CUDA nástroje a knihovny

Jiří Matela

podzim 2009

Rekapitulace

- Proč programovat GPU

Rekapitulace

What does it mean to someone who cares how long it takes to do something when you can speed things up 140 times, 100 times or even 50 times? It is like being able to go from San Francisco to New York in three minutes. A speed up of that kind is transformative. It would completely transform adjacent industries.

– Jen-Hsun Huang, nVidia CEO

Rekapitulace

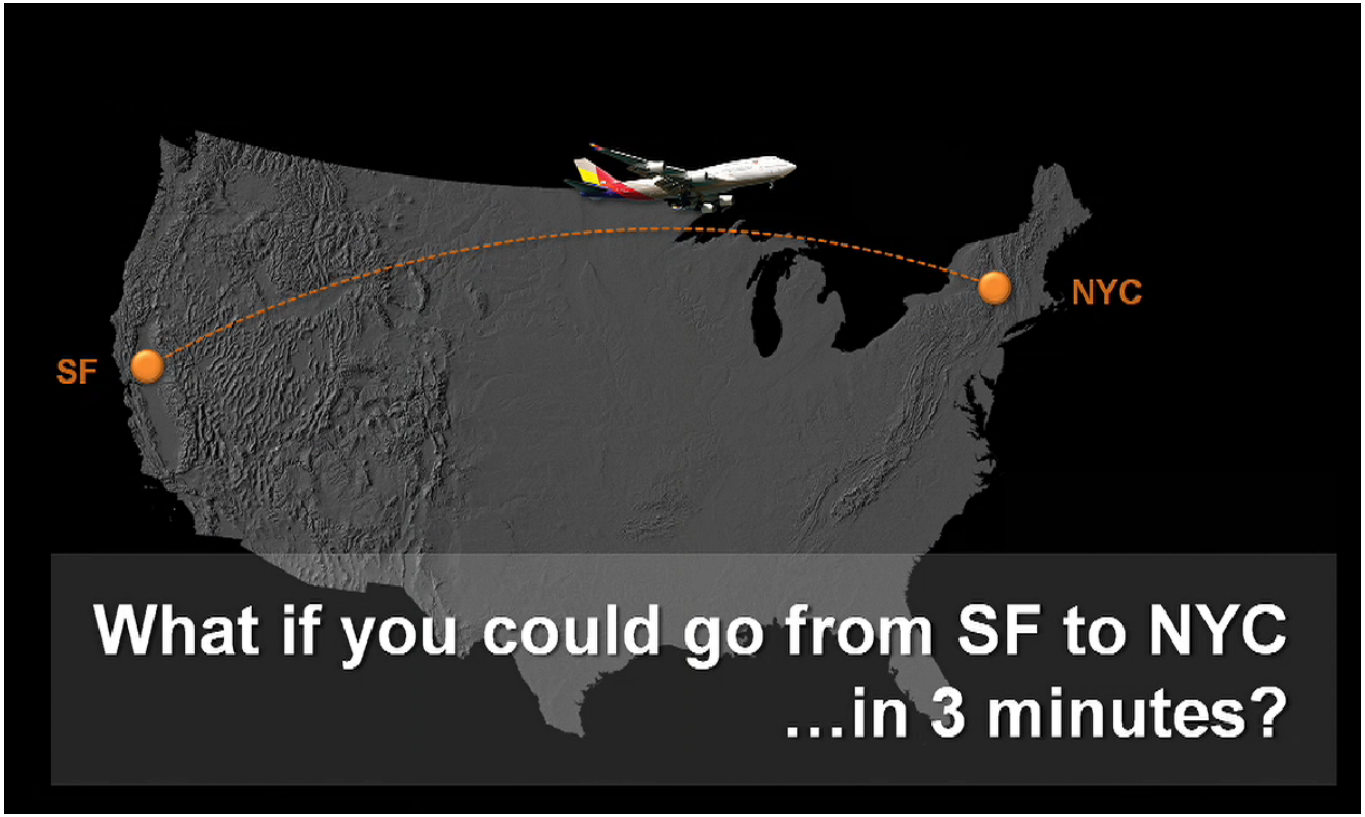

What does it mean to someone who cares how long it takes to do something when you can speed things up 140 times, 100 times or even 50 times? It is like being able to go from San Francisco to New York in three minutes. A speed up of that kind is transformative. It would completely transform adjacent industries.

– Jen-Hsun Huang, nVidia CEO

Rekapitulace

- Proč programovat GPU

Rekapitulace

- Proč programovat GPU
- GPU architektura (vs. CPU)

Rekapitulace

- Proč programovat GPU
- GPU architektura (vs. CPU)
- CUDA (Compute Unified Device Architecture)

