OpenCL

Jiří Filipovič

podzim 2012

OpenCL

Co je OpenCL?

- otevřený standard pro programování heterogenních systémů
- nízkoúrovňový, odvozený od C, velmi podobná HW abstrakce jako CUDA

Výhody oproti CUDA

- možno programovat pro širokou škálu hardware
- otevřený standard, nezávislý na osudu jedné firmy

Nevýhody oproti CUDA

- složitější API (podobné CUDA Driver API)
- mladší, obecně méně ,,dospělá" implementace
- pomalejší reflektování novinek v hardware

Přenostelnost

Jedna implementace lze kompilovat pro různý HW

- nepoužíváme-li extenze

Implementace vyladěná pro jeden HW však může mít velmi nízký výkon na jiném

- přílišná rozdílnost HW vyžaduje odlišnou optimalizaci

OpenCL nám tedy umožňuje používat jeden standard pro programování široké škály HW, nicméně optimalizace se musíme naučit pro každý zvlášť.

- usnadňuje autotuning

Přenostelnost výkonu

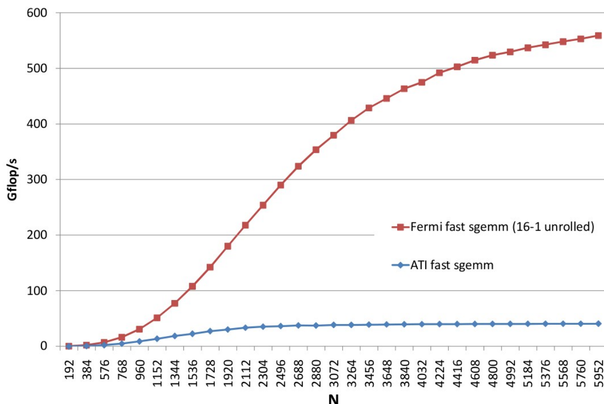

Obrázek: SGEMM optimalizované pro Fermi a Cypress, běh na Fermi[1].

[1] Du et al. From CUDA to OpenCL: Towards a Performance-portable Solution for Multi-platform GPU Programming

Přenostelnost výkonu

1600
1400
1200
1000
800
600
400
200
0
Gflop/s
192 384 576 768 960 1152 1344 1536 1728 1920 2112 2304 2496 2688 2880 3072 3264 3456 3648 3840 4032 4224 4416 4608 4800 4992 5184 5376 5568 5760 5952
N
ATI fast sgemm
Fermi sgemm, removed array
Fermi sgemm (direct translation)

Obrázek: SGEMM optimalizované pro Fermi a Cypress, běh na Cypress[2].

[2] Du et al. From CUDA to OpenCL: Towards a Performance-portable Solution for Multi-platform GPU Programming

Hlavní rozdíly

OpenCL není integrováno s C/C++

- může být kompilováno za běhu, v kódu uložen OCL kernel jako řetězec
- nemůže sdílet části kódu s C/C++ (uživatelské typy, kód pro OCL i C atp.)

Kernely v OpenCL nepracují s klasickými ukazateli

- nelze dereferencovat, používat pointerovou aritmetiku, nelze přecházet mezi buffery
- v rámci bufferu se můžeme pohybovat pomocí offsetu

OpenCL je odvozeno striktně od C

- žádné vlastnosti z C++

OpenCL ovládá různá zařízení pomocí front

- není třeba přepínat kontext

Fronty v OpenCL mohou být out-of-order

- umožňuje runtime balancování využití zdrojů

CUDA-OpenCL slovníček

Hlavní rozdíly v základní terminologii

CUDA	OpenCL
multiprocessor	compute unit
scalar procesor	processing element
thread	work-item
thread block	work-group
grid	NDRange
shared memory	local memory

Součet vektorů – kernel

CUDA

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

OpenCL

```
__kernel void vecadd(__global float * a, __global float * b,
__global float * c)
{
  int i = get_global_id(0);
  c[i] = a[i] + b[i];
}
```

Součet vektorů – host kód

Ke spuštění kernelu potřebujeme

- definovat platformu
  - zařízení (může být více)
  - kontext
  - fronty
- alokovat a nakopírovat příslušná data
- skompilovat kód kernelu
- nakonfigurovat běh kernelu a spustit jej

Součet vektorů – definice platformy

```
cl_uint num_devices_returned;
cl_device_id cdDevice;
err = clGetDeviceIDs(NULL, CL_DEVICE_TYPE_GPU, 1,
&cdDevice, &num_devices_returned);

cl_context hContext;
hContext = clCreateContext(0, 1, &cdDevice, NULL, NULL, &err);

cl_command_queue hQueue;
hQueue = clCreateCommandQueue(hContext, hDevice, 0, &err);
```

Součet vektorů – spuštění kernelu

Každá platforma může mít více zařízení

- lze vybrat nahrubo podle typu
- můžeme také upřednostnit výrobce
- jemnější dělení dle informací o HW
  - počet jader
  - frekvence
  - velikost paměti
  - rozšíření (dvojitá přesnost, atomické operace aj.)

Každé zařízení musí mít alespoň jednu frontu

- jinak jej neumíme využít

Součet vektorů – alokace a kopírování

```
cl_mem hdA, hdB, hdC;
hdA = clCreateBuffer(hContext, CL_MEM_READ_ONLY,
  cnDimension * sizeof(cl_float), pA, 0);
...
```

Kopírovat není explicitně třeba – alokace a kopie dat funguje líně – až když jsou data potřeba. Není tedy ani nutno specifikovat zařízení, pro které data alokujeme.

Součet vektorů – spuštění kernelu

```
const unsigned int cnBlockSize = 512;
const unsigned int cnBlocks = 3;
const unsigned int cnDimension = cnBlocks * cnBlockSