

# Úvod, základy CUDA

Jiří Filipovič

podzim 2010

# Motivace – Moorův zákon

## Moorův zákon

Počet tranzistorů na jednom čipu se přibližně každých 18 měsíců **zdvojnásobí**.

# Motivace – Moorův zákon

## Moorův zákon

Počet tranzistorů na jednom čipu se přibližně každých 18 měsíců **zdvojnásobí**.

Adekvátní růst výkonu je zajištěn:

- **dříve** zvyšováním frekvence, instrukčním paralelismem, out-of-order spouštěním instrukcí, vyrovnávacími pamětími atd.
- **dnes** vektorovými instrukcemi, zmnožováním jader

# Motivace – změna paradigmatu

Důsledky Moorova zákona:

- **dříve:** rychlosť zpracování programového vlákna procesorem se každých 18 měsíců zdvojnásobí
  - změny ovlivňují především návrh komplilátoru, aplikační programátor se jimi nemusí zabývat
- **dnes:** rychlosť zpracování **dostatečného počtu** programových vláken se každých 18 měsíců zdvojnásobí
  - pro využití výkonu dnešních procesorů je zapotřebí paralelizovat algoritmy
  - paralelizace vyžaduje nalezení souběžnosti v řešeném problému, což je (stále) úkol pro programátora, nikoliv komplilátor

## Motivace – druhy paralelismu

- úlohouvý paralelismus
    - problém je dekomponován na úlohy, které mohou být prováděny souběžně
    - úlohy jsou zpravidla komplexnější, mohou provádět různou činnost
    - vhodný pro menší počet výkonných jader
    - zpravidla častější (a složitější) synchronizace
  - datový paralelismus
    - souběžnost na úrovni datových struktur
    - zpravidla prováděna stejná operace nad mnoha prvky datové struktury
    - jemnější paralelismus umožňuje konstrukci jednodušších procesorů

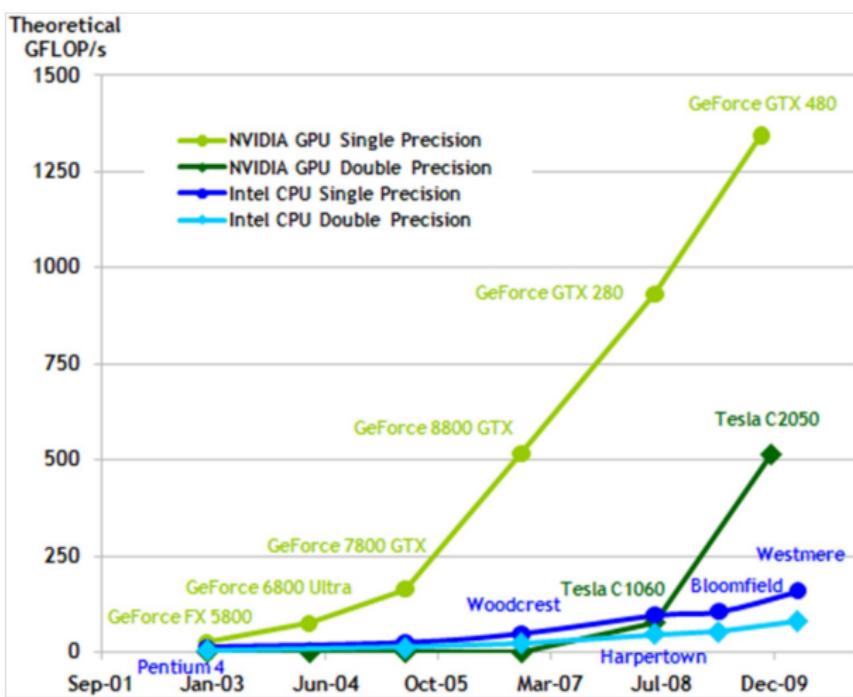
# Motivace – druhy paralelismu

- z pohledu programátora
  - rozdílné paradigma znamená rozdílný pohled na návrh algoritmů
  - některé problémy jsou spíše datově paralelní, některé úlohově
- z pohledu vývojáře hardware
  - procesory pro datově paralelní úlohy mohou být **jednodušší**
  - při stejném počtu tranzistorů lze dosáhnout **vyššího aritmetického výkonu**
  - jednodušší vzory přístupu do paměti umožňují konstrukci HW s **vysokou paměťovou propustností**

