = local_sum + i; // somma dei valori da "par" a "arr"
    }
    //***** mettiamo la somma locale in un array globale
  }
  for (i=0;i<numThreads; i++) {sum += arr_sum[i];}
  printf("Somma= %d, teorica %d\n", sum, N*(N+1)/2);
}
```

Un primo esercizio: soluzione

Sommiamo i primi numeri da 1 a N. Usare `omp_set_num_threads()` per decidere il numero dei thread, `omp_get_thread_num()` per conoscere il proprio id, e `#pragma omp parallel` per iniziare il blocco. La parte “difficile” è: suddividere il compito tra i thread correttamente!

```
#include<omp.h> // una somma inutilmente difficile dei numeri da 1 a N
#include<stdio.h>
static long N = 1000; // numero di punti da sommare
void main ()
{
  int i, sum=0;
  int numThreads = N / 10; // numero di thread usato
  omp_set_num_threads(numThreads); // def num thread
  int arr_sum[numThreads]; // array con somme parziali
  #pragma omp parallel private(i)
  {
    int par , arr; // partenza e arrivo
    int me = omp_get_thread_num(); // numero identificativo del thread
    int stxt = N / numThreads; // punti calcolati da ogni thread
    int local_sum=0;
    par = me * stxt+1; // indice di partenza
    arr = par + stxt; // indice di arrivo
    for (i= par; i< arr; i++){
      local_sum = local_sum + i; // somma dei valori da "par" a "arr"
    }
    arr_sum[me] = local_sum; // array locale
  }
  for (i=0;i<numThreads; i++) {sum += arr_sum[i];}
  printf("Somma= %d, teorica %d\n", sum, N*(N+1)/2);
}
```

Un primo esercizio: false sharing

Nell'esercizio precedente possono esservi problemi di cosiddetto: **false sharing**

- Supponiamo che il codice giri su un sistema con **cache coherence** tra i vari core, ognuno dei quali ha una propria **cache**
- Se il codice e' stato scritto a dovere, i vari thread "riempiono" indici diversi dello stesso array
- l'array, con buona probabilita', sara' su una singola **cache line** quindi il computer dovra' riscrivere la cache per tutti i thread ogni volta che un ingresso dell'array viene aggiornato (passando per la memoria)!

Un primo esercizio: false sharing

Nell'esercizio precedente possono esservi problemi di cosiddetto: **false sharing**

- Supponiamo che il codice giri su un sistema con **cache coherence** tra i vari core, ognuno dei quali ha una propria **cache**
- Se il codice e' stato scritto a dovere, i vari thread "riempiono" indici diversi dello stesso array
- l'array, con buona probabilita', sara' su una singola **cache line** quindi il computer dovra' riscrivere la cache per tutti i thread ogni volta che un ingresso dell'array viene aggiornato (passando per la memoria)!

Un primo esercizio: false sharing

Nell'esercizio precedente possono esservi problemi di cosiddetto: **false sharing**

- Supponiamo che il codice giri su un sistema con **cache coherence** tra i vari core, ognuno dei quali ha una propria **cache**
- Se il codice e' stato scritto a dovere, i vari thread "riempiono" indici diversi dello stesso array
- l'array, con buona probabilita', sara' su una singola **cache line** quindi il computer dovra' riscrivere la cache per tutti i thread ogni volta che un ingresso dell'array viene aggiornato (passando per la memoria)!

Un primo esercizio: false sharing

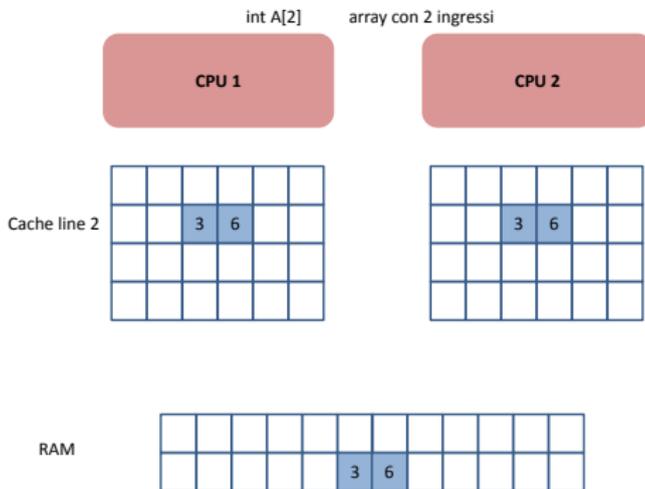
Nell'esercizio precedente possono esservi problemi di cosiddetto: **false sharing**

- Supponiamo che il codice giri su un sistema con **cache coherence** tra i vari core, ognuno dei quali ha una propria **cache**
- Se il codice e' stato scritto a dovere, i vari thread "riempiono" indici diversi dello stesso array
- l'array, con buona probabilita', sara' su una singola **cache line** quindi il computer dovra' riscrivere la cache per tutti i thread ogni volta che un ingresso dell'array viene aggiornato (passando per la memoria)!

Un primo esercizio: false sharing

Nell'esercizio precedente possono esservi problemi di cosiddetto: **false sharing**

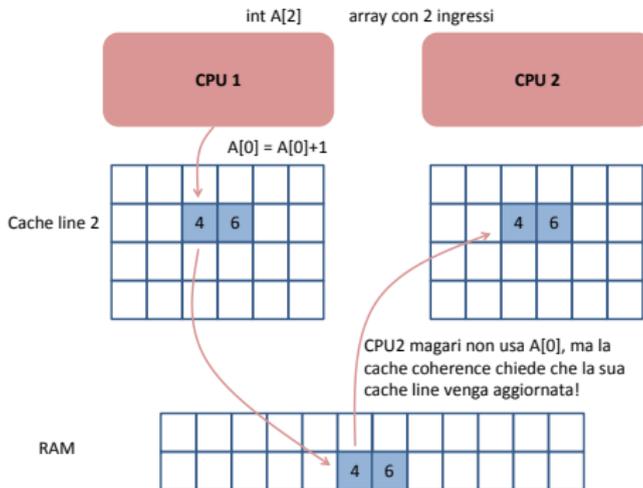
- Supponiamo che il codice giri su un sistema con **cache coherence** tra i vari core, ognuno dei quali ha una propria **cache**
- Se il codice e' stato scritto a dovere, i vari thread "riempiono" indici diversi dello stesso array
- l'array, con buona probabilita', sara' su una singola **cache line** quindi il computer dovra' riscrivere la cache per tutti i thread ogni volta che un ingresso dell'array viene aggiornato (passando per la memoria)!



Un primo esercizio: false sharing

Nell'esercizio precedente possono esservi problemi di cosiddetto: **false sharing**

- Supponiamo che il codice giri su un sistema con **cache coherence** tra i vari core, ognuno dei quali ha una propria **cache**
- Se il codice e' stato scritto a dovere, i vari thread "riempiono" indici diversi dello stesso array
- l'array, con buona probabilita', sara' su una singola **cache line** quindi il computer dovra' riscrivere la cache per tutti i thread ogni volta che un ingresso dell'array viene aggiornato (passando per la memoria)!



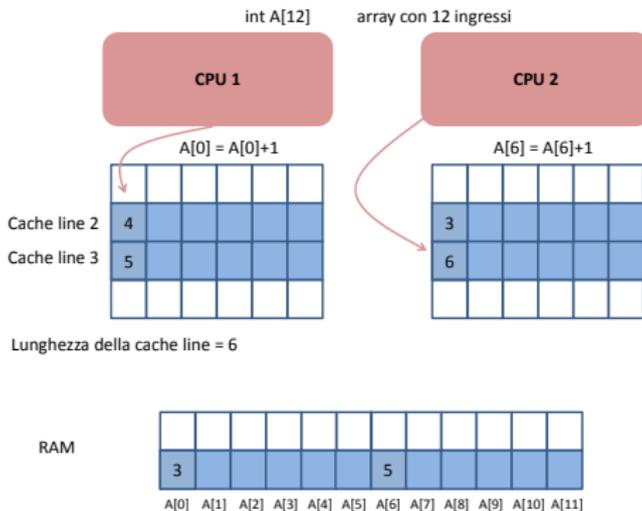
Come evitare il false sharing?

Nella diapositiva precedente abbiamo visto un caso in cui:

- due core accedono e modificano un solo array.
- Il primo core lavora solo con il primo ingresso dell'array
- il secondo core lavora solo con il secondo ingresso dell'array

Per questo motivo se non si sta attenti ci si aspetta che non si "calpestino i piedi"! sfortunatamente il sistema ha la proprietà di **cache coherence**, e quindi non appena uno dei due core scrive su una cache line e l'altro deve accedere alla stessa cache line, il sistema deve aggiornare la cache del secondo core, rallentando il processo.

Consiglio Per evitare questo potrebbe essere possibile scegliere di creare un array piu' grande, in modo che i due ingressi su cui lavorano i due core, appartengano a due cache line differenti!



Nel caso in cui sia necessario che tutti i thread abbiano **finito di eseguire** il proprio compito prima di continuare l'esecuzione si mette una barriera:

```
#pragma omp barrier
```

- **Attenzione:** alla fine di una regione `parallel`, c'è **una barriera implicita**, quindi non serve metterne un'altra!
- **Attenzione:** alla fine di altri costrutti di OpenMP, potrebbe **NON** esserci **una barriera implicita**, bisogna quindi controllare sempre lo standard!
- **Attenzione:** e' come una **collective** di MPI, se anche uno solo dei thread della regione parallela non chiama questo pragmatic statement si ottiene un bel **DEADLOCK!**

Alcuni costrutti di sincronizzazione: *critical*

```
#pragma omp critical
```

specifica che nel blocco che la segue puo' entrare solo **un thread** alla volta.

- **rallenta** il sistema (serializza il lavoro dei thread)
 - ci sono degli **overhead** dovuti al fatto di fare entrare e uscire un singolo thread, per esempio l'addizione diventa circa 200 volte piu' lenta rispetto alla controparte senza *critical*.
 - aiuta ad evitare le **datarace/race condition**
 - Non ci sono **barriere** ne' in **ingresso** ne' in **uscita**.
 - Tutti i thread entrano nella *critical*
 - se ci sono piu' *critical* senza nome (*unnamed*), quando un thread entra in uno di questi blocchi, li chiude tutti a chiave (nessun processo puo' entrare negli altri blocchi!), questo puo' essere superato se si danno i nomi alle sessioni
 - si puo' dare un nome alla sessione *critical*, per esempio:

```
#pragma omp critical (PrimaSessione)
```

Una *critical unnamed* e' mutualmente esclusiva (**mutex**) rispetto a tutte le *unnamed*
Una *critical con nome* e' mutualmente esclusiva rispetto a tutte le *critical con lo stesso nome*

Alcuni costrutti di sincronizzazione: *critical*

```
#pragma omp critical
```

specifica che nel blocco che la segue puo' entrare solo **un thread** alla volta.

- rallenta il sistema (serializza il lavoro dei thread)
- ci sono degli **overhead** dovuti al fatto di fare entrare e uscire un singolo thread, per esempio l'addizione diventa circa 200 volte piu' lenta rispetto alla controparte senza `critical`.
- aiuta ad evitare le `datarace/race condition`
- Non ci sono **barriere** ne' in **ingresso** ne' in **uscita**.
- Tutti i thread entrano nella `critical`
- se ci sono piu' `critical` senza nome (`unnamed`), quando un thread entra in uno di questi blocchi, li chiude tutti a chiave (nessun processo puo' entrare negli altri blocchi!), questo puo' essere superato se si danno i nomi alle sessioni
- si puo' dare un nome alla sessione `critical`, per esempio:

```
#pragma omp critical (PrimaSessione)
```

Una `critical unnamed` e' mutualmente esclusiva (`mutex`) rispetto a tutte le `unnamed`
Una `critical` con nome e' mutualmente esclusiva rispetto a tutte le `critical` con lo stesso nome

Alcuni costrutti di sincronizzazione: *critical*

```
#pragma omp critical
```

specifica che nel blocco che la segue puo' entrare solo **un thread** alla volta.

- rallenta il sistema (serializza il lavoro dei thread)
- ci sono degli **overhead** dovuti al fatto di fare entrare e uscire un singolo thread, per esempio l'addizione diventa circa 200 volte piu' lenta rispetto alla controparte senza *critical*.
- aiuta ad evitare le **datarace/race condition**
- Non ci sono **barriere** ne' in **ingresso** ne' in **uscita**.
- **Tutti** i thread entrano nella *critical*
- se ci sono piu' *critical* senza nome (*unnamed*), quando un thread entra in uno di questi blocchi, li chiude tutti a chiave (nessun processo puo' entrare negli altri blocchi!), questo puo' essere superato se si danno i nomi alle sessioni
- si puo' dare un nome alla sessione *critical*, per esempio:

```
#pragma omp critical (PrimaSessione)
```

Una *critical unnamed* e' mutualmente esclusiva (**mutex**) rispetto a tutte le *unnamed*
Una *critical con nome* e' mutualmente esclusiva rispetto a tutte le *critical con lo stesso nome*

Alcuni costrutti di sincronizzazione: *critical*

```
#pragma omp critical
```

specifica che nel blocco che la segue puo' entrare solo **un thread** alla volta.

- *rallenta* il sistema (serializza il lavoro dei thread)
- ci sono degli *overhead* dovuti al fatto di fare entrare e uscire un singolo thread, per esempio l'addizione diventa circa 200 volte piu' lenta rispetto alla controparte senza *critical*.
- aiuta ad evitare le *datarace/race condition*
- **Non** ci sono *barriere* ne' in *ingresso* ne' in *uscita*.
- **Tutti** i thread entrano nella *critical*
- se ci sono piu' *critical* senza nome (*unnamed*), quando un thread entra in uno di questi blocchi, li chiude tutti a *chiave* (nessun processo puo' entrare negli altri blocchi!), questo puo' essere superato se si danno i nomi alle sessioni
- si puo' dare un nome alla sessione *critical*, per esempio:

```
#pragma omp critical (PrimaSessione)
```

Una *critical unnamed* e' mutualmente esclusiva (*mutex*) rispetto a tutte le *unnamed*
Una *critical con nome* e' mutualmente esclusiva rispetto a tutte le *critical con lo stesso nome*

Alcuni costrutti di sincronizzazione: *critical*

```
#pragma omp critical
```

specifica che nel blocco che la segue puo' entrare solo **un thread** alla volta.

- **rallenta** il sistema (serializza il lavoro dei thread)
- ci sono degli **overhead** dovuti al fatto di fare entrare e uscire un singolo thread, per esempio l'addizione diventa circa 200 volte piu' lenta rispetto alla controparte senza **critical**.
- aiuta ad evitare le **datarace/race condition**
- Non ci sono **barriere** ne' in **ingresso** ne' in **uscita**.
- **Tutti i thread entrano nella *critical***
- se ci sono piu' **critical** senza nome (**unnamed**), quando un thread entra in uno di questi blocchi, li chiude tutti **a chiave** (nessun processo puo' entrare negli altri blocchi!), questo puo' essere superato se si danno i nomi alle sessioni
- si puo' dare un nome alla sessione **critical**, per esempio:

```
#pragma omp critical (PrimaSessione)
```

Una **critical unnamed** e' mutualmente esclusiva (**mutex**) rispetto a tutte le **unnamed**
Una **critical con nome** e' mutualmente esclusiva rispetto a tutte le **critical con lo stesso nome**

Alcuni costrutti di sincronizzazione: *critical*

```
#pragma omp critical
```

specifica che nel blocco che la segue puo' entrare solo **un thread** alla volta.

- **rallenta** il sistema (serializza il lavoro dei thread)
- ci sono degli **overhead** dovuti al fatto di fare entrare e uscire un singolo thread, per esempio l'addizione diventa circa 200 volte piu' lenta rispetto alla controparte senza **critical**.
- aiuta ad evitare le **data/race condition**
- **Non** ci sono **barriere** ne' in **ingresso** ne' in **uscita**.
- **Tutti** i thread entrano nella **critical**
- se ci sono piu' **critical** senza nome (**unnamed**), quando un thread entra in uno di questi blocchi, li chiude tutti **a chiave** (nessun processo puo' entrare negli altri blocchi!), questo puo' essere superato se si danno i nomi alle sessioni
- si puo' dare un nome alla sessione **critical**, per esempio:

```
#pragma omp critical (PrimaSessione)
```

Una **critical** **unnamed** e' mutualmente esclusiva (**mutex**) rispetto a tutte le **unnamed**
Una **critical** con **nome** e' mutualmente esclusiva rispetto a tutte le **critical** con lo stesso nome

Alcuni costrutti di sincronizzazione: *critical*

```
#pragma omp critical
```

specifica che nel blocco che la segue puo' entrare solo **un thread** alla volta.

- **rallenta** il sistema (serializza il lavoro dei thread)
- ci sono degli **overhead** dovuti al fatto di fare entrare e uscire un singolo thread, per esempio l'addizione diventa circa 200 volte piu' lenta rispetto alla controparte senza **critical**.
- aiuta ad evitare le **datarace/race condition**
- Non ci sono **barriere** ne' in **ingresso** ne' in **uscita**.
- **Tutti** i thread entrano nella **critical**
- se ci sono piu' **critical** senza nome (**unnamed**), quando un thread entra in uno di questi blocchi, li chiude tutti a **chiave** (nessun processo puo' entrare negli altri blocchi!), questo puo' essere superato se si danno i nomi alle sessioni
- si puo' dare un nome alla sessione **critical**, per esempio:

```
#pragma omp critical (PrimaSessione)
```

Una **critical** **unnamed** e' mutualmente esclusiva (**mutex**) rispetto a tutte le **unnamed**

Una **critical** con **nome** e' mutualmente esclusiva rispetto a tutte le **critical** con lo stesso nome

Alcuni costrutti di sincronizzazione: *critical*

