

Metriky efektivity na GPU

Petr Holub

`hopet@ics.muni.cz`



Laboratoř pokročilých síťových technologií

PV197

2010-11-17

Přehled přednášky

Vlastnosti CUDA

Metriky algoritmů

Měření

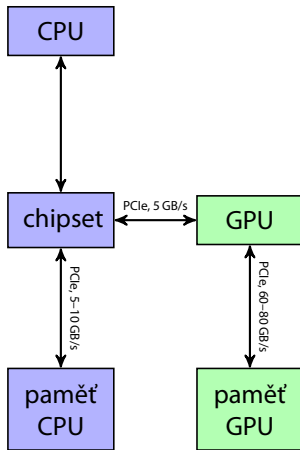
Literatura

- Park I. K., Singhal N., Lee M. H., Cho S., Kim C. W., “Design and Performance of Evaluation of Image Processing Algorithms on GPUs,” *IEEE Transactions on Parallel and Distributed Systems*, 2010 (zatím pouze v elektronické verzi)
- Cope B., Cheung P. Y. K., Luk W., Howes L., “Performance Comparison of Graphics Processors to Reconfigurable Logic: A Case Study”, *IEEE Transactions on Computers*, vol. 59, no. 4, April 2010
- Best Practices Guide – CUDA 2.2, 2009 http://developer.download.nvidia.com/compute/cuda/2_3/toolkit/docs/NVIDIA_CUDA_BestPracticesGuide_2.3.pdf
- Wil Braithwaite, “The CUDA architecture: The Art of performance optimization”, Siggraph 2009, http://developer.download.nvidia.com/presentations/2009/SIGGRAPH/asia/6_cuda_optimization.pdf

Shrnutí práce s pamětí

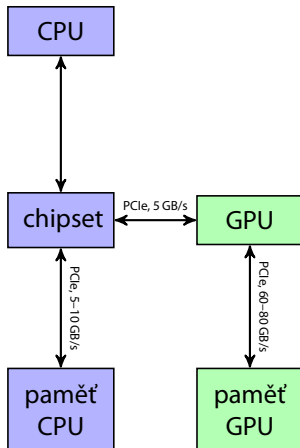
- Práce s pamětí
 - omezení paměti
 - ◆ omezená šířka pásma mezi host a device (cca 6 GB/s pro PCI-e x16 Gen2)
 - ◆ latence globální paměti (teoreticky 141 GB/s, cca 400–600 cyklů latence)

$$\underbrace{1107 \times 10^6}_{\text{takt paměti [Hz]}} \times \underbrace{(512/8)}_{\text{Inteface paměti}} \times \underbrace{2}_{\text{DDR}} / 10^9 = 141,6 \text{ GB/s}$$
 (ev. 132 GB/s při dělení 1024^3)
 - ◆ omezená velikost sdílené paměti
 - ◆ omezený počet registrů

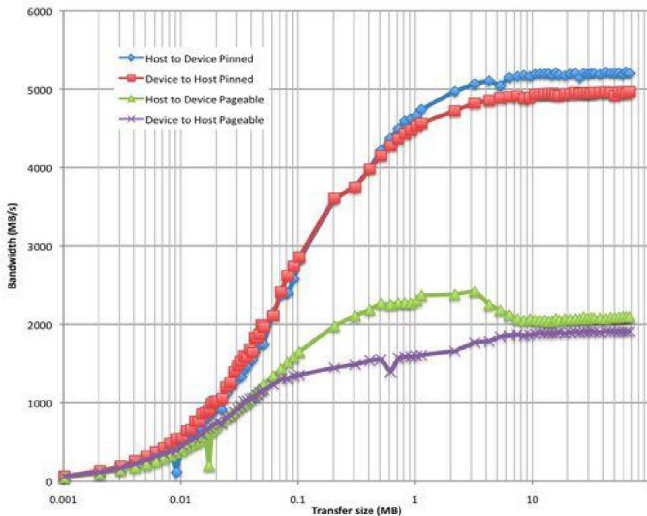


Shrnutí práce s pamětí

- Práce s pamětí
 - optimalizace
 - ◆ maximální využití sdílené paměti a registrů
 - ◆ koalescentní přístup do globální paměti a vyhnutí se partition campingu
 - ◆ překrývání výpočtů a přístupu k datům
 - ◆ využití asynchronních přenosů: `cudaMemcpyAsync(...)`;
 - ◆ přiměřené používání page-locked paměti: `cudaHostAlloc(...)`;
 - ◆ co největší přenosy host ↔ device najednou



Shrnutí práce s pamětí



Zdroj: Wil Braithwaite, "The CUDA architecture: The Art of performance optimization"

Pokročilá práce s pamětí

- Další triky s pamětí
 - rozvrhnout, co cacheovat a co opakovaně počítat
 - mapování OpenGL bufferu do adresního prostoru zařízení (device)
 1. zaregistrujte si buffer pomocí CUDA-C
`cudaGLRegisterBufferObject (GLuint buffObj);`
 2. namapujte zaregistrovaný buffer do globální paměti zařízení (vrátí adresu)
`cudaGLMapBufferObject (void** devPtr, GLuint buffObj);`
 3. použijte adresu v kernelu
 4. odmapujte buffer
`cudaGLUnmapBufferObject (GLuint buffObj);`
 5. odregistrujte buffer
`cudaGLUnregisterBufferObject (GLuint buffObj);` (potřeba pouze pokud je buffer cíl rendrování)
 6. použijte buffer v OpenGL
 - ◆ může pomoci odstranit přenosy host ↔ device
 - ◆ automatické DMA mezi kartami Tesla a Quadro (momentálně přes host)
 - ◆ vykreslování z pixel buffer object pomocí `glDrawPixels` nebo `glTexImage2D`

Pokročilá práce s pamětí

Textura generovaná pomocí CUDA:

```
2 // setup code:
3 cudaGLRegisterBufferObject (pbo);
4 // CUDA texture generation code:
5 unsigned char *d_buffer;
6 cudaGLMapBufferObject ((void**) &d_buffer, pbo);
7 prep_texture_kernel<<<...>>>(d_buffer);
8 cudaGLUnmapBufferObject (pbo);
9 // OpenGL rendering code:
10 glBindBuffer (GL_PIXEL_UNPACK_BUFFER_ARB, pbo);
11 glBindTexture (GL_TEXTURE_2D, tex);
12 glTexSubImage2D (GL_TEXTURE_2D, 0, 0, 0, 256, 256, GL_BGRA, GL_UNSIGNED_BYTE, 0);
```

Zpracování snímku pomocí CUDA:

```
2 // OpenGL rendering code:
3 // ...
4 // CUDA post-processing code:
5 unsigned char *d_buffer;
6 cudaGLRegisterBufferObject (pbo);
7 cudaGLMapBufferObject ((void**) &d_buffer, pbo);
8 post_process_kernel<<<...>>>(d_buffer);
9 cudaGLUnmapBufferObject (pbo);
10 cudaGLUnRegisterBufferObject (pbo);
```

Zdroj: Wil Braithwaite, "The CUDA architecture: The Art of performance optimization"

Pokročilá práce s pamětí

- Další triky s pamětí

- Write-Combining

```
cudaHostAlloc((void**)&h_data, num_bytes,
              cudaHostAllocWriteCombined);
```

- ◆ paměť není cacheovaná ani cache koherentní
- ◆ PCI nedělá snooping
- ◆ podle CUDA 2.2 Pinned Memory APIs (http://www.fcsc.es/download/Archivo%20Cursos/CUDA_Unileon_2009/CUDA2.2PinnedMemoryAPIs.pdf) může poskytnout až o 40 % větší výkon
- ◆ může zvýšit i výkon pro zápis procesorem (Write Combining Memory Implementation Guidelines, <http://download.intel.com/design/PentiumII/applnots/24442201.pdf>): agregací zápisu, obcházením L1/L2 cache
- ◆ problematické čtení – potřeba používat paměťové bariéry před čtením hodnot (`_mm_sfence` na Linuxu, `_WriteBarrier` na Windows, u SSE4 lze pro čtení použít instrukci `MOVNTDQA`); bariéry provádí CUDA driver a jsou relativně pomalé

Pokročilá práce s pamětí

- Události
 - synchronizace omezená na specifickou událost

```
1  cudaEvent_t HtoDdone;
2  cudaEventCreate(&HtoDdone, 0);
3  cudaMemcpyAsync(d_dest, h_source, bytes, cudaMemcpyHostToDevice, 0);
4  cudaEventRecord(HtoDdone);
5  myKernel<<<grid,block>>>(...);
6  cudaMemcpyAsync(d_dest, h_source, bytes, cudaMemcpyDeviceToHost, 0);
7  // cpu can do stuff here
8  cudaEventSynchronize(HtoDdone);
9  // waits just for everything before
10 //  cudaEventRecord(HtoDdone)
11 //  to complete and then runs
12 //
13 // The first memory copy is done,
14 // so the memory at source could be
15 // used again by the CPU
16 cudaThreadSynchronize();
17 // waits for everything on GPU to finish, then returns
```

Pokročilá práce s pamětí

- Streamy
 - identifikace při asynchronních přenosech
 - `cudaStream_t`, `cudaStreamCreate()`
 - fronty se plní v pořadí vykonávání kódu

```
1 CudaMemcpyAsync (A1..., StreamA);  
2 KernelA1<<<..., StreamA>>> ();  
3 KernelA2<<<..., StreamA>>> ();  
4 KernelA3<<<..., StreamA>>> ();  
5 CudaMemcpyAsync (A2..., StreamA);  
6 CudaMemcpyAsync (B1..., StreamB);  
7 CudaMemcpyAsync (B2..., StreamB);  
8 KernelB1<<<..., StreamB>>> ();  
9 CudaMemcpyAsync (B3..., StreamB);  
10 CudaMemcpyAsync (B4..., StreamB);
```

Špatně – blokováno vykonávání kernelu B1 kvůli kopírování výsledků A2

Pokročilá práce s pamětí

- Streamy
 - identifikace při asynchronních přenosech
 - `cudaStream_t`, `cudaStreamCreate()`
 - fronty se plní v pořadí vykonávání kódu

```
1  CudaMemcpyAsync (A1..., StreamA);  
2  KernelA1<<<..., StreamA>>> ();  
3  KernelA2<<<..., StreamA>>> ();  
4  KernelA3<<<..., StreamA>>> ();  
5  CudaMemcpyAsync (B1..., StreamB);  
6  CudaMemcpyAsync (B2..., StreamB);  
7  KernelB1<<<..., StreamB>>> ();  
8  CudaMemcpyAsync (A2..., StreamA);  
9  CudaMemcpyAsync (B2..., StreamB);  
10 CudaMemcpyAsync (B2..., StreamB);
```

OK

Pokročilá práce s pamětí

- Streamy
 - vícecestné překryvy (3-way, 4-way)
Wil Braithwaite, "The CUDA architecture: The Art of performance optimization"
 - Fermi obsahuje druhou kopírovací jednotku – zajímavé pro 4-cestné přenosy
- Způsoby čekání na synchronní události
 - `cudaError_t cudaSetDeviceFlags (int flags)`
 - parametry:
 - `cudaDeviceScheduleSpin` – minimalizuje latenci, CPU vlákno aktivně spinuje
 - `cudaDeviceScheduleYield` – umožňuje co nejefektivnější běh vlákna na CPU
 - `cudaDeviceBlockingSync` – CPU vlákno se při čekání zablokuje pomocí synchronizačního primitiva
 - `cudaDeviceScheduleAuto` – default, heuristika: buď aktivně spinuje nebo provede yield, podle počtu aktivních CUDA kontextů a počtu logických procesorů v systému

Pokročilá práce s pamětí

- Zero-copy mapování paměti
 - přímý přístup k datům v paměti CPU
 - schopnost tohoto se testuje pomocí pole `canMapHostMemory` dotazu `cudaDeviceProp`
 - automatický přenos dat po PCIe dle potřeby
 - relativně pomalé
 - ◆ pro jednorázově použitá malá data
 - ◆ pokud dokáže vysoký podíl výpočtu maskovat latenci
 - zajímavé zejména v kombinaci s integrovanými kartami – `integrated` pole `cudaDeviceProp`
 - ◆ na UMA architektuře odpadá přenos úplně
 - ◆ Nvidia ION

Shrnutí práce s procesory

- Vlákna a multiprocesory
 - potřebujeme využít výpočetní výkon karty
 - kolik warpů potřebujeme k maskování latence globální paměti?
 - ◆ řekněme, že potřebujeme 100 aritmetických instrukcí k maskování latence (400 taktů latence / 4 takty na instrukci)
 - ◆ řekněme, že máme 8 aritmetických instrukcí (8×4 takty) na 1 přístup do globální paměti (400 taktů latence)
 - ◆ $100/8 \approx 13$ warpů
 - kolik warpů potřebujeme k maskování read-after-write latence registrů?
 - ◆ latence je cca 24 cyklů
 - ◆ $24/4 \approx 6$ warpů

Shrnutí práce s procesory

- Vlákna a multiprocesory
 - obsazení (occupancy)

$$O = \frac{\text{\# warpů běžících na MP v daný okamžik}}{\text{maximální \# souběžných warpů}}$$

- ◆ c. c. 1.2: maximálně 32 warpů
c. c. 1.1: maximálně 24 warpů
- ◆ $13/32 = 40\%$ obsazení pro maskování latence globální paměti (c. c. 1.2)
- ◆ $6/32 = 18,75\%$ obsazení pro maskování latence registrů (c. c. 1.2)
- více vláken $\stackrel{?}{=}$ větší výkon
 - ◆ záleží na zdrojích požadovaných vláknem
 - ◆ záleží na uspořádání vláken