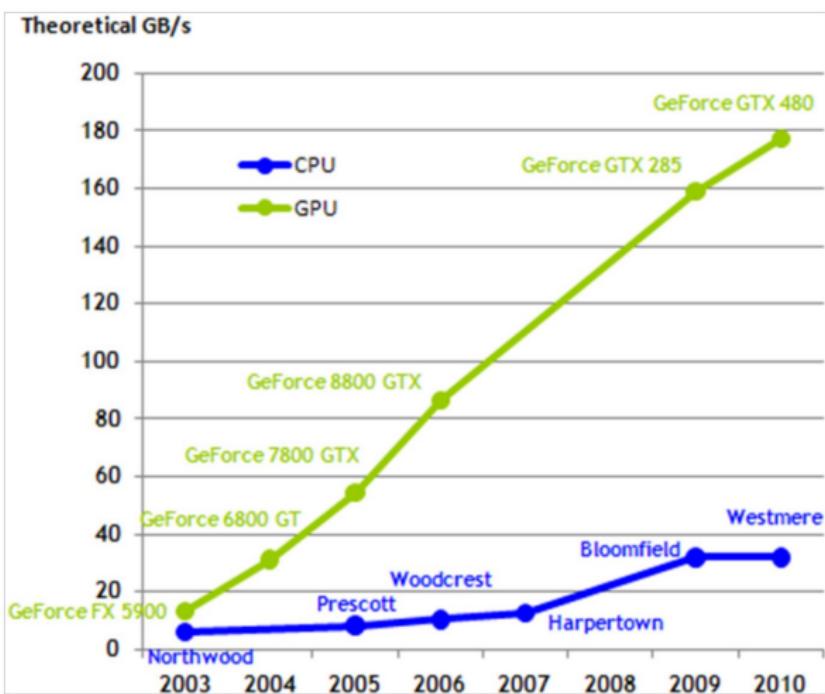
# Motivace – grafické výpočty

- datově paralelní
  - provádíme stejné výpočty pro různé vertexy, pixely, ...
- předdefinované funkce
- programovatelné funkce
  - specifické grafické efekty
  - GPU se stávají stále více programovatelnými
  - díky tomu lze zpracovávat i jiné, než grafické úlohy

# Motivace – výkon



# Motivace – výkon



# Motivace – shrnutí

- GPU jsou výkonné
  - řádový nárůst výkodu již stojí za studium nového programovacího modelu
- pro plné využití moderních GPU i CPU je třeba programovat paralelně
  - paralelní architektura GPU přestává být řádově náročnější
- GPU jsou široce rozšířené
  - jsou levné
  - spousta uživatelů má na stole superpočítač

# Motivace – uplatnění

Využití GPU pro obecné výpočty je dynamicky se rozvíjející oblast s širokou škálou aplikací

# Motivace – uplatnění

Využití GPU pro obecné výpočty je dynamicky se rozvíjející oblast s širokou škálou aplikací

- vysoce náročné vědecké výpočty
  - výpočetní chemie
  - fyzikální simulace
  - zpracování obrazů
  - a mnohé další...

# Motivace – uplatnění

Využití GPU pro obecné výpočty je dynamicky se rozvíjející oblast s širokou škálou aplikací

- vysoce náročné vědecké výpočty
  - výpočetní chemie
  - fyzikální simulace
  - zpracování obrazů
  - a mnohé další...
- výpočetně náročné aplikace pro domácí uživatele
  - kódování a dekódování multimedialních dat
  - herní fyzika
  - úprava obrázků, 3D rendering
  - atd...

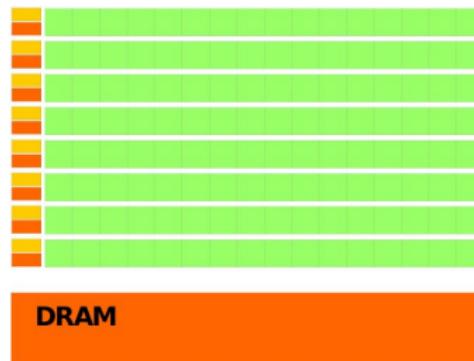
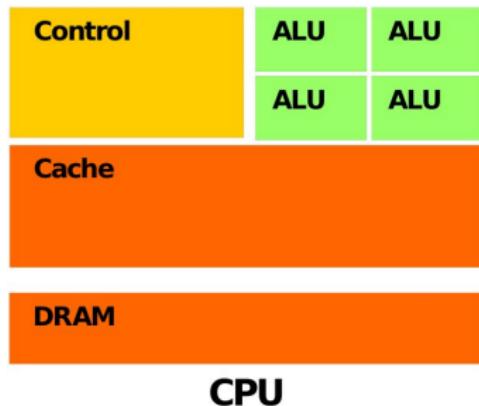
# Architektura GPU

## CPU vs. GPU

- jednotky jader vs. **desítky multiprocesorů**
- out of order vs. **in order**
- MIMD, SIMD pro krátké vektory vs. **SIMT pro dlouhé vektory**
- velká cache vs. **malá cache, často pouze pro čtení**

GPU používá více tranzistorů pro výpočetní jednotky než pro cache a řízení běhu => vyšší výkon, méně univerzální

# Architektura GPU



# Architektura GPU

V rámci systému:

- koprocessor s dedikovanou pamětí
- asynchronní běh instrukcí
- připojen k systému přes PCI-E

# Procesor G80

## G80

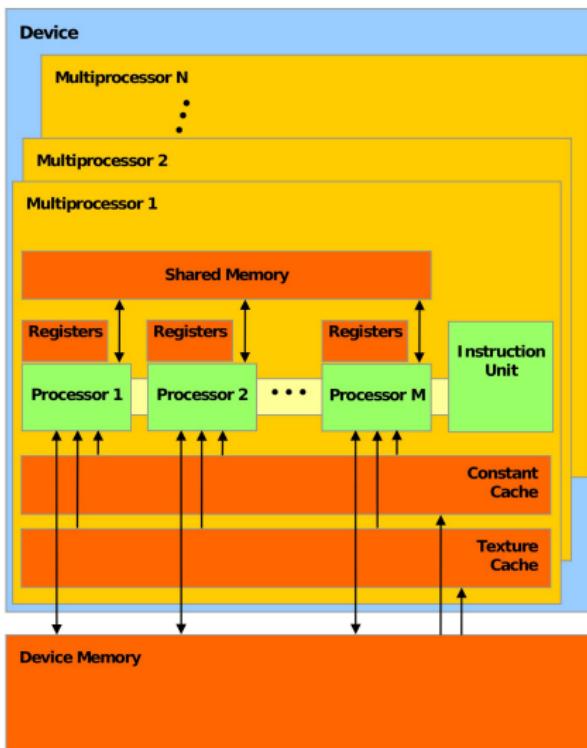
- první CUDA procesor
- obsahuje 16 multiprocesorů
- multiprocesor
  - 8 skalárních procesorů
  - 2 jednotky pro speciální funkce
  - až 768 threadů
    - HW přepínání a plánování threadů
  - thready organizovány po 32 do warpů
    - SIMT
  - nativní synchronizace v rámci multiprocesoru

# Paměťový model G80

## Paměťový model

- 8192 registrů sdílených mezi všemi thready multiprocesoru
- 16 KB sdílené paměti
  - lokální v rámci multiprocesoru
  - stejně rychlá jako registry (za dodržení určitých podmínek)
- paměť konstant
  - cacheovaná, pouze pro čtení
- paměť pro texturey
  - cacheovaná, 2D prostorová lokalita, pouze pro čtení
- globální paměť
  - pro čtení i zápis, necacheovaná
- přenosy mezi systémovou a grafickou pamětí přes PCI-E

# Procesor G80



# Další vývoj

## Procesory odvozené od G80

- double-precision výpočty
- relaxovány pravidla pro efektivní přístup ke globální paměti
- navýšeny on-chip zdroje (více registrů, více threadů na MP)
- lepší možnosti synchronizace (atomické operace, hlasování warpů)

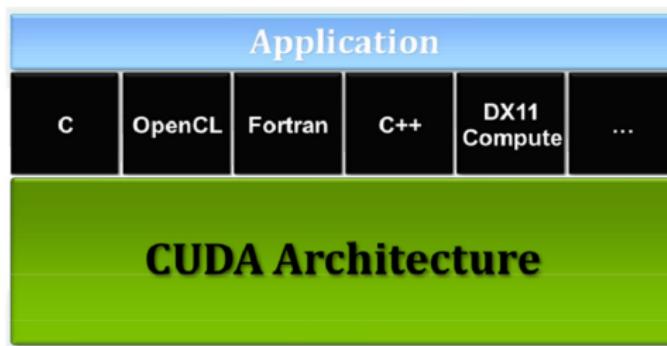
## Fermi

- vyšší paralelizace na úrovni multiprocessoru (více jader, dva warp schedulery, více DP výkonu)
- konfigurovatelná L1 a sdílená L2 cache
- plochý adresní prostor
- lepší přesnost v plovoucí řádové čárce
- paralelní běh kernelů
- širší možnosti synchronizace
- další změny plynoucí z odlišné architektury

# CUDA

## CUDA (Compute Unified Device Architecture)

- architektura pro paralelní výpočty vyvinutá firmou NVIDIA
- poskytuje nový programovací model, který umožňuje efektivní implementaci obecných výpočtů na GPU
- je možné použít ji s více programovacími jazyky



# C for CUDA

C for CUDA přináší rozšíření jazyka C pro paralelní výpočty

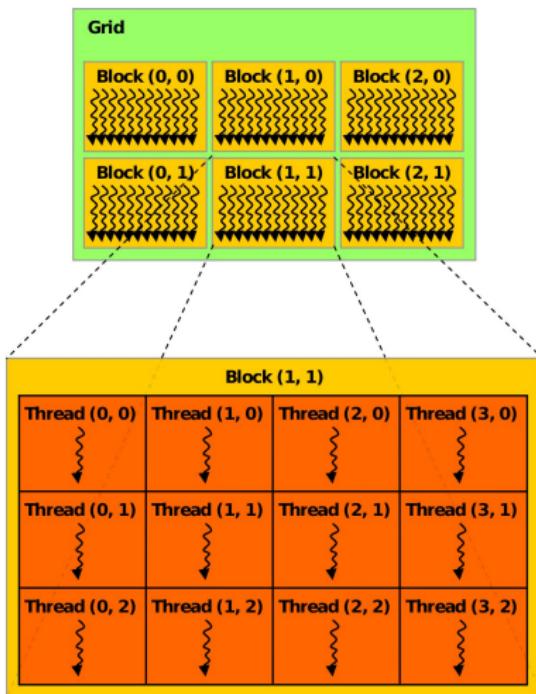
- explicitně oddělen host (CPU) a device (GPU) kód
- hierarchie vláken
- hierarchie pamětí
- synchronizační mechanismy
- API

# Hierarchie vláken

## Hierarchie vláken

- vlákna jsou organizována do bloků
- bloky tvoří mřížku
- problém je dekomponován na podproblémy, které mohou být prováděny nezávisle paralelně (bloky)
- jednotlivé podproblémy jsou rozděleny do malých částí, které mohou být prováděny kooperativně paralelně (thready)
- dobře škáluje

# Hierarchie vláken

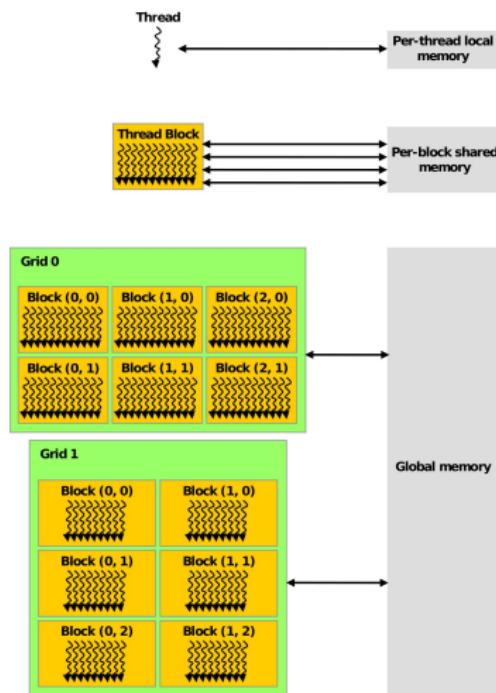


# Hierarchie pamětí

## Více druhů pamětí

- rozdílná viditelnost
- rozdílný čas života
- rozdílné rychlosti a chování
- přináší dobrou škálovatelnost

# Hierarchie pamětí



# Příklad – součet vektorů

Chceme sečít vektory  $a$  a  $b$  a výsledek uložit do vektoru  $c$ .

# Příklad – součet vektorů

Chceme sečíst vektory  $a$  a  $b$  a výsledek uložit do vektoru  $c$ .  
Je třeba najít v problému paralelismus.

# Příklad – součet vektorů

Chceme sečít vektory  $a$  a  $b$  a výsledek uložit do vektoru  $c$ .

Je třeba najít v problému paralelismus.

Sériový součet vektorů:

```
for (int i = 0; i < N; i++)  
    c[i] = a[i] + b[i];
```

## Příklad – součet vektorů

Chceme sečíst vektory  $a$  a  $b$  a výsledek uložit do vektoru  $c$ .

Je třeba najít v problému paralelismus.

Sériový součet vektorů:

```
for (int i = 0; i < N; i++)  
    c[i] = a[i] + b[i];
```

Jednotlivé iterace cyklu jsou na sobě nezávislé – lze je paralelizovat, škáluje s velikostí vektoru.

# Příklad – součet vektorů

Chceme sečíst vektory  $a$  a  $b$  a výsledek uložit do vektoru  $c$ .

Je třeba najít v problému paralelismus.

Sériový součet vektorů:

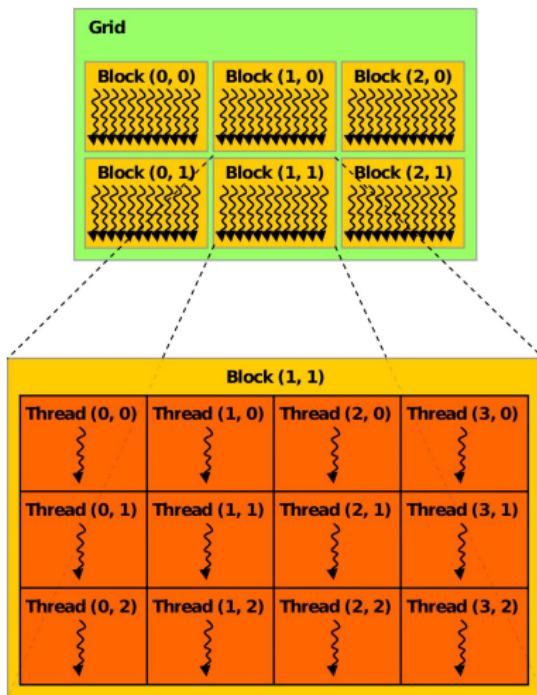
```
for (int i = 0; i < N; i++)  
    c[i] = a[i] + b[i];
```

Jednotlivé iterace cyklu jsou na sobě nezávislé – lze je paralelizovat, škáluje s velikostí vektoru.  
i-tý thread seče i-té složky vektorů:

```
c[i] = a[i] + b[i];
```

Jak zjistíme, kolikátý jsme thread?

# Hierarchie vláken



# Identifikace vlákna a bloku

C for CUDA obsahuje zabudované proměnné:

- **threadIdx.{x, y, z}** udává pozici threadu v rámci bloku
- **blockDim.{x, y, z}** udává velikost bloku
- **blockIdx.{x, y, z}** udává pozici bloku v rámci mřížky (z je vždy 1)
- **gridDim.{x, y, z}** udává velikost mřížky (z je vždy 1)

# Příklad – součet vektorů

Vypočítáme tedy globální pozici threadu (mřížka i bloky jsou jednorozměrné):

# Příklad – součet vektorů

Vypočítáme tedy globální pozici threadu (mřížka i bloky jsou jednorozměrné):

```
int i = blockIdx.x*blockDim.x + threadIdx.x;
```

## Příklad – součet vektorů

Vypočítáme tedy globální pozici threadu (mřížka i bloky jsou jednorozměrné):

```
int i = blockIdx.x*blockDim.x + threadIdx.x;
```

Celá funkce pro paralelní součet vektorů:

```
--global__ void addvec(float *a, float *b, float *c){  
    int i = blockIdx.x*blockDim.x + threadIdx.x;  
    c[i] = a[i] + b[i];  
}
```

## Příklad – součet vektorů

Vypočítáme tedy globální pozici threadu (mřížka i bloky jsou jednorozměrné):

```
int i = blockIdx.x*blockDim.x + threadIdx.x;
```

Celá funkce pro paralelní součet vektorů:

```
--global__ void addvec(float *a, float *b, float *c){  
    int i = blockIdx.x*blockDim.x + threadIdx.x;  
    c[i] = a[i] + b[i];  
}
```

Funkce definuje tzv. kernel, při volání určíme, kolik threadů a v jakém uspořádání bude spuštěno.

# Kvantifikátory typů funkcí

Syntaxe C je rozšířena o kvantifikátory, určující, kde se bude kód provádět a odkud půjde volat:

- **`__device__`** funkce je spouštěna na device (GPU), lze volat jen z device kódu
- **`__global__`** funkce je spouštěna na device, lze volat jen z host (CPU) kódu
- **`__host__`** funkce je spouštěna na host, lze ji volat jen z host
- kvantifikátory `__host__` a `__device__` lze kombinovat, funkce je pak komplilována pro obojí

Ke kompletnímu výpočtu je třeba:

Ke kompletnímu výpočtu je třeba:

- alokovat paměť pro vektory, naplnit je daty

Ke kompletnímu výpočtu je třeba:

- alokovat paměť pro vektory, naplnit je daty
- **alokovat paměť na GPU**

Ke kompletnímu výpočtu je třeba:

- alokovat paměť pro vektory, naplnit je daty
- **alokovat paměť na GPU**
- **zkopírovat vektory  $a$  a  $b$  na GPU**

Ke kompletnímu výpočtu je třeba:

- alokovat paměť pro vektory, naplnit je daty
- **alokovat paměť na GPU**
- **zkopírovat vektory  $a$  a  $b$  na GPU**
- **spočítat vektorový součet na GPU**

Ke kompletnímu výpočtu je třeba:

- alokovat paměť pro vektory, naplnit je daty
- **alokovat paměť na GPU**
- **zkopírovat vektory  $a$  a  $b$  na GPU**
- **spočítat vektorový součet na GPU**
- **uložit výsledek z GPU paměti do  $c$**

Ke kompletnímu výpočtu je třeba:

- alokovat paměť pro vektory, naplnit je daty
- **alokovat paměť na GPU**
- **zkopírovat vektory  $a$  a  $b$  na GPU**
- **spočítat vektorový součet na GPU**
- **uložit výsledek z GPU paměti do  $c$**
- použít výsledek v  $c$  :-)

# Příklad – součet vektorů

CPU kód naplní  $a$  a  $b$ , vypíše  $c$ :

```
#include <stdio.h>
#define N 64
int main(){
    float a[N], b[N], c[N];
    for (int i = 0; i < N; i++)
        a[i] = b[i] = i;

    // zde bude kód provádějící výpočet na GPU

    for (int i = 0; i < N; i++)
        printf("%f, ", c[i]);
    return 0;
}
```

# Správa GPU paměti

Paměť je třeba dynamicky alokovat.

```
cudaMalloc( void** devPtr, size_t count );
```

Alokuje paměť velikosti *count*, nastaví na ni ukazatel *devPtr*.  
Uvolnění paměti:

```
cudaFree( void* devPtr );
```

Kopírování paměti:

```
cudaMemcpy( void* dst, const void* src, size_t count,  
enum cudaMemcpyKind kind );
```

Kopíruje *count* byte z *src* do *dst*, *kind* určuje, o jaký směr kopírování se jedná (např. *cudaMemcpyHostToDevice*, nebo *cudaMemcpyDeviceToHost*).

# Příklad – součet vektorů

Alokujeme paměť a přeneseme data:

```
float *d_a, *d_b, *d_c;  
cudaMalloc((void**)&d_a, N*sizeof(*d_a));  
cudaMalloc((void**)&d_b, N*sizeof(*d_b));  
cudaMalloc((void**)&d_c, N*sizeof(*d_c));  
  
cudaMemcpy(d_a, a, N*sizeof(*d_a), cudaMemcpyHostToDevice);  
cudaMemcpy(d_b, b, N*sizeof(*d_b), cudaMemcpyHostToDevice);  
  
// zde bude spuštěn kernel  
  
cudaMemcpy(c, d_c, N*sizeof(*c), cudaMemcpyDeviceToHost);  
  
cudaFree(d_a);  
cudaFree(d_b);  
cudaFree(d_c);
```

# Příklad – součet vektorů

Spuštění kernelu:

- kernel voláme jako funkci, mezi její jméno a argumenty vkládáme do trojitých špičatých závorek velikost mřížky a bloku
- potřebujeme znát velikost bloků a jejich počet
- použijeme 1D blok i mřížku, blok bude pevné velikosti
- velikost mřížky vypočteme tak, aby byl vyřešen celý problém násobení vektorů

Pro vektory velikosti dělitelné 32:

```
#define BLOCK 32
addvec<<<N/BLOCK , BLOCK>>>(d_a , d_b , d_c );
```

Jak řešit problém pro obecnou velikost vektoru?

# Příklad – součet vektorů

Upravíme kód kernelu:

```
--global__ void addvec(float *a, float *b, float *c, int n){  
    int i = blockIdx.x*blockDim.x + threadIdx.x;  
    if (i < n) c[i] = a[i] + b[i];  
}
```

A zavoláme kernel s dostatečným počtem vláken:

```
addvec<<<N/BLOCK + 1, BLOCK>>>(d_a, d_b, d_c, N);
```

# Příklad – spuštění

Nyní už zbývá jen komplikace :-).

```
nvcc -I/usr/local/cuda/include -L/usr/local/cuda/lib -lcudart \
-o vecadd vecadd.cu
```

Kde s CUDA pracovat?

- vlastní stroj: stáhněte a nainstalujte CUDA toolkit a SDK z developer.nvidia.com
- windowsí stanice v učebnách (titan)
- ke vzdálené práci s hi-end GPU: barracuda.fi.muni.cz, airacuda.fi.muni.cz, účty na přání

# Paměti lokální v rámci threadu

## Registers

- nejrychlejší paměť, přímo využitelná v instrukcích
- lokální proměnné v kernelu i proměnné nutné pro mezivýsledky jsou automaticky v registrech
  - pokud je dostatek registrů
  - pokud dokáže kompilátor určit statickou indexaci polí
- mají životnost threadu (warpu)

# Paměti lokální v rámci threadu

## Registry

- nejrychlejší paměť, přímo využitelná v instrukcích
- lokální proměnné v kernelu i proměnné nutné pro mezivýsledky jsou automaticky v registrech
  - pokud je dostatek registrů
  - pokud dokáže kompilátor určit statickou indexaci polí
- mají životnost threadu (warpu)

## Lokální paměť

- co se nevlezí do registrů, jde do lokální paměti
- ta je fyzicky uložena v DRAM, je tudíž pomalá a má dlouhou latenci
- má životnost threadu (warpu)

# Paměť lokální v rámci bloku

## Sdílená paměť

- u c.c. 1.x rychlá jako registry
  - nedojde-li ke konfliktům paměťových bank
  - instrukce umí využít jen jeden operand ve sdílené paměti (jinak je třeba explicitní load/store)
- v C for CUDA deklarujeme pomocí `_shared_`
- proměnná ve sdílené paměti může mít dynamickou velikost (určenou při startu), pokud je deklarována jako `extern` bez udání velikosti pole
- má životnost bloku

# Sdílená paměť

Deklarace statické sdílené paměti

```
__shared__ float myArray[128];
```

Dynamická alokace

```
extern __shared__ char myArray[];  
float *array1 = (float*)myArray;  
int *array2 = (int*)&array1[128];  
short *array3 = (short*)&array2[256];
```

Vytvoří pole *array1* typu *float* velikosti 128, pole *array2* typu *int* velikosti 256 a pole *array3* plovoucí velikosti. Celkovou velikost je nutné specifikovat při spouštění kernelu.

```
myKernel<<<grid, block, n>>>();
```

# Paměť lokální pro GPU

## Globální paměť

- řádově nižší přenosová rychlosť než u sdílené paměti
- latence ve stovkách GPU cyklů
- pro dosažení optimálního výkonu je třeba paměť adresovat zarovnaně
- má životnost aplikace
- u Fermi L1 cache (128 byte na řádek) a L2 cache (32 byte na řádek)

Lze dynamicky alokovat pomocí *cudaMalloc*, či staticky pomocí deklarace *\_\_device\_\_*

# Ostatní paměti

- paměť konstant
- texturová paměť
- systémová paměť

# Synchronizace v rámci bloku

- nativní bariérová synchronizace
  - musí do ní vstoupit všechny `thready` (pozor na podmínky!)
  - pouze jedna instrukce, velmi rychlá, pokud nereduuje parallelismus
  - v C for CUDA volání `__syncthreads()`
  - Fermi rozšíření: `count`, `and`, or

# Atomické operace

- provádí read-modify-write operace nad sdílenou nebo globální pamětí
- žádná interference s ostatními thready
- pro celá 32-bitová či 64-bitová (pro compute capability  $\geq 1.2$ ) čísla (float add u c.c.  $\geq 2.0$ )
- nad globální pamětí u zařízení s compute capability  $\geq 1.1$ , nad sdílenou c.c.  $\geq 1.2$
- aritmetické (Add, Sub, Exch, Min, Max, Inc, Dec, CAS) a bitové (And, Or, Xor) operace

# Hlasování warpu

Všechny thready v jednom warpu vyhodnocují podmínu a provedou její srovnání.

Dostupné u zařízení s c.c.  $\geq 1.2$ .

```
int __all(int predicate);
```

Nabývá nenulové hodnoty tehdy a jen tehdy když je nenulový predikát pro všechny thready ve warpu.

```
int __any(int predicate);
```

Nebývá nenulové hodnoty tehdy a jen tehdy když alespoň jeden thread ve warpu vyhodnotí predikát jako nenulový.

```
unsigned int __ballot(int predicate);
```

Obsahuje bitovou masku hlasování jednotlivých threadů.

# Synchronizace paměťových operací

Sdílenou paměť obvykle využíváme ke komunikaci mezi thready a nebo jako cache pro data užívaná více thready.

- thready využívají data uložená jinými thready
- je třeba zajistit, abychom nečetli data, která ještě nejsou k dispozici
- chceme-li počkat, až jsou data k dispozici, používáme `--syncthreads()`

# Synchronizace paměťových operací

Kompilátor může optimalizovat operace se sdílenou/globální pamětí (mezivýsledky mohou zůstat v registrech) a může měnit jejich pořadí,

- chceme-li se ujistit, že jsou námi ukládaná data viditelná pro ostatní, používáme `_threadfence()`, popř.  
`_threadfence_block()`
- deklarujeme-li proměnnou jako `volatile`, jsou veškeré přístupy k ní realizovány přes load/store do sdílené či globální paměti
  - velmi důležité pokud předpokládáme implicitní synchronizaci warpu

# Synchronizace bloků

## Mezi bloky

- globální paměť viditelná pro všechny bloky
- slabá nativní podpora synchronizace
  - žádná globální bariéra
  - u novějších GPU *atomické operace* nad globální pamětí
  - globální bariéru lze implementovat voláním kernelu (jiné řešení dosti trikové)
  - slabé možnosti globální synchronizace znesnadňují programování, ale umožňují velmi dobrou škálovatelnost

# Globální synchronizace přes atomické operace

Problém součtu všech prvků vektoru

- každý blok seče prvky své části vektoru
- poslední blok seče výsledky ze všech bloků
  - implementuje slabší globální bariéru (po zkončení výpočtu u bloků  $1..n - 1$  pokračuje pouze blok  $n$ )

```
--device__ unsigned int count = 0;
__shared__ bool isLastBlockDone;
__global__ void sum(const float* array, unsigned int N,
    float* result) {
    float partialSum = calculatePartialSum(array, N);
    if (threadIdx.x == 0) {
        result[blockIdx.x] = partialSum;
        __threafence();
        unsigned int value = atomicInc(&count, gridDim.x);
        isLastBlockDone = (value == (gridDim.x - 1));
    }
    __syncthreads();
    if (isLastBlockDone) {
        float totalSum = calculateTotalSum(result);
        if (threadIdx.x == 0) {
            result[0] = totalSum;
            count = 0;
        }
    }
}
```

# Materiály

CUDA dokumentace (instalována s CUDA Toolkit, ke stažení na [developer.nvidia.com](http://developer.nvidia.com))

- CUDA C Programming Guide (nejdůležitější vlastnosti CUDA)
- CUDA C Best Practices Guide (detailnější zaměření na optimalizace)
- CUDA Reference Manual (kompletní popis C for CUDA API)
- další užitečné dokumenty (manuál k nvcc, popis PTX jazyka, manuály knihoven, ...)

Textbook ke kurzům na University of Illinois

- dostupný z  
<http://courses.ece.illinois.edu/ece498/al/Syllabus.html>

Série článků CUDA, Supercomputing for the Masses

- <http://www.ddj.com/cpp/207200659>

Dnes jsme si ukázali

- k čemu je dobré znát CUDA
- v čem jsou GPU jiná
- základy programování v C for CUDA

Dnes jsme si ukázali

- k čemu je dobré znát CUDA
- v čem jsou GPU jiná
- základy programování v C for CUDA

Příště se zaměříme na

- jak psát efektivní GPU kód

Dnes jsme si ukázali

- k čemu je dobré znát CUDA
- v čem jsou GPU jiná
- základy programování v C for CUDA

Příště se zaměříme na

- jak psát efektivní GPU kód

K samostatné práci

- zkuste si přeložit první CUDA program
- máte-li chuť, experimentujte s ním!