

# Optimalizace

Jiří Filipovič

podzim 2010

# Naivní implementace

```
--global__ void mmul(float *A, float *B, float *C, int n){  
    int x = blockIdx.x*blockDim.x + threadIdx.x;  
    int y = blockIdx.y*blockDim.y + threadIdx.y;  
  
    float tmp = 0;  
    for (int k = 0; k < n; k++)  
        tmp += A[y*n+k] * B[k*n+x];  
  
    C[y*n + x] = tmp;  
}
```

## Co jsme se naučili

## Naivní implementace algoritmu

- každý thread zpracovává odděleně jeden element výsledné matice
  - omezena propustností paměti
  - teoretické maximum jsme určili jako 66.8 GFlops
  - výkon velmi závislý na uspořádání threadů – bloky  $128 \times 1$  dávají výkon 36.6 GFlops, bloky  $1 \times 128$  3.9 GFlops

# Co jsme se naučili

## Naivní implementace algoritmu

- každý thread zpracovává odděleně jeden element výsledné matice
- omezena propustností paměti
- teoretické maximum jsme určili jako 66.8 GFlops
- výkon velmi závislý na uspořádání threadů – bloky  $128 \times 1$  dávají výkon 36.6 GFlops, bloky  $1 \times 128$  3.9 GFlops

Nyní rozumíme rozdílným výsledkům

- teoretického maxima nelze docílit – z paměti GPU přenášíme po nejméně 32-bytových částech, musíme tedy přenést více dat, než je nutné
- je-li 128 threadů v bloku zarovnáno ve smyslu osy  $x$ , je přenos dat neprokládaný, v opačném případě je prokládaný

# Co jsme se naučili

Navrhli jsme blokovou implementaci

- každý blok threadů načítá bloky matic  $A$  a  $B$  do sdílené paměti, znova užívá data ke snížení omezení přenosovou rychlosťí globální paměti
- teoretické maximum 568 GFlops, dosáhli jsme 198 GFlops

S novými znalostmi můžeme jeho implementaci přehodnotit...

# Násobení po blocích

```
--global__ void mmul(float *A, float *B, float *C, int n){  
    int bx = blockIdx.x;  
    int by = blockIdx.y;  
    int tx = threadIdx.x;  
    int ty = threadIdx.y;  
    __shared__ float As[BLOCK][BLOCK];  
    __shared__ float Bs[BLOCK][BLOCK];  
  
    float Csub = 0.0f;  
    for (int b = 0; b < n/BLOCK; b++){  
        As[ty][tx] = A[(ty + by*BLOCK)*n + b*BLOCK+tx];  
        Bs[ty][tx] = B[(ty + b*BLOCK)*n + bx*BLOCK+tx];  
        __syncthreads();  
  
        for (int k = 0; k < BLOCK; k++)  
            Csub += As[ty][k]*Bs[k][tx];  
        __syncthreads();  
    }  
    C[(ty + by*BLOCK)*n + bx*BLOCK+tx] = Csub;  
}
```

## Hříchy implementace

```

As[ty][tx] = A[(ty + by*BLOCK)*n + b*BLOCK+tx];
Bs[ty][tx] = B[(ty + b*BLOCK)*n + bx*BLOCK+tx];
...
C[(ty + by*BLOCK)*n + bx*BLOCK+tx] = Csub;

```

Přístup do globální paměti se zdá být v pořádku.

```
Csub += As[ty][k]*Bs[k][tx];
```

Přístup do sdílené také

- má-li blok threadů velikost ve smyslu osy  $x$  násobek velikosti warpu, dochází u proměnné  $As$  k broadcastu
  - proměnná  $Bs$  je čtena v souvislých řádcích, přístup tedy negeneruje konflikty bank

# Teoretické maximum

Lze určit přesněji teoretické omezení výkonu?

- maximum jsme určili podle výkonu GPU v MAD instrukcích (622 GFlops)
- nyní víme, že MAD instrukce pracující s operandem ve sdílené paměti pracují rychlostí 6 taktů na warp
- nově lze tedy teoretické maximum určit jako 415 GFlops
- stále jsme od něj však daleko

# Ztráty výkonu

Co nás vzdaluje od maxima?