Architektura CUDA

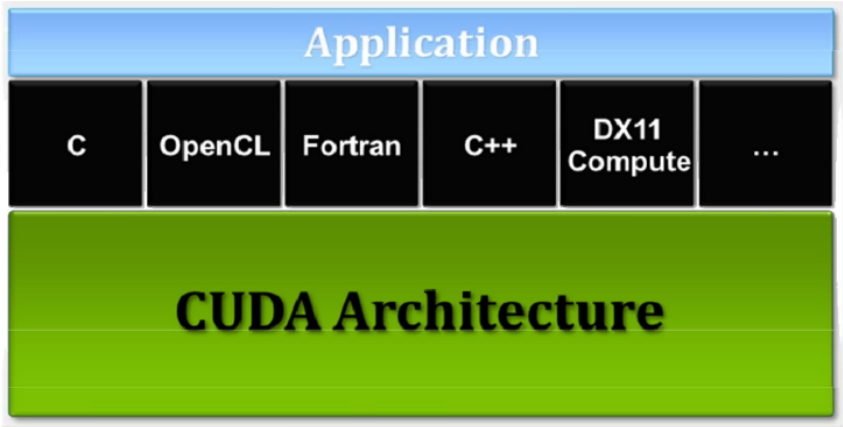

Rekapitulace

- Proč programovat GPU
- GPU architektura (vs. CPU)
- CUDA (Compute Unified Device Architecture)

Hierarchie vláken

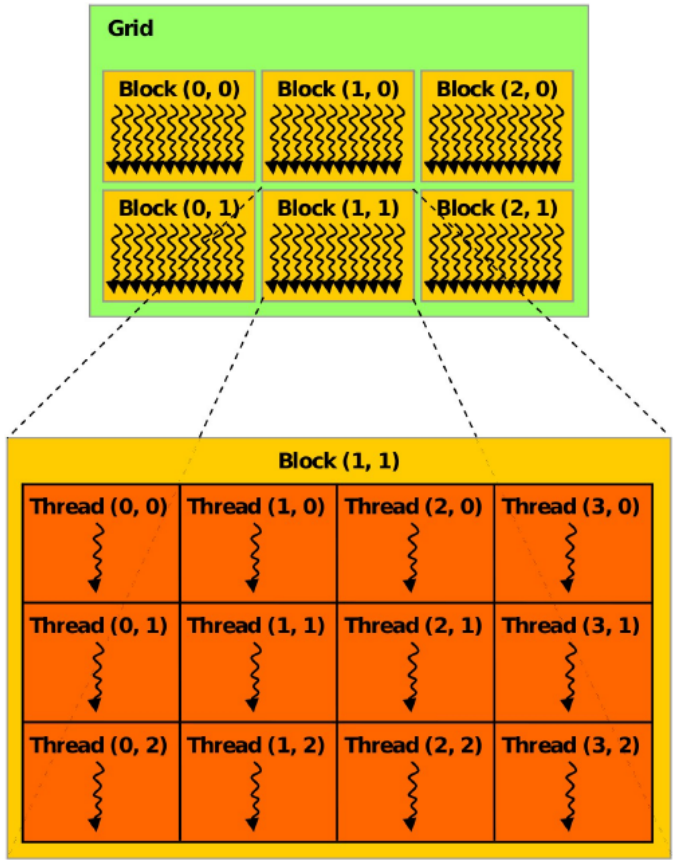

Rekapitulace

- Proč programovat GPU
- GPU architektura (vs. CPU)
- CUDA (Compute Unified Device Architecture)

Hierarchie pamětí

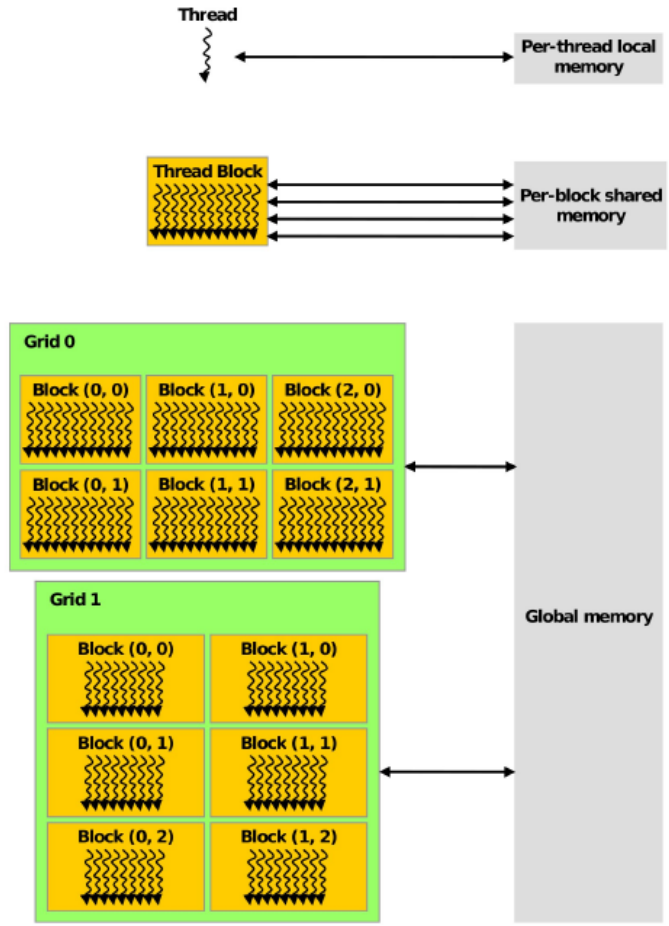

Rekapitulace

- Proč programovat GPU
- GPU architektura (vs. CPU)
- CUDA (Compute Unified Device Architecture)
  - Dvě API

Rekapitulace

- Proč programovat GPU
- GPU architektura (vs. CPU)
- CUDA (Compute Unified Device Architecture)
  - Dvě API
- Ukázkový příklad
  - Syntaktická rozšíření jazyka C – např.: `__device__`
  - Volání *runtime API* – např.: `cudaMalloc()`

Runtime API vs. Driver API

Vytvářet CUDA aplikace lze užitím buďto Runtime API nebo Driver API.

