

ΕΡΓΑΛΕΙΑ ΠΡΟΓΡΑΜΜΑΤΙΣΜΟΥ

# ΕΙΣΑΓΩΓΗ ΣΤΟΝ ΠΑΡΑΛΛΗΛΟ ΠΡΟΓΡΑΜΜΑΤΙΣΜΟ ΜΕ OpenMP

Νίκος Τρυφωνίδης


Μέρος 1<sup>ο</sup>:

# **Η ΑΝΑΓΚΗ ΓΙΑ ΠΑΡΑΛΛΗΛΟ ΠΡΟΓΡΑΜΜΑΤΙΣΜΟ**

# Γιατί Παράλληλος Προγραμματισμός;

- Οι επιστημονικές υπολογιστικές εφαρμογές είναι πλέον βασικό κομμάτι στις θετικές επιστήμες (και όχι μόνο).
- Οι εφαρμογές αυτές είναι συνήθως ιδιαίτερα απαιτητικές σε υπολογιστικούς πόρους.
- Υπάρχει ανάγκη για όσο το δυνατό περισσότερους υπολογιστικούς πόρους (ταχύτητα, μνήμη).

# Νόμος του Moore




# Νόμος του Moore

- Ο αριθμός των transistors σε ένα ολοκληρωμένο κύκλωμα (μπορεί να) διπλασιάζεται (περίπου) κάθε δύο χρόνια.


- Μέχρι κάποιο σημείο:

**Περισσότερα  
transistors**




**Υψηλότερη  
Συχνότητα  
CPU**

# Συχνότητα CPU – Χρόνος



# Το πρόβλημα;

**Υψηλότερη  
Συχνότητα CPU**



**Υψηλότερη  
Ενέργεια**




**Θερμότητα,  
Κόστος**

# Η Λύση (;)


- Πώς μπορούν να χρησιμοποιηθούν τα διαρκώς αυξανόμενα transistors ενός CPU;
- Αντί για **έναν** επεξεργαστή/πυρήνα υψηλής συχνότητας, μπορούμε να έχουμε **πολλούς** πυρήνες χαμηλότερης συχνότητας.

# Η Λύση (;)

- Πώς μπορούν να χρησιμοποιηθούν τα διαρκώς αυξανόμενα transistors ενός CPU;
- Αντί για **έναν** επεξεργαστή/πυρήνα υψηλής συχνότητας, μπορούμε να έχουμε **πολλούς** πυρήνες χαμηλότερης συχνότητας.



# Multi-Core CPUs




- Με αυτόν τον τρόπο, *δεν κερδίζουμε υψηλότερη ταχύτητα υπολογισμών*, αλλά έχουμε τη **δυνατότητα εκτέλεσης πολλών υπολογισμών ταυτόχρονα**.
- Σήμερα κυκλοφορούν αποκλειστικά πολυπύρρηνοι επεξεργαστές.

# Χρήση των Multi-Core CPUs

- Συνηθισμένη χρήση υπολογιστή: το λειτουργικό σύστημα κατανέμει τις διάφορες διεργασίες του στους διαφορετικούς πυρήνες.
- Πώς μπορούμε να χρησιμοποιήσουμε τους πολλούς πυρήνες ενός επεξεργαστή για υπολογιστικές εφαρμογές;


# Χρήση Shared Memory

- Ας υποθέσουμε ότι έχουμε να εκτελέσουμε κάποιον υπολογισμό στα στοιχεία ενός πίνακα
- Σειριακά (με έναν πυρήνα), ο επεξεργαστής πηγαίνει από το πρώτο στοιχείο μέχρι το τελευταίο, εκτελώντας τους υπολογισμούς:



# Χρήση Shared Memory

- Με περισσότερους πυρήνες, μπορούμε να μοιράσουμε τη δουλειά και οι πυρήνες να εκτελέσουν τους υπολογισμούς **παράλληλα**.
- Για παράδειγμα, με 3 πυρήνες:



# Παράλληλος Προγραμματισμός

- Η ανάπτυξη προγραμμάτων για παράλληλη εκτέλεση αποτελεί πλέον ξεχωριστό κλάδο της υπολογιστικής επιστήμης.
- Τεράστια χρηματικά ποσά ξοδεύονται για δημιουργία και συντήρηση υπερυπολογιστών, που περιέχουν εκατοντάδες χιλιάδες επεξεργαστές.
- Λίστα με τους 500 ισχυρότερους υπερυπολογιστές στον κόσμο: [www.top500.org](http://www.top500.org)

# Πώς προγραμματίζονται οι υπερυπολογιστές;

- Βασικό θέμα στον προγραμματισμό πολλαπλών πυρήνων είναι ο διαμοιρασμός της εργασίας και ο συγχρονισμός μεταξύ των πυρήνων.
- Υπάρχουν τρία βασικά μοντέλα παράλληλου προγραμματισμού:
  1. Message-Passing Programming
  2. Shared-Memory Programming
  3. Accelerators (GPUs)

# Shared-Memory Programming

- Το Shared-Memory Programming είναι ίσως το απλούστερο μοντέλο παράλληλου προγραμματισμού.
- Μπορεί να χρησιμοποιηθεί εύκολα χωρίς επιπλέον απαιτούμενο υλικό.
- Το OpenMP, με το οποίο θα ασχοληθούμε, είναι ίσως το πιο γνωστό και δημοφιλές περιβάλλον για shared-memory programming.

Μέρος 2<sup>ο</sup>:

# **ΕΙΣΑΓΩΓΗ ΣΤΟ OPENMP: THREADS, PARALLEL REGIONS**

# Τί Είναι Το OpenMP;


- Το **OpenMP** (Open Multiprocessing) είναι ένα περιβάλλον προγραμματισμού (**API**) που αποτελείται από εντολές, συναρτήσεις και μεταβλητές.
- Υποστηρίζεται από τις δύο δημοφιλέστερες γλώσσες προγραμματισμού για υπολογιστικές εφαρμογές (**C/C++** και **FORTRAN**).

# Τί Είναι Το OpenMP;


- Το OpenMP χρησιμοποιείται ουσιαστικά ως **προσθήκη** σε ένα πρόγραμμα.
- Με τις κατάλληλες εντολές, τα ιδιαίτερα «βαριά» σημεία του προγράμματος μπορούν να εκτελεστούν παράλληλα από πολλούς πυρήνες, εφόσον αυτοί υπάρχουν.

# OpenMP: Βασική Λειτουργία

- Serial (1 Core)




- Parallel (4 Cores)




# OpenMP: Βασική Λειτουργία

## Serial (1 Core)



## Parallel (4 Cores)



# OpenMP: Parallel Regions

- Οι περιοχές στον κώδικα που ορίζουμε για να εκτελεστούν παράλληλα, λέγονται ***Parallel Regions***.
- Κατά την εκτέλεση ενός προγράμματος, μόλις ο επεξεργαστής συναντήσει μια parallel region, δημιουργεί μια ομάδα από ***threads***, τα οποία θα εκτελέσουν **παράλληλα** τον κώδικα της parallel region.

# OpenMP: Parallel Regions

- Οι parallel regions ορίζονται στον κώδικα με ειδικά ***compiler directives***, ως εξής:

```
#pragma omp parallel  
{  
    (parallel region code)  
}
```

# OpenMP: Parallel Regions

- Οι parallel regions ορίζονται στον κώδικα με ειδικά ***compiler directives***, ως εξής:

```
#pragma omp parallel
```

```
{
```

```
    (parallel region code)
```

```
}
```

Parallel Region  
Directive

Parallel Region  
Code

# OpenMP: Παράδειγμα (4 Threads)


```
int main () {  
    /* (Serial Code) */  
    (...)  
  
    /* Parallel Region */  
    #pragma omp parallel  
    {  
        (Parallel Code)  
    }  
    /* (Serial Code) */  
    (...)  
}
```