- overhead spuštění kernelu a spouštění threadů
  - z principu se mu nevyhneme, počet threadů lze redukovat
- operace „režije“
  - pointerová aritmetika, cykly
  - lze redukovat
- synchronizace
  - může a nemusí být problém
- load/store ve výpočtu
  - dva operandy v SMEM na jednu MAD instrukci
  - je tedy zapotřebí jeden load na jednu MAD

Počítáme-li výkonový strop pro kombinaci load + MAD s operandem ve sdílené paměti, dostaneme se k omezení 244 GFlops.

- od toho již nejsou naměřené výsledky příliš vzdáleny

# Nalezení lepší implementace

Lze počet load instrukcí omezit?

# Nalezení lepší implementace

Lze počet load instrukcí omezit?

- data ve sdílené paměti snižují přenosy z paměti globální

# Nalezení lepší implementace

Lze počet load instrukcí omezit?

- data ve sdílené paměti snižují přenosy z paměti globální
- můžeme snížit přenosy ze sdílené paměti pomocí dat v registrech?

# Nalezení lepší implementace

Lze počet load instrukcí omezit?

- data ve sdílené paměti snižují přenosy z paměti globální
- můžeme snížit přenosy ze sdílené paměti pomocí dat v registrech?
- můžeme – stačí nechat pracovat méně threadů nad více daty

# Nalezení lepší implementace

Lze počet load instrukcí omezit?

- data ve sdílené paměti snižují přenosy z paměti globální
- můžeme snížit přenosy ze sdílené paměti pomocí dat v registrech?
- můžeme – stačí nechat pracovat méně threadů nad více daty

Blok o velikosti  $m \times n$  threadů necháme pracovat s daty o velikosti  $m \times m$ , kde  $m = n \cdot k$ ;  $k \in N$ .

- větší bloky potenciálně nevýhodné kvůli synchronizaci
- menší bloky potenciálně nevýhodné kvůli overheadu daném pointerovou aritmetikou
- experimentálně najdeme vhodnou velikost bloku

# Nalezení lepší implementace

Nejlepší výsledky dosaženy pro bloky velikosti  $32 \times 32$ , na kterých pracuje  $32 \times 16$  threadů.

- půl loadu na jednu MAD instrukci dává teoretické omezení 311 GFlops
- naměřili jsme 235.4 GFlops
- něco je ještě špatně

# Deassembling kódu

Zaměříme se na vnitřní smyčku

```
Csub1 += As[ty][k]*Bs[k][tx];  
Csub2 += As[ty+16][k]*Bs[k][tx];
```

```
...  
mov.b32 $r0, s[$ofs4+0x0000]  
add.b32 $ofs4, $ofs2, 0x00000180  
mad.rn.f32 $r7, s[$ofs1+0x0008], $r0, $r7  
mad.rn.f32 $r8, s[$ofs3+0x0008], $r0, $r8  
...
```

# Deassembling kódu

Zaměříme se na vnitřní smyčku

```
Csub1 += As[ty][k]*Bs[k][tx];  
Csub2 += As[ty+16][k]*Bs[k][tx];
```

```
...  
mov.b32 $r0, s[$ofs4+0x0000]  
add.b32 $ofs4, $ofs2, 0x00000180  
mad.rn.f32 $r7, s[$ofs1+0x0008], $r0, $r7  
mad.rn.f32 $r8, s[$ofs3+0x0008], $r0, $r8  
...
```

Kompilátor dokázal převést adresaci přes  $k$  na konstantní offsety pouze u proměnné  $As$

- $k$   $Bs$  je přistupováno prokládaně
- znamená to jednu add instrukci navíc

# Odstanění add instrukce

Do pole  $Bs$  můžeme ukládat transponovaná data, pak vypadá kód vnitřní smyčky takto

```
Csub1 += As[ty][k]*Bs[tx][k];  
Csub2 += As[ty+16][k]*Bs[tx][k];
```