Shrnutí práce s procesory

- Limity multiprocesoru:
 - počty registrů: 16384 (64 kB) nebo jen 8192 (32 kB) na starším železe
 - sdílená paměť: 16 kB
 - maximální počet warpů: 32
 - maximální počet bloků: 8
- Pozor na dostatečný počet vláken/warpů v bloku (≥ 96)
- Pozor na limity v počtu potřebných registrů

Shrnutí práce s procesory

- Příklad limitů pro 8132 registrů a 24 warpů:
 - 10 registrů na vlákno, 256 vláken na blok
 - ◆ každý blok použije 2650 registrů \implies mohou běžet 3 bloky (7680 registrů)
 - ◆ $256 \times 3/32 = 24$ warpů může běžet současně \implies může dosáhnout 100 % využití
 - 17 registrů na vlákno, 256 vláken na blok
 - ◆ každý blok použije 4352 registrů \implies může běžet 1 blok (4352 registrů)
 - ◆ $256 \times 1/32 = 8$ warpů může běžet současně \implies může dosáhnout jen 33 % využití
 - 17 registrů na vlákno, 128 vláken na blok
 - ◆ každý blok použije 2176 registrů \implies mohou běžet 3 bloky (6528 registrů)
 - ◆ $128 \times 3/32 = 12$ warpů může běžet současně \implies může dosáhnout 50 % využití

Shrnutí práce s procesory

- Určení používaných zdrojů
 - přeložíme s `-cubin`
 - výsledný `.cubin` soubor obsahuje

```

1 architecture {sm_10}
2 abiversion {0}
3 modname {cubin}
4 code {
5     name = MyKernel
6     lmem = 0      // lokalni pamet per blok
7     smem = 68    // sdilena pamet per blok
8     reg = 20     // pocet registru per vlakno
9     bar = 0
10    bincode {
11        0xa0004205 0x04200780 0x40024c09 0x00200780

```

- nebo použijeme `-ptxas-options=-v`

```

ptxas info : Used 4 registers, 60+56 bytes lmem, 44+40 bytes
smem, 20 bytes cmem[1], 12 bytes cmem[14]

```

Shrnutí práce s procesory

- Omezení tlaku na registry
 - kompilátor se snaží počet registrů minimalizovat
 - `-maxrregcount=<N>` umožňuje nastavit požadovaný maximální počet registrů na kernel
 - přetečení do lokální paměti způsobí zpomalení
- Heuristiky pro velikost mřížky
 - # bloků > # multiprocesorů
 - ◆ aby všechny multiprocesory měly alespoň jeden blok k vykonávání
 - # bloků / # multiprocesorů > 2
 - ◆ na jednom procesoru může běžet více bloků
 - ◆ bloky nečekající v `__syncthreads()`; udržují zátěž hardware
 - # bloků > 1000
 - ◆ rezerva do budoucnosti přes několik generací karet

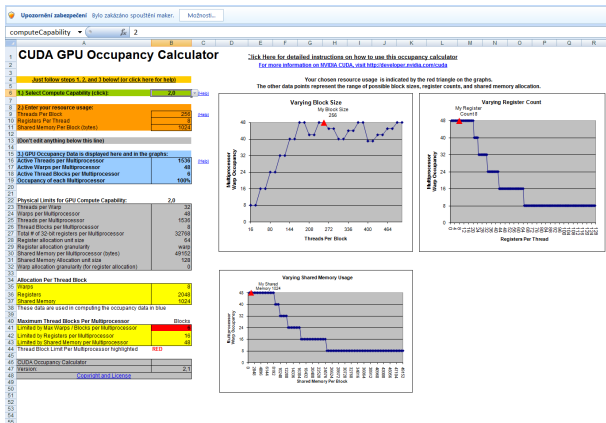
Shrnutí práce s procesory

- Heuristiky na velikost bloku
 - čím více vláken v bloku, tím méně může jedno vlákno používat registrů
 - čím více vláken v bloku, tím hlubší pipeline a lepší maskování latence
 - počty vláken v bloku by měly být násobky 64
 - ◆ minimalizace bank konfliktů na registrech
 - ◆ rozmné: 192 nebo 256

Shrnutí práce s procesory

- CUDA Occupancy Calculator

http://developer.download.nvidia.com/compute/cuda/CUDA_Occupancy_calculator.xls



Zdroj: Wil Braithwaite, "The CUDA architecture: The Art of performance optimization"

Metriky z pohledu obrazových algoritmů

1. Paralelní podíl
2. Poměr mezi operacemi v plovoucí čárce a přístupů do globální paměti
3. Počet operací v plovoucí čárce na pixel
4. Počet přístupů do paměti na pixel
5. Míra větvení
6. Závislost úloh
 - Srovnávané algoritmy implementovány na CPU
 - výpočet metrik před implementací na CUDA