```
#pragma omp critical
```

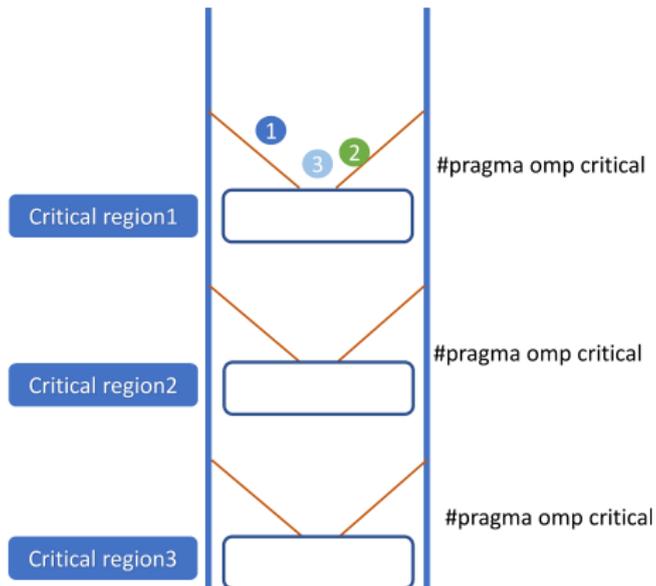
specifica che nel blocco che la segue puo' entrare solo **un thread** alla volta.

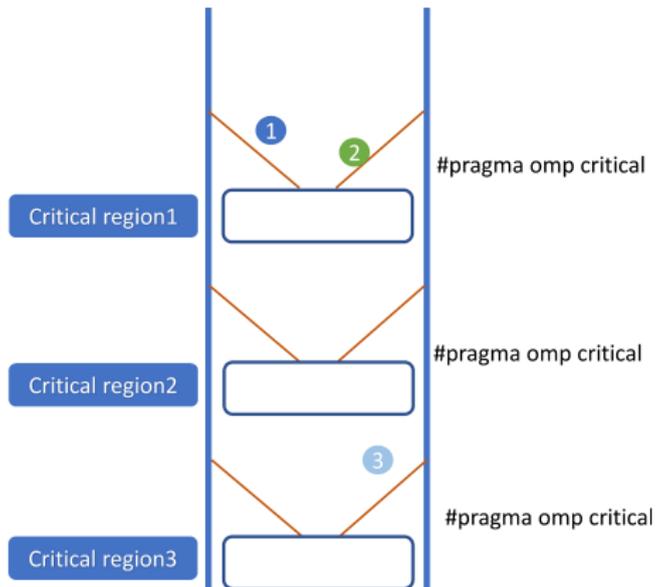
- **rallenta** il sistema (serializza il lavoro dei thread)
- ci sono degli **overhead** dovuti al fatto di fare entrare e uscire un singolo thread, per esempio l'addizione diventa circa 200 volte piu' lenta rispetto alla controparte senza `critical`.
- aiuta ad evitare le **datarace/race condition**
- **Non** ci sono **barriere** ne' in **ingresso** ne' in **uscita**.
- **Tutti** i thread entrano nella `critical`
- se ci sono piu' `critical` senza nome (`unnamed`), quando un thread entra in uno di questi blocchi, li chiude tutti **a chiave** (nessun processo puo' entrare negli altri blocchi!), questo puo' essere superato se si danno i nomi alle sessioni
- si puo' dare un nome alla sessione `critical`, per esempio:

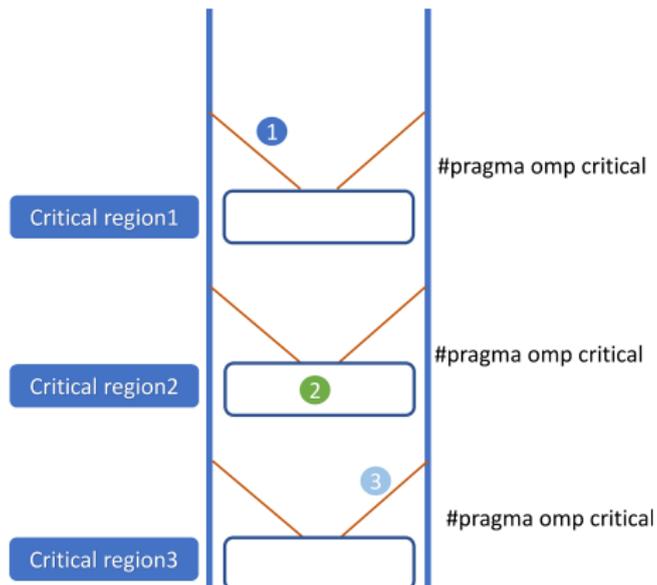
```
#pragma omp critical (PrimaSessione)
```

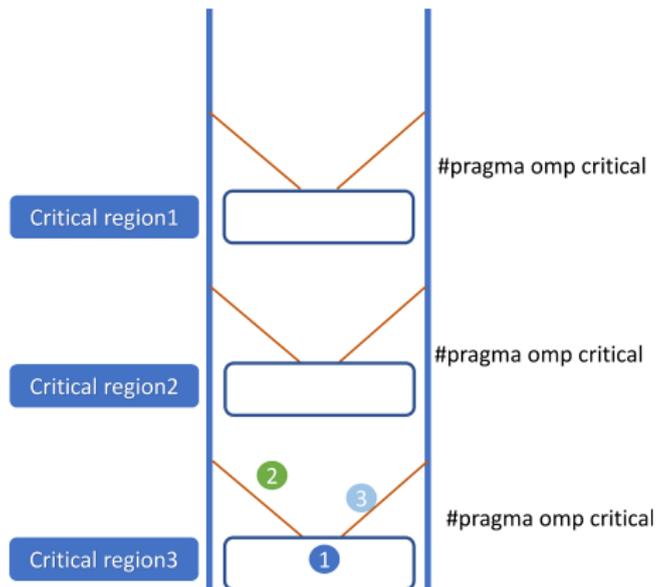
Una `critical` **unnamed** e' mutualmente esclusiva (**mutex**) rispetto a tutte le **unnamed**

Una `critical` con **nome** e' mutualmente esclusiva rispetto a tutte le `critical` **con lo stesso nome**









Esempio critical

```
#include"omp.h"  
#include<stdio.h>  
#include <unistd.h>  
int main(){  
    int id;  
    #pragma omp parallel private(id) num_threads(2)  
    {  
        id = omp_get_thread_num();  
        #pragma omp critical // prima critical =====  
        {  
            printf("A\n");  
        }  
  
        #pragma omp critical // seconda critical =====  
        {  
            printf("B\n");  
        }  
  
        printf("C\n");           // non e' in nessuna critical -----  
    }  
    printf("\n");  
}
```

- La sequenze **ABCABC** puo' apparire, perche'?
- La sequenza **AABBCC** puo' apparire, perche'?
- La sequenza **ACBABC** puo' apparire, perche'?

altri costrutti di sincronizzazione: *atomic*

`#pragma omp atomic` permette di fare aggiornare **una variabile** ad un thread alla volta.

- c'e' (molto) meno **overhead** rispetto alle **critical**
- assicura la serializzazione di una **singola** operazione. In pratica il primo thread che arriva, e trova una operazione su una variabile, dice a tutti gli altri: adesso io ho il controllo della variabile!
- l'addizione **atomic** e' circa 25 volte piu' lenta rispetto ad una addizione normale
- le funzioni che si possono usare sono: `+`, `*`, `-`, `/`, `&`, `'|'`, `<<`, `>>` (occhio che una scrittura tipo `i=i+miafunc()` e' valida, in quanto all'oggetto di cui vogliamo fare l'update ho fatto solo una somma)

Esercizio: Scrivere un codice che aggiorna la variabile `conto` per ogni thread in modo da avere il numero totale di thread della regione parallela:

```
#include <stdio.h>
#include <omp.h>
int main() {
    int conto = 0;
    #pragma omp parallel num_threads(10)
    {
        #pragma omp atomic
        conto++;
    }
    printf("Numero di thread: %d\n", conto);
}
```

Attenzione: Che differenza c'e' tra **Atomic** e **Critical**?

Atomic protegge una **variabile**, mentre **critical** protegge una parte di codice

Altri costrutti di sincronizzazione: *master, single e ordered*

`#pragma omp master` fa eseguire il blocco di seguito solo al master thread.

- gli altri thread saltano il costrutto `master`
- **NON** c'è nessuna barriera implicita né ingresso né in uscita (quindi gli altri thread semplicemente ignorano il costrutto!)
- la mancanza di barriere è **pericolosa**

Il costrutto `single` assomiglia al `master`, ma:

- non è eseguito dal master, qualunque (**singolo**) thread potrebbe essere l'esecutore
- esiste una **barriera** implicita in uscita (tutti i thread attendono che il costrutto `single` venga eseguito prima di continuare)

La clausola `nowait` elimina la **barriera**:

```
#include <omp.h>
#pragma omp parallel {
    #pragma omp single nowait    // il nowait elimina la barriera
    {
        printf("Starting calculation\n"); // solo uno scrive, ma tutti lo aspettano
    }

    // continua a lavorare
}
```

La clausola `ordered` fa eseguire in ordine i vari thread come se fossero in un loop seriale (in qualche modo sospende il costrutto parallelo). Altrimenti se ci fosse una parte che va eseguita in serie dovrei de facto chiudere tutto il costrutto parallelo e perdere le informazioni private di ogni thread.

anche in **openMP** e' possibile definire delle operazioni di **riduzione** con la seguente sintassi:

```
#pragma omp reduction(operazione:nomevariabile)
```

- **nomevariabile** e' dove viene messo il **risultato** della riduzione. E' una variabile **shared** tra tutti i thread. Se non si specifica che c'e' una riduzione questo darebbe luogo ad una **race condition**: tutti i thread cercano di agire sulla variabile **nomevariabile** "contemporaneamente". La direttiva di riduzione "crea una copia" **privata** per ogni thread della variabile da ridurre e gestisce la riduzione stessa! (e' un po' controintuitivo... ho una variabile **shared** gestita come una **private**!)
- dove le operazioni subito disponibili sono: +, -, *, &, |, &&, ||
- Per esempio, potrebbe essere la variabile per la somma di tutti gli elementi, **Non** e' l'array da sommare!
- OpenMP si aspetta che venga proprio scritta una riga in cui si esplicita l'operazione da eseguire (subito sotto la il pragmatic statement della riduzione), per esempio: `somma = somma+4;`
- **Attenzione** si possono definire opportunamente delle funzioni da usare nella riduzione (noi non lo faremo). Una funzione di riduzione deve poter prendere 2 valori e restituirne 1, e deve godere della proprieta' associativa (vedi diapositiva successiva).

Reduce: esempio di implementazione

tot=5

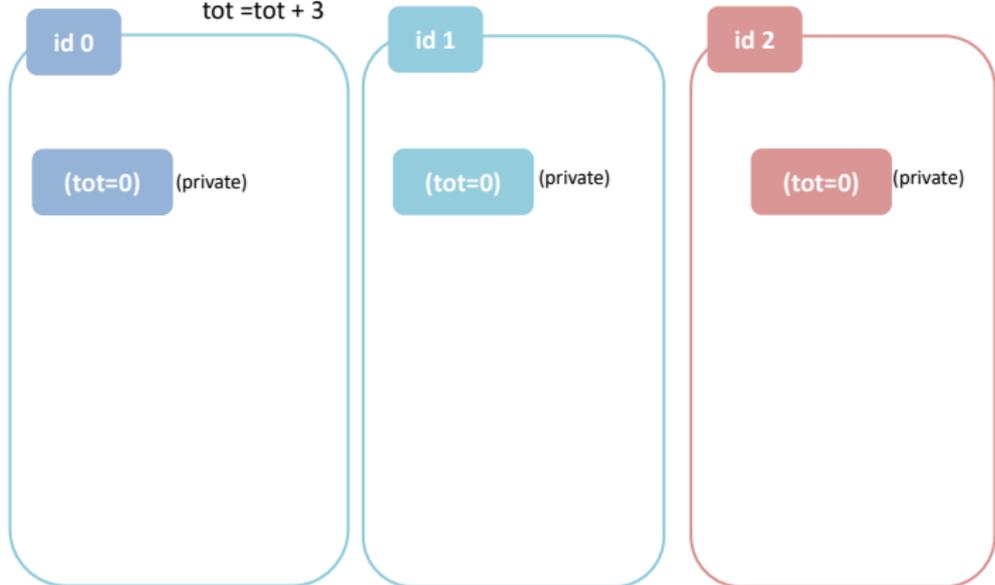
(implicit shared)