# Odstanění add instrukce

Do pole  $Bs$  můžeme ukládat transponovaná data, pak vypadá kód vnitřní smyčky takto

```
Csub1 += As[ty][k]*Bs[tx][k];
Csub2 += As[ty+16][k]*Bs[tx][k];
```

Ve výsledném assembleru již instrukce add chybí

```
...
mov.b32 $r0, s[$ofs4+0x0008]
mad.rn.f32 $r6, s[$ofs3+0x0034], $r0, $r6
mad.rn.f32 $r8, s[$ofs1+0x0008], $r0, $r8
...
```

# Odstanění add instrukce

Do pole  $Bs$  můžeme ukládat transponovaná data, pak vypadá kód vnitřní smyčky takto

```
Csub1 += As[ty][k]*Bs[tx][k];
Csub2 += As[ty+16][k]*Bs[tx][k];
```

Ve výsledném assembleru již instrukce add chybí

```
...
mov.b32 $r0, s[$ofs4+0x0008]
mad.rn.f32 $r6, s[$ofs3+0x0034], $r0, $r6
mad.rn.f32 $r8, s[$ofs1+0x0008], $r0, $r8
...
```

Nový problém – konflikty bank sdílené paměti

# Odstanění add instrukce

Do pole  $Bs$  můžeme ukládat transponovaná data, pak vypadá kód vnitřní smyčky takto

```
Csub1 += As[ty][k]*Bs[tx][k];
Csub2 += As[ty+16][k]*Bs[tx][k];
```

Ve výsledném assembleru již instrukce add chybí

```
...
mov.b32 $r0, s[$ofs4+0x0008]
mad.rn.f32 $r6, s[$ofs3+0x0034], $r0, $r6
mad.rn.f32 $r8, s[$ofs1+0x0008], $r0, $r8
...
```

Nový problém – konflikty bank sdílené paměti

- vyřeší padding

# Odstanění add instrukce

Do pole  $Bs$  můžeme ukládat transponovaná data, pak vypadá kód vnitřní smyčky takto

```
Csub1 += As[ty][k]*Bs[tx][k];
Csub2 += As[ty+16][k]*Bs[tx][k];
```

Ve výsledném assembleru již instrukce add chybí

```
...
mov.b32 $r0, s[$ofs4+0x0008]
mad.rn.f32 $r6, s[$ofs3+0x0034], $r0, $r6
mad.rn.f32 $r8, s[$ofs1+0x0008], $r0, $r8
...
```

Nový problém – konflikty bank sdílené paměti

- vyřeší padding

Výsledná rychlosť: 276.2 GFlops.

# Lze matice násobit ještě rychleji?

Naměřený výkon je již poměrně blízký teoretickému maximu

- rozdíl je dán spouštěním kernelu/threadů, synchronizací a pointerovou aritmetikou
- chceme-li dosáhnout vyšší rychlosti, je třeba přehodnotit algoritmus

# Lze matice násobit ještě rychleji?

Naměřený výkon je již poměrně blízký teoretickému maximu

- rozdíl je dán spouštěním kernelu/threadů, synchronizací a pointerovou aritmetikou
- chceme-li dosáhnout vyšší rychlosti, je třeba přehodnotit algoritmus

Zásadním problémem je, že spolu násobíme dvě matice ve sdílené paměti

- nutnost provádět load instrukce spolu s MAD instrukcemi

# Lze matice násobit ještě rychleji?

Naměřený výkon je již poměrně blízký teoretickému maximu

- rozdíl je dán spouštěním kernelu/threadů, synchronizací a pointerovou aritmetikou
- chceme-li dosáhnout vyšší rychlosti, je třeba přehodnotit algoritmus

Zásadním problémem je, že spolu násobíme dvě matice ve sdílené paměti

- nutnost provádět load instrukce spolu s MAD instrukcemi

Můžeme mít ve sdílené paměti jen jeden blok?

