

OpenMP και παράλληλες λειτουργίες reduction

(Συγχρονισμός και έλεγχος κοινών πόρων)

<https://mixstef.github.io/courses/parprog/>

Μ.Στεφανιδάκης



Απαιτήσεις Reduction

- **Αποκλειστική προσπέλαση πόρων**
 - Οι λειτουργίες reduction απαιτούν την ενημέρωση κοινόχρηστων πόρων
- **Συγχρονισμός threads**
 - Για την ολοκλήρωση του reduction συχνά απαιτείται συγχρονισμός των threads
- **Τι παρέχει το OpenMP**
 - Δήλωση και αρχικοποίηση κοινόχρηστων πόρων
 - Κρίσιμες περιοχές για αποκλειστική προσπέλαση πόρων
 - Σημεία συγχρονισμού (barrier, έμμεσα ή ρητά δηλωμένα)
 - «Συντομεύσεις» για την εύκολη χρήση του reduction

Εμβέλεια μεταβλητών στο OpenMP

- **Data Scope**
 - Πολύ σημαντική έννοια στον προγραμματισμό με το OpenMP
 - Τι συμβαίνει με τις μεταβλητές του σειριακού προγράμματος; τι βλέπει κάθε thread;
- **Δύο βασικές κατηγορίες μεταβλητών**
 - **Private**: κάθε thread βλέπει διαφορετική «κόπια» της μεταβλητής
 - **Shared**: όλα τα threads βλέπουν την ίδια μεταβλητή
 - Κοινός πόρος, πρέπει να υπάρχει έλεγχος πρόσβασης
- **Όταν δεν δηλώνεται ρητά το είδος μιας μεταβλητής, το OpenMP έχει default κανόνες για αυτό**

Παράλληλη περιοχή και εμβέλεια μεταβλητών

- **Μέσα στην παράλληλη περιοχή**
 - Οποιαδήποτε μεταβλητή δηλώνεται **μέσα** στην παράλληλη περιοχή θεωρείται **private**
 - Το ίδιο ισχύει για μεταβλητές συναρτήσεων που καλούνται μέσα από την παράλληλη περιοχή
 - Οι global μεταβλητές είναι **shared**
 - Μεταβλητές που δεν έχει προσδιοριστεί το είδος τους χρησιμοποιούν το default (εξ' ορισμού **shared**)
- **Ρητός προσδιορισμός είδους εμβέλειας**
 - Το `#pragma omp parallel` (όπως και άλλα pragmas) παίρνουν προαιρετικά clauses προσδιορισμού εμβέλειας για λίστες μεταβλητών
 - **private()** και **shared()**

```
#pragma omp parallel private(id)
```

Αρχική τιμή private μεταβλητών

- Σε μια παράλληλη περιοχή οι μεταβλητές μπορούν να είναι **shared** ή **private**
 - Οι **shared** μεταβλητές έχουν πάντα την ίδια και μοναδική θέση
 - Οι **private** μεταβλητές έχουν μια «κόπια» ανά thread της παράλληλης περιοχής
- **Αρχικοποίηση private μεταβλητών**
 - Δεν γίνεται!
 - Συνήθως έχουν τιμή 0 αν δεν τις αρχικοποιήσουμε εμείς (εξαρτάται πώς το λειτουργικό σύστημα αρχικοποιεί τις σελίδες μνήμης)
 - Ακόμα και αν έχει τιμή έξω από την παράλληλη περιοχή
 - Η υπάρχουσα τιμή δεν αντιγράφεται στις «κόπιες»

Firstprivate

- **Firstprivate**: αντιγραφή της υπάρχουσας τιμής έξω από την παράλληλη περιοχή **σε κάθε κόπια** της μεταβλητής

```
int main() {
```

```
    int x = 22;
```

```
    #pragma omp parallel private(x)
```

```
    {
```

```
        printf("Thread %d: my private x=%d\n", omp_get_thread_num(), x);
```

```
    }
```

```
    #pragma omp parallel firstprivate(x)
```

```
    {
```

```
        printf("Thread %d: my firstprivate x=%d\n", omp_get_thread_num(), x);
```

```
    }
```

```
    return 0;
```

```
}
```

*θα τυπώσει (μάλλον) 0: η
κόπια της x δεν είναι
αρχικοποιημένη*



*θα τυπώσει 22: η αρχική
τιμή αντιγράφεται στην
κόπια της x*



Συγχρονισμός threads

- **critical construct**: υλοποίηση κρίσιμων περιοχών για αμοιβαίο αποκλεισμό κατά την ενημέρωση κοινών πόρων
 - Μπορεί να περιβάλλει μια περιοχή κώδικα οσοδήποτε μεγάλη – **μόνο ένα thread** μπορεί κάθε στιγμή να εκτελεί τον κώδικα αυτόν
 - Χρησιμοποιεί locks (mutexes) του λειτουργικού συστήματος
 - Είναι αργή διαδικασία και μειώνει τον παραλληλισμό – **δεν πρέπει να χρησιμοποιείται σε κώδικα που εκτελείται πολλές φορές**
 - Named/Unnamed – περιοχές με το ίδιο (ή χωρίς) όνομα θεωρούνται η ίδια κρίσιμη περιοχή
 - Κατά την είσοδο/έξοδο στην/από την κρίσιμη περιοχή τα updates σε κοινούς πόρους που προκάλεσε κάθε thread γίνονται εγγυημένα ορατά στα άλλα threads (memory flush)

```
#pragma omp critical
{
    count++;
}
```

Συγχρονισμός threads

- Υπάρχει και το **atomic construct** για γρήγορες ενημερώσεις με εγγυημένη ατομικότητα εκτέλεσης
 - Χρησιμοποιείται ο μηχανισμός locking του **hardware**, για μικρές ποσότητες (μεταβλητές) – **πιο γρήγορο από το critical construct**
 - Περιορισμένη λειτουργικότητα: π.χ. $\dots = x$ (read) $x = \dots$ (write) $x++$ ή $x += \dots$ (update) $\dots = x++$ (capture)

```
#pragma omp atomic // update  
gsum += sum;
```

- **barrier construct**: συγχρονισμός όλων των threads μιας παράλληλης περιοχής

```
#pragma omp barrier
```

master vs single construct

- **To master construct**
 - Απλό εργαλείο για την εκτέλεση ενός κομματιού κώδικα από το master thread
 - Δεν παρέχει κανέναν συγχρονισμό με τα άλλα threads
 - Όποιο thread δεν είναι master παρακάμπτει το κομμάτι αυτό του κώδικα
- **To single construct**
 - Είναι ένα worksharing construct όπως το for
 - Αναθέτει την εκτέλεση του κομματιού κώδικα σε ένα οποιοδήποτε thread
 - Στο τέλος προστίθεται ένα έμμεσο barrier – όλα τα υπόλοιπα threads θα περιμένουν να ολοκληρωθεί η εργασία στο single
 - Δυνατότητα αφαίρεσης έμμεσου barrier με το **nowait**

OpenMP reduction

- Οι λειτουργίες reduction μπορούν να κατασκευαστούν με όσα constructs ξέρουμε μέχρι τώρα
 - `parallel for` για τον κατανεμημένο υπολογισμό επιμέρους αποτελεσμάτων
 - Θα χρειαστούμε `private` ή `firstprivate` μεταβλητές
 - `critical` για ενημέρωση του συνολικού αποτελέσματος από τα επιμέρους αποτελέσματα
- Το OpenMP προσφέρει όμως μια πολύ πιο «αυτοματοποιημένη» λύση
 - Σε ορισμένα constructs (όπως το `parallel` ή το `for`) μπορεί να χρησιμοποιηθεί το clause `reduction(τελεστής:λίστα μεταβλητών)`

reduction clause

- **reduction(τελεστής:λίστα μεταβλητών)**
 - Ο τελεστής είναι ένας από τους +, -, *, &, |, ^, &&, ||, min, max
 - Μπορούν επίσης να οριστούν custom τελεστές με το **#pragma omp declare reduction** (σε τι τύπο δεδομένων, ποια η συνάρτηση reduction, ποια η αρχικοποίηση)
 - Για τις μεταβλητές που ορίζονται στη λίστα θα δημιουργηθούν «κόπιες» ανά thread
 - Οι «κόπιες» θα αρχικοποιηθούν στην κατάλληλη τιμή ανάλογα με τον τελεστή
 - Π.χ. στο 0 για το + και στο 1 για το *
 - Στο τέλος της εκτέλεσης του construct που ορίστηκε το reduction οι μεταβλητές **συνδυάζονται σε τελικό αποτέλεσμα**
 - Συνδυασμός σύμφωνα με τον επιλεγμένο τελεστή