Master Thread (0)


# OpenMP: Παράδειγμα (4 Threads)

```
int main () {  
    /* (Serial Code) */  
    (...)  
  
    /* Parallel Region */  
    #pragma omp parallel  
    {  
        (Parallel Code)  
    }  
    /* (Serial Code) */  
    (...)  
}
```



# OpenMP: Παράδειγμα (4 Threads)

```
int main () {  
    /* (Serial Code) */  
    (...)  
  
    /* Parallel Region */  
    #pragma omp parallel  
    {  
        (Parallel Code)  
    }  
    /* (Serial Code) */  
    (...)  
}
```



# “Hello World” ... Παράλληλα!

## Serial

```
#include <stdio.h>

int main() {

    printf("Hello World!\n");

    return 0;
}
```

## Parallel

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

int main() {
    #pragma omp parallel
    {
        printf("Hello World!\n");
    }
    return 0;
}
```

# “Hello World” ... Παράλληλα!

## Serial

```
#include <stdio.h>

int main() {

    printf("Hello World!\n");

    return 0;
}
```

## Parallel

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

int main() {
    #pragma omp parallel
    {
        printf("Hello World!\n");
    }
    return 0;
}
```

OpenMP  
Library



# Compilation και Εκτέλεση

- Το compilation για ένα πρόγραμμα που χρησιμοποιεί OpenMP γίνεται με ένα επιπλέον flag στην εντολή. Για παράδειγμα, για το gcc έχουμε:

```
gcc hello.c -o hello -fopenmp
```

Οπότε δημιουργούμε το εκτελέσιμο *hello*.

# Compilation και Εκτέλεση

- Πριν εκτελέσουμε ένα πρόγραμμα OpenMP πρέπει να ορίσουμε τον αριθμό των threads που θέλουμε να δημιουργηθούν.

Π.χ. για να τρέξουμε με 4 threads  
πληκτρολογούμε σε ένα terminal:

```
export OMP_NUM_THREADS=4
```

# Compilation και Εκτέλεση

- Τέλος, εκτελούμε το πρόγραμμα ως συνήθως:

`./hello`

# Compilation και Εκτέλεση

- Τέλος, εκτελούμε το πρόγραμμα ως συνήθως:

`./hello`

Και παίρνουμε:

```
Hello World!  
Hello World!  
Hello World!  
Hello World!
```

# “Hello World”: Δοκιμή

- Γράψτε ένα πρόγραμμα σαν το παραπάνω και εκτελέστε το με 1, 2, 4 και 8 threads.

# Thread ID, Number of Threads

- Κάθε thread, τη στιγμή που δημιουργείται, έχει μια ταυτότητα (ακέραιος, από 0 έως  $N-1$ ).
- Το αρχικό (*master*) thread έχει τον αριθμό 0.
- Με βάση την ταυτότητα τους και τον συνολικό αριθμό των threads, μπορούμε να χωρίσουμε την υπολογιστική εργασία στα threads.

# Thread ID

- Τα threads μπορούν να μάθουν την ταυτότητα τους καλώντας τη συνάρτηση:

`omp_get_thread_num()`

η οποία επιστρέφει τον ακέραιο αριθμό που αντιστοιχεί στην ταυτότητα του thread που την κάλεσε. Π.χ.

```
int myid = omp_get_thread_num();
```

# Number of Threads

- Με χρήση μιας παρόμοιας συνάρτησης, τα threads μπορούν να μάθουν πόσα threads υπάρχουν συνολικά:

```
int nThreads = omp_get_num_threads();
```

# Thread ID, Number of Threads

- Καλώντας τις δύο παραπάνω συναρτήσεις μέσα από μια parallel region, τα threads πλέον γνωρίζουν την ταυτότητα τους και το συνολικό αριθμό των threads.