# Přehodnocený blokový přístup

Namísto čtvercových bloků v matici  $C$  můžeme použít obdélníkové

# Přehodnocený blokový přístup

Namísto čtvercových bloků v matici  $C$  můžeme použít obdélníkové

- provádíme iterativně rank-1 update bloků v  $C$  ze sloupce matice  $A$  a řádku matice  $B$

# Přehodnocený blokový přístup

Namísto čtvercových bloků v matici  $C$  můžeme použít obdélníkové

- provádíme iterativně rank-1 update bloků v  $C$  ze sloupce matice  $A$  a řádku matice  $B$
- sloupce je nutno číst se sdílené paměti

# Přehodnocený blokový přístup

Namísto čtvercových bloků v matici  $C$  můžeme použít obdélníkové

- provádíme iterativně rank-1 update bloků v  $C$  ze sloupce matice  $A$  a řádku matice  $B$
- sloupce je nutno číst se sdílené paměti
- řádky můžeme načítat postupně, lze tedy použít data v registrech

# Přehodnocený blokový přístup

Namísto čtvercových bloků v matici  $C$  můžeme použít obdélníkové

- provádíme iterativně rank-1 update bloků v  $C$  ze sloupce matice  $A$  a řádku matice  $B$
- sloupce je nutno číst se sdílené paměti
- řádky můžeme načítat postupně, lze tedy použít data v registrech
- výsledný blok může být uložen vregistrech

# Přehodnocený blokový přístup

Namísto čtvercových bloků v matici  $C$  můžeme použít obdélníkové

- provádíme iterativně rank-1 update bloků v  $C$  ze sloupce matice  $A$  a řádku matice  $B$
- sloupce je nutno číst se sdílené paměti
- řádky můžeme načítat postupně, lze tedy použít data v registrech
- výsledný blok může být uložen vregistrech
- pracujeme tedy pouze s jedním operandem ve sdílené paměti, není nutný load

# Přehodnocený blokový přístup

Namísto čtvercových bloků v matici  $C$  můžeme použít obdélníkové

- provádíme iterativně rank-1 update bloků v  $C$  ze sloupce matice  $A$  a řádku matice  $B$
- sloupce je nutno číst se sdílené paměti
- řádky můžeme načítat postupně, lze tedy použít data v registrech
- výsledný blok může být uložen vregistrech
- pracujeme tedy pouze s jedním operandem ve sdílené paměti, není nutný load
- není nutná aritmetika uprostřed smyčky (viz předchozí optimalizace)

# Přehodnocený blokový přístup

Namísto čtvercových bloků v matici  $C$  můžeme použít obdélníkové

- provádíme iterativně rank-1 update bloků v  $C$  ze sloupce matice  $A$  a řádku matice  $B$
- sloupce je nutno číst se sdílené paměti
- řádky můžeme načítat postupně, lze tedy použít data v registrech
- výsledný blok může být uložen vregistrech
- pracujeme tedy pouze s jedním operandem ve sdílené paměti, není nutný load
- není nutná aritmetika uprostřed smyčky (viz předchozí optimalizace)
- teoretické maximum výkonu je tak omezeno rychlosí instrukce MAD pracující se sdílenou pamětí na cca 415 GFlops

# Implementace

Nejvyšší rychlosti bylo dosaženo s konfigurací

- matice  $A$  zpracovávána po blocích  $16 \times 16$ , uložených ve sdílené paměti
- matice  $B$  zpracovávána po blocích  $64 \times 1$ , uložených vregistrech
- bloky matice  $C$  mají tedy rozměr  $64 \times 16$ , jsou uloženy vregistrech

# Implementace

Nejvyšší rychlosti bylo dosaženo s konfigurací

- matice  $A$  zpracovávána po blocích  $16 \times 16$ , uložených ve sdílené paměti
- matice  $B$  zpracovávána po blocích  $64 \times 1$ , uložených vregistrech
- bloky matice  $C$  mají tedy rozměr  $64 \times 16$ , jsou uloženy vregistrech

Dosažená rychlosť této implementace **375 GFlops**.