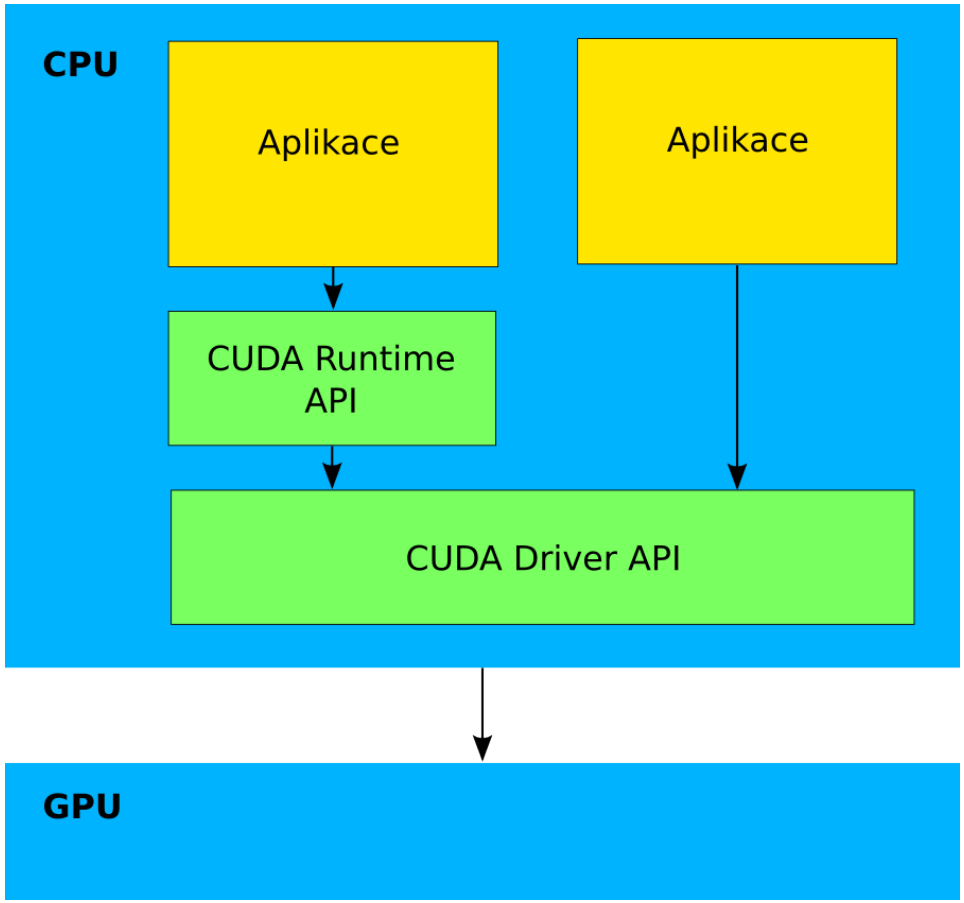

Možnosti rozhraní

Rozhraní umožňují provádět na úrovni hostitelského systému (kód vykonávaný na CPU) následující operace

- Správa zařízení
- Práce s kontextem
- Práce s kernely (moduly)
- Konfigurace výpočtu
- Paměťové operace
- Práce s texturami
- Spolupráce s OpenGL a Direct3D

Runtime API

- Runtime API a C for CUDA – množina rozšíření jazyka C
- Automatická inicializace, práce s kontextem a práce s kernely (moduly)
- Konfigurace výpočtu (volání kernelu) – syntaktický konstrukt (rozšíření jazyka C)
- Kód používající rozšíření musí být přeložen nvcc kompilátorem
- Jinak lze hostitelský kód přeložit pomoci gcc

Příklad kódu používajícího CUDA rozšíření jazyka C

Konfigurace CUDA kernelu `addvec()`

```
int main() {
   .....
   addvec<<<N/BLOCK, BLOCK>>>(d_a, d_b, d_c);
   .....
}
```

Příklad kódu používajícího CUDA rozšíření jazyka C

Konfigurace CUDA kernelu `addvec()`

```
int main() {
   .....
   addvec<<<N/BLOCK, BLOCK>>>(d_a, d_b, d_c);
   .....
}
```

Překlad:

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

Runtime API

Knihovna runtime API:

- cuda_runtime_api.h – nízkoúrovňové C funkce
- cuda_runtime.h – vysokoúrovňové C++ funkce – obaluje C api

Runtime API

Knihovna runtime API:

- cuda_runtime_api.h – nízkoúrovňové C funkce
- cuda_runtime.h – vysokoúrovňové C++ funkce – obaluje C api
- Funkce pro alokaci a dealokaci paměti

Runtime API

Knihovna runtime API:

- cuda_runtime_api.h – nízkoúrovňové C funkce
- cuda_runtime.h – vysokoúrovňové C++ funkce – obaluje C api
- Funkce pro alokaci a dealokaci paměti
- Správa karet – výběr a konfigurace karty

Runtime API

Knihovna runtime API:

- cuda_runtime_api.h – nízkoúrovňové C funkce
- cuda_runtime.h – vysokoúrovňové C++ funkce – obaluje C api
- Funkce pro alokaci a dealokaci paměti
- Správa karet – výběr a konfigurace karty
- Přenos dat z/do karty

Runtime API

Knihovna runtime API:

- cuda_runtime_api.h – nízkoúrovňové C funkce
- cuda_runtime.h – vysokoúrovňové C++ funkce – obaluje C api
- Funkce pro alokaci a dealokaci paměti
- Správa karet – výběr a konfigurace karty
- Přenos dat z/do karty
- Podpora emulace karty na CPU – debuging
- Volání prefixované `cuda*`

Příklad kódu používajícího runtime API volání

Informace o kartě

```
int main() {
    .....
  cudaGetDeviceCount(&devCount);
  printf("Available devices: %d\n", devCount);

  cudaGetDeviceProperties(devProp, 0);
  printf("Device: %d\n", i);
  printf("Name: %s\n", devProp->name);
    .....
}
```

Příklad kódu používajícího runtime API volání

Informace o kartě

```
int main() {
    .....
  cudaGetDeviceCount(&devCount);
  printf("Available devices: %d\n", devCount);

  cudaGetDeviceProperties(devProp, 0);
  printf("Device: %d\n", i);
  printf("Name: %s\n", devProp->name);
    .....
}
```

Překlad:

```
$ gcc -I/usr/local/cuda/include -L/usr/local/cuda/lib \
-lcudart -x c -o info info.cu
```

Driver API

Nízkoúrovňové rozhraní pro programování CUDA aplikací. (V pomyslné hierarchii je položeno níž než runtime API)

- Více kontroly nad kartami – jedno CPU vlákno může pracovat s více kartami
- Neobsahuje žádné rozšíření jazyka C
- Umožňuje pracovat s binárním kódem a assemblerem (PTX)
- Složitější programování, upovídanější syntax
- Složitější debugging
- Žádná GPU emulace
- Volání prefixované `cu*`

Context

Prostředí CUDA výpočtu představuje context (analogie CPU procesu nebo vlákna).

- Vztahuje se ke konkrétnímu GPU zařízení
- Zastřešuje všechny zdroje a vykonané akce
- Má vlastní 32-bit paměťový prostor (paměťové ukazatele nelze mezi kontexty přenášet)
- CPU vlákno může v danou chvíli používat vždy jen jeden kontext
- Kontexty lze mezi vlákny předávat (v Runtime API je však kontext svázán s CPU vláknem)
- Použití více karet jedním CPU vláknem

Příklad inicializace contextu

Inicializace kontextu je v případě runtime API implicitní, zatímco v případě driver API vyžaduje několik příkazů:

```
CUcontext cont;
CUdevice dev;

cuInit(0); // 0 je povinná, parametr zatím nemá význam
cuDeviceGet(&cont, 0); // vyber první kartu (0)
cuCtxCreate(&cont, CU_CTX_SCHED_AUTO, dev));
```

Moduly

S kernely se pracuje jako s moduly, které jsou (obdobně jako GLSL shadery) nahrávány za běhu.

- Binární moduly – kompilovány pro konkrétní architekturu, mohou být pomalejší nebo nekompatibilní na budoucích architekturách
- PTX moduly – kompilovány až v době natažení (PTX je meta assembler, jehož instrukce jsou nejprve přeloženy do skutečné instrukční sady dané architektury a následně pak do binárního kódu)

Příklad konfigurace a spuštění modulu

```
CUmodule myModule;
CUfunction myKern;

//nahrát modul, získat kernel "addvec"
cuModuleLoad(&myModule, "vectorAdd.cubin");
cuModuleGetFunction(&myKern, myModule, "addvec");
```

Příklad konfigurace a spuštění modulu

```
CUmodule myModule;
CUfunction myKern;

//nahrát modul, získat kernel "addvec"
cuModuleLoad(&myModule, "vectorAdd.cubin");
cuModuleGetFunction(&myKern, myModule, "addvec");

// nastavit parametry thread bloku
cuFuncSetBlockShape(myKern, x, y, z);
```

Příklad konfigurace a spuštění modulu

```
CUmodule myModule;
CUfunction myKern;

//nahrát modul, získat kernel "addvec"
cuModuleLoad(&myModule, "vectorAdd.cubin");
cuModuleGetFunction(&myKern, myModule, "addvec");

// nastavit parametry thread bloku
cuFuncSetBlockShape(myKern, x, y, z);

// nakopírovat size bajtů z &ptr do prostoru parametrů
// kernelu myKern na pozici offset
cuParamSetv(myKern, offset, &ptr, size);
```

Příklad konfigurace a spuštění modulu

```
CUmodule myModule;
CUfunction myKern;

//nahrát modul, získat kernel "addvec"
cuModuleLoad(&myModule, "vectorAdd.cubin");
cuModuleGetFunction(&myKern, myModule, "addvec");

// nastavit parametry thread bloku
cuFuncSetBlockShape(myKern, x, y, z);

// nakopírovat size bajtů z &ptr do prostoru parametrů
// kernelu myKern na pozici offset
cuParamSetv(myKern, offset, &ptr, size);

// celková velikost parametrů
cuParamSetSize(myKern, offset);
```

Příklad konfigurace a spuštění modulu

```
CUmodule myModule;
CUfunction myKern;

//nahrát modul, získat kernel "addvec"
cuModuleLoad(&myModule, "vectorAdd.cubin");
cuModuleGetFunction(&myKern, myModule, "addvec");

// nastavit parametry thread bloku
cuFuncSetBlockShape(myKern, x, y, z);

// nakopírovat size bajtů z &ptr do prostoru parametrů
// kernelu myKern na pozici offset
cuParamSetv(myKern, offset, &ptr, size);

// celková velikost parametrů
cuParamSetSize(myKern, offset);

// execute kernel
cuLaunchGrid(myKern, grid_width, grid_height);
```

Specifické výhody obou rozhraní

Aneb, které rozhraní použít.
Runtime API:

- Jednodužší
- CUFFT, CUBLAS, CUDPP knihovny
- Emulace karty

Driver API:

- Správa kontextů
- Větší kontrola CUDA prostředí

Specifické výhody obou rozhraní

Aneb, které rozhraní použít.

Runtime API:

- Jednodužší
- CUFFT, CUBLAS, CUDPP knihovny
- Emulace karty

Driver API:

- Správa kontextů
- Větší kontrola CUDA prostředí

Rozhraní lze kombinovat!

Jak pracovat s kartami – základní funkce

Zakladní funkce pro výběr karty

- **cudaGetDeviceCount***(int *count)* – počet dostupných karet s compute capability ≥ 1.0, pokud v systému není dostupná žádná karta, vrátí funkce hodnotu 1, protože systém podporuje emulační mód – compute capability bude Major: 9999 Minor: 9999
- **cudaSetDevice***(int dev)* – musí být voláno před inicializací, v opačném případě vrací funkce chybové hlášeni cudaErrorSetOnActiveProcess
- **cudaGetDevice***(int *dev)* – právě používané zařízení

Jak pracovat s kartami – pokročilé funkce

- **cudaGetDeviceProperties**(*struct cudaDeviceProp *p, int dev*) – ve struktuře *cudaDeviceProp* vrací informace o zařízení *dev*
- **cudaChooseDevice**(*int *dev, const struct cudaDeviceProp *p*) – funkce vybere kartu na základě kriterií **p*
- **cudaSetValidDevices**(*int *dev_arr,int len*) – seznam karet, ze kterých může být vybíráno
- **cudaSetDeviceFlags**(*int flags*) – nastavuje jak bude CPU vlákno čekat na kartu (Spin, Yield, Sync, Auto) nebo příznak umožňující mapovat paměť. Funkce musí být volána před inicializací

Práce s pamětí

- Alokace paměti na kartě – **cudaMalloc{Pitch, Array, 3D, 3DArray}()**
  - Lineární paměť
  - 2D paměť a 2D pole
  - 3D paměť a 3D pole
- Kopírování paměti mezi počítačem a kartou (host $\Leftrightarrow$ device) kopírování dat na kartě (device $\Leftrightarrow$ device) – **cudaMemcpy***()
- Alokace paměti v RAM počítače
  - K čemu?

Kopírování paměti mezi počítačem a kartou

- Základní funkce **cudaMemcpy**(*void *dst, const void *src, size_t count, enum cudaMemcpyKind kind*)
  - cudaMemcpyHostToDevice
  - cudaMemcpyDeviceToHost
  - cudaMemcpyDeviceToDevice, cudaMemcpyHostToHost
- Teoretická přenosová rychlost dosažitelná na PCI Express 2.0 $\times 16$ sběrnici je 8 GB/s. Prakticky však mnohem méně.

Kopírováni dat do karty

Dva přístupy, jeden výrazně rychlejší.

```
int *hmem, *dmem;
hmem = (int *)malloc(SIZE);
cudaMalloc((void**)&dmem, SIZE);

cudaMemcpy(dmem, hmem, SIZE,
        cudaMemcpyHostToDevice);
```

```
int *hmem, *dmem;
cudaMallocHost((void**)&hmem,
                        SIZE);
cudaMalloc((void**)&dmem, SIZE);

cudaMemcpy(dmem, hmem, SIZE,
        cudaMemcpyHostToDevice);
```

Kopírováni dat do karty

Dva přístupy, jeden výrazně rychlejší.

```
int *hmem, *dmem;
hmem = (int *)malloc(SIZE);
cudaMalloc((void**)&dmem, SIZE);

cudaMemcpy(dmem, hmem, SIZE,
        cudaMemcpyHostToDevice);
```

- PCI-e 1.0 ×16 1,5 GB/s
- PCI-e 2.0 ×16 4,7 GB/s

```
int *hmem, *dmem;
cudaMallocHost((void**)&hmem,
                        SIZE);
cudaMalloc((void**)&dmem, SIZE);

cudaMemcpy(dmem, hmem, SIZE,
        cudaMemcpyHostToDevice);
```