# Thread ID, Number of Threads

- Καλώντας τις δύο παραπάνω συναρτήσεις μέσα από μια *parallel region*, τα threads πλέον γνωρίζουν την ταυτότητα τους και το συνολικό αριθμό των threads.
- Δηλώνοντας μεταβλητές (π.χ. τις *myid* και *nThreads*) **εντός της *parallel region***, το κάθε thread θα έχει από ένα **προσωπικό αντίγραφο** της κάθε μεταβλητής.

# Παραλλαγή του “Hello”

- **Δοκιμή #2:** Προσαρμόστε το προηγούμενο πρόγραμμα (*hello*), ώστε τα threads να εκτυπώνουν, μετά το “Hello World”, την ταυτότητα τους και τον συνολικό αριθμό τους.
- **Δοκιμή #3:** Καλέστε την *printf* μέσω μιας ενδιάμεσης, δικής σας, συνάρτησης.

# Συμπεράσματα

- Το πρόγραμμα σε OpenMP τρέχει με όσα threads έχουν οριστεί προηγουμένως με την environment variable **OMP\_NUM\_THREADS**.
- Η **σειρά** με την οποία τα threads εκτελούν τον κώδικα σε μια parallel region είναι **εντελώς ακαθόριστη**.

Μέρος 3<sup>ο</sup>:

# **DATA SCOPE, ΑΠΛΗ ΠΑΡΑΛΛΗΛΗ ΕΡΓΑΣΙΑ ΣΕ SHARED MEMORY**

# Data Scope

- Οι μεταβλητές χωρίζονται σε **δύο βασικές κατηγορίες**, όσο αφορά το πώς φαίνονται σε ένα thread:
  1. **Shared:** Όλα τα threads μπορούν να διαβάσουν και να τροποποιήσουν τις shared μεταβλητές.
  2. **Private:** Κάθε thread δημιουργεί ένα προσωπικό αντίγραφο των private μεταβλητών, και μόνο εκείνο μπορεί να τις προσπελάσει.

# Δήλωση του Data Scope

```
#pragma omp parallel shared(a) \  
                        private(i) \  
                        default(none)
```

# Δήλωση του Data Scope


```
#pragma omp parallel shared(a) \  
                        private(i) \  
                        default(none)
```

- **a**: *shared*, προσβάσιμη από όλα τα threads.
- **i**: *private*, κάθε thread έχει το δικό του αντίγραφο (**απροσδιόριστη αρχική τιμή!**)

# Δήλωση του Data Scope

```
#pragma omp parallel shared(a) \  
                        private(i) \  
                        default(none)
```

■ `a: shared`  
Αναγκάζει το χρήστη να ορίσει  
ακριβώς το scope κάθε  
μεταβλητής στην parallel region  
**(προτείνεται).**



όλα τα threads.  
το δικό του  
αρχική τιμή!)

# Καταμερισμός της Εργασίας

- Με βάση το *Thread ID* και το *συνολικό αριθμό threads* μπορούμε να μοιράσουμε την υπολογιστική εργασία στα threads.
- Έστω ότι κάθε thread αποθηκεύει το ID του και τον αριθμό των threads στις μεταβλητές **myid** και **nThreads**, αντίστοιχα.

# Καταμερισμός της Εργασίας: Παράδειγμα


- Ας υποθέσουμε ότι θέλουμε να προσθέσουμε τον αριθμό 1 σε κάθε στοιχείο ενός πίνακα  $N$  στοιχείων  $A[N]$ , χρησιμοποιώντας **4 Threads**.
- Για να χωρίσουμε την εργασία στα 4 threads, θα ορίσουμε τον πίνακα  $A$  ως **shared**, ώστε να είναι προσβάσιμος από όλα τα threads.
- Θα αναθέσουμε, έπειτα, σε κάθε thread ένα διαφορετικό κομμάτι του πίνακα. Τα threads θα εργαστούν στα κομμάτια που τους αντιστοιχούν **παράλληλα**.