## Shrnutí

Implementace	rychlosť	rel. $\Delta$	abs. $\Delta$
Naivní implementace, $thready 1 \times 128$	3.9 GFlops		
Naivní implementace	36.6 GFlops	9.4 $\times$	9.4 $\times$
Blokový přístup	198 GFlops	5.4 $\times$	51 $\times$
Bloky $32 \times 16$ pracující s daty $32 \times 16$	235 GFlops	1.19 $\times$	60 $\times$
Odstranění ADD instrukce	276 GFlops	1.17 $\times$	71 $\times$
Jen jeden blok ve sdílené paměti	375 GFlops	1.36 $\times$	96 $\times$

## Shrnutí

Implementace	rychlosť	rel. $\Delta$	abs. $\Delta$
Naivní implementace, $thready 1 \times 128$	3.9 GFlops		
Naivní implementace	36.6 GFlops	9.4 $\times$	9.4 $\times$
Blokový přístup	198 GFlops	5.4 $\times$	51 $\times$
Bloky $32 \times 16$ pracující s daty $32 \times 16$	235 GFlops	1.19 $\times$	60 $\times$
Odstranění ADD instrukce	276 GFlops	1.17 $\times$	71 $\times$
Jen jeden blok ve sdílené paměti	375 GFlops	1.36 $\times$	96 $\times$

- Nejzásadnější je redukce poměru aritmetických operací k paměťovým přenosům a základní optimalizace přístupu do paměti.

## Shrnutí

Implementace	rychlosť	rel. $\Delta$	abs. $\Delta$
Naivní implementace, <code>thready 1 × 128</code>	3.9 GFlops		
Naivní implementace	36.6 GFlops	9.4×	9.4×
Blokový přístup	198 GFlops	5.4×	51×
Bloky $32 \times 16$ pracující s daty $32 \times 16$	235 GFlops	1.19×	60×
Odstranění ADD instrukce	276 GFlops	1.17×	71×
Jen jeden blok ve sdílené paměti	375 GFlops	1.36×	96×

- Nejzásadnější je redukce poměru aritmetických operací k paměťovým přenosům a základní optimalizace přístupu do paměti.
- Optimalizace na úrovni instrukcí je relativně náročná, avšak pro kritické kódy může přinést relativně významné zrychlení.

# Součet prvků vektoru

Pro vektor  $v$  o  $n$  prvcích chceme spočítat  $x = \sum_{i=1}^n v_i$ .

# Součet prvků vektoru

Pro vektor  $v$  o  $n$  prvcích chceme spočítat  $x = \sum_{i=1}^n v_i$ .  
Zápis v jazyce C

```
int x = 0;  
for (int i = 0; i < n; i++)  
    x += v[i];
```

Jednotlivé iterace cyklu jsou na sobě závislé.

# Součet prvků vektoru

Pro vektor  $v$  o  $n$  prvcích chceme spočítat  $x = \sum_{i=1}^n v_i$ .  
Zápis v jazyce C

```
int x = 0;  
for (int i = 0; i < n; i++)  
    x += v[i];
```

Jednotlivé iterace cyklu jsou na sobě závislé.

- nemůžeme udělat všechnu práci paralelně
- sčítání je však (alespoň teoreticky :-) ) asocitativní
- není tedy nutno počítat sekvenčně

# Paralelní algoritmus

Představený sekvenční algoritmus provádí pro 8 prvků výpočet:

$$((((((v_1 + v_2) + v_3) + v_4) + v_5) + v_6) + v_7) + v_8$$

# Paralelní algoritmus

Představený sekvenční algoritmus provádí pro 8 prvků výpočet:

$$((((((v_1 + v_2) + v_3) + v_4) + v_5) + v_6) + v_7) + v_8$$

Sčítání je asociativní... spřeházejme tedy závorky:

$$(v_1 + v_2) + (v_3 + v_4)) + ((v_5 + v_6) + (v_7 + v_8))$$

# Paralelní algoritmus

Představený sekvenční algoritmus provádí pro 8 prvků výpočet:

$$((((((v_1 + v_2) + v_3) + v_4) + v_5) + v_6) + v_7) + v_8$$

Sčítání je asociativní... spřeházejme tedy závorky:

$$((v_1 + v_2) + (v_3 + v_4)) + ((v_5 + v_6) + (v_7 + v_8))$$

Nyní můžeme pracovat paralelně

- v prvním kroku provedeme 4 sčítání
- ve druhém dvě
- ve třetím jedno

Celkově stejné množství práce ( $n - 1$  sčítání), ale v  $\log_2 n$  paralelních krocích!