- PCI-e 1.0 ×16 2,8 GB/s
- PCI-e 2.0 ×16 5,5 GB/s

Page-locked memory

- Page-locked (pinned) paměť umožňuje alokovat funkce **cudaMallocHost**(*void **ptr, size_t size*)
  nebo:
- **cudaHostAlloc**(*void **ptr, size_t size, usignedt int flags*)
  - cudaHostAllocDefault, cudaHostAllocPortable, cudaHostAllocMapped, cudaHostAllocWriteCombined
- Paměť je alokována jako souvislý blok ve fyzickém adresním prostoru který je navíc uzamčen proti přesunu do swapovacího oddílu
- CUDA totiž může použít pouze DMA přístup, pro který je právě potřeba, aby daný paměťový blok byl umístěn v RAM
- CUDA nepodporuje ani scatter-gather DMA, kdy je možno najednou přistoupit ke množině adres (bloků)
- Toho nelze docílit kombinací volání `malloc()` a `mlock()` (zejména souvislost nelze zajistit z US)

Page-locked memory

- Není-li paměť alokována tímto způsobem, musí pak driver při kopírování do karty nejprve interně přenést data do "vhodné" paměťové oblasti a odtud je teprve kopírovat do karty (pomoci DMA)
- **cudaHostAlloc***()* tedy:
  - Alokuje souvislý blok paměti ve fyzickém adresním prostoru (a namapuje jej do virtuální paměti aplikace)
  - Znemožní přesun této paměti do swapovací oblasti
  - Driver si navíc pro daný kontext (nebo pro všechy) pamatuje že k dané paměti lze přistoupit přímo pomoci DMA

Souběžný běh výpočtu na GPU a CPU

Aby CPU vlákno mohlo během GPU výpočtu vykonávat další operace a nemusel vždy čekat na GPU, jsou některé CUDA funkce asynchronní. *Příklad: Příprava dalších dat, zatímco probíhá výpočet nad předchozími daty.* Asynchronní je:

- Vykonání kernelu
- Funkce s příponou Async určené ke kopírování paměti
- Funkce vykonávající device⇔device paměťové kopie
- Funkce vykonávající host⇔device paměťové kopie nad daty $\leq$ 64KB
- Funkce nastavující paměť

Vykonání CPU funkce během GPU výpočtu

Příklad:

```
cudaMemcpyAsync(dev, hst, cudaMemcpyHostToDevice, 0);
cpuFunkce();
kernelFunkce<<<grid, block>>>(dev);
cpuFunkce();
```

Překrývání GPU výpočtu a datových přenosů – použití `streams`

Má-li GPU schopnost deviceOverlap je možné kopírovat z/do karty a zároveň provádět na kartě výpočet.

- Paměť musí být page-locked (pinned)
- Použití streams
  - Representuje posloupnost CUDA volání
  - Volání příslušná různým streamům mohou být vykonána souběžně
  - Streamy lze synchronizovat, případně se dotazovat na stav výpočtu ve streamu

Příklad překrývání GPU výpočtu a datových přenosů

```
cudaStream_t stream[2];
for (int i = 0; i < 2; ++i)
    cudaStreamCreate(&stream[i]);
```

Příklad překrývání GPU výpočtu a datových přenosů

```
cudaStream_t stream[2];
for (int i = 0; i < 2; ++i)
    cudaStreamCreate(&stream[i]);

float* hostPtr;
cudaMallocHost((void**)&hostPtr, 2 * size);
```

Příklad překrývání GPU výpočtu a datových přenosů

```
cudaStream_t stream[2];
for (int i = 0; i < 2; ++i)
    cudaStreamCreate(&stream[i]);

float* hostPtr;
cudaMallocHost((void**)&hostPtr, 2 * size);

for (int i = 0; i < 2; ++i)
    cudaMemcpyAsync(inputDevPtr + i * size, hostPtr + i * size,
    size, cudaMemcpyHostToDevice, stream[i]);
```

Příklad překrývání GPU výpočtu a datových přenosů

```
cudaStream_t stream[2];
for (int i = 0; i < 2; ++i)
    cudaStreamCreate(&stream[i]);

float* hostPtr;
cudaMallocHost((void**)&hostPtr, 2 * size);

for (int i = 0; i < 2; ++i)
    cudaMemcpyAsync(inputDevPtr + i * size, hostPtr + i * size,
    size, cudaMemcpyHostToDevice, stream[i]);

for (int i = 0; i < 2; ++i)
    myKernel<<<100, 512, 0, stream[i]>>>
        (outputDevPtr + i * size, inputDevPtr + i * size, size);
```

Příklad překrývání GPU výpočtu a datových přenosů

```
cudaStream_t stream[2];
for (int i = 0; i < 2; ++i)
    cudaStreamCreate(&stream[i]);

float* hostPtr;
cudaMallocHost((void**)&hostPtr, 2 * size);

for (int i = 0; i < 2; ++i)
    cudaMemcpyAsync(inputDevPtr + i * size, hostPtr + i * size,
    size, cudaMemcpyHostToDevice, stream[i]);

for (int i = 0; i < 2; ++i)
    myKernel<<<100, 512, 0, stream[i]>>>
        (outputDevPtr + i * size, inputDevPtr + i * size, size);

for (int i = 0; i < 2; ++i)
    cudaMemcpyAsync(hostPtr + i * size, outputDevPtr + i * size,
        size, cudaMemcpyDeviceToHost, stream[i]);
```