# Καταμερισμός: Εντός της Parallel Region

```
/* Get Thread ID */  
int myid = omp_get_thread_num();  
/* Get Total Number of Threads */  
int nThreads = omp_get_num_threads();
```

# Καταμερισμός: Εντός της Parallel Region

```
/* Get Thread ID */  
int myid = omp_get_thread_num();  
/* Get Total Number of Threads */  
int nThreads = omp_get_num_threads();
```



**Υπενθύμιση:** Μεταβλητές που ορίζονται εντός της *parallel region* θεωρούνται **private**.

## Καταμερισμός: Εντός της Parallel Region (Συνέχεια)

```
/* Each Thread's Starting Point */  
int iStart = myid*N/nThreads;  
/* Each Thread's Ending Point */  
int iEnd = (myid+1)*N/nThreads;
```

# Καταμερισμός: Εντός της Parallel Region (Συνέχεια)

```
/* Each Thread's Starting Point */  
int iStart = myid*N/nThreads;  
/* Each Thread's Ending Point */  
int iEnd = (myid+1)*N/nThreads;
```

Για πίνακα μεγέθους  $N = 20$  και 4 threads:

|           |                    |                  |
|-----------|--------------------|------------------|
| Thread 0: | <b>iStart = 0</b>  | <b>iEnd = 5</b>  |
| Thread 1: | <b>iStart = 5</b>  | <b>iEnd = 10</b> |
| Thread 2: | <b>iStart = 10</b> | <b>iEnd = 15</b> |
| Thread 3: | <b>iStart = 15</b> | <b>iEnd = 20</b> |

# Μετατροπή του Loop σε Παράλληλο

## Serial

```
for (i=0; i<N; i++) {  
    A[i] += 1;  
}
```

## Parallel

```
for (i=iStart; i<iEnd; i++) {  
    A[i] += 1;  
}
```

Κάθε thread λειτουργεί  
μόνο εντός των  
προσωπικών του ορίων!

# Ψιλά Γράμματα 1:

- Για να καλύψουμε την περίπτωση που δε διαιρείται ακριβώς ο αριθμός των στοιχείων  $N$  με τον αριθμό των threads, θέτουμε το τέλος των iterations του τελευταίου thread ως εξής:

```
if (myid == nThreads - 1) iEnd = N;
```

## Ψιλά Γράμματα 2:

- Πώς θα ορίζατε το Data Score της μεταβλητής του μεγέθους του πίνακα  $N$ ;

## Ψιλά Γράμματα 2:

- Πώς θα ορίζατε το Data Score της μεταβλητής του μεγέθους του πίνακα  $N$ ;
- Μπορεί να είναι `private`, αλλά πρέπει να διατηρηθεί η αρχική του τιμή.

## Ψιλά Γράμματα 2:

- Πώς θα ορίζατε το Data Score της μεταβλητής του μεγέθους του πίνακα N;
- Μπορεί να είναι `private`, αλλά πρέπει να διατηρηθεί η αρχική του τιμή.
- **Λύση:** *firstprivate*. Κάθε thread έχει προσωπικό αντίγραφο με την αρχική τιμή της μεταβλητής.

# Τελικά;

```
#pragma omp parallel \  
    shared(A) \  
    private(i) \  
    firstprivate(N)  
  
{  
    /* Get Thread ID */  
    int myid = omp_get_thread_num();  
    /* Get Total Number of Threads */  
    int nThreads=omp_get_num_threads();  
  
    /* Each Thread's Starting Point */  
    int iStart = myid*N/nThreads;  
    /* Each Thread's Ending Point */  
    int iEnd = (myid+1)*N/nThreads;
```

```
/* continued... */  
    /* Take care of bound */  
    if(myid == nThreads-1) iEnd=N;  
  
    /* The Loop */  
    for (i=iStart; i<iEnd; i++) {  
        A[i] += 1;  
    }  
  
} /* End of Parallel Region */
```

# Εφαρμογή 1: Vector Addition

- Γράψτε ένα πρόγραμμα που να αρχικοποιεί δύο διανύσματα και να τα προσθέτει. Φροντίστε να επαληθεύεται το αποτέλεσμα.
- Αφού σιγουρευτείτε ότι το σειριακό πρόγραμμα λειτουργεί σωστά, μετατρέψτε το πρόγραμμα σε παράλληλο με χρήση OpenMP.

