

Grafikus kártyák programozása

Optimalizálás

Tóth Gyula

MTA-SZFKI

MTA-RMKI, Budapest, 2011. július 8.

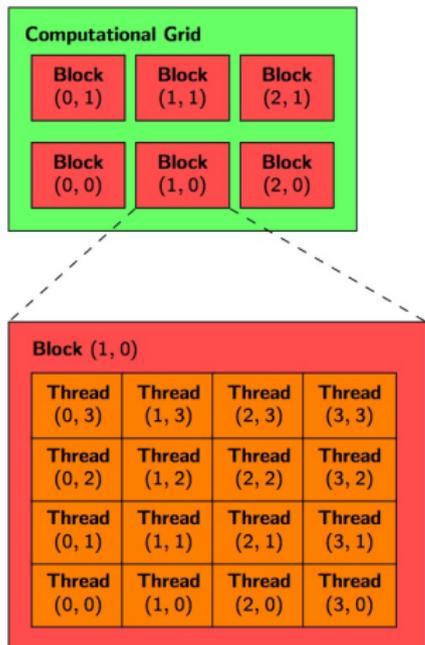


Tartalom

- 1 Bevezetés
 - A CUDA futtatási modellje
 - A párhuzamos feladat
- 2 Programozási folyamat
 - Make it work. - A működő párhuzamos kódig
 - Make it right. - A helyes eredmény
 - Make it fast. - Optimalizálás
- 3 Optimalizálás - elmélet
 - Memóriakezelés: global & shared
 - Pontosság vagy sebesség? IEEE-754 vs. GPU
 - További lehetőségek
- 4 Optimalizálás - gyakorlat
 - 1. példa: radiális eloszlásfüggvény
 - 2. példa: lineáris tömb elemeinek összeadása
- 5 Összefoglalás



A CUDA futtatási modell



A számítási háló (Computational grid)

- 1 A párhuzamosan futtatandó program a mag (**kernel**)
- 2 A magot szálak (**thread**) futtatják
- 3 A szálak 1,2 v. 3 dimenziós logikai csoportja a blokk (**block**)
- 4 A blokkok 1 v. 2 dimenziós logikai csoportja a teljes számítási háló (**grid**)

Adatpárhuzamosítás

Egyértelmű háló \Leftrightarrow adathalmaz megfeleltetés az egyéni szálonosítókön keresztül

Implementáció

Feladat: az adathalmaz párhuzamosítása (**grid**) + a számítási feladat párhuzamosítása (**kernel**)

Make it work. Make it right. Make it fast.

"Premature optimization is the root of all evil."

A párhuzamos optimalizálás területei

- Az implementáció optimalizálása az architektúrára
- Az optimális implementáció optimalizálása

Megéri?

- **A feladatmegoldás ideje (τ) = programfejlesztési idő (τ_p) + futtatási idő (τ_f)**
- Hibajavítási (**debug**) idő: $\tau_d^{\text{soros}} \ll \tau_d^{\text{párhuzamos}}$
- Murphy: $\tau_p \approx \tau_d \Rightarrow$ Előfordulhat, hogy $\tau^{\text{soros}} < \tau^{\text{párhuzamos}}$



Make it work. - A működő párhuzamos kódig

$n * m$ -es mátrixok összeadása

CPU függvény

```
void add_matrix(float *a,float *b,float *c,int
n,int m){

int idx;

for (idx=0; idx<n*m; idx++)
c[idx]=a[idx]+b[idx];

}
```

- Lineáris tömbkezelés:
 $a[n][m]$ 2D tömb NEM folytonos
- Egyszerű soros ciklus
- CPU *host* memórián dolgozik
⇒ A főprogramból közvetlenül hívható

GPU mag

```
__global__
void add_matrix(float *a,float *b,float *c,int n,int m){

int whoami=blockDim.x*blockIdx.x+threadIdx.x;

if (whoami<n*m)
c[whoami]=a[whoami]+b[whoami];

}
```

- Eltűnt a *for* ciklus,
minden szál egyetlen összeadást végez
 $whoami = 0 \dots gridDim.x * blockDim.x - 1$
- Lineáris tömbkezelés, 1D háló: Ha
 $blockDim.x * gridDim.x \geq n * m$
⇒ minden elemet lefedtünk!
- GPU *device* memórián dolgozik



Make it work. - A működő párhuzamos kódig

$n * m$ -es mátrixok összeadása

Hívás a CPU-ról

```
__device__  
float *a_gpu,*b_gpu,*c_gpu;  
  
main(){  
  
float *a,*b,*c;  
  
// ...  
  
cudaMemcpy(a_gpu,a,N*M*sizeof(float),cudaMemcpyHostToDevice);  
cudaMemcpy(b_gpu,b,N*M*sizeof(float),cudaMemcpyHostToDevice);  
  
dim3 threads(THREADS);  
dim3 grid(N*M/THREADS+1);  
  
add_matrix<<<grid,threads>>>(a_gpu,b_gpu,c_gpu,N,M);  
  
cudaMemcpy(c,c_gpu,N*M*sizeof(float),cudaMemcpyDeviceToHost);  
  
// ...  
}
```

GPU mag

```
__global__  
void add_matrix(float *a,float *b,float *c,int  
n,int m){  
  
int whoami=blockDim.x*blockIdx.x+threadIdx.x;  
  
if (whoami<n*m)  
c[whoami]=a[whoami]+b[whoami];  
  
}
```

Folyamat

- Adatok felmásolása a GPU-ra
- A mag futtatása megadott hálón
- Az eredmény másolása a CPU-ra



Make it right. - A helyes eredmény

Az eredmény helyessége

- Informatikai helyesség:
helyes kernel művelet sor (soros debug) & helyes párhuzamosítás (!)
- Pontosság:
Az informatikailag helyesen futó program eredménye megfelel a kívánalmaknak?

Általános GPU hibák

- Informatikai hibák:
Helytelen párhuzamos adatkezelés, szinkronizációs hiba, rossz adathalmaz lefedés
- Pontosság:
A GPU **nativ** műveleteinek ismerete (IEEE-754 kivételek)

Figyelem!

A GPU gyors 3D ábrázolásra készült, nem tudományos szuperszámítógépnek!



Make it fast. - Optimalizálás

Memóriahasználat

- global memory (**coalesced memory access**):
A (**lassú**) globális memória írása/olvasása **nagyságrendekkel** felgyorsítható.
- multiprocessor cache (**shared memory**):
kisebb ($\sim 16kB$), de **gyors** memória, egy blokk számára látható

Egyéb

- Ciklus kifejtés (loop unrolling): $\tau_{loop+arithmetic} > N \times \tau_{arithmetic}$
- Beépített adattípusok - float2, float3, float4, double2, stb.
- GPU nativ függvények - minél pontosabb, annál lassabb...
- Algoritmus csere - hatékonyabb implementáció
- A fordítás optimalizálása - kapcsolók



GLOBAL MEMORY: Coalesced Memory access

Alapprobléma

A globális memória látens ideje 400-600 órajel (1 összeadás = 4 órajel)

Fizikai futtatási modell: **warp** - a szálak fizikailag 32-es csokrokban futnak

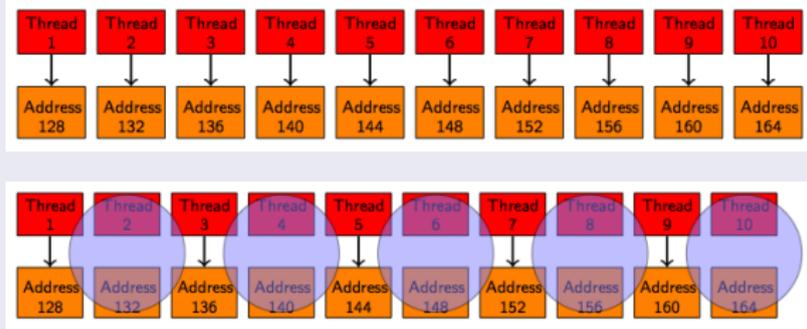
A szálak hozzáférése a globális memóriához **rendezett**, amennyiben:

- A memóriatartomány összefüggő és **rendezett**:
 - **128 byte**: minden szál egy *float* v. egy *int* adatot olvas
 - **256 byte**: minden szál egy *float2* v. egy *int2* adatot olvas
 - **512 byte**: minden szál egy *float4* v. egy *int4* adatot olvas
 - a *float3* NEM rendezett!!!
- A *warp* olvasási báziscíme (*WBA*) $16 \times \text{sizeof}(\text{type})$ többszöröse
- Egy csokron belül a *k*. szál éppen a $(\text{WBA}+k)$. elemhez fér hozzá
- A memóriaműveletben nem muszáj minden szálnak részt venni
- A fenti szabályok írásra és olvasásra egyaránt vonatkoznak



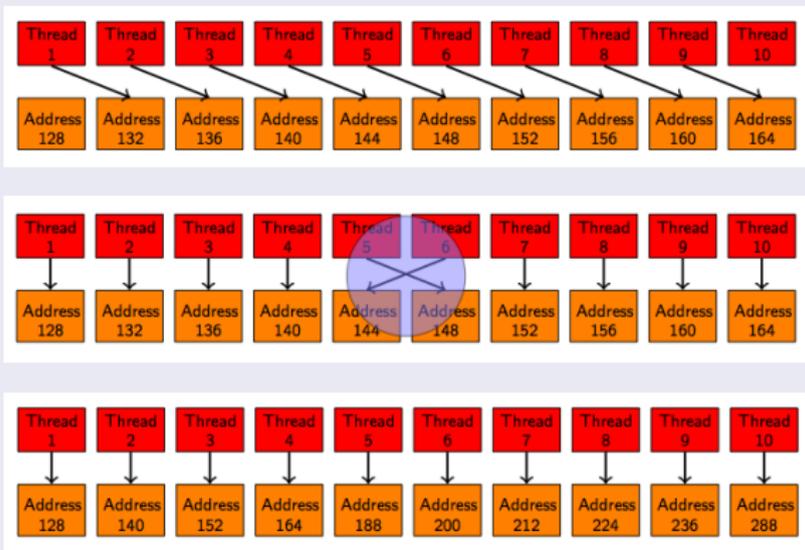
GLOBAL MEMORY: Coalesced Memory access

Rendezett memória hozzáférés:



GLOBAL MEMORY: Coalesced Memory access

NEM rendezett memória hozzáférés:



SHARED MEMORY

Feladat: Négyzetes ($n * n$) mátrix transzponálása

Naiv GPU mag

```
__global__  
void transpose_matrix_naive(float *in,float *out,int n){  
  
int i=blockDim.x*blockIdx.x+threadIdx.x;  
int j=blockDim.y*blockIdx.y+threadIdx.y;  
  
if ((i<n)&&(j<n))  
    out[i*n+j]=in[j*n+i];  
  
}
```

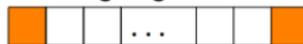
Memóriahozzáférés

Reading from global mem:



stride=1, coalesced

Writing to global mem:



stride=16, uncoalesced



SHARED MEMORY

Megoldás a shared memory használatán keresztül

Naiv modell

- rendezett olvasás (gyors)
- NEM rendezett írás (lassú)

GPU modell

- rendezett olvasás:
global → shared (gyors)
- transzponálás:
shared → shared (gyors)
- rendezett írás:
shared → global (gyors)

Read from global mem

| | | | | |
|-------|-------|-------|---|-------|
| 0,0 | 0,1 | 0,2 | • | 0,15 |
| 1,0 | 1,1 | 1,2 | • | 1,15 |
| • | • | • | • | • |
| 15, 0 | 15, 1 | 15, 2 | • | 15,15 |

Write to shared mem

| | | | | |
|-------|-------|-------|---|-------|
| 0,0 | 0,1 | 0,2 | • | 0,15 |
| 1,0 | 1,1 | 1,2 | • | 1,15 |
| • | • | • | • | • |
| 15, 0 | 15, 1 | 15, 2 | • | 15,15 |

Read "transposed" address from SMEM

| | | | | |
|-------|-------|-------|---|-------|
| 0,0 | 1,0 | 2,0 | • | 15,0 |
| 0,1 | 1,1 | 2,1 | • | 15,1 |
| • | • | • | • | • |
| 0, 15 | 1, 15 | 2, 15 | • | 15,15 |

Write to global mem

| | | | | |
|-------|-------|-------|---|-------|
| 0,0 | 1,0 | 2,0 | • | 15,0 |
| 0,1 | 1,1 | 2,1 | • | 15,1 |
| • | • | • | • | • |
| 0, 15 | 1, 15 | 2, 15 | • | 15,15 |



SHARED MEMORY

Gyors GPU mag

```
__global__  
void transpose(float *in,float *out,int n) {  
    __shared__float block[BLOCK_DIM*BLOCK_DIM];  
  
    int xBlock=blockDim.x*blockIdx.x;  
    int yBlock=blockDim.y*blockIdx.y;  
    int xIndex=xBlock+threadIdx.x;  
    int yIndex=yBlock+threadIdx.y;  
  
    int index_out, index_transpose;  
  
    if ((xIndex<n)&&(yIndex<n)) {  
        int index_in=n*yIndex+xIndex;  
        int index_block=threadIdx.y*BLOCK_DIM+threadIdx.x;  
  
        block[index_block]=in[index_in];  
  
        index_transpose=threadIdx.x*BLOCK_DIM+threadIdx.y;  
        index_out=n*(xBlock+threadIdx.y)+(yBlock+threadIdx.x);  
    }  
  
    __syncthreads();  
  
    if ((xIndex<n)&&(yIndex<height)) {  
        out[index_out]=block[index_transpose];  
    }  
}
```

Naiv GPU mag

```
__global__  
void transpose_matrix_naive(float *in,float *out,int n){  
  
    int i=blockDim.x*blockIdx.x+threadIdx.x;  
    int j=blockDim.y*blockIdx.y+threadIdx.y;  
  
    if ((i<n)&&(j<n))  
        out[i*n+j]=in[j*n+i];  
  
}
```

Megérte?

| Grid Size | Coalesced | Non-coalesced | Speedup |
|-------------|-----------|---------------|---------|
| 128 × 128 | 0.011 ms | 0.022 ms | 2.0× |
| 512 × 512 | 0.07 ms | 0.33 ms | 4.5× |
| 1024 × 1024 | 0.30 ms | 1.92 ms | 6.4× |
| 1024 × 2048 | 0.79 ms | 6.6 ms | 8.4× |



SHARED MEMORY

`__syncthreads()`

- Az egy blokkban futó szálak ennél az utasításnál "bevárják" egymást
- shared memory használat esetén a szálak tudnak "egymásnak" dolgozni:
 - transzponálás: egy szál $s(i, j)$ -t írja, de $s(j, i)$ -t olvassa!
 - molekuladinamika: egy szál az i . atom adatait tölti be ($i \in [0 \dots THREADS - 1]$) de mindenkiét használja - összes párkölcsönhatás!

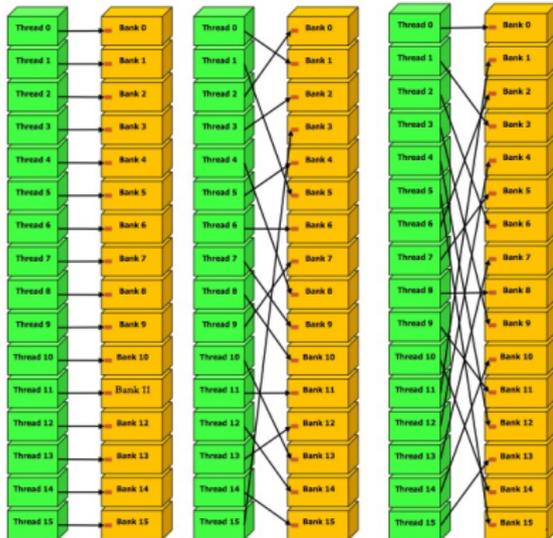
A shared memory hozzáférés modellje: bank conflict

- Regiszter sávszélesség (32 bit / 2 órajel) biztosítása: shared memory = 16 × **bank**
- ideális hozzáférés: 1 szál \Leftrightarrow 1 bank
- n -utas **bank conflict**: n szál \rightarrow 1 bank (\Rightarrow soros: $n \times 1$ hozzáférés)
warp = 32 szál \Rightarrow fordító $\rightarrow 2 \times 16$ felosztású hozzáférés
- A shared változó tárolási rendje: lineáris, 32 bites szavanként periodikusan \Rightarrow Egy lineáris *float* típusú tömb esetén biztosan NINCS bank conflict!

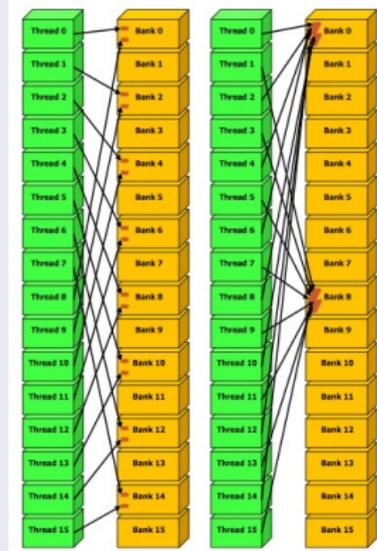


SHARED MEMORY - Bank conflict példák

No bank conflict



Bank conflict



Az IEEE-754 és a GPU

Az IEEE-754 szabvány

A számítástechnikai eszközök számítási szabványa

- digitális számábrázolási szabványok
- műveleti pontosság szabványai - kerekítés, vágás?

A GPU gyári utasításkészlete

- Alapfeladat: + és * gyors elvégzése \Rightarrow kisebb átmeneti tár
- Utasításkészlet: jóval kisebb, mint a CPU-é, de van "mad": $a * b + c$
 \rightarrow A fordító megteszi a lehetséges összevonásokat a kódból!

A GPU *float* műveleti pontossága - IEEE-754 kivételek

- + és *: IEEE-754 pontos
- *mad*, valamint bonyolultabb NATIV műveletek ($1/x$, y/x , \sqrt{x} , $\exp(x)$, ...) pontatlanabbak (vágás)
- szoftveres megoldások a CPU pontosságának elérésére (de lassabbak...!)



Példa: elemenkénti $A * B + C$

"naiv" GPU mag

```
__global__  
void mad(float *A,float *B,float *C,float *D,int n){  
  
int whoami=blockDim.x*blockIdx.x+threadIdx.x;  
  
if (whoami<n*n)  
    D[whoami]=A[whoami]*B[whoami]+C[whoami];  
}
```

IEEE-754 helyes GPU mag

```
__global__  
void mad(float *A,float *B,float *C,float *D,int n){  
  
int whoami=blockDim.x*blockIdx.x+threadIdx.x;  
  
if (whoami<n*n)  
    D[whoami]=__fmf_rn(A[whoami],B[whoami],C[whoami]);  
}
```

Gépi kód

+ és * összevonása *mad* műveletté
⇒ + és * külön-külön IEEE-754 pontos,
de *mad* nem!

Gépi kód

Nincs összevonás fordításnál
__fmf_xx() : IEEE-754 pontos *mad*
⇒ Lassabb, de pontosabb

A GPU programozás "kereskedelem": pontosság + gyorsaság \approx const.



Műveleti idők

Natív műveletek

- 4 clock cycles:
 - Floating point: add, multiply, fused multiply-add
 - Integer add, bitwise operations, compare, min, max
- 16 clock cycles:
 - reciprocal, reciprocal square root, $_log(x)$, 32-bit integer multiplication
- 32 clock cycles:
 - $_sin(x)$, $_cos(x)$ and $_exp(x)$
- 36 clock cycles:
 - Floating point division (24-bit version in 20 cycles)
- Particularly costly:
 - Integer division, modulo
 - **Remedy: Replace with shifting whenever possible**
- Double precision (when available) will perform at half the speed

Tanács

Kerüljük az **osztást**, a maradékképzést, és a magasabb szintű függvényeket!



A feladat

- Adott N db részecske 3D-ben: $\{x_i, y_i, z_i\}$, $i = 1 \dots N$.
- Készítsünk hisztogramot (h) a páronkénti távolságukból ($BINS, DR$)!
- Fizika: $g[(i + 1/2)DR] = \frac{2}{N} h[i]/dV_i$ (Radial Distribution Function)

CPU kód

```
void rdf(void){  
  
int i,j;  
  
for (i=0; i<N-1; i++)  
    for (j=i+1; j<N; j++)  
        if ((int)(dist(i,j)/DR)<BINS) h[idx]++;  
  
}
```

CPU kód

```
float dist(int i,int j){  
  
float dx=x[i]-x[j];  
float dy=y[i]-y[j];  
float dz=z[i]-z[j];  
  
return(sqrtf(dx*dx+dy*dy+dz*dz));  
  
}
```

Implementációs probléma

A változó hosszúságú belső ciklus nem jól párhuzamosítható!



Alternatív implementáció

- A részecskék koordinátái: $x[i], y[i], z[i]$ lineáris tömbök, $i = 0 \dots N - 1$
- $dist(i, j)$, ahol $j = (i + d) \% N$, ciklus $i = 0 \dots N - 1$, valamint $d = 1 \dots N/2 - 1$ -re

CPU kód I.

```
void rdf(void){
    int i,j;

    for (i=0; i<N-1; i++)
        for (j=i+1; j<N; j++)
            if ((int)(dist(i,j)/DR)<BINS) h[idx]++;
}
```

CPU kód II.

```
void rdf(void){
    int d,i;

    for (d=1; d<N/2; d++)
        for (i=0; i<N; i++)
            if ((int)(dist(i,(i+d)%N)/DR)<BINS) h[idx]++;
}
```



naiv GPU mag

```
--global--  
void gpu_test_kernel(float *x,float *y,float *z,int  
*h,int d){  
  
int whoami=blockIdx.x*blockDim.x+threadIdx.x;  
int idx;  
  
if (whoami<N){  
    idx=(whoami+d)%N;  
    float3 p1,p2;  
    p1.x=x[whoami]; p1.y=y[whoami]; p1.z=z[whoami];  
    p2.x=x[idx];    p2.y=y[idx]; p2.z=z[idx];  
    idx=(int)(__fdiv_rn(dist(p1,p2),DR));  
    if (idx<BINS)  
        atomicAdd(h+idx,1);  
}  
}
```

GPU kód

```
--device--  
float dist(float3 p1,float3 p2){  
  
    float dx=p1.x-p2.x;  
    float dy=p1.y-p2.y;  
    float dz=p1.z-p2.z;  
  
    float dx2=__fmul_rn(dx,dx);  
    float dy2=__fmul_rn(dy,dy);  
    float dz2=__fmul_rn(dz,dz);  
  
    float tmp=__fadd_rn(dx2,dy2);  
    float d2=__fadd_rn(tmp,dz2);  
  
    float d=__fsqrt_rn(d2);  
  
    return(d);  
}
```

Tulajdonságok:

- A GPU távolságszámoló függvénye és az osztás a magban CPU pontos (IEEE-754)
- Egy új függvény: `__atomicAdd(int *,int)` (sm_12)



Optimalizálás

A naiv GPU mag "hibái"

- A beolvasás, bár rendezett, 3 tömbre fut
- Központi probléma: a memóriahozzáférés a kiemeneten ($h[idx]++$)
ADATFÜGGŐ
A memória írás BIZTOSAN NEM rendezett, sőt, *atomic* függvényre van szükség.

Megoldás

- A rendezett beolvasás *float4* segítségével gyorsítható (*float3*-mal nem, mert az memóriaművelet szempontból NEM rendezett!)
- Definiáljunk al-hisztogramokat a blokkokon a shared memory-ba!
→ Az al-hisztogramokat a számítás végén rendezetten egyesítjük



Optimalizált RDF

(koránt sem naív) GPU mag

```
__global__  
void gpu_test_kernel(float4 *p,int *h,int d){  
  
    int whoami=blockIdx.x*blockDim.x+threadIdx.x;  
    int idx;  
  
    __shared__int sh[BINS];  
  
    for (int i=0; i<D; i++){  
        sh[i*THREADS+threadIdx.x]=0;  
        __syncthreads();  
  
        if (whoami<N){  
            idx=(whoami+d)%N;  
            float4 p1=p[whoami];  
            float4 p2=p[idx];  
            idx=(int)(__fdiv_rn(dist(p1,p2),DR));  
            if (idx<BINS)  
                atomicAdd(sh+idx,1);  
        }  
        __syncthreads();  
  
        for (int i=0; i<D; i++){  
            idx=i*THREADS+threadIdx.x;  
            atomicAdd(h+idx,sh[idx]);  
        }  
    }  
}
```

GPU kód

```
__device__  
float dist(float4 p1,float4 p2){  
  
    float dx=p1.x-p2.x;  
    float dy=p1.y-p2.y;  
    float dz=p1.z-p2.z;  
  
    float dx2=__fmul_rn(dx,dx);  
    float dy2=__fmul_rn(dy,dy);  
    float dz2=__fmul_rn(dz,dz);  
  
    float tmp=__fadd_rn(dx2,dy2);  
    float d2=__fadd_rn(tmp,dz2);  
  
    float d=__fsqrt_rn(d2);  
  
    return(d);  
}
```

- gyors shared műveletek
- bank conflict (random pattern)
- rendezett global műveletek



Teszteredmények

$N = 44028, BINS/THREADS = 1, THREADS = 512$

- 1 CPU mag: 58.23 s
- GPU naiv (*float4*, no shared): 16.3 s (3.57x)
- GPU optim. 1 (*float4*, shared): 1.9 s (30.6x)
- GPU optim. 2 (teljes probléma kernel): < 1s (> 60x)

Üzenet: $\tau_{CPU}^{single} / \tau_{GPU}^{ideal} > 60$ (Fermi + CUDA 4.0: $\approx 500!$)

A kimeneti oldalon rosszul kondicionált probléma ellenére úgy tűnik, megérte!