Metriky z pohledu obrazových algoritmů

- Paralelní podíl
 - odpovídá Amdahlovu zákonu se všemi důsledky
 - při složeném algoritmu odpovídá poměrům částí
- Poměr mezi operacemi v plovoucí čárce a přístupů do globální paměti
 - jakékoli zápisy (sdílená, lokální, globální paměť)
 - skrývání latence překrýváním výpočtem
- Počet operací v plovoucí čárce (FP) na pixel
 - při výpočtech v plovoucí čárce překonávají GPU cca 20× CPU
 - obrazové zpracování zahrnuje typicky hodně operací v plovoucí čárce
 - nepřímo koreluje i s přístupy do paměti
- Počet přístupů do paměti na pixel
 - GPU mají přibližně 10× větší kapacitu přístupu do paměti než CPU
 - per pixel charakteristika umožňuje často využití sdílené paměti
 - problémy se sekvenčními přístupy do paměti u některých algoritmů – omezují paralelismus

Metriky z pohledu obrazových algoritmů


- Míra větvení
 - větvení přes `if`, `switch`, `do`, `for`, `while`
 - algoritmy pro zpracování obrázků často používají větvení na základě výsledku bitových operací
 - počítá se na základě rozptylu délky běhu jednotlivých vláken
 - berou se vlákna po blocích velikosti 32
- Závislost úloh
 - při zpracování obrázků se závislosti většinou řeší sekvenčním spouštěním CUDA kernelů
 - sleduje se počet bariér

Relativní důležitost metrik

- Paralelní podíl > Větvení > FP operace per pixel > přístupy do paměti per pixel > poměr mezi FP operacemi a přístupy do paměti > závislost úloh
 1. Amdahl limituje vše
 2. omezení SIMT modelu
 3. algoritmy na zpracování obrazu mají obecně hodně FP operací
 4. poměr je závislý na předchozích dvou hodnotách (proč ho zavádět?)
 5. závislost úloh určuje obtížnost implementace (opravdu?)

Studované pilotní algoritmy

- Stereo srovnávání obrázků (Multiview Stereo Matching, MVS)



Studované pilotní algoritmy


- Stereo srovnávání obrázků (Multiview Stereo Matching, MVS)
 - popis algoritmu
 - ◆ vstup:
 - zkalibrované obrazy $I = I_0, \dots, I_{N-1}$
 - projekční matice $P = P_0, \dots, P_{N-1}$
 - ◆ výstup:
 - 3D body $X = X_0, \dots, X_{M-1}$
 - ◆ porovnávání lokálních oken mezi jednotlivými obrazy
 - ◆ hloubka se pro bod (x, y) v referenčním obrazu určí přeložením příslušné oblasti z I_i na oblasti v obraz I_{i-1}
 - ◆ bod s minimálním součtem absolutních odchylek (SAD) a normalizovanou cross-korelací (NCC) je uložen jako best-match
 - ◆ opakujeme pro ostatní sousedící obrazy (např. I_{i+1})
 - ◆ bod je korektně určen, pokud počet best-match je nad hranici MIN_COUNT
 - ◆ opakujeme pro všechny body a všechny referenční obrazy
 - složitost: $\mathcal{O}(N^2 WHL)$
 - N ... počet vstupních obrazů, W resp. H ... vodorovné resp. svislé rozlišení, L ... velikost ohraničujícího boxu

Studované pilotní algoritmy

- Stereo srovnávání obrázků (Multiview Stereo Matching, MVS)
 - mapování na GPU
 - ◆ porovnávání lokálních oken je nezávislé – dobře mapuje na GPU
 - ◆ vlákno \sim pixel, tj. $W \times H$ vláken
 - ◆ $\mathcal{O}(N)$ volání kernelu pro výpočet hloubky pro jeden referenční obraz
 - ◆ $\mathcal{O}(L)$ volání uvnitř kernelu
 - ◆ obrázky se nakopírují do globální paměti
 - ◆ koeficienty lokálního okna jdou do sdílené paměti – častý přístup
 - ◆ složitost: $\mathcal{O}\left(\frac{N^2 WHL}{T_{max}}\right)$
 T_{max} ... maximální počet vláken na GPU (např. 12288 na G80)

Studované pilotní algoritmy

- Získávání lineárních charakteristik (Linear Feature Extraction)
 - rozpoznávací aplikace: budovy, silniční pruhy, ...




T. Zhou, "Linear Feature Extraction Based on an AR Model Edge Detector"
<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=01169687>

Studované pilotní algoritmy

- Získávání lineárních charakteristik (Linear Feature Extraction)
 - popis algoritmu
 - ◆ vstup: obrázek
 - ◆ výstup: obrázek s detekovanými hranami
 - ◆ použijeme algoritmus Nevatia-Babu s Cannyho metodou detekce hran
 - 1. detekce hran
 - 2. zúžení hran
 - 3. vytvoření řetízků hran na základě spojitosti v 8 směrech
 - 4. fitting čar na řetízky
 - 5. pokud segment čáry dává větší chybu než hraniční hodnota, je čára rozdělena na 2
 - 6. poslední krok iterativně opakujeme

Studované pilotní algoritmy

- Získávání lineárních charakteristik (Linear Feature Extraction)
 - mapování na GPU



- ◆ 6 per-pixel kernelů


1. Cannyho detekce hran jako per-pixel filtr
2. klasifikace pixelů podle okolí 3×3 – Initialization
3. nalezení co nejdelších souvislých částí, určení počátečního a koncového bodu – Linking
4. výpočet odchylky od úsečky proložené mezi počáteční a koncový bod – Fitting
5. pokud odchylka přesahuje D_{max} , rozdělí se souvislý řetězec na dva
6. iterujeme poslední 3 kroky, dokud vznikají nové segmenty

Studované pilotní algoritmy

- Získávání lineárních charakteristik (Linear Feature Extraction)
 - mapování na GPU
 - ◆ počítá se pro všechny pixely – i ty, co hrany neobsahují \implies omezení
 - ◆ redundantní hledání nejdelších souvislých čar
 - ◆ významný podíl over-computation

Studované pilotní algoritmy

- JPEG2000 – diskrétní vlnková transformace (DWT) a EBCOT



Matela, Rusňák, Holub, "GPU-Based Sample-Parallel Context Modelling for EBCOT in JPEG2000", MEMICS2010


- DWT: per pixel, coefficient lifting
- EBCOT Tier-1: problém se sériovou definicí algoritmu
 - uvnitř bloku (code block) jsou složité závislosti
 - algoritmus je definován tak, blokem prochází postupně a aktualizuje stav
 - mezi bloky závislosti nejsou

Studované pilotní algoritmy

- JPEG2000 – diskrétní vlnková transformace (DWT) a EBCOT
 - mapování na GPU
 - ◆ DWT: per pixel
 - ◆ EBCOT Tier-1: per blok

Studované pilotní algoritmy

- Nefotorealistický rendering



- Cartoon-style NPR
- Oily-style NPR

Studované pilotní algoritmy

- Nefotorealistický rendering
 - popis algoritmu: Cartoon-style NPR
 - ◆ bilaterální filtrování (plochy)
 - ◆ Cannyho detekce hran (čáry)
 - ◆ přeložení čar přes plochy
 - mapování na GPU: Cartoon-style NPR
 - ◆ per pixel pro všechny operace
 - ◆ vstupní obrázky jsou uloženy ve 2D texturové paměti

Studované pilotní algoritmy

- Nefotorealistický rendering
 - popis algoritmu: Oily-style NPR
 - ◆ rozdíl původního obrazu a gaussovsky rozostřeného obrazu per pixel (míra rozostření udává tloušťku štětce)
 - ◆ tah se generuje, pokud oblast v součtu rozdílů dosahuje nad stanovenou hranici
 - ◆ tah začíná od lokálního maxima a vede po gradientu
 - ◆ tah se uloží pouze je-li dost dlouhý
 - ◆ uložené tahy se „obtáhnou štětcem“ dané tloušťky
 - ◆ proces začíná s čistým pozadím a opakuje se od nejtlustšího štětce k nejtenčímu
 - mapování na GPU: Oily-style NPR
 - ◆ paralelizace per tah: problém s překryvem tahů
 - ◆ paralelizace per pixel: problém jak vybrat pořadí tahů
 - ◆ reformulace/heuristika: světlejší štětec se použije později než tmavší
⇒ pro daný pixel vybereme nejsvětlejší barvu překrývajících se tahů
 - ◆ musíme hledat, kterými tahy bude pixel ovlivněn (maximální vzdálenost od trajektorie tahu)
 - ◆ vstupní obrázky jsou uloženy ve 2D texturové paměti

Přehled pilotních algoritmů

Characteristics Algorithms	Processing Domain	Degree of Concurrency	Branching Diversity of Parallel Threads
Multiview Stereo Matching	Pixel	Massive	Low
Linear Feature Extraction	Pixel / Feature	Medium	Low (Edge) High (Linking, Fitting)
JPEG2000 Encoding	Pixel / Bitplanes	Massive (DWT) Low (EBCOT)	High
Non-Photorealistic Rendering	Pixel	Massive	Low

Characteristics Algorithms	Floating-Point Arithmetic Intensity	Other Features
Multiview Stereo Matching	Low	-
Linear Feature Extraction	High	Overcomputation occurs
JPEG2000 Encoding	High (DWT) High (EBCOT)	-
Non-Photorealistic Rendering	High	Only pixelwise convolutions