Μέρος 4<sup>ο</sup>:

# **ΑΥΤΟΜΑΤΟΣ ΚΑΤΑΜΕΡΙΣΜΟΣ ΕΡΓΑΣΙΑΣ (WORK-SHARING)**

# Work-Sharing

- Η παραπάνω διαδικασία χωρισμού της εργασίας σε threads μπορεί να γίνει αυτόματα με χρήση ειδικών directives, που λέγονται ***work-sharing constructs***.
- Ουσιαστικά, αυτό που επιτυγχάνουν τα work-sharing constructs είναι να **παραλληλοποιούν αυτόματα ένα loop** εντός μιας parallel region.

# Work-Sharing

## Serial

```
for (i=0; i<N; i++) {  
    A[i] += 1;  
}
```

## Parallel – Work-Sharing

```
#pragma omp parallel \  
    shared(A)private(i)\  
    firstprivate(N)  
{  
    #pragma omp for  
    for (i=0; i<N; i++) {  
        A[i] += 1;  
    }  
}
```

# Work-Sharing

## Serial

Ίδιο με το σειριακό loop!

```
for (i=0; i<N; i++) {  
    A[i] += 1;  
}
```

## Parallel – Work-Sharing

```
#pragma omp parallel \  
    shared(A)private(i) \  
    firstprivate(N)
```

```
{  
    #pragma omp for  
    for (i=0; i<N; i++) {  
        A[i] += 1;  
    }  
}
```

Καθόλου επιπλέον κώδικας – μόνο directives!

# Work-Sharing Schedules

- Το πώς θα μοιραστεί το loop στα threads εξαρτάται από το schedule που θα δηλώσουμε δίπλα στο work-sharing directive.
- Υπάρχουν 3 διαφορετικά schedules:
  - Static
  - Dynamic
  - Guided

# Static Schedule

- Μοιράζει τις επαναλήψεις του loop **εξίσου** στα threads:

```
#pragma omp for schedule(static)
```



**4 Threads, 16 Iterations:  
4 iterations/Thread**

# Static Schedule

- Δηλώνοντας έναν αριθμό (*chunksize*):

```
#pragma omp for schedule(static, 2)
```

*chunksize*



**4 Threads, 16 Iterations:**  
**4 iterations/Thread**  
**σε ομάδες των 2 iterations**

# Dynamic Schedule

- Μοιράζει αρχικά  $n$  επαναλήψεις στα threads  
`#pragma omp for schedule(dynamic,  $n$ )`
- Μόλις κάποιο thread ολοκληρώσει τις επαναλήψεις του, παίρνει τις επόμενες  $n$  επαναλήψεις.

*Σημείωση: το default dynamic chunksize είναι 1*

# Guided Schedule

- Όμοιο με το `dynamic`, αλλά ξεκινά να μοιράζει μεγάλα κομμάτια επαναλήψεων, τα οποία διαρκώς μειώνει.

`#pragma omp for schedule(guided,n)`

**n:** Ο ελάχιστος αριθμός επαναλήψεων  
(*default: 1*)

# Work-Sharing Schedules

- Το **static** είναι η απλούστερη και συνήθως αποτελεσματικότερη μέθοδος, επειδή απαιτεί τον ελάχιστο συγχρονισμό από το σύστημα.
- Το **dynamic** επιβαρύνει το σύστημα, αλλά είναι χρήσιμο σε περιπτώσεις που ορισμένα μέρη ενός loop είναι βαρύτερα από άλλα (load imbalance).