# Paralelní algoritmus

Našli jsme vhodný paralelní algoritmus

- provádí stejné množství operací jako sériová verze
- při dostatku procesorů je proveden v logaritmickém čase

Sčítáme výsledky předešlých součtů

- předešlé součty provádělo více threadů
- vyžaduje globální bariéru

# Naivní přístup

Nejjednodušší schéma algoritmu:

- kernel pro sudá  $i < n$  provede  $v[i] += v[i+1]$
- opakujeme pro  $n /= 2$  dokud  $n > 1$

Omezení výkonu

- $2n$  čtení z globální paměti
- $n$  zápisů do globální paměti
- $\log_2 n$  volání kernelu

Na jednu aritmetickou operaci připadají 3 paměťové přenosy, navíc je nepříjemný overhead spouštění kernelu.

# Využití rychlejší paměti

V rámci volání kernelu můžeme posčítat více, než jen dvojice

- každý blok  $bx$  načte  $m$  prvků do sdílené paměti
- provede redukci (ve sdílené paměti v  $\log_2 m$  krocích)
- uloží pouze jedno číslo odpovídající  $\sum_{i=m \cdot bx}^{m \cdot bx + m} v_i$

Výhodnější z hlediska paměťových přenosů i spuštění kernelů

- $n + \frac{n}{m} + \frac{n}{m^2} + \dots + \frac{n}{m^{\log_m n}} = (n - 1) \frac{m}{m - 1}$
- přibližně  $n + \frac{n}{m}$  čtení,  $\frac{n}{m}$  zápisů
- $\log_m n$  spuštění kernelu

# Implementace 1

```
--global__ void reduce1(int *v){  
    extern __shared__ int sv[];  
  
    unsigned int tid = threadIdx.x;  
    unsigned int i = blockIdx.x*blockDim.x + threadIdx.x;  
    sv[tid] = v[i];  
    __syncthreads();  
  
    for(unsigned int s=1; s < blockDim.x; s *= 2) {  
        if (tid % (2*s) == 0)  
            sv[tid] += sv[tid + s];  
        __syncthreads();  
    }  
  
    if (tid == 0)  
        v[blockIdx.x] = sv[0];  
}
```

# Výkon

## Vysoká úroveň divergence

- první iteraci pracuje každý 2. thread
- druhou iteraci pracuje každý 4. thread
- třetí iteraci pracuje každý 8 thread
- atd.

Přenos (GTX 280) 3.77 GB/s, 0.94 MElem/s.

# Implementace 2

Nahradíme indexaci ve for cyklu

```
for (unsigned int s = 1; s < blockDim.x; s *= 2) {  
    int index = 2 * s * tid;  
    if (index < blockDim.x)  
        sv[index] += sv[index + s];  
    __syncthreads();  
}
```

Přenos 8.33 GB/s, 2.08 MElem/s.

Řeší divergenci, generuje konflikty bank.

# Implementace 3

Tak ještě jinak...

```
for (unsigned int s = blockDim.x/2; s > 0; s >>= 1) {  
    if (tid < s)  
        sv[tid] += sv[tid + s];  
    __syncthreads();  
}
```

Žádná divergence ani konflikty.

Přenos 16.34 GB/s, 4.08 MElem/s.

Polovina threadů nic nepočítá...

# Implementace 4

První sčítání provedeme již během načítání.

```
unsigned int i = blockIdx.x*(blockDim.x*2) + threadIdx.x;  
sv[tid] = v[i] + v[i+blockDim.x];
```

Přenos 27.16 GB/s, 6.79 MElem/s.

Data zřejmě čteme optimálně, stále je zde však výkonová rezerva – zaměřme se na instrukce.

# Implementace 5

V jednotlivých krocích redukce ubývá aktivních threadů

- nakonec bude pracovat pouze jeden warp
- ten je však synchronizován implicitně, můžeme tedy odebrat `__syncthreads()`
- podmínka `if(tid < s)` je zde zbytečná (nic neušetří)

Unrollujme tedy poslední warp...

# Implementace 5

```
for (unsigned int s = blockDim.x/2; s > 32; s >>= 1){  
    if (tid < s)  
        sv[tid] += sv[tid + s];  
    __syncthreads();  
}  
  
if (tid < 32){  
    sv[tid] += sv[tid + 32];  
    sv[tid] += sv[tid + 16];  
    sv[tid] += sv[tid + 8];  
    sv[tid] += sv[tid + 4];  
    sv[tid] += sv[tid + 2];  
    sv[tid] += sv[tid + 1];  
}
```

Ušetříme čas i ostatním waprům (zkončí dříve s for cyklem).  
Přenos 37.68 GB/s, 9.42 MElem/s.

# Implementace 6

Jak je to s rozvinutím for cyklu?

Známe-li počet iterací, můžeme cyklus rozvinout

- počet iterací je závislý na velikosti bloku

Můžeme být obecní?

- algoritmus pracuje s bloky o velikosti  $2^n$
- velikost bloku je shora omezena
- známe-li při komplilaci velikost bloku, můžeme použít šablonu

```
template <unsigned int blockSize>
__global__ void reduce6(int *v)
```

# Implementace 6

Podmínky s *blockSize* se vyhodnotí již pří překladu:

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

# Implementace 6

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

Spuštění kernelu:

```
reduce6<block><<<grid, block, mem>>>(d_v);
```

Přenos 50.64 GB/s, 12.66 MElem/s.

# Implementace 7

Můžeme algoritmus ještě vylepšit?

Vraťme se zpět ke složitosti:

- celkem  $\log n$  kroků
- celkem  $n - 1$  sčítání
- časová složitost pro  $p$  threadů běžících paralelně ( $p$  procesorů)  
 $\mathcal{O}\left(\frac{n}{p} + \log n\right)$

Cena paralelního výpočtu

- definována jako počet procesorů krát časová složitost
- přidělíme-li každému datovému elementu jeden thread, lze uvažovat  $p = n$
- pak je cena  $\mathcal{O}(n \cdot \log n)$
- není efektivní

# Implementace 7

## Snížení ceny

- použijeme  $\mathcal{O}(\frac{n}{\log n})$  threadů
- každý thread provede  $\mathcal{O}(\log n)$  sekvenčních kroků
- následně se provede  $\mathcal{O}(\log n)$  paralelních kroků
- časová složitost zůstane
- cena se sníží na  $\mathcal{O}(n)$

## Co to znamená v praxi?

- redukujeme práci spojenou s vytvářením threadu a pointerovou aritmetikou
- to přináší výhodu v momentě, kdy máme výrazně více threadů, než je třeba k saturaci GPU
- navíc snižujeme overhead spouštění kernelů

# Implementace 7

Modifikujeme načítání do sdílené paměti

```
unsigned int gridSize = blockSize*2*gridDim.x;  
sv[tid] = 0;  
  
while(i < n){  
    sv[tid] += v[i] + v[i+blockSize];  
    i += gridSize;  
}  
__syncthreads();
```

Přenos 77.21 GB/s, 19.3 MElem/s.

# Implementace 7

Modifikujeme načítání do sdílené paměti

```
unsigned int gridSize = blockSize*2*gridDim.x;  
sv[tid] = 0;  
  
while(i < n){  
    sv[tid] += v[i] + v[i+blockSize];  
    i += gridSize;  
}  
__syncthreads();
```

Přenos 77.21 GB/s, 19.3 MElem/s.

Jednotlivé implementace jsou k nalezení v CUDA SDK.

# Výběr vhodného problému

Než se pustíme do GPU akcelerace, je vhodné se zamyslet, jestli nám může pomoci :-).

Akcelerovaný problém by měl být

- kritický pro výkon aplikace
- musí se jednat o dostatečně velký problém (z hlediska počtu operací k jeho vyřešení)
- musí být paralelizovatelný (to zpravidla velké problémy jsou)
- k řešení problému musí být zapotřebí dostatek operací na jeden datový element (omezení přenosu zadání po PCI-E)

Optimalizujeme čas či spotřebu?

# Postup návrhu algoritmu

## Paralelizace

- v řešeném problému je třeba najít paralelismus
- již zde je vhodné uvažovat o omezeních architektury

## Teoretické maximum rychlosti algoritmu

- než začneme implementovat, je vhodné mít představu, jak rychle může algoritmus na daném HW pracovat
- základní omezení dává paměťová propustnost a aritmetický výkon
- výkon CPU a GPU se může sčítat

# Optimalizace

Je ruzumné postupovat od obecně významnějších k méně významným (tak se jejich efekt lépe projeví)

- přístup do globální paměti (bandwidth, latence)
- přístup do ostatních pamětí
- konfigurace běhu (počet threadů na blok, množství práce na thread)
- divergence běhu
- optimalizace na úrovni instrukcí

Nezapomínejte

- poctivě benchmarkovat
- kontrolovat kód profilerem

# Pozor na interpretaci rychlosti algoritmu

Efekt některých optimalizací může být skryt významnějšími neoptimalitami

- omezíme přednostním aplikováním významnějších optimalizací
- omezíme používáním profileru

Prostor optimalizací je nespojitý

- dáno omezenými zdroji GPU
- rychlejší kód threadu může vézt k celkově nižšímu výkonu

Výkon je závislý na velikosti problému

- menší instance mohou mít jiné nároky
- partition camping

# Jaké zrychlení oproti CPU je reálné?

- základní odhad zrychlení vychází z porovnání aritmetického výkonu a propustnosti paměti
- GPU však nemusí přinést adekvátní zrychlení
  - nedostatečně či nevhodně paralelizovatelný algoritmus
  - nevhodné datové struktury, náhodný přístup
  - PCI-E bottleneck (málo výpočtu vzhledem k přenosům, multi-GPU algoritmy)
- GPU také může přinést vyšší zrychlení
  - významné využití SFU
  - komplikovaná vektorizace u CPU
  - degradace výkonu paměti u CPU
  - špatně škálující SMP
- odlišné škálování CPU a GPU s rostoucí velikostí problému

# Pozor na příliš optimistická měření

- vysoké zrychlení má často za příčinu špatný CPU algoritmus
- je zapotřebí si uvědomit, že CPU má více jader a vektorové jednotky
  - nevektorizovaný jednothreadový kód využívá (v jednoduché přesnosti) 1/16 teoretického maxima 4-jádrového CPU
- přínos GPU řešení lze podložit spočítáním flopsů

# Prevence chyb

- testujte úspěšnost volání API a kernelů
  - chyby se jinak umí projevit se spožděním
- na GPU je docela deterministická alokace paměti
  - pokud se nic nezapíše, obvykle dostanete správný výsledek
  - pro účely ladění mažte výstupní data
- pozor na pošlapání sdílené paměti
  - kernel často nespadne, objevují se interference mezi bloky

# Ladění výkonu

- je dobré psát snadno konfigurovatelný kód
  - konfigurovatelná velikost bloku, práce na thread, ...
  - konfigurace výhodnější přes makra (část výpočtů proveditelná v době komplikace)
- někdy není jasný bottleneck
  - přístup do paměti nemusí být zcela optimální, rychlosť instrukcí obtížně odhadnutelná, schopnost překrýt výpočet a paměťové přenosy také
  - a kdo tedy zdržuje?
  - paměťové přenosy i výpočet lze benchmarkovat zvlášť
  - pak můžeme kernel rozdělit, zvětšit, zvýšit obsazenost GPU...

# Měření výkonu

- samostatné paměťové přenosy
  - zakomentujeme výpočet
  - načtená data musíme nějak "použít" (často jednodušší situace u sdílené paměti)
- samostatný výpočet
  - data nemusíme načítat
  - výsledek výpočtu je však třeba uložit, aby kompilátor neodstranil výpočet
    - my ale ukládat nechceme...
    - uložení výsledků lze vložit do podmínky, která nikdy nebude splněna
  - u rychlých kernelů pozor na overhead jejich spuštění