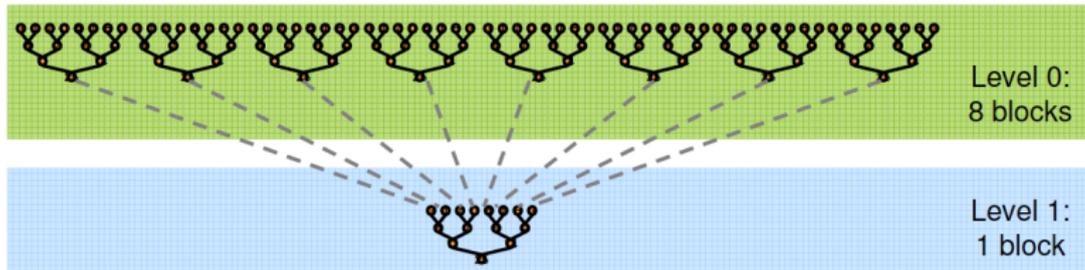
Megjegyzések

- Az IEEE-754 pontosság kikapcsolása 5.0%; (% \rightarrow if) áttérés 2.5%
- shared memory $\rightarrow \tau \approx 1/THREADS \Rightarrow$ A rendezetlen írás a szűk keresztmetszet
- Teljes probléma kernel, `__atomicAdd()` \rightarrow bitwise, $\dots \rightarrow \dots$



A feladat

Adjuk össze egy lineáris tömb elemeit párhuzamos GPU kóddal!



A GPU kernel feladata

- Adatlefedés: $N \text{ block} \times T \text{ thread} \rightarrow T$ db elem részösszege blokkonként
- Bemenet \rightarrow kimenet: $N \times T$ hosszú lineáris tömb $\rightarrow N$ hosszú lineáris tömb
- Rekurzív (iteratív) kernel hívás a részösszegek tömbjén, míg előáll a teljes összeg

A feladat alapszintű megoldása

$T = 2^p$ elemszámú tömb elemeinek összeadása párhuzamos redukcióval

Naiv kernel

```
__global__ void reduce0(int *g_idata, int *g_odata) {
    extern __shared__ int sdata[];

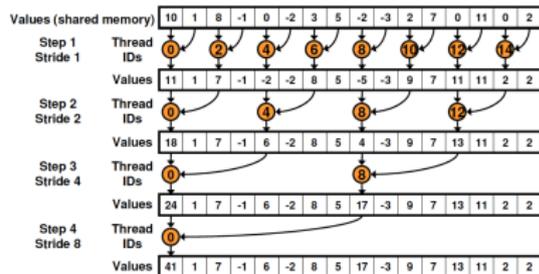
    // each thread loads one element from global to shared mem
    unsigned int tid = threadIdx.x;
    unsigned int i = blockIdx.x*blockDim.x + threadIdx.x;
    sdata[tid] = g_idata[i];
    __syncthreads();

    // do reduction in shared mem
    for(unsigned int s=1; s < blockDim.x; s *= 2) {
        if (tid % (2*s) == 0) {
            sdata[tid] += sdata[tid + s];
        }
        __syncthreads();
    }

    // write result for this block to global mem
    if (tid == 0) g_odata[blockIdx.x] = sdata[0];
}
```

Az eljárás elemei

- A tömb beolvasása a shared memory-ba
- Az elemek összeadása ciklikus redukcióval
- Az eredmény kiírása a globális memóriába



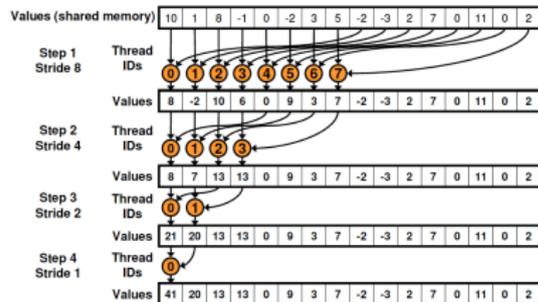
Optimalizálás

"Az állatorvosi ló"

- 1 **divergent warps + %**: nem egymás utáni thread-ek futnak + % sokba kerül
- 2 **shared memory bank conflict**: több thread egyszerre akar ugyanahhoz a területhez férni
- 3 **Idle threads**: a thread-ek fele eleve nem csinál semmit a beolvasáson kívül
- 4 **loop unrolling #1**: az utolsó warp-ban sok a felesleges művelet
- 5 **loop unrolling #2**: ha tudnánk a szükséges iterációk számát, meg lehetne szüntetni a ciklust
- 6 **complexity problem**: túl kevés aritmetikai művelet vs. túl sok memóriaművelet / thread

Sok kicsi sokra megy!

- 1 Első 2^n dolgozik - $2.33\times$
- 2 stride-olt összeadás - $2.01\times$
- 3 1. összeadás beolvasáskor - $1.78\times$
- 4 utolsó warp kifejtés - $1.8\times$
- 5 teljes ciklus kifejtés - $1.41\times$
- 6 algoritmus kaszkád - $1.41\times$

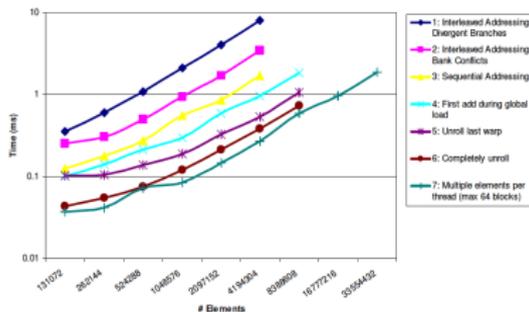


Eredmény

Performance

| | Time (2 ²² ints) | Bandwidth | Step Speedup | Cumulative Speedup |
|--|-----------------------------|-------------|--------------|--------------------|
| Kernel 1: interleaved addressing with divergent branching | 8.054 ms | 2.083 GB/s | | |
| Kernel 2: interleaved addressing with bank conflicts | 3.456 ms | 4.854 GB/s | 2.33x | 2.33x |
| Kernel 3: sequential addressing | 1.722 ms | 9.741 GB/s | 2.01x | 4.68x |
| Kernel 4: first add during global load | 0.965 ms | 17.377 GB/s | 1.78x | 8.34x |
| Kernel 5: unroll last warp | 0.536 ms | 31.289 GB/s | 1.8x | 15.01x |
| Kernel 6: completely unrolled | 0.381 ms | 43.996 GB/s | 1.41x | 21.16x |
| Kernel 7: multiple elements per thread | 0.268 ms | 62.671 GB/s | 1.42x | 30.04x |

Kernel 7 on 32M elements: 73 GB/s!



Az optimális kernel

```
template <unsigned int blockSize>
__global__ void reduce6(int *g_idata, int *g_odata, unsigned int n)
{
    extern __shared__ int sdata[];
```



Final Optimized Kernel

```
    unsigned int tid = threadIdx.x;
    unsigned int i = blockIdx.x*(blockSize*2) + tid;
    unsigned int gridSize = blockSize*2*gridDim.x;
    sdata[tid] = 0;
```

```
    while (i < n) { sdata[tid] += g_idata[i] + g_idata[i+blockSize]; i += gridSize; }
    __syncthreads();
```

```
    if (blockSize >= 512) { if (tid < 256) { sdata[tid] += sdata[tid + 256]; } __syncthreads(); }
    if (blockSize >= 256) { if (tid < 128) { sdata[tid] += sdata[tid + 128]; } __syncthreads(); }
    if (blockSize >= 128) { if (tid < 64) { sdata[tid] += sdata[tid + 64]; } __syncthreads(); }
```

```
    if (tid < 32) {
        if (blockSize >= 64) sdata[tid] += sdata[tid + 32];
        if (blockSize >= 32) sdata[tid] += sdata[tid + 16];
        if (blockSize >= 16) sdata[tid] += sdata[tid + 8];
        if (blockSize >= 8) sdata[tid] += sdata[tid + 4];
        if (blockSize >= 4) sdata[tid] += sdata[tid + 2];
        if (blockSize >= 2) sdata[tid] += sdata[tid + 1];
    }
```

```
    if (tid == 0) g_odata[blockIdx.x] = sdata[0];
```

35

Üzenet: 30x gyorsabb, de...

"Nem kezdőnek való vidék"



A GPU programozás optimalizálása

- A feladat: adatpárhuzamosítás (**grid**) + művelet párhuzamosítás (**kernel**)
- "Premature optimization is the root of all evil."
⇒ Programozási modell: MAKE IT WORK. MAKE IT RIGHT. MAKE IT FAST.
- Az optimalizálás fő területei:
 - A feladat ideális implementációja az architektúrához!
 - memóriakezelés (global és shared)- nagy gyorsulások
 - Egyéb: $\approx 2 \times$ faktorok, de sok - nem kezdőknek való!
- Pontosság: A GPU gyors 3D ábrázoló, nem tudományos szuperszámítógép!
- MEGÉRI? - $\tau_{\text{feladatmagoldás}} = \tau_{\text{programfejlesztés}} + \tau_{\text{programfuttatás}}$
- GPU vs. CPU verseny: gyors fejlődés, érdemes várni a kész megoldásokra!