Výsledky pilotních algoritmů

- charakteristika algoritmů

Algorithms	Characteristics	Parallel Fraction (↑)	FP Computation to Memory Access Ratio (↑)	FP Computation Per Pixel (↑)
Multiview Stereo Matching		0.994	1.838	4,900
Linear Feature Extraction		0.706	5.183	1,083
JPEG2000 Encoding (DWT)		0.983	3.630	552
JPEG2000 Encoding (Tier-1)		0.834	7.630	579
Cartoon-Style NPR		0.987	8.043	45,118
Oily-Style NPR		0.992	13.363	4,972

- MVS kompenzuje malý poměr FLOP/mem vysokou mírou paralelismu
- DWT kompenzuje málo FLOP/pixel vysokou mírou paralelismu
- LFE má problém s nízkou mírou paralelismu

Výsledky pilotních algoritmů

- charakteristika algoritmů

Algorithms	Characteristics	Memory Access Per Pixel (↑)	Branching diversity (↓)	Task dependency (↓)
Multiview Stereo Matching		2,665	0.117	1
Linear Feature Extraction		209	0.113	11
JPEG2000 Encoding (DWT)		152	0.138	12
JPEG2000 Encoding (Tier-1)		76	0.307	1
Cartoon-Style NPR		5,609	0.156	6
Oily-Style NPR		372	0.121	34

- task depenednecy: implementace bude stát hodně úsilí (schoval se nám díky zvolenému přístupu EBCOT Tier-1)
 - ⇒ Oily-Style NPR má mnoho iterací, během nichž aktualizuje buffer
- EBCOT Tier-1 má problém s větvením, nižším paralelismem a malým počtem FLOP/pixel

Výsledky pilotních algoritmů

- benchmarky CUDA

Algorithms	Characteristics	Global memory coalescing (↑)	SM to GM access ratio (↑)	Global memory Transfer (ms) (↓)	GPU occupancy (↑)
Multiview Stereo Matching		0.0013	0.020	107.28	33%
Linear Feature Extraction		0.0256	0.090	3.382	41.65%
JPEG2000 Encoding (DWT)		0.000	5.000	3.069	33.33% (vertical) 83.33% (horizontal)
JPEG2000 Encoding (Tier-1)		0.0167	1.903	0.307	17.00%
Cartoon-Style NPR		0.1439	0.000	0.435	40.18%
Oily-Style NPR		0.1517	0.823	0.435	52.19%

- DWT: agregace dlaždic snižuje potřebný počet registrů (\implies GPU occupancy)

Výsledky pilotních algoritmů

- benchmarky CUDA

Algorithms	Characteristics	Data dependency (↓)	Source lines (Host)	Kernel lines (Device)
Multiview Stereo Matching		2	184	187
Linear Feature Extraction		36	620	318
JPEG2000 Encoding (DWT)		2	132	112 (vertical) 90 (horizontal)
JPEG2000 Encoding (Tier-1)		2	>1500	406
Cartoon-Style NPR		0	223	232
Oily-Style NPR		4	514	635

- Data Dependency: celkový počet volání `__syncthreads()`; v rámci bloku vláken

Výsledky pilotních algoritmů

- zrychlení

Algorithms	Data Resolution	Speedup		GPU Scalability
		G92/CPU	GX200/CPU	GX200/G92
Multiview Stereo Matching	TempleRing (47 Images)	54.18x	167.47x	3.09x
Cartoon-Style NPR	512 × 512	93.71x	149.84x	1.61x
	1024 × 768	97.51x	168.46x	1.73x
	1280 × 1024	76.79x	131.34x	1.71x
	1200 × 1800	117.30x	201.27x	1.72x
	2288 × 1712	126.64x	219.03x	1.73x
Oily-Style NPR	512 × 512	81.71x	129.72x	1.59x
	1024 × 768	69.00x	112.52x	1.63x
	1280 × 1024	105.47x	159.17x	1.51x
	1200 × 1800	83.16x	130.00x	1.56x
	2288 × 1712	85.27x	139.01x	1.63x

Výsledky pilotních algoritmů

- zrychlení

Algorithms	Data Resolution	Speedup		GPU Scalability
		G92/CPU	GX200/CPU	GX200/G92
Linear Feature Extraction	512 × 512	1.99x	2.42x	1.22x
	1024 × 768	2.53x	2.90x	1.14x
	1280 × 1024	2.43x	2.72x	1.11x
	1200 × 1800	2.65x	3.22x	1.22x
	2288 × 1712	2.33x	3.00x	1.29x
JPEG2000 Encoding (DWT)	512 × 512	4.06x	6.94x	1.71x
	1024 × 768	7.27x	12.92x	1.78x
	1280 × 1024	5.28x	8.98x	1.70x
	1200 × 1800	5.14x	9.13x	1.78x
	2288 × 1712	5.18x	9.26x	1.79x
	3024 × 2089	5.30x	9.34x	1.76x
JPEG2000 Encoding (Tier-1)	512 × 512	0.46x	0.35x	0.77x
	1024 × 768	0.60x	0.70x	1.17x
	1280 × 1024	0.68x	0.75x	1.11x
	1200 × 1800	1.21x	1.12x	0.92x
	2288 × 1712	1.12x	1.61x	1.44x
	3024 × 2089	0.73x	0.98x	1.35x

Pár poznámek k měření...

<i>velikost obrázku</i>	<i>čas běhu</i>
640 × 480	124,12983930928
1280 × 720	539,98450298239
1920 × 1080	1529,02398429008
4096 × 2160	10210,09238488922

Pár poznámek k měření...

<i>velikost obrázku</i>	<i>čas běhu</i>
640 × 480	124,12983930928
1280 × 720	539,98450298239
1920 × 1080	1529,02398429008
4096 × 2160	10210,09238488922

TAKHLE NE!

- Co je špatně? ... skoro všechno
 - jednotky
 - jak byl sestaven systém pro měření
 - jak bylo měření provedeno
 - jak bylo měření vyhodnoceno
 - opravdu jsme měřili až na 16 platných míst?





Pár poznámek k měření...

- Návrh experimentu
 - co chceme změřit? – formulujeme hypotézu, kterou ověřujeme
 - máme měření nastavené tak, abychom změřili skutečně to, co chceme?
 - neměříme např. místo výpočetního výkonu propustnost nějaké sběrnice?
- Protokolování měření
 - podklady pro zajištění reprodukovatelnosti měření

Hardware and software configuration was as follows: CPU Intel Core i7 950 at 3.07 GHz, 6 GB DDR3 main memory, ASUS P6T6 WS Revolution motherboard, GeForce GTX 285 GPU (with 30 multiprocessors, 240 cores, 16 MB of shared memory, 2 GB of global memory). Software stack included Ubuntu Linux 9.04 with 2.6.28-15-server kernel, NVIDIA device drivers version 256.53, CUDA toolkit 3.1, and GCC version 4.3.3.
 - příklad s měřením AGC po půl roce...

Pár poznámek k měření...

- Statistické zpracování experimentu (ve velmi malém, nedostatečném, a občas až za hranice přijatelnosti zjednodušeném kostce)
 - chyby v měření: systematické, náhodné
 - opakování měření: eliminace náhodných chyb



Pár poznámek k měření...

- Statistické zpracování experimentu (ve velmi malém, nedostatečném, a občas až za hranice přijatelnosti zjednodušeném kostce)
 - náhodná chyba měření (směrodatná odchylka průměru) klesá s \sqrt{n} , kde n je počet měření
 - ◆ běžný počet opakování je 5–15
 - použít průměr, medián nebo minimální hodnotu?
 - ◆ jaká je distribuce výsledků?
 - ◆ co chceme výsledkem říci?
 - stačí nám jedno číslo jako výsledek?

Pár poznámek k měření...

- Statistické zpracování experimentu (ve velmi malé, nedostatečné, a občas až za hranice přijatelnosti zjednodušené kostce)
 - při intervalu důvěryhodnosti 95 % a normálním rozdělení se udává

$$\bar{x} \pm 1,96\sigma_{\bar{x}} \quad [\text{jednotka}]$$

kde průměr \bar{x}

$$\bar{x} = \frac{\sum_{i=1}^N x_i}{N}$$

směrodatná neboli standardní odchylka σ_x

$$\sigma_x = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} = \sqrt{\frac{1}{N-1} \left(\sum_{i=1}^N x_i^2 - N\bar{x}^2 \right)}$$

směrodatná odchylka aritmetického průměru $\sigma_{\bar{x}}$

$$\sigma_{\bar{x}} = \frac{\sigma_x}{\sqrt{N}}$$

Pár poznámek k měření...

- Statistické zpracování experimentu (ve velmi malém, nedostatečném, a občas až za hranice přijatelnosti zjednodušeném kostce)
 - chybu zaokrouhlujeme na 1, výjimečně 2 desetinná místa a zaokrouhlení průměru tomu přizpůsobíme
 - můžeme mít ne-normální rozdělení (např. Poissonovo)
 - propagace chyb
 - můžeme potřebovat složitější statistické zpracování
 - *omlouvám se statistice za příliš zjednodušený a místy ne moc korektní výklad :-)*
- Pořádné materiály o experimentech vydají na přednášku a cvika