```
#omp parallel num_threads(3) reduce(+, tot)
  tot =tot + 3
```

Reduce: esempio di implementazione

tot=5 (implicit shared)

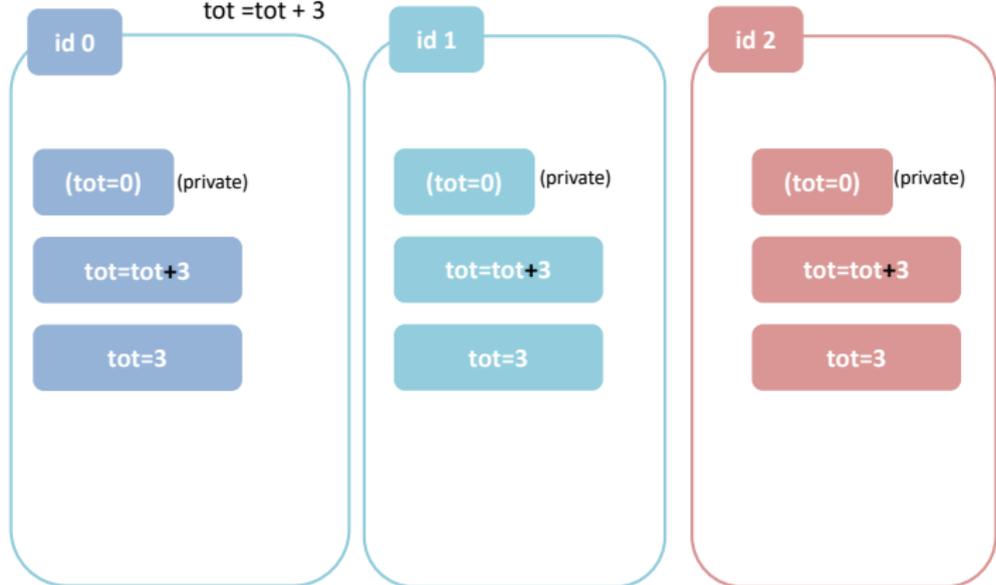
```
#omp parallel num_threads(3) reduce(+, tot)  
tot = tot + 3
```



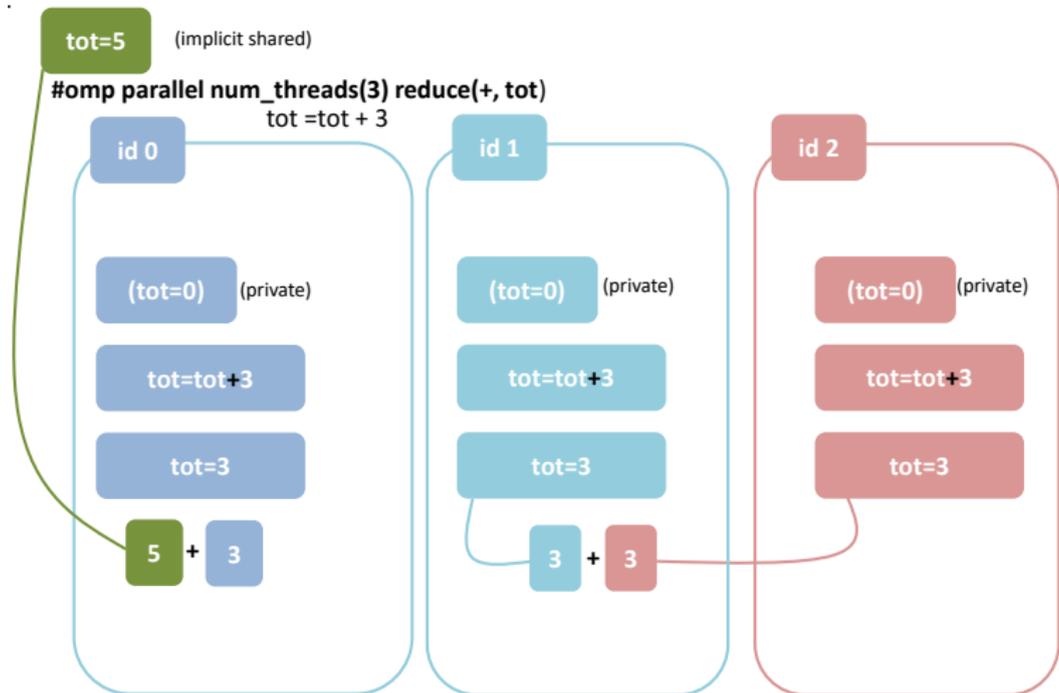
Reduce: esempio di implementazione

tot=5 (implicit shared)

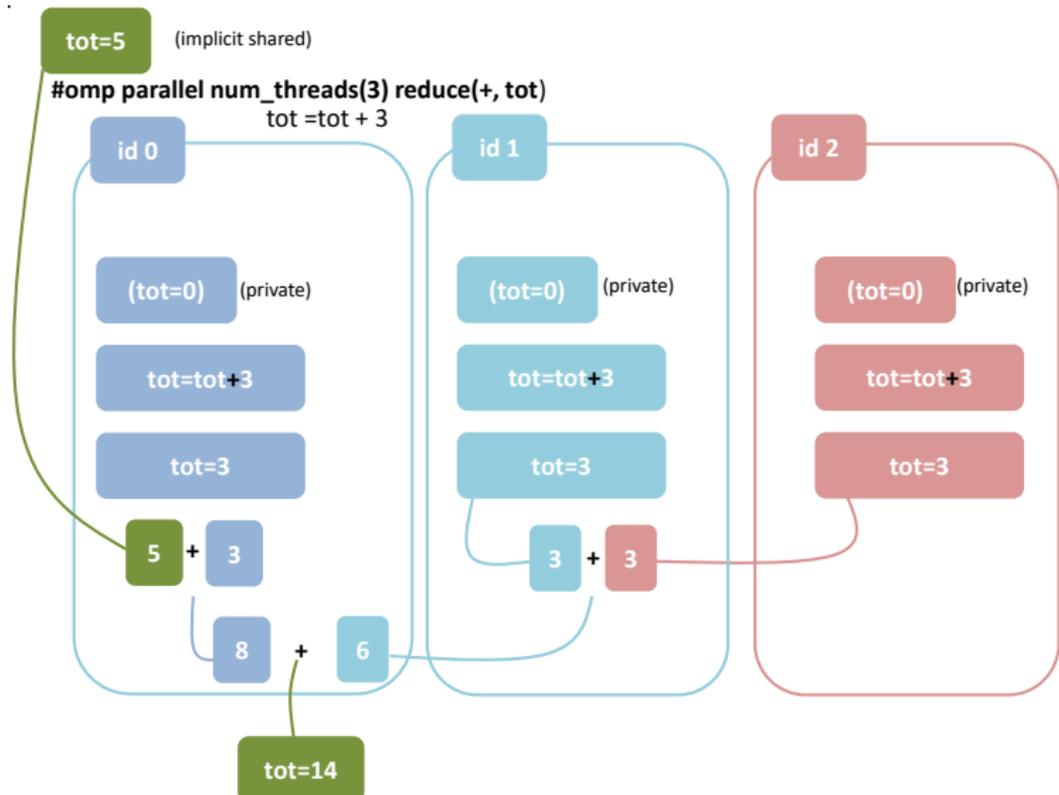
```
#omp parallel num_threads(3) reduce(+, tot)  
tot = tot + 3
```



Reduce: esempio di implementazione

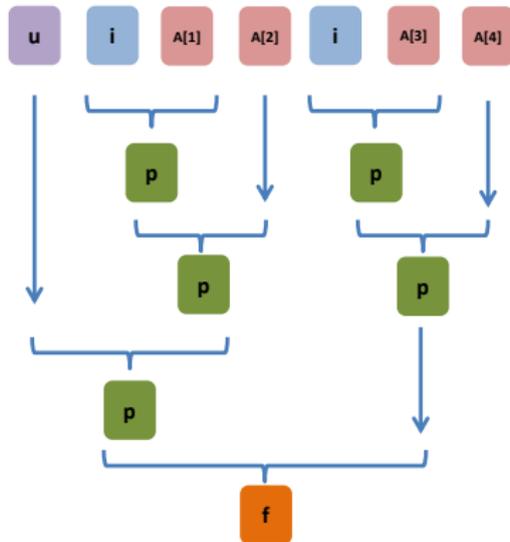


Reduce: esempio di implementazione



La riduzione in generale

Attenzione: tutte le operazioni di riduzione hanno come default un valore, spesso (ma non sempre) sarà l'**elemento neutro** dell'operazione (per esempio per la somma lo 0, per il prodotto l'1, etc...). Questo perché la riduzione viene effettuata in un modo non banale, per esempio



- u = valore di inizializzazione assegnato dal programmatore alla variabile da ridurre
- i = valore di inizializzazione di default dell'operazione
- $A[1], A[2], A[3], A[4]$... sono i valori che ottengono i thread, il thread(1), il thread(2), etc...
- f = valore finale della riduzione

Un esercizio sulla riduzione

Esercizio: scrivere un codice che usi la somma come operazione di riduzione per contare il numero di thread all'interno della regione parallela:

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

int main ()
{
    int somma=0;

    // introduco la regione parallela con clausola di riduzione per "somma"
    {
        // aggiungo 1 a "somma" per ogni thread della regione parallela
    }
    printf("Numero di thread presenti = %d\n",somma);
}
```

Un esercizio sulla riduzione: soluzione

Esercizio: scrivere un codice che usi la somma come operazione di riduzione per contare il numero di thread all'interno della regione parallela:

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

int main ()
{
    int  somma=0;