# Parallel Region + Work-Sharing

- Έναρξη parallel region και work-sharing με το ίδιο directive:

```
#pragma omp parallel for \  
                shared(...) private(...) \  
                schedule(...)
```

## Ψιλά Γράμματα #3: Synchronization

- Στο τέλος κάθε *parallel* και *work-sharing* region υπάρχει *implicit barrier*.
- Αυτό σημαίνει ότι **όλα τα threads πρέπει να φτάσουν στο σημείο εκείνο**, πριν συνεχιστεί η εκτέλεση.

## Εφαρμογή 2: Vector Addition + Work-Sharing

- Παραλληλοποιήστε το πρόγραμμα πρόσθεσης διανυσμάτων του προηγούμενου μέρους, κάνοντας χρήση **work-sharing**.
- Συγκρίνετε την απόδοση των δύο παράλληλων προγραμμάτων και δοκιμάστε διαφορετικά schedules.

Μέρος 5<sup>ο</sup>:

# THREAD SAFETY

# Thread Safety?

- Μέχρι τώρα, στα παραδείγματα που είδαμε, τα threads δουλεύουν αποκλειστικά στο δικό τους κομμάτι μνήμης.
- Δεν υπήρχε κίνδυνος να μεταβάλλουν μια μεταβλητή ταυτόχρονα.
- Αν κάτι τέτοιο συμβεί, το αποτέλεσμα είναι **απροσδιόριστο** και προφανώς **λάθος**.

# Thread Safety

- Τα προγράμματα OpenMP πρέπει να είναι *thread-safe*, δηλαδή η εκτέλεση ενός προγράμματος με πολλά threads δεν πρέπει εισάγει σφάλματα στο πρόγραμμα.

# Thread-Unsafe Παράδειγμα

```
sum = 0;
#pragma omp parallel shared(sum, a) private(i)\
                    firstprivate(size)
{
    #pragma omp for schedule(static)
    for(i=0; i<size; i++) {
        sum += a[i];
    }
}
printf("sum = %f\n", sum);
```

# Thread-Unsafe Παράδειγμα

```
sum = 0;
#pragma omp parallel shared(sum) firstprivate(sum)
{
    #pragma omp for schedule(dynamic, 1)
    for(i=0; i<size; i++) {
        sum += a[i];
    }
}
printf("sum = %f\n", sum);
```

Τα threads προσπαθούν  
να γράψουν στη  
μεταβλητή sum  
ταυτόχρονα!  
**Αποτέλεσμα:**  
**απροσδιόριστο!**

# Critical Regions

- Θέτοντας μια thread-unsafe περιοχή της parallel region ως ***critical region***, εξασφαλίζουμε ότι **μόνο ένα thread μπορεί να εκτελεί τις εντολές της συγκεκριμένης περιοχής σε μια συγκεκριμένη στιγμή.**
- Τα υπόλοιπα threads περιμένουν τη σειρά τους εκτός της critical region.

# Χρήση της Critical Region

```
sum = 0;
#pragma omp parallel shared(sum,
                           firstpriv
{
    #pragma omp for schedule(static)
    for(i=0; i<size; i++) {
        #pragma omp critical
        {
            sum += a[i];
        }
    }
}
printf("sum = %f\n", sum);
```

Τα threads γράφουν στη  
sum ένα-ένα:  
**Σωστό αποτέλεσμα!**

# Critical Regions

- Οι critical regions είναι ένας εύκολος τρόπος να εξασφαλίσουμε τη σωστή συνεργασία των threads.
- Όμως, επιβαρύνουν ιδιαίτερα τη λειτουργία ενός προγράμματος (απαιτούν πολύ συγχρονισμό).
- Είναι προτιμότερο, αν γίνεται, να αντικαθίστανται με άλλους τρόπους.

# Αντικατάσταση Μιας Critical Region

- Στο προηγούμενο παράδειγμα, προσθέσαμε τα στοιχεία ενός πίνακα σε μια μεταβλητή.
- Για να αποφύγουμε τη χρήση critical region, η συνηθισμένη λύση θα ήταν η χρήση ενός προσωρινού πίνακα (**size = nThreads**).

# Αντικατάσταση Μιας Critical Region

- Κάθε thread θα γράψει στο αντίστοιχο στοιχείο του προσωρινού πίνακα το **προσωπικό του άθροισμα**.
- **Μετά την parallel region**, το master thread θα προσθέσει σειριακά τα επιμέρους αθροίσματα.

# Χρήση του Reduction Scope

- Η παραπάνω διαδικασία είναι τόσο συχνή που έχει αυτοματοποιηθεί στο OpenMP, με χρήση του reduction scope.
- Το μόνο που έχουμε να κάνουμε είναι να ορίσουμε τη μεταβλητή στην οποία θα αθροίζουμε ως ***reduction***.

# Reduction Example

```
sum = 0;
#pragma omp parallel shared(a) private(i)\
                    firstprivate(size) \
                    reduction(+:sum)
{
    #pragma omp for schedule(static)
    for(i=0; i<size; i++) {
        sum += a[i];
    }
}
printf("sum = %f\n", sum);
```

# Χρήση του Reduction Scope

reduction(+:sum)



Η μεταβλητή sum  
θα **αθροιστεί**  
παράλληλα

- Άλλα reductions:
  - - (initialized: 0)
  - \* (initialized: 1)

# Εφαρμογή 3: Dot Product

- Γράψτε ένα πρόγραμμα OpenMP που να υπολογίζει παράλληλα το εσωτερικό γινόμενο δύο διανυσμάτων με χρήση work-sharing.
- Αφού δείτε ότι αν δηλώσετε τη μεταβλητή `sum` ως `shared` το αποτέλεσμα είναι απρόβλεπτο, κάντε χρήση `critical region` για να το προστατέψετε. Μετρήστε το χρόνο εκτέλεσης.

# Εφαρμογή 3: Dot Product

- Κάντε χρήση του reduction. Βεβαιωθείτε ότι το αποτέλεσμα είναι σωστό και μετρήστε το χρόνο εκτέλεσης.

# Εφαρμογή 3: Dot Product

- **Επιπλέον Άσκηση (Δύσκολο):**

Γράψτε το ίδιο πρόγραμμα εφαρμόζοντας το reduction μη-αυτόματα (με shared temporary array). Συγκρίνετε το χρόνο εκτέλεσης με το αυτόματο.

Μέρος 6<sup>ο</sup>:

# ΕΠΙΠΛΕΟΝ ΕΦΑΡΜΟΓΕΣ

# Εφαρμογή 4: Matrix Multiplication

- Γράψτε ένα πρόγραμμα που να πολλαπλασιάζει δύο (τετράγωνους) πίνακες παράλληλα. Συγκρίνετε το χρόνο εκτέλεσης με το σειριακό αντίστοιχο.

## Εφαρμογή 5: Μέσος Όρος - Απόκλιση

- Γράψτε ένα πρόγραμμα που να υπολογίζει παράλληλα το μέσο όρο και την απόκλιση των στοιχείων ενός πίνακα, τα οποία προέρχονται από κανονική κατανομή.

# Εφαρμογή 6: Εύρεση Μεγίστου

- Γράψτε ένα πρόγραμμα που να αναζητεί και να βρίσκει το μέγιστο από τα στοιχεία ενός πίνακα παράλληλα.
- **Επιπλέον εφαρμογή (δύσκολο):** Κάντε το προηγούμενο πρόγραμμα χωρίς critical region.

# Υλικό OpenMP

- <http://openmp.org/wp/>
- <https://computing.llnl.gov/tutorials/openMP/>
- Βιβλία:
  - **Using OpenMP** (Barbara Chapman, Gabriele Jost and Ruud van der Pas)
  - **Parallel Programming In OpenMP** (Chandra, Dagum et al)

Ευχαριστώ!

Νίκος Τρυφωνίδης