# Úvod, základy CUDA

Jiří Filipovič

jaro 2015

# 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 pamětmi atd.
- **dnes** vektorovými instrukcemi, zmnožováním jader

# Motivace – změna paradigmatu

Důsledky Moorova zákona:

- **dříve**: rychlost zpracování programového vlákna procesorem se každých 18 měsíců zdvojnásobí
  - změny ovlivňují především návrh kompilátoru, aplikační programátor se jimi nemusí zabývat
- **dnes**: rychlost zpracování dostatečného počtu dat 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 kompilátor

# Motivace – druhy paralelismu

- úlohový 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 – výkon

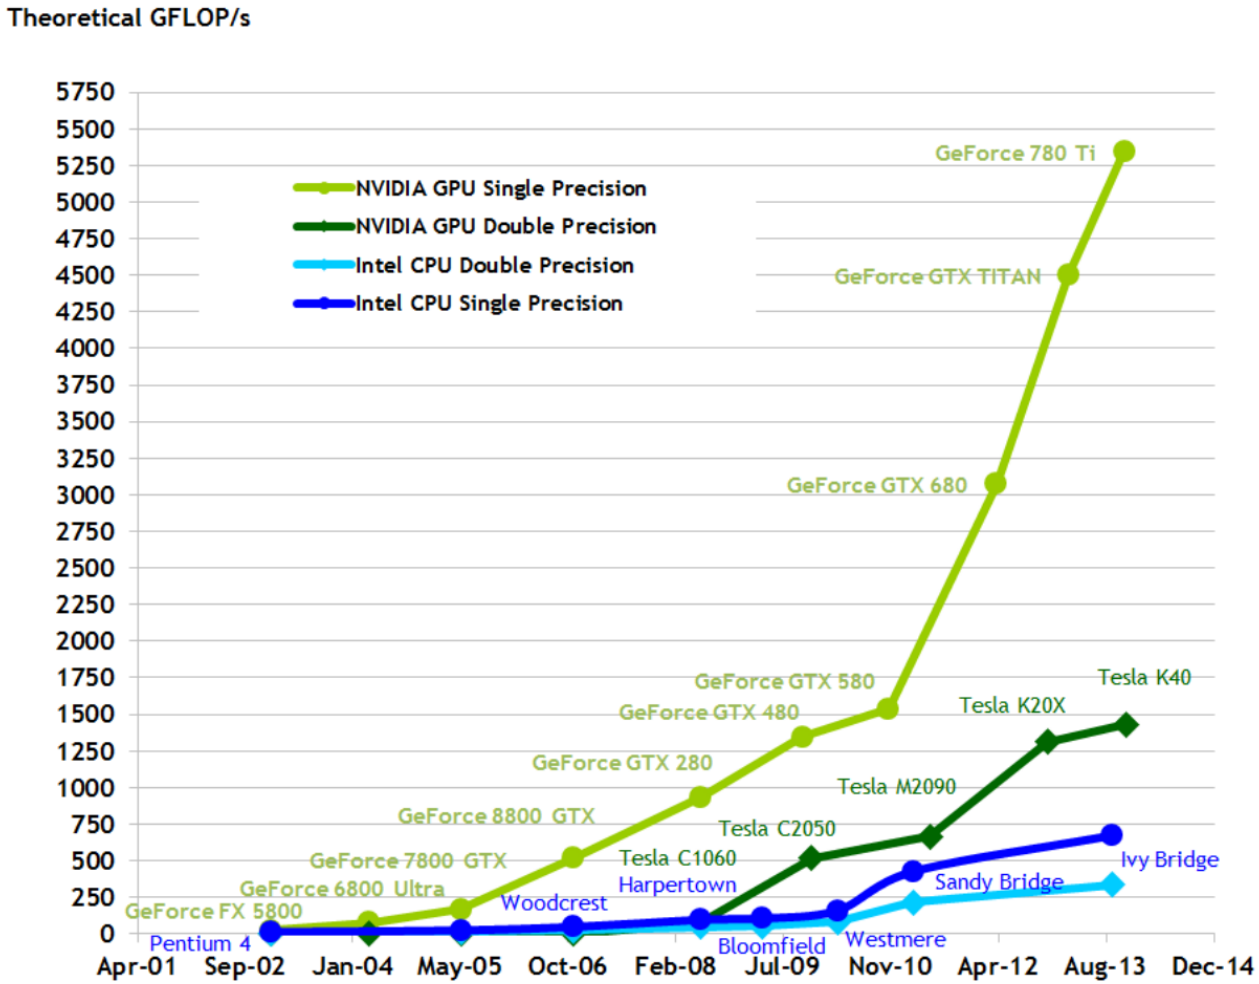

# Motivace – výkon

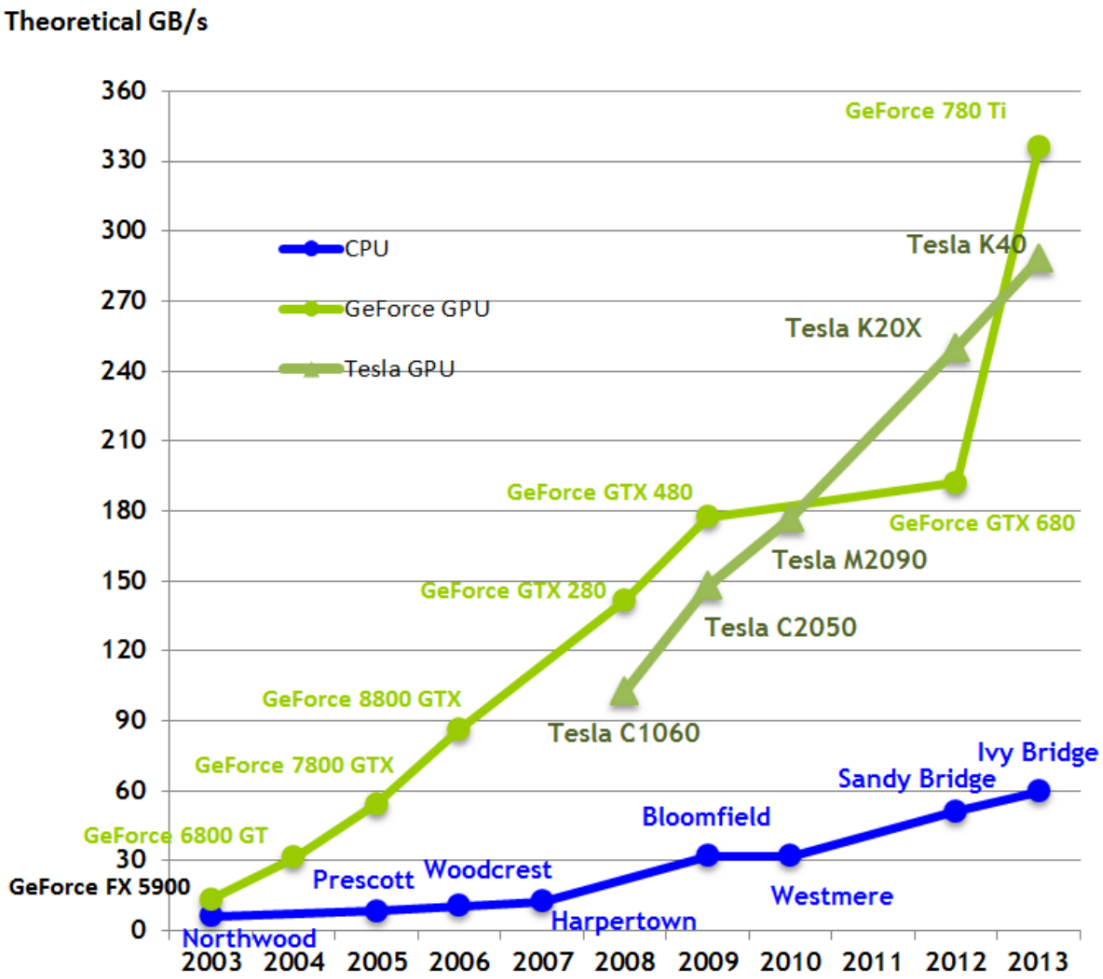

# Motivace – shrnutí

- GPU jsou výkonné
  - řádový nárůst výkodu již stoji 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
  - lze psát uživatelské aplikace

# 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 multimediálních 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

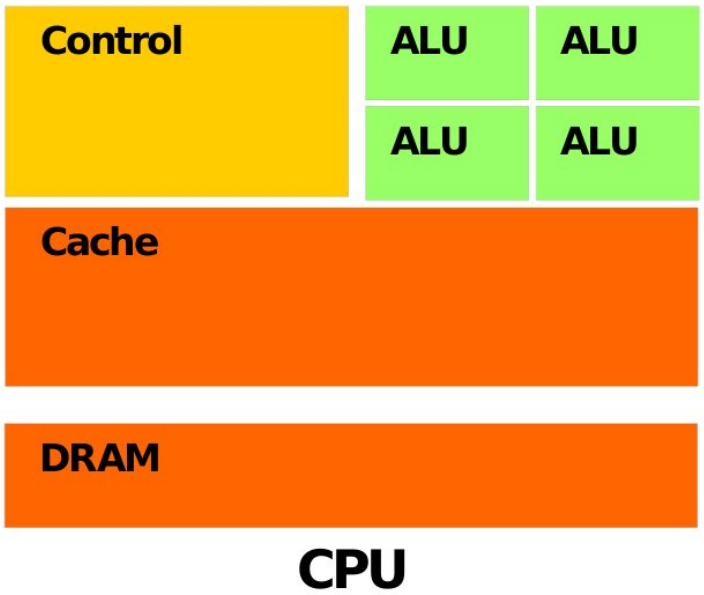


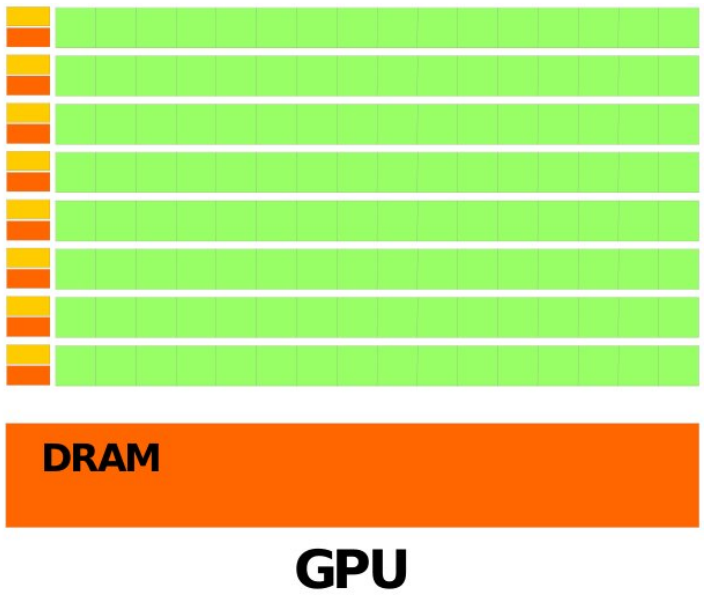

# Architektura GPU

High-end GPU:

- koprocesor 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 textury
  - 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

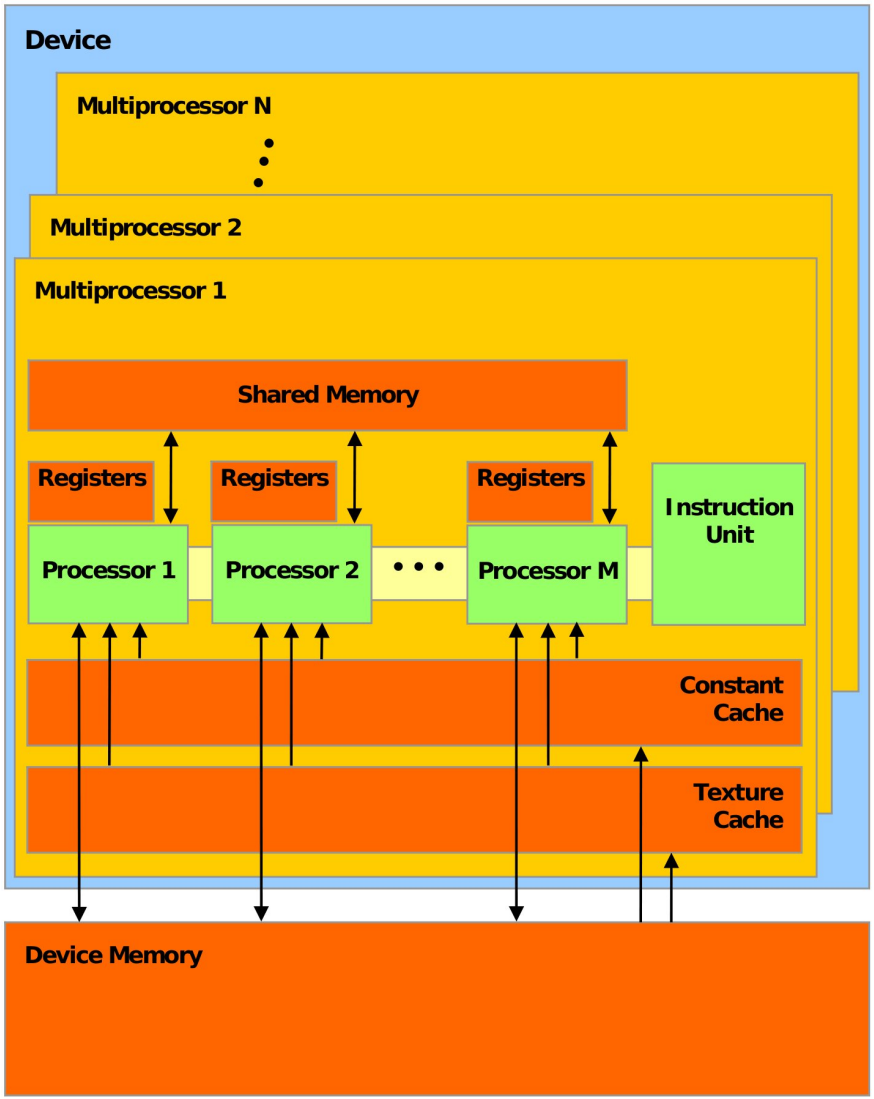

# Další vývoj

Procesory CUDA architektury

- double-precision výpočty
- benevolentnější pravidla pro efektivní přístup ke globální paměti
- L1, L2/data cache
- navýšeny on-chip zdroje (více registrů, více threadů na MP)
- lepší možnosti synchronizace
- dynamický paralelismus
- přístup na vstupně-výstupní porty

# Srovnání teoretické rychlosti GPU a CPU

Teoretická maxima

- GPU má cca 10× rychlejší aritmetiku
- GPU má cca 5× vyšší propustnost paměti
- zajímavé pro mnohé problémy (budu čekat na výsledky simulace měsíc nebo rok? pojede mi hra na 3 nebo 30 fps?)

Některé publikace ukazují 100× i 1000× zrychlení

- v pořádku, je-li interpretováno jako zrychlení oproti produkčnímu SW (ten nemusí být perfektně optimalizovaný)
- interpretováno jako srovnání CPU a GPU zpravidla nesmysl

Srovnáváme-li přínos GPU oproti CPU, musíme uvažovat efektivní implementaci pro obě platformy.

# Srovnání teoretické rychlosti GPU a CPU

V praxi máme však často sériový CPU kód

- běh v jednom vlákně znamená až 16× zpomalení (16-jádrové CPU)
- absence vektorizace znamená až 4× zpomalení (32-bit operace u SSE instrukcí), 8× u AVX instrukcí

Oproti sériové implementaci tedy můžeme kód paralelizací a vektorizací zrychlit

- 32× pro čtyřjádrové CPU s AVX nebo osmijádrové s SSE

GPU akcelerací pak

- cca 300×

Vektorizace a paralelizace pro CPU je však programátorskou náročností **srovnatelná** s GPU akcelerací.

# Teoretické vs. dosažitelné zrychlení

Výkonový odstup GPU může být vyšší

- jednotky pro speciální funkce, operace na texturách
- SIMT pružnější než SIMD
- neduhy SMP (omezení škálování propustnosti paměti, „vytloukání řádků cache")

Stejně jako nižší

- nedostatek paralelismu
- příliš vysoký overhead
- nevhodný algoritmus pro GPU architekturu

Dále se podíváme, jak rozlišit, jestli je nebo naopak není váš algoritmus vhodný pro GPU.

# Paralelizace

Sčítání vektorů

- jednoduché datově-paralelní vyjádření
- žádná synchronizace
- potřebujeme velké vektory

Game of Life

- co chceme paralelizovat?

Game of Life – zjištění nového stavu hry

- pro větší herní plochy dostatek paralelismu
- jednoduchá synchronizace

Game of Life – zjištění stavu buňky po $n$ krocích

- inherentně sekvenční? (Game of Life je $P$-complete, $P \stackrel{?}{=} NC$)
- neznáme paralelní algoritmus

# Paralelizace

Redukce

- na první pohled může vypadat sekvenčně
- ve skutečnosti realizovatelná v $\log n$ krocích
- často je třeba nedržet se sekvenční verze a zamyslet se nad paralelizací problému (ne sekvenčního algoritmu)

# Paralelizace

Problém nalezení povodňové mapy

- máme výškovou mapu terénu, přítok vody, a chceme zjistit, jaká oblast se zatopí
- sekvenčnost dána rozléváním vody
- je snadné najít úlohově-paralelní algoritmus, datově-paralelní už tak ne
  - periodická aktualizace stavu každého bodu mapy
  - aktualizace omezená jen na hranice vodní plochy (šetří procesory)
  - rozlévání vody zametací přímkou (vhodnější pro GPU, jednodušší synchronizace)
  - hledání souvislých oblastí a jejich spojování (odstraňuje sekvenčnost rozlévání)
  - vždy práce navíc oproti sekvenční/úlohově-paralelní verzi
- úkol PV197 na podzim 2010, výkon odevzdaných implementací se lišil o 4 řády (!)

# Divergence kódu

Divergence kódu

- serializace, divergují-li thready uvnitř warpu
- nalezení nedivergujícího algoritmu může být snadné
  - redukce
- ale také může prakticky znemožnit akceleraci některých jinak dobře paralelizovatelných algoritmů
  - mnoho nezávislých stavových automatů
  - nutnost zamyslet se nad výrazně odlišným algoritmem pro daný problém

# Divergence přístupu do paměti

Divergence přístupu do paměti

- není-li do paměti přistupováno po souvislých blocích v rámci warpu, snižuje se její propustnost
- často velmi těžko překonatelný problém
  - průchod obecného grafu
- může vyžadovat využití odlišných datových struktur
  - práce s řídkými maticemi
- u rigidnějších struktur si lze často pomoci on-chip pamětí
  - transpozice matic

# Latence GPU

GPU je dnes často propojena se zbytkem systému přes PCI-E

- kopírování vstupů/výstupů je relativně pomalé
- akcelerovaný algoritmus musí provádět dostatečné množství aritmetiky na přenášená data
  - násobení matic je vhodné ($\mathcal{O}(n^3)$ operací na $\mathcal{O}(n^2)$ dat)
  - sčítání vhodné není ($\mathcal{O}(n^2)$ operací na $\mathcal{O}(n^2)$ dat), může být však součástí většího problému

# 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

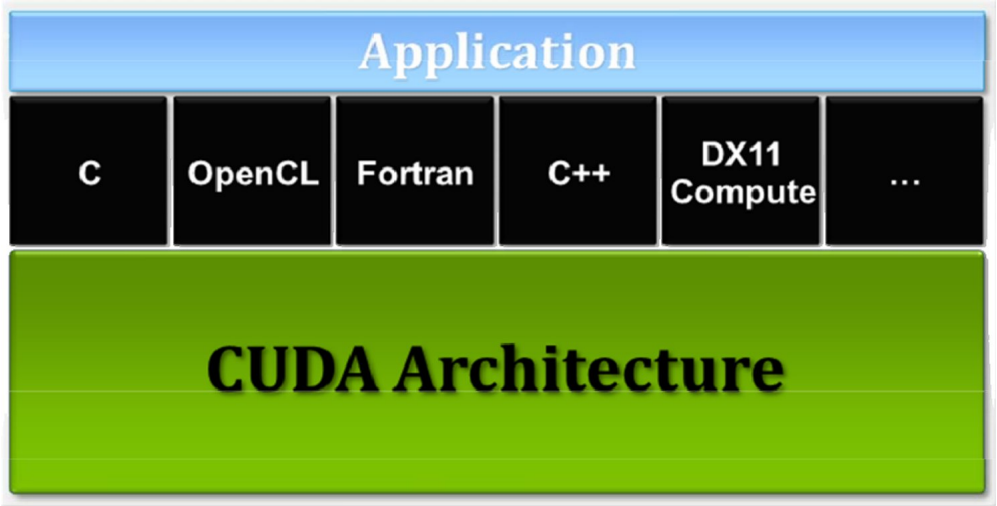

# C for CUDA

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

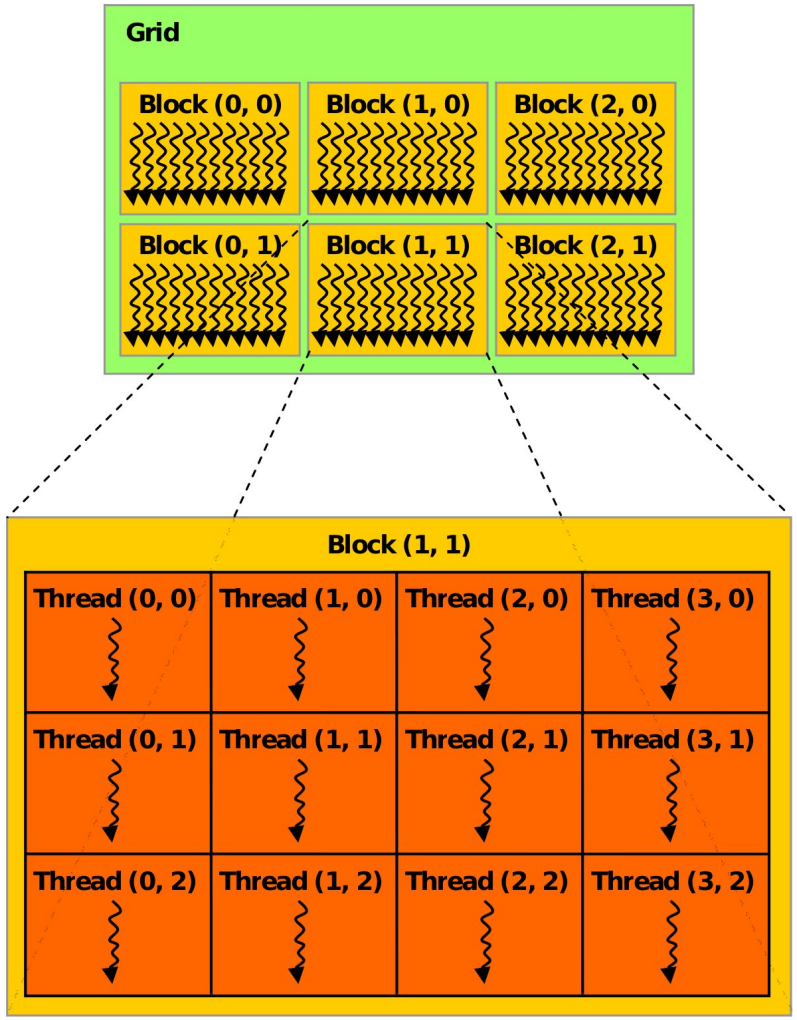

# Hierarchie pamětí

Více druhů pamětí

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

# Hierarchie pamětí

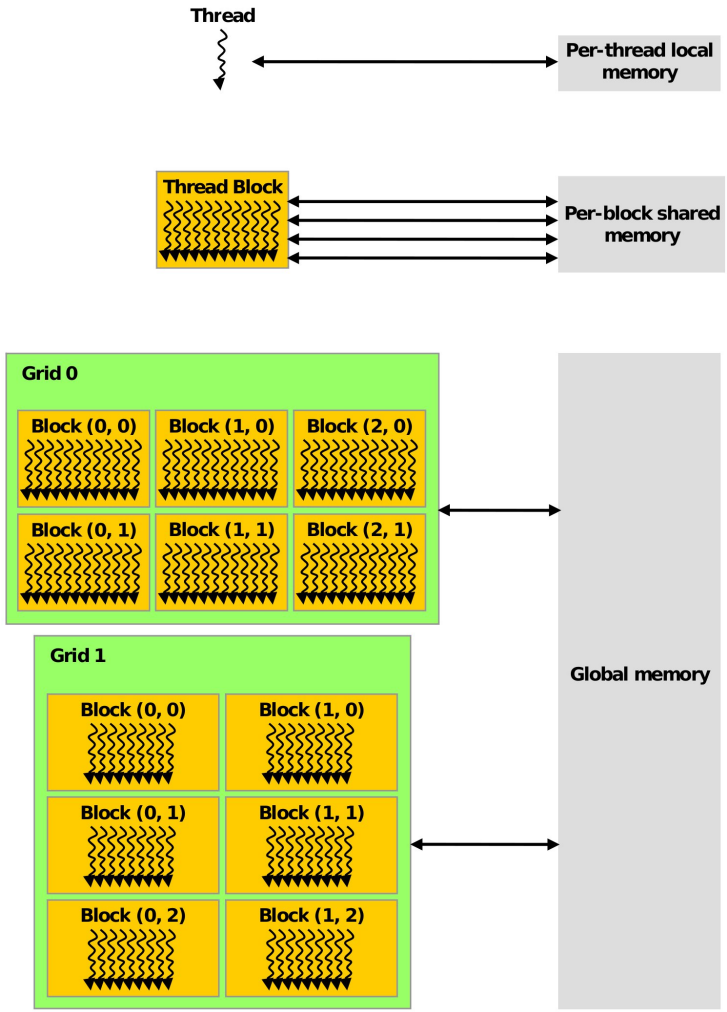

# Příklad – součet vektorů

Chceme sečíst 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 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];
```

# 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 sečte i-té složky vektorů:

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

Jak zjistíme, kolikátý jsme thread?

# Hierarchie vláken

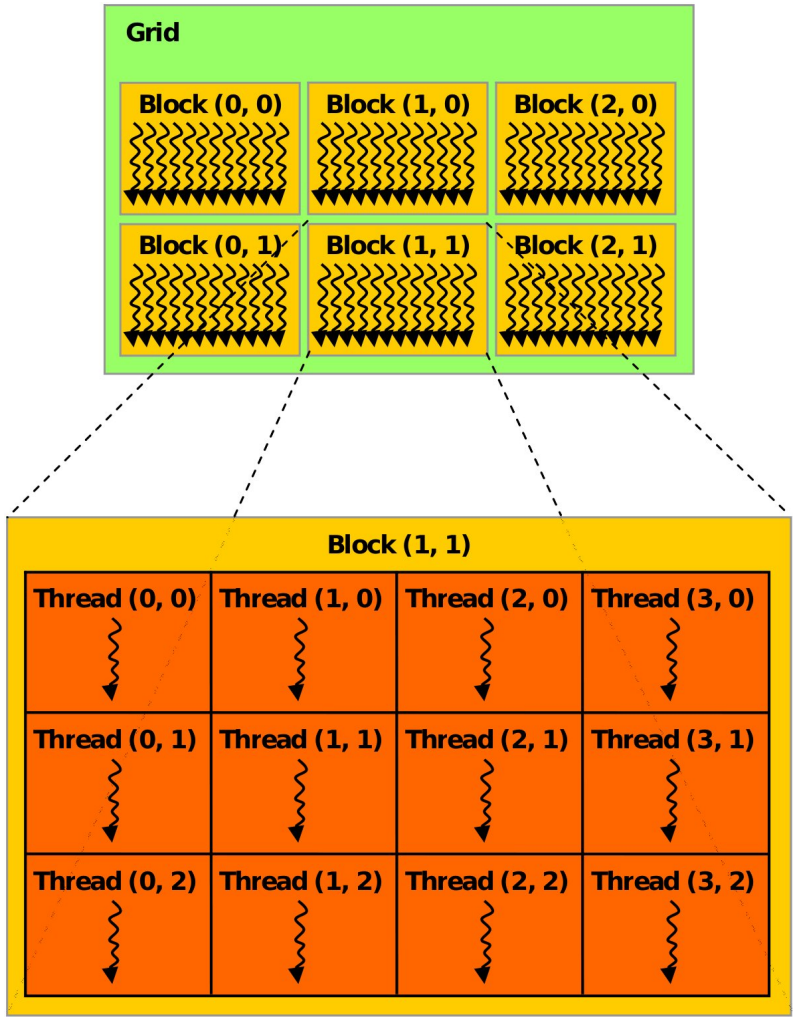

# Identifikace vlákna a bloku

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 kompilována 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* :-)

Při použití managed memory (od compute capability 3.0, CUDA 6.0) není třeba explicitně provádět kroky psané kurzívou.

# Příklad – součet vektorů

CPU kód naplní *a* a *b*, vypíše *c*:

```
#include <stdio.h>
#define N 64
int main(){
  float *a, *b, *c;
  cudaMallocManaged(&a, N*sizeof(*a));
  cudaMallocManaged(&b, N*sizeof(*b));
  cudaMallocManaged(&c, N*sizeof(*c));

  for (int i = 0; i < N; i++)
    a[i] = i; b[i] = i*2;

// zde bude kód provádějící výpočet na GPU

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

  cudaFree(a); cudaFree(b); cudaFree(c);

  return 0;
}
```

# Správa GPU paměti

Použili jsme managed paměť, CUDA se automaticky stará o přesuny mezi CPU a GPU.

- koherence je automaticky zajištěna
- k paměti nelze přistupovat, pokud běží CUDA kernel (i když ji nepoužívá)

Lze použít také explicitní alokaci:

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

# 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);
cudaDeviceSynchronize();
```

Synchronizace za voláním kernelu zajistí, že výpis hodnoty v c bude proveden až po dokončení kernelu.

# Příklad – součet vektorů

Jak řešit problém pro obecnou velikost vektoru?
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 kompilace :-).

```
nvcc -o vecadd vecadd.cu
```

# 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)

# 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 nevejde do registrů, jde do lokální paměti
- ta je fyzicky uložena v DRAM, je tudíž pomalá a má dlouhou latenci (může být však cacheována)
- 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

# Paměť lokální pro GPU

Globální paměť

- řádově nižší přenosová rychlost než u sdílené paměti
- latence ve stovkách GPU cyklů
- pro dosažení optimálního výkonu je třeba paměť adresovat sdruženě
- má životnost aplikace
- u Fermi L1 cache (128 byte na řádek) a L2 cache (32 byte na řádek), Kepler L2, c.c. 3.5 data cache, Maxwell data cache

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 neredukuje paralelismus
  - 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

# 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 sečte prvky své části vektoru
- poslední blok sečte výsledky ze všech bloků
  - implementuje slabší globální bariéru (po dokončení 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;
    __threadfence();
    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*)

- 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, ...)

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

Příště se zaměříme na

- jak psát efektivní GPU kód