

Λειτουργίες reduction σε GPU

(Θέματα συγχρονισμού και shared memory)

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


*Το εργαστήριο του μαθήματος χρησιμοποιεί υπολογιστικούς πόρους
AWS Cloud χρηματοδοτούμενους από το ΕΛΥΤΕ*

Μ.Στεφανιδάκης



Reduction

- Συνδυάζει όλα τα στοιχεία μιας συλλογής (collection) σε ένα μοναδικό στοιχείο μέσω τελεστή f



Reduction σε GPU

- **Απαιτείται κάποιου είδους συγχρονισμός**
 - Για την παραγωγή του ενός και μοναδικού τελικού αποτελέσματος
- **Τι γνωρίζουμε ως τώρα;**
 - Το πρώτο είδος συγχρονισμού που έχουμε συναντήσει είναι **έμμεσο**, μετά την ολοκλήρωση του kernel
 - Πριν τη μεταφορά των αποτελεσμάτων πίσω στο host ή την εκτέλεση ενός νέου kernel
 - Εγγύηση ότι έχουν τελειώσει όλα τα threads, όλων των blocks, για το σύνολο του grid
 - Γνωρίζουμε επίσης ότι δεν μπορεί να υπάρξει συγχρονισμός μεταξύ των διαφορετικών blocks
 - Δεν γνωρίζουμε καν με ποια σειρά θα εκτελεστούν τα blocks

Συγχρονισμός threads του ίδιου block

```
// synchronize all threads of block  
__syncthreads();
```

- Η πιο βασική λειτουργία συγχρονισμού
 - Πρέπει να εκτελεστεί **από όλα τα threads ενός block** για να συνεχιστεί η εκτέλεση μετά το σημείο αυτό (μορφή barrier)
 - Σε τμήματα κώδικα υπό συνθήκη, αν κάποια threads του block δεν εκτελέσουν το `__syncthreads()` τότε η εκτέλεση στο block αυτό θα «παγώσει»
 - Εγγυάται ότι όλες οι προσπελάσεις μνήμης (global και shared) από τα threads του block **πριν** το `__syncthreads()` έχουν ολοκληρωθεί
 - Τα threads του block θα δουν εγγυημένα τις αλλαγές στη μνήμη **μετά** το `__syncthreads()`


Υπολογισμός αποτελέσματος ανά block

- Κάθε block συνδυάζει όλα τα μερικά αποτελέσματα των threads του σε ένα μερικό άθροισμα
 - Τα μερικά αθροίσματα θα έχουν μέγεθος ίσο με τον αριθμό των blocks
 - Διαχειρίσιμο μέγεθος, ακόμα κι από CPU
 - Το τελικό αποτέλεσμα πρέπει να υπολογιστεί μετά τη λήξη του συνολικού kernel
 - Θυμηθείτε: δεν μπορούμε να συγχρονίσουμε τα blocks μεταξύ τους!

Reduction σε ένα block

- Η αρχική ιδέα

- Reduction σε βήματα
- Σε κάθε βήμα ο αριθμός των threads που είναι ενεργά υποδιπλασιάζεται
- Το τελευταίο thread παράγει το μερικό αποτέλεσμα για το block



```
for (int stride=1;stride<THREADS;stride*=2) {  
    if (threadIdx.x%(2*stride) == 0) {  
        buffer[threadIdx.x] += buffer[threadIdx.x + stride];  
    }  
    // synchronize all threads of block  
    __syncthreads();  
}
```

Reduction σε ένα block: απαιτήσεις

- Συγχρονισμός μεταξύ threads
 - Σε κάθε βήμα μείωσης πρέπει να είμαστε σίγουροι ότι τα threads που συμμετείχαν στο προηγούμενο βήμα έχουν τελειώσει → `syncthreads()`
- Χώρος αποθήκευσης
 - Απαιτείται η προσπέλαση δεδομένων από άλλα threads του ίδιου block
 - Δεν μπορούμε να χρησιμοποιήσουμε καταχωρητές (είναι ξεχωριστοί ανά thread)
 - Χρειαζόμαστε έναν κοινό χώρο **πιο γρήγορο** από την κύρια μνήμη της GPU για ανταλλαγή δεδομένων μεταξύ των threads του block → **shared memory**

Δήλωση χώρου από το shared memory

```
__global__ void sumReduction(float *a, float *psums) {  
    __shared__ float buffer[THREADS];
```

- Χώρος για ανταλλαγή δεδομένων μεταξύ threads του block
 - Με μέγεθος ίσο με τον αριθμό των threads του block
 - Κάθε ένα από τα ενεργά threads συνδυάζει δύο αποτελέσματα από προηγούμενο βήμα (2 αναγνώσεις) και γράφει το αποτέλεσμα πίσω στο buffer (1 εγγραφή)


Απόδοση block reduction

- **Απόκλιση εκτέλεσης των threads κάθε warp**
 - Το σχήμα στην προηγούμενη διαφάνεια δεν είναι βέλτιστο
 - Τα threads εκτελούν δύο διαφορετικά μονοπάτια
 - Συμμετέχουν στη μείωση ή όχι
 - Χωρίς να υπάρχει ομοιομορφία στην απόκλιση εκτέλεσης
 - Στο ίδιο warp υπάρχουν εναλλάξ ενεργά και μη threads
 - Κάποια warps έχουν ένα ενεργό thread μέχρι το τέλος του υπολογισμού

Reduction σε ένα block (2)


- Βελτίωση απόκλισης εκτέλεσης

- Ταυτόχρονα όμως αυξάνονται οι συγκρούσεις (bank conflicts) σε shared memory (>50x)
- Τα threads του ίδιου warp προσπελούν το ίδιο bank ταυτόχρονα



```
for (int stride=1;stride<THREADS;stride*=2) {  
    int index = 2*stride*threadIdx.x;  
    if (index<THREADS) {  
        buffer[index] += buffer[index + stride];  
    }  
    // synchronize all threads of block  
    __syncthreads();  
}
```

Βελτιωμένο σχήμα reduction ενός block



Παράδειγμα κώδικα για το reduction στο block

```
// reduce block results, number of threads must be a power of 2
for (unsigned int stride = blockDim.x/2; stride>0; stride /= 2)
{
    if (tid<stride) {
        buffer[tid] += buffer[tid+stride];
    }

    // synchronize all threads of block before next step
    __syncthreads();
}
```

- Σε κάθε βήμα τα threads που βρίσκονται στο «κάτω μισό» προσθέτουν την αντίστοιχη τιμή από το «πάνω μισό»
 - tid είναι το threadIdx.x
- Ο χώρος μειώνεται στο μισό και επαναλαμβάνουμε στο επόμενο βήμα