Příklad překrývání GPU výpočtu a datových přenosů

```
cudaStream_t stream[2];
for (int i = 0; i < 2; ++i)
    cudaStreamCreate(&stream[i]);

float* hostPtr;
cudaMallocHost((void**)&hostPtr, 2 * size);

for (int i = 0; i < 2; ++i)
    cudaMemcpyAsync(inputDevPtr + i * size, hostPtr + i * size,
    size, cudaMemcpyHostToDevice, stream[i]);

for (int i = 0; i < 2; ++i)
    myKernel<<<100, 512, 0, stream[i]>>>
        (outputDevPtr + i * size, inputDevPtr + i * size, size);

for (int i = 0; i < 2; ++i)
    cudaMemcpyAsync(hostPtr + i * size, outputDevPtr + i * size,
        size, cudaMemcpyDeviceToHost, stream[i]);

cudaThreadSynchronize();
```

Detekce chyb

- Všechny runtime funkce (**cuda***()) vracejí chybový kód typu **cudaError_t**
- CUDA runtime udržuje pro každé CPU vlákno chybovou proměnou, která je v případě chyby přepsána chybovou hodnotou posledního volání
- Funkce **cudaGetLastError**() vrací obsah chybové proměnné a zároveň nastaví její hodnotu na **cudaSuccess**
- Chybový kód lze do slovní podoby přeložit voláním **cudaGetErrorString**()
- Návratová hodnota asynchronních funkcí lze spolehlivě ověřit pouze explicitním voláním **cudaThreadSynchronize**() a ověřením jeho návratové hodnoty

Příklad detekce chyb

```
cudaError_t err = cudaSetDevice(...);    //< synchronní volání
if(err != cudaSuccess) {
    fprintf(stderr, "Error: '%s'\n", cudaGetErrorString(err));
    exit(CHYBA);
}
```

Příklad detekce chyb

```
cudaError_t err = cudaSetDevice(...);    //< synchronní volání
if(err != cudaSuccess) {
    fprintf(stderr, "Error: '%s'\n", cudaGetErrorString(err));
    exit(CHYBA);
}

cudaError_t err;
cudaMemcpyAsync(...);    //< asynchronní volání
err = cudaThreadSynchronize();
if(err != cudaSuccess) {
    fprintf(stderr, "Error: '%s'\n", cudaGetErrorString(err));
    exit(CHYBA);
}
```

Kompilátor NVCC

- Kompiluje CUDA zdrojové kódy obsahující CPU i GPU kód (host/device code)
- CPU kód je předán externímu kompilátoru – `gcc` na linuxu, `cl` ve windows
- GPU kód převeden do `PTX` formy, dál do binární `cubin` podoby
- Výsledek GPU kompilace – `.cubin` výstup – je zabudován do zbytku programu
- Může být načten za běhu – viz driver API

Kroky nvcc kompilace

- Jednotlivé kroky `nvcc` kompilátoru lze prohlédnout, je-li kompilace spustěna s parametry --**dryrun** a --**keep**
- Vyzkoušej!

Generování kódu pro konkrétní Compute Capability

- **--gpu-architecture (-arch)**
  - virtualni architektura **compute_*** PTX

- **--gpu-code (-code)**
  - generuje binarni kod pro konkretni architekturu **sm_***

Generování kódu pro konkrétní Compute Capability

- **--gpu-architecture (-arch)**
  - virtualni architektura **compute_*** PTX
  - neni-li zadano -code pouzije se odpovidajici nastaveni z -arch
  - napr: `nvcc -arch=sm_13` ekvivalentní k `nvcc -arch=compute_13 -code=sm_13`
- **--gpu-code (-code)**
  - generuje binarni kod pro konkretni architekturu **sm_***

Generování kódu pro konkrétní Compute Capability

- **--gpu-architecture (-arch)**
  - virtualni architektura **compute_*** PTX
  - neni-li zadano -code pouzije se odpovidajici nastaveni z -arch
  - napr: `nvcc -arch=sm_13` ekvivalentní k `nvcc -arch=compute_13 -code=sm_13`
- **--gpu-code (-code)**
  - generuje binarni kod pro konkretni architekturu **sm_***
  - je li parametrem i virtualni architektura, pak je pribalen PTX
  - napr: `-arch=compute_13 -code=compute_13,sm_13`

Generování kódu pro konkrétní Compute Capability

- **--gpu-architecture (-arch)**
  - virtualni architektura **compute_*** PTX
  - neni-li zadano -code pouzije se odpovidajici nastaveni z -arch
  - napr: `nvcc -arch=sm_13` ekvivalentní k `nvcc -arch=compute_13 -code=sm_13`
- **--gpu-code (-code)**
  - generuje binarni kod pro konkretni architekturu **sm_***
  - je li parametrem i virtualni architektura, pak je pribalen PTX
  - napr: `-arch=compute_13 -code=compute_13,sm_13`
- compute_10, compute_11, compute_12, compute_13, compute_20, compute_30, sm_10, sm_11, sm_12, sm_13, sm_20, sm_21, sm_22, sm_23, sm_30

Užitečné parametry nvcc kompilátoru

- **-arch=sm_13** – zapne podporu double precission
- **-use_fast_math** – automatické použití "rychlých" matematických funkcí prefixovaných __ (vyšší rychlost nižší přesnost)
- **--ptxas-options=-v** – mj. zobrazí využití registrů a paměti
- **-G** – zapne debuging pro GPU kód
- **--maxrregcount** $< N >$ – nastaví maximální počet registrů, pro GPU funkce
- **-deviceemu** – emulace

Debuging CUDA aplikací

- Obtížnější než na CPU
- Na GPU nelze použít `printf`
- Lze kopírovat mezivýsledky do globální paměti a zpět do RAM počítače – obtížné
- Hledání chybové řádky půlením intervalů (zakomentování řádků)
- Emulace běhu na CPU

Emulace běhu na CPU

- Použitím přepínače nvcc kompilátoru lze emulovat všechen GPU kód na CPU
- **-deviceemu**, **--device-emulation**
- Lze použít standardní techniky hledání chyb `gdb`, `printf`
- Vlákna jsou však spouštěna sekvenčně – nemusí se projevit chyby paralelního přístupu do paměti, odlišné paměťové modely,
- Práce s CPU ukazatelem v GPU kódu se nemusí při emulaci projevit, avšak při běhu na GPU způsobí chybu
- Výsledky operací v plovoucí desetinné mohou být jemně odlišné
- Velikost warpu je rovna jedné

CUDA gdb

- Umožňuje za hledání chyb v aplikaci za běhu na GPU
- Port GNU GDB 6.6
- Velmi podobný přístup
- Podporováno na všech kartách s compute capability 1.1 a vyšší
  - Například 8800 Ultra/GTX je pouze 1.0
- Součást CUDA Toolkit 2.3

CUDA gdb

- Zastavení běhu na libovolné CPU i GPU funkci nebo řádku zdrojového kódu
  - `(cuda-gdb) break mujKernel`
  - `(cuda-gdb) break mujKod.cu:45`
- Krokování GPU kódu po `warpech`
  - `(cuda-gdb) next` – posun po řádcích, nevkročí do funkce
  - `(cuda-gdb) step` – krok do funkce
- Prohlížení paměti, registrů a speciálních proměnných
  - `(cuda-gdb) print blockIdx`

```
$ 1 = {x = 0, y = 0}
```

CUDA gdb

- Výpis informací o použité kartě, paměti alokované na karatě
  - `(cuda-gdb) info cuda state`
- Výpis informací o blocích a vláknech běžících na kartě
  - `(cuda-gdb) info cuda threads`
- Přepnutí na konkrétní blok nebo vlákno
  - `(cuda-gdb) thread<<<Bx, By, Tx, Ty, Tz>>>`

CUDA gdb

- Program musí být zkompilován s parametry **-g -G**

```
nvcc -g -G -o program program.cu
```

CUDA Profiler

- Umožňuje analyzovat HW čítače a odhalit neoptimální sekce kódu
- Pro funkci umí zobrazit:
- Čas strávený na CPU a GPU
- Obsazení GPU
- Počet ne/sdružených čtení/zápisů do globální paměti
- Počet čtení/zápisů do lokální paměti
- Počet divergentních větvení uvnitř warpu

Hodnoty jsou však měřeny pouze na jednom multiprocesoru, tzn. spíše pro relativní porovnání mezi jednotlivými verzemi kernelu

Knihovny využívající CUDA

- Součástí CUDA instalace
  - **CUBLAS** – Basic Linear Algebra Subprograms (BLAS)
  - **CUFFT** – Fast Fourier Transform (FFT)
- **CUDPP** – Data Parallel Primitives (DPP)
  - `http://gpgpu.org/developer/cudpp`
  - Například:
  - Paralelní třídění
  - Paralelní redukce
  - Pseudonáhodný generátor čísel
  - BSD licence

CUBLAS

- Implementace BLAS pro CUDA
- Není potřeba přímá interakce s CUDA API
- Funkce definovány v **cublas.h**
- Jednoduché použití
  - CUBLAS inicializace
  - Alokace paměti na GPU použitím CUBLAS volání
  - Naplnění alokované paměti (kopírování dat)
  - Volání CUBLAS funkcí
  - Získání výsledků (kopírování z karty)
  - Ukončení CUBLAS
- `simpleCUBLAS` příklad v CUDA SDK

CUFFT

- Implementace FFT pro CUDA
- Vyžaduje použití základních runtime API volání (`cudaMalloc()`, `cudaMemcpy()`)
- Funkce definovány v **cufft.h**
- 1D, 2D, 3D transformace na reálných i komplexních číslech

- `simpleCUFFT` příklad v CUDA SDK

Závěr

Dnes jsme si ukázali

- Jak programovat CUDA aplikace – dvě rozhraní a rozdíly mezi nimi
- Základní funkce runtime API
- Jak efektivně využít šířku PCIe sběrnice při kopírování dat
- Jak souběžně vykonávat CPU a GPU kód (překrývání)
- Jak hledat chyby – emulace a cuda-gdb
- Knihovny používající CUDA

Samostatná práce

K samostatné práci

- Zkuste změřit jaké rychlosti jste schopni dosáhnout při přenosu dat po PCIe sběrnici na vašem systému
- Zkuste si vytvořit jednoduchý program, který vypíše základní informace o vaši kartě (zkuste takovýto program spustit na systému bez CUDA enabled karty)
- Na kódu z minulé přednášky vyzkoušejte použití `cuda-gdb` a `cudaprof`