#pragma omp parallel num_threads(2) reduction(+:somma)
    {
        somma += 1;           // sommo 1 per ogni thread
    }
    printf("Numero di thread presenti = %d\n",somma);
}
```

Work-sharing

- All'interno di una regione parallela, le direttive di tipo **work-sharing** consentono ai thread (o ai task, che vedremo piu' avanti) di gestire la **concorrenza** del lavoro.
- i costrutti **work-sharing** **NON** creano **nuovi** thread.
- un costrutto **work-sharing** deve essere incluso in una regione parallela per poter eseguire in parallelo... (sembra ovvio ma alle volte si dimentica)
- i costrutti **work-sharing** devono essere chiamati da **tutti** i thread o da **nessuno** (assomigliano in questo a delle **collective** di MPI)
- le regioni di tipo **worksharing**, hanno una **barriera implicita** alla fine del costrutto, ovvero tutti i thread devono avere completato il proprio lavoro, prima che si possa passare oltre il costrutto stesso.

Due costrutti work-sharing principali per il C:

- 1 `for` per i **loop**
- 2 `sections`

La direttiva di Work-sharing: *for*

(in FORTRAN e' sostituita dalla direttiva `do`)

E' una direttiva **utilissima**: openMP **suddivide** automaticamente un ciclo `for` tra i thread della regione parallela, de facto rendendo la varibile del loop privata e suddivisa tra thread.

- questa direttiva parallelizza automaticamente il ciclo `for` rendendo privata la variabile del ciclo per ogni thread.
- non ci devono essere **dipendenze** all'interno dei loop, tipo `a[i] = a[i-1] + 3`
- Esistono modi differenti per "suddividere" (worksharing) il lavoro tra i thread. Supponiamo che il ciclo `for` consti di 100 iterazioni. Quante di queste vengono assegnate al thread con id 0? e quante a id 1?
- la suddivisione del lavoro puo' essere **statica** (definita una volta per tutte) o **dinamica** (a seconda di come si comportano i thread il lavoro viene re-distribuito)

La direttiva di Work-sharing: *for*

(in FORTRAN e' sostituita dalla direttiva *do*)

E' una direttiva **utilissima**: openMP **suddivide** automaticamente un ciclo `for` tra i thread della regione parallela, de facto rendendo la varibile del loop privata e suddivisa tra thread.

- questa direttiva parallelizza automaticamente il ciclo `for` rendendo privata la variabile del ciclo per ogni thread.
- non ci devono essere **dipendenze** all'interno dei loop, tipo `a[i]=a[i-1]+3`
- Esistono modi differenti per "suddividere" (worksharing) il lavoro tra i thread. Supponiamo che il ciclo `for` consti di 100 iterazioni. Quante di queste vengono assegnate al thread con id 0? e quante a id 1?
- la suddivisione del lavoro puo' essere **statica** (definita una volta per tutte) o **dinamica** (a seconda di come si comportano i thread il lavoro viene re-distribuito)

La direttiva di Work-sharing: *for*

(in FORTRAN e' sostituita dalla direttiva `do`)

E' una direttiva **utilissima**: openMP **suddivide** automaticamente un ciclo `for` tra i thread della regione parallela, de facto rendendo la varibile del loop privata e suddivisa tra thread.

- questa direttiva parallelizza automaticamente il ciclo `for` rendendo privata la variabile del ciclo per ogni thread.
- non ci devono essere **dipendenze** all'interno dei loop, tipo `a[i] = a[i-1] + 3`
- Esistono modi differenti per "suddividere" (worksharing) il lavoro tra i thread. Supponiamo che il ciclo `for` consti di 100 iterazioni. Quante di queste vengono assegnate al thread con id 0? e quante a id 1?
- la suddivisione del lavoro puo' essere **statica** (definita una volta per tutte) o **dinamica** (a seconda di come si comportano i thread il lavoro viene re-distribuito)

La direttiva di Work-sharing: *for*

(in FORTRAN e' sostituita dalla direttiva `do`)

E' una direttiva **utilissima**: openMP **suddivide** automaticamente un ciclo `for` tra i thread della regione parallela, de facto rendendo la varibile del loop privata e suddivisa tra thread.

- questa direttiva parallelizza automaticamente il ciclo `for` rendendo privata la variabile del ciclo per ogni thread.
- non ci devono essere **dipendenze** all'interno dei loop, tipo `a[i] = a[i-1] + 3`
- Esistono modi differenti per "suddividere" (worksharing) il lavoro tra i thread. Supponiamo che il ciclo `for` consti di 100 iterazioni. Quante di queste vengono assegnate al thread con id 0? e quante a id 1?
- la suddivisione del lavoro puo' essere **statica** (definita una volta per tutte) o **dinamica** (a seconda di come si comportano i thread il lavoro viene re-distribuito)

La direttiva di Work-sharing: *for*

(in FORTRAN e' sostituita dalla direttiva `do`)

E' una direttiva **utilissima**: openMP **suddivide** automaticamente un ciclo `for` tra i thread della regione parallela, de facto rendendo la varibile del loop privata e suddivisa tra thread.

- questa direttiva parallelizza automaticamente il ciclo `for` rendendo privata la variabile del ciclo per ogni thread.
- non ci devono essere **dipendenze** all'interno dei loop, tipo $a[i]=a[i-1]+3$
- Esistono modi differenti per "suddividere" (worksharing) il lavoro tra i thread. Supponiamo che il ciclo `for` consti di 100 iterazioni. Quante di queste vengono assegnate al thread con id 0? e quante a id 1?
- la suddivisione del lavoro puo' essere **statica** (definita una volta per tutte) o **dinamica** (a seconda di come si comportano i thread il lavoro viene re-distribuito)

Esercizio: for

Esempio (con dubbi): implementare ciclo `for` che riempia un array:

```
#include <omp.h>
#include <stdio.h>
#include <stdlib.h>
void main()
{
    int i, N=20;
    int *a;
    a = (int*) malloc(N*sizeof(int));
    // inizio costruito parallelo con 5 thread
    //
    // inserire un comando openMP che suddivida il ciclo tra thread
    for (i=0; i<N; i++)
    {
        a[i]=i; // ogni thread deve riempire un ingresso diverso
    }
    // fine costruito parallelo
    for (i=0; i<N; i++)
    printf("%d\n", a[i]); // controllo
}
```

Soluzione costruito for

Esempio:

```
#include <omp.h>
#include <stdio.h>
#include <stdlib.h>
void main()
{
    int i, N=20;
    int *a;
    a = (int*) malloc(N*sizeof(int));
    # pragma omp parallel num_threads(5)
    {
        # pragma omp for // rende la variabile del ciclo
        for (i=0; i<N; i++) // successivo privata!
        {
            a[i]=i; // ogni thread deve riempire un ingresso diverso
        }
    }
    for (i=0; i<N; i++)
    printf("%d\n", a[i]); // controllo
}
```

Errore: dopo un costrutto `for` serve un ciclo `for...` anche delle semplici parentesi graffe per contenere altre istruzioni, oltre al ciclo `for`, producono un **errore**! Se avessi messo delle graffe per contenere lo statement `for` avrei avuto dei problemi.

Non tutti i “for” sono uguali...

Non tutti i cicli `for` possono essere parallelizzati. Questo e' intuitivo, in quanto il computer deve essere in grado di suddividere il lavoro tra i vari thread e quindi deve avere ben chiaro l'ambito della variabile di loop, ovvero

```
for (inizializzazione; test; incremento)
```

- **inizializzazione** e' del tipo, per esempio: `i=0, i=37, ...`
- **test**, se il test e' vero, il loop continua. In pratica e' un vincolo entro cui si muove la variabile `i`. In un loop generico, basta che la condizione testata sia vera e si passa all' **incremento**. Pero' ci sono delle condizioni per cui e' difficile per il compilatore definire a priori quali valori puo' assumere la variabile `i`. Per esempio una condizione `i != 45` puo' essere difficile da raggiungere (magari `i` non vale mai 45...). Quindi le condizioni di **test** devono essere delle semplici:
`< , <=, >, >=`
- per questo motivo anche l'**incremento** deve essere **semplice**: la variabile puo' essere **solo** incrementata (o diminuita) di quantita' costanti! (`i++`, `i=i+3`, `--i`, ...)

Con queste condizioni, il compilatore trova facilmente quanti `i` diversi tra loro ci sono e puo' decidere come suddividerli tra i vari thread.

Esempio di lastprivate: chi e' l'ultimo?

- **Attenzione:** una clausola `lastprivate` non puo' essere messa su un costrutto `parallel` qualsiasi: deve esserci un modo per definire qual'e' l'**ultimo** thread...
- Per **ultimo** non si intende (necessariamente) dal punto di vista **temporale**, ma ultimo secondo un **univoco** ordine **logico/sintattico**. Nel caso di un ciclo `for` il thread che lavora con gli ultimi indici e' l'ultimo. Quindi per un costrutto `for e` per le `sections` (che vedremo poi) si possono definire variabili `lastprivate`.

```
#include <stdio.h>
#include <stdlib.h>
#include <omp.h>
int main()
{
    int a=5, j;
    omp_set_num_threads(4);           // uso 4 thread nella regione parallela
    #pragma omp parallel for lastprivate(a) // regione for parallela
    for (j=0; j<7; j++)               // j=0,1,2,3,4,5,6
    {
        if (omp_get_thread_num()== 0) rallenta(); // rallento il thread 0
        a = j + 2;
        printf("Il thread =%d lavora con j=%d, il valore di a=%d\n", omp_get_thread_num(),j, a);
    }
    printf("Dopo il costrutto parallelo il valore di a=%d\n", a);
}
```

- A quale thread e' associata la variabile `a`?
- Sebbene il thread 0 esegua per ultimo dal punto di vista **temporale**, per colpa della funzione `rallenta()`; (non la esplicito qui, basta fare un loop lungo)
- la variabile stampata e' quella del thread 3 ...
- ...perche' openMP, nel ciclo `for`, gli assegna l'**ultimo** valore dell'indice del ciclo (`j=6`).

for collapse

Nel caso in cui ci siano dei loop che siano innestati perfettamente, e' possibile usare questa clausola aggiuntiva, in questo modo:

- il compilatore **crea un unico loop** e poi lo parallelizza
- non c'e' bisogno di scrivere 2 direttive `#pragma omp for`, una per ogni ciclo

```
# pragma omp parallel for collapse (2)
{
  for (i=1; i<10; i++)
  {
    for (j=1, j<10;j++)
    {
      somma = somma +i;
    }
  }
}
```

Come viene suddiviso il lavoro in un for (worksharing)

- clausola `static`: lavoro allocato e assegnato all'inizio del loop
- clausola `dynamic`: il sistema decide come e quando assegnare un lavoro ad thread, non appena il thread ha eseguito e diventa idle, un nuovo compito puo' essere assegnato

openMP Scheduling:

- `schedule(static [, chunksize])`
- `schedule(dynamic[, chunksize])`

Per esempio:

```
#pragma omp parallel for default(none), shared(chunksize) schedule(static, chunksize)
for( int index = 0 ; index < 12 ; index++ )
```

Bell'esempio: <http://jakascorner.com/blog/2016/06/omp-for-scheduling.html> Prendiamo un loop con 64 iterazioni (i=0,..., 63)

`schedule(static)`

```
th1 *****
th2          *****
th2          *****
th4                      *****
```

`schedule(static,4)`

```
th1 ****          ****          ****          ****
th2     ****      ****          ****          ****
th3       ****    ****          ****          ****
th4        ****   ****          ****          ****
```

`schedule(static,8)`

```
th1 *****          *****
th2     *****      *****
th3       *****    *****
th4        *****   *****
```

Esercizio: π in modo poco elegante

Un codice che calcola π , usando il seguente risultato $\int_{-\infty}^{+\infty} \frac{1}{1+x^2} dx = \pi$

```
#include <omp.h>           // una versione di Pi greco con worksharing "MANUALE"
#include <stdio.h>
static long num_steps = 100000;           // numero di punti integrale
double step;
void main ()
{
    int i, tot=100; double x, pi, sum = 0.0;
    omp_set_num_threads(tot);           // def num thread
    step = 40000.0/(double) num_steps;   // grandezza step
    double arr_sum[tot];                 // array con somme parziali
#pragma omp parallel private(x,i)
    {
        int par , arr;                   // partenza e arrivo
        int me = omp_get_thread_num();   // numero identificativo del thread
        int stxt = num_steps / tot;      // punti calcolati da ogni thread
        double local_sum=0;
        par = me * stxt;                  // indice di partenza
        arr = par + stxt;                 // indice di arrivo
        for (i= par; i < arr; i++){
            x = (i+0.5)*step;             // punto integrazione
            local_sum = local_sum + 2.0/(1.0+x*x);
        }
        arr_sum[me] = local_sum;         // array locale
    }

    for (i=0;i<tot; i++) {sum += arr_sum[i];}
    pi = step * sum;
    printf("Pi Greco= %f\n", pi);
}
```

Esercizio: π

Qui proviamo ad ottenere lo stesso risultato ma:

- 1 usare come scheletro l'esercizio di somma della lezione precedente
- 2 invece che suddividere la somma "manualmente" usare il costrutto `#pragma omp for`
- 3 alla fine usare l'operazione di riduzione "somma"

π con il costrutto for

```
#include<omp.h>          //
#include<stdio.h>
static long num_steps = 1000000;          // numero di punti integrale
double step;
void main ()
{
    int i, tot=100; double x, pi, sum = 0.0;
    omp_set_num_threads(tot);           // def num thread
    step = 40000.0/(double) num_steps;  // grandezza step
    double arr_sum[tot];                // array con somme parziali
//===== costrutto di openMP
    {
        int me = omp_get_thread_num();  // numero identificativo del thread
        double local_sum=0;
//===== costrutto di openMP
        for (i= 0; i< num_steps; i++){
            x = (i+0.5)*step;           // punto integrazione
            local_sum = local_sum + 2.0/(1.0+x*x);
            arr_sum[me] = local_sum;    // array locale
        }
        sum = 0 ;
//===== qui starebbe bene una riduzione
        for (i=0;i<tot; i++) {
            printf(" %f\n", step*arr_sum[i]);
            sum += arr_sum[i];
        }
        pi = step * sum;
        printf("Pi Greco= %f\n", pi);
    }
}
```

π con il costrutto for, soluzione

```
#include<omp.h>          //
#include<stdio.h>
static long num_steps = 1000000;      // numero di punti integrale
double step;
void main ()
{
    int i, tot=100; double x, pi, sum = 0.0;
    omp_set_num_threads(tot);          // def num thread
    step = 40000.0/(double) num_steps; // grandezza step
    double arr_sum[tot];               // array con somme parziali
#pragma omp parallel private(x,i)
    {
        int me = omp_get_thread_num(); // numero identificativo del thread
        double local_sum=0;
#pragma omp for
        for (i= 0; i< num_steps; i++){
            x = (i+0.5)*step;           // punto integrazione
            local_sum = local_sum + 2.0/(1.0+x*x);
            arr_sum[me] = local_sum;    // array locale
        }

        sum = 0 ;
        for (i=0;i<tot; i++) {
            printf(" %f\n", step*arr_sum[i]);
            sum += arr_sum[i];
        }

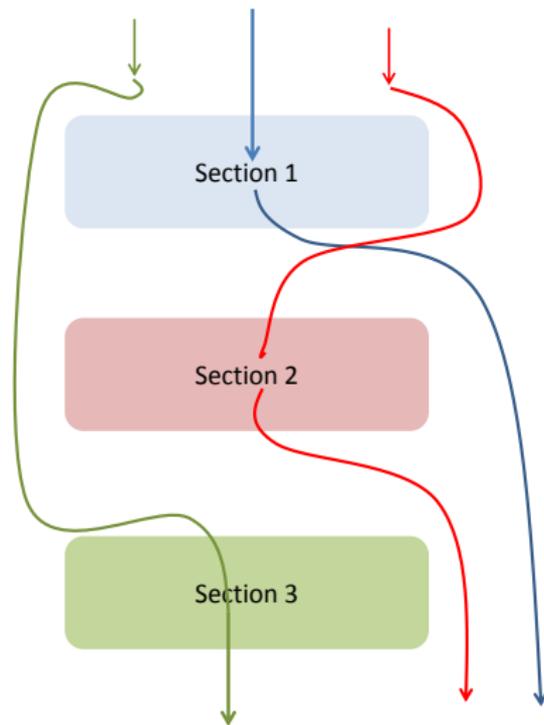
        pi = step * sum;
        printf("Pi Greco= %f\n", pi);
    }
}
```

Worksharing: Sections

La direttiva `sections` divide esplicitamente il lavoro tra i thread, (anche in questo caso puo' essere utile utilizzare la clausola `nowait` per evitare che ci sia una barriera implicita alla fine di una direttiva `sections`).

```
#pragma omp parallel sections      // <= siamo in una regione parallela con sezioni
{
    #pragma omp section
    {
        fai_qualcosa();           // solo un thread esegue la funzione fai_qualcosa()
    }
    #pragma omp section
    {
        fai_qualcosltro();        // solo un thread esegue la funzione fai_qualcosaltro()
    }
}                                  // qui c'e' una barriera implicita (eliminabile con nowait)
```

- il primo comando **openMP** inizializza le sezioni
- il secondo e il terzo comando **openMP** esplicitano l'inizio di una sezione
- alla fine della direttiva `sections` c'e' una **barriera implicita**
- supponiamo che ci siano 4 thread nella regione parallela, ma solo 2 sezioni, cosa succede? solo 2 thread lavoreranno, gli altri saranno inattivi!
- **Occhio** alla differenza tra `#pragma omp sections` (identifica dove comincia il costrutto di worksharing) e `#pragma omp section` (senza la "s" identifica la singola sezione!)



Domanda: Cosa succede se ci sono piu' "sections" che thread? **Risposta:** Un thread eseguirà piu' di una section. ▶

In openMP 3 (e migliorato in 4.0) e' stato introdotto il costrutto **Task**. Il nome e' intuitivo: si crea un compito che dovra' poi essere eseguito. L'idea e' quella che i compiti possano necessitare un'esecuzione non semplicemente gestibile con gli altri costrutti. Per esempio se si deve lavorare con delle funzioni ricorsive o con dei "linked set".

Un **task** si compone di:

- codice da eseguire
- Data environment (ovvero degli argomenti di input e di output)
- da chi il task viene eseguito (un thread)

- si deve definire **esplicitamente** cosa e' un task (con il task construct)
- un task puo' essere eseguito immediatamente (appena costruito) (**undeferrred**) o posticipato (**deferred**) (messo nel task pool ed eseguito poi)
- a **runtime** viene deciso se il momento di esecuzione del task e' *deferred* o *undeferrred*
- i task possono essere **innestati** (ricorsivi)

N.B. Anche prima di openMP 3.0 i **task esistevano**, pero' venivano assegnati ai thread automaticamente.

il costrutto **task** funziona in questo modo:

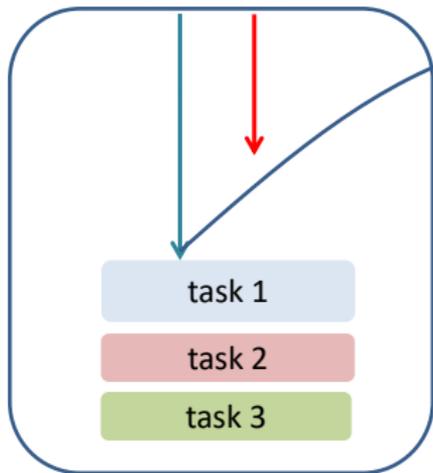
- un thread arriva sul costrutto **task**, tutto quello che trova all'interno del costrutto diventera' un compito (o piu' d'uno) che viene messo nel **task pool** (oppure con una decisione a runtime, il task viene eseguito subito)
- il thread continua nella sua **parallel region** (per esempio, se incontra nuovamente costrutti task, ne crea di nuovi)
- il thread, arrivato alla **fine** della **parallel region**, comincia a pescare dai task e li esegue; piu' in generale i task cominciano ad essere eseguiti non appena i thread incontrano una barriera (esplicita o implicita).
- un **task** puo' essere **tied** ad un thread o **untied**. Nel primo caso se un thread comincia un task solo quel thread puo' continuarlo. Nel secondo caso, un thread puo' cominciare un task, interrompere il lavoro (con opportune clausole o direttive, o anche perche' l'esecuzione del task richiede un altro task, per esempio se stiamo usando task ricorsivi) e magari un altro thread finisce il lavoro. `tied` e `untied` sono delle clausole che possono essere usate sulla direttiva `task`

I **task** possono essere **ricorsivi** e sono eseguiti secondo la execution tree (prima il genitore, poi il figlio etc...)

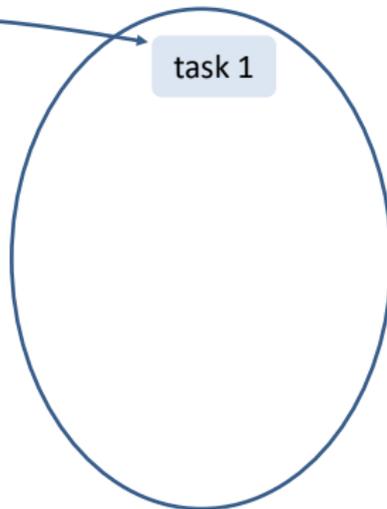
L'utente identifica i task e poi lascia che sia il computer ad scegliere l'ordine di esecuzione: **parallelismo irregolare**

Deferred task visualizzato

Parallel region num_threads(2)

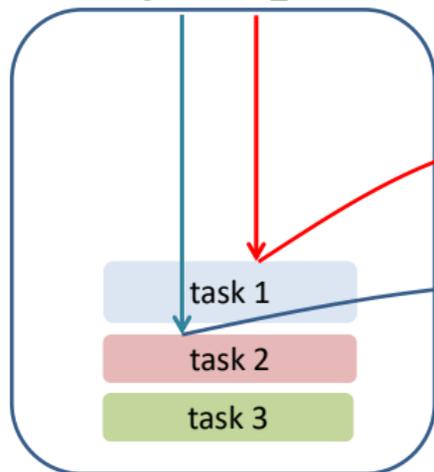


Pool of tasks

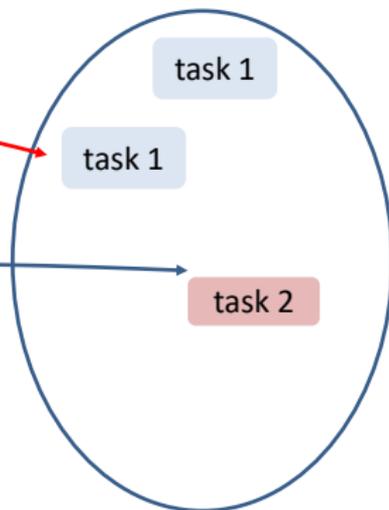


Deferred task visualizzato

Parallel region num_threads(2)

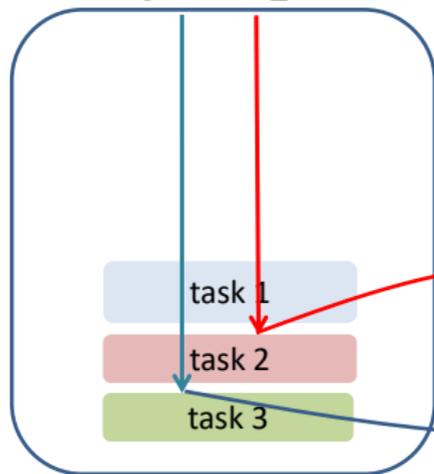


Pool of tasks

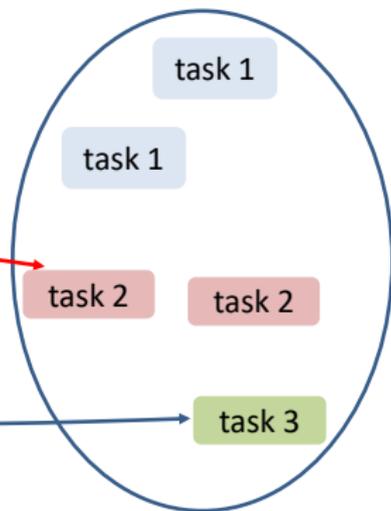


Deferred task visualizzato

Parallel region num_threads(2)

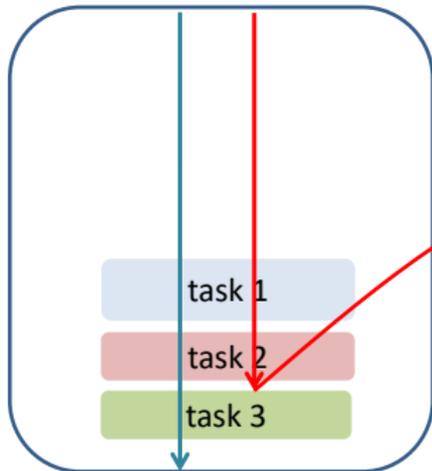


Pool of tasks

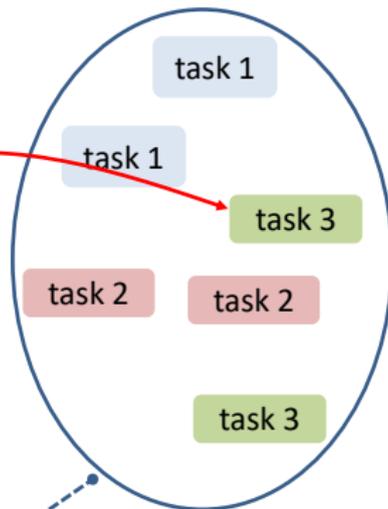


Deferred task visualizzato

Parallel region num_threads(2)

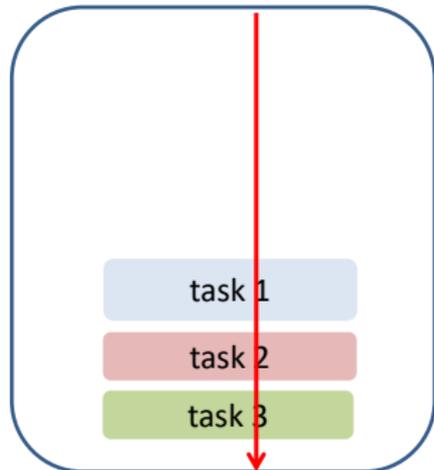


Pool of tasks

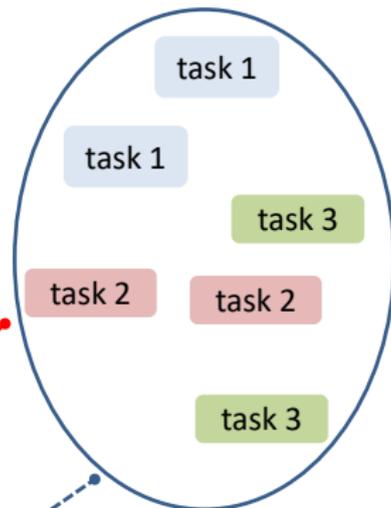


Deferred task visualizzato

Parallel region num_threads(2)

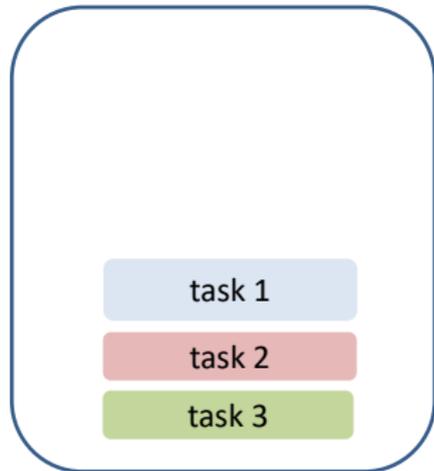


Pool of tasks

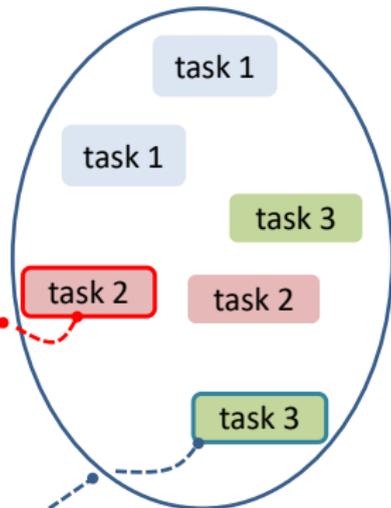


Deferred task visualizzato

Parallel region num_threads(2)

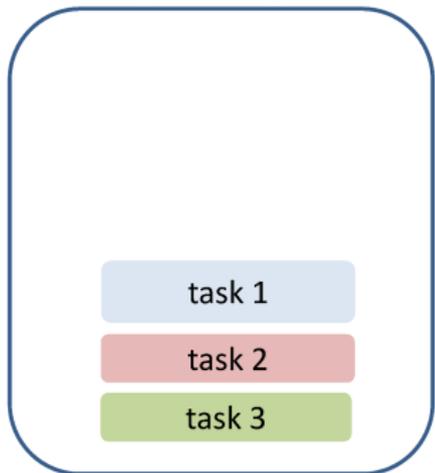


Pool of tasks

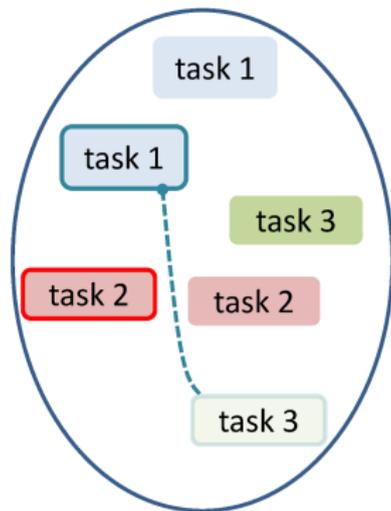


Deferred task visualizzato

Parallel region num_threads(2)

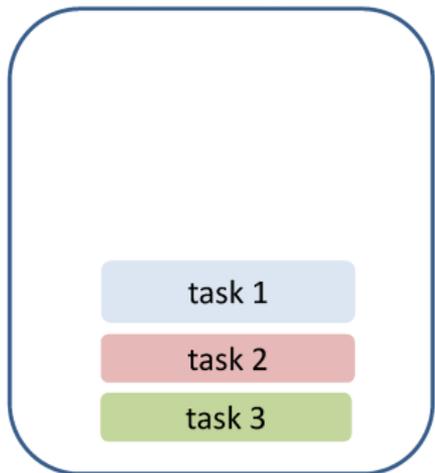


Pool of tasks

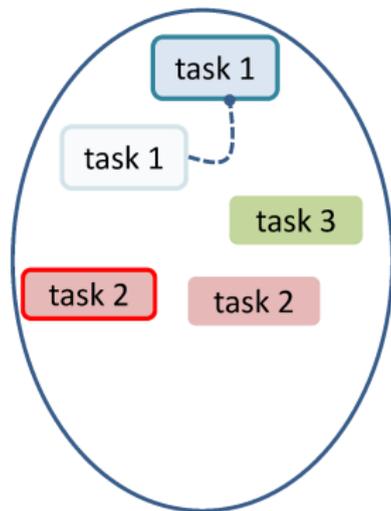


Deferred task visualizzato

Parallel region num_threads(2)

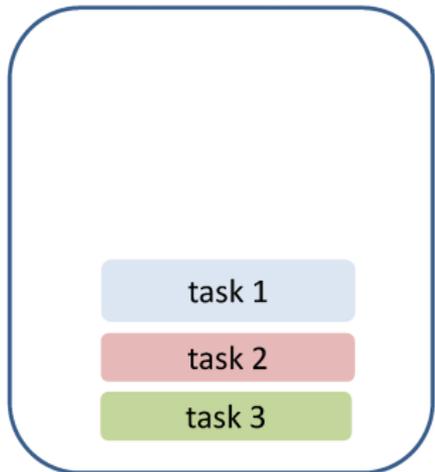


Pool of tasks

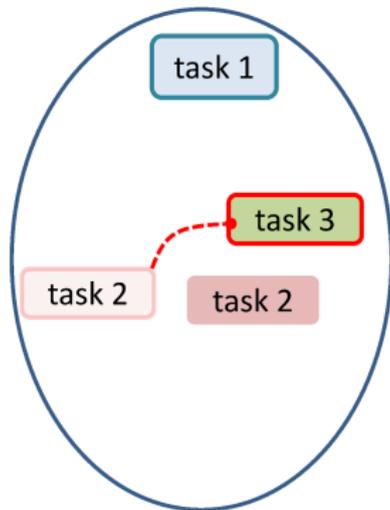


Deferred task visualizzato

Parallel region num_threads(2)

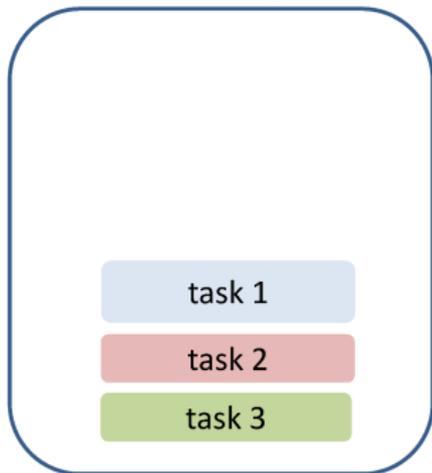


Pool of tasks

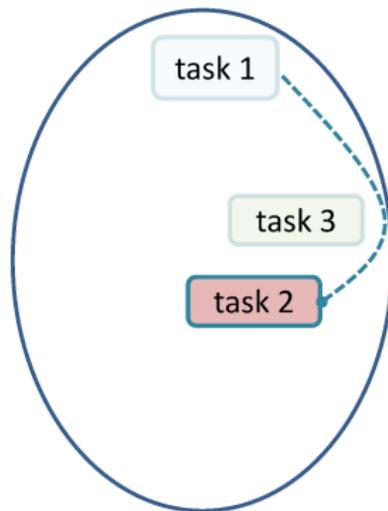


Deferred task visualizzato

Parallel region num_threads(2)

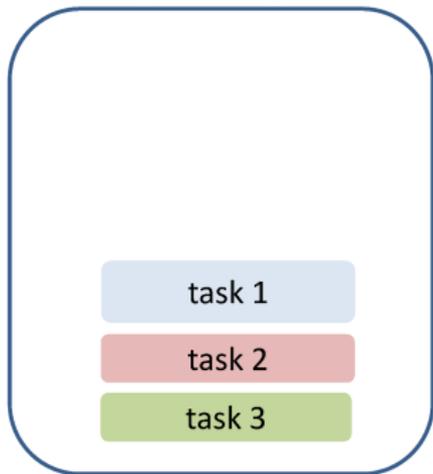


Pool of tasks

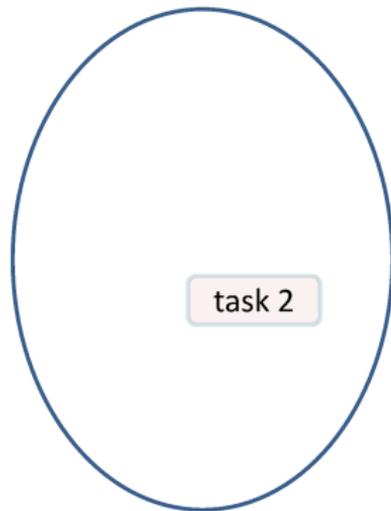


Deferred task visualizzato

Parallel region num_threads(2)



Pool of tasks



Generare Task

Per generare i task posso per esempio usare un codice del tipo:

```
#pragma omp parallel                // siamo in una regione parallela
{
    #pragma omp single                // <= perche' uso il costrutto single?
    {
        for (i=0; i<1000; i++)
        {
            #pragma omp task
            {
                miaFunzione(i);
            } // fine del costrutto task
        } // fine del ciclo
    } // fine del costrutto single
} // fine della regione parallela
```

- **quanti task** verranno generati?
- **quando** verranno eseguiti?
- **da chi** verranno eseguiti?
- se sto generando una lista troppo grande di task, l'implementazione puo' decidere di passare dalla **generazione** alla **esecuzione** dei task stessi
- **Pericolo**: se, prima di avere finito di generare tutti i task, il thread che genera i task si mette ad eseguire un task molto lungo... si arriva in una condizione di **starvation** (i task hanno fame...). Nuovi task non vengono generati, e ci sono dei thread che aspettano!

Task data scoping

Ricordiamo che la **generazione** ed **esecuzione** di un task non coincidono temporalmente.

- 1 Se una variabile e' `shared` in un costrutto `task` il suo valore (referenza) all'interno del costrutto e' riferito al momento in cui il task e' stato **generato**.
- 2 le referenze ad una variabile `private` all'interno del costrutto hanno un nuovo valore non inizializzato, e creato al momento dell'esecuzione del task.
- 3 le referenze una variabile `firstprivate`, all'interno del costrutto, sono rispetto ad un nuovo oggetto, **creato al momento dell'esecuzione** con valore di **inizializzazione** uguale a quello della variabile al **momento di creazione** del task.
- 4 In un costrutto di tipo `task`, se non e' presente nessuna clausola di tipo `default`, allora una variabile che e' `shared`, nel piu' interno dei costrutti esterni (al `task`), continua ad essere `shared`.
- 5 in un costrutto `task`, se non c'e' nessuna clausola `default`, una variabile i cui attributi di data sharing non siano determinati dal punto precedente (ovvero `shared`), e' `firstprivate`.

(Per esempio se un costrutto `task` e' incluso in un costrutto parallelo, allora tutte le variabili che sono `shared` rimangono `shared` anche nel `task`, altrimenti vengono trasformate in `firstprivate`)

Consiglio: per evitare confusione sarebbe meglio che si definisse **esplicitamente** come sono le variabili all'interno del `task`, tramite l'utilizzo di clausole tipo: `private`, `lastprivate`, etc... (usare sempre `default(none)` non provoca **crampi** alle dita!)

Esempi coi task

```
int a=1;
int b=2;
# pragma omp parallel firstprivate (b)
{
    int c=4;
    # pragma omp task shared(c)
    {
        int d = 5;
        eseguiFunzione(e,b); // esempio di funzione da eseguire
    }
}
```

- a
- b
- c
- d

Variabili e task: esempio

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

void main()
{
    int tot=6;
    int i,j;
    #pragma omp parallel num_threads(tot) // creo 6 thread
    {
        int id = omp_get_thread_num(); // id e' private, per ogni thread
        #pragma omp single // faccio creare i task ad un solo thread
        {
            for (i=0; i<3;i++) // costruisce 3 task
            {
                #pragma omp task
                {
                    for (j=0; j<1000000; j++); // task deferred
                    printf("Sono il thread=%d\n", id);
                }
            }
        }
    }
}
```

Attenzione: Cosa scrive a video?

- `id` e' definito dentro il costrutto parallel, quindi e' **privato** per ogni thread
- quando `id` entra nel costrutto task diventa **firstprivate**
- le variabili del task vengono "create" dal thread che e' entrato nel single, che definisce il valore di `id` (non e' `id` di chi esegue)!

Una delle caratteristiche del costrutto task e' quello di poter agevolare la scrittura di codici che abbiano delle parti ricorsive. Per questo motivo e' stata introdotto un utilissimo comando:

```
#pragma omp taskwait
```

Questa direttiva specifica che il task deve aspettare il completamento di tutti i task **figli** generati dall'inizio del task corrente **occhio** che vale per i **figli** non tutti i discendenti!

Invece:

```
#pragma omp taskgroup
```

fa bloccare il thread finche' tutti i task **discendenti** all'interno della regione sono completi.

Costuire un codice per calcolare il fattoriale

- creare una funzione fattoriale
- se $i < 2 \Rightarrow \text{fat}(i) = i$ (se $i=0$ $\text{fat}(i)=1$)
- costruire un task $\text{fat}(i-1)$
- Quanto ci si guadagna in termini di tempi di esecuzione?

```
#include <stdio.h>
#include <omp.h>
int fat(int n)
{
    int i, j;
    if (n<1) return 1;
    if (n<2)
        return n;
    else
    {
        // ===== omp =====
        i=fat(n-1);
        // ===== omp =====
        return i*n;
    }
}
int main()
{
    int n = 14;
    omp_set_num_threads(100);
    // ===== omp =====
    {
        // ===== omp =====
        printf ("fat(%d) = %d\n", n, fat(n));
    }
}
```

Costuire un codice per calcolare il fattoriale: soluzione

- creare una funzione fattoriale
- se $i < 2 \Rightarrow \text{fat}(i) = i$ (se $i=0$ $\text{fat}(i)=1$)
- costruire un task $\text{fat}(i-1)$
- Quanto ci si guadagna in termini di tempi di esecuzione? **Nulla! anzi...**

```
#include <stdio.h>
#include <omp.h>
int fat(int n)
{
    int i, j;
    if (n<1) return 1;
    if (n<2)
        return n;
    else
    {
        #pragma omp task shared(i) firstprivate(n)
        i=fat(n-1);
        #pragma omp taskwait
        return i*n;
    }
}
int main()
{
    int n = 14;
    omp_set_num_threads(100);
    #pragma omp parallel shared(n)
    {
        #pragma omp single
        printf ("fat(%d) = %d\n", n, fat(n));
    }
}
```

- Introdotta l'idea di openMP: team di tread con **fork** e **join**. Sistemi a memoria condivisa.
- introdotto come comunicano i thread: **data sharing**
- definite le clausole principali per il **data sharing** (shared, private, firstprivate, ...)
- introdotti i costrutti di **worksharing**, **sections** e soprattutto i **task**.

Compito Provare ad impostare un codice che sfrutti openMP per calcolare il prodotto tra matrici.

Domanda: Cannon e' un buon algoritmo per la moltiplicazione tra matrici per openMP? perche'?

- Introdotta l'idea di openMP: team di tread con **fork** e **join**. Sistemi a memoria condivisa.
- introdotto come comunicano i thread: **data sharing**
- definite le clausole principali per il **data sharing** (shared, private, firstprivate, ...)
- introdotti i costrutti di **worksharing**, **sections** e soprattutto i **task**.

Compito Provare ad impostare un codice che sfrutti openMP per calcolare il prodotto tra matrici.

Domanda: Cannon e' un buon algoritmo per la moltiplicazione tra matrici per openMP? perche'?

- Introdotta l'idea di openMP: team di tread con **fork** e **join**. Sistemi a memoria condivisa.
- introdotto come comunicano i thread: **data sharing**
- definite le clausole principali per il **data sharing** (shared, private, firstprivate, ...)
- introdotti i costrutti di **worksharing**, **sections** e soprattutto i **task**.

Compito Provare ad impostare un codice che sfrutti openMP per calcolare il prodotto tra matrici.

Domanda: Cannon e' un buon algoritmo per la moltiplicazione tra matrici per openMP? perche'?

- Introdotta l'idea di openMP: team di tread con **fork** e **join**. Sistemi a memoria condivisa.
- introdotto come comunicano i thread: **data sharing**
- definite le clausole principali per il **data** sharing (shared, private, firstprivate, ...)
- introdotti i costrutti di **worksharing**, sections e soprattutto i **task**.

Compito Provare ad impostare un codice che sfrutti openMP per calcolare il prodotto tra matrici.

Domanda: Cannon e' un buon algoritmo per la moltiplicazione tra matrici per openMP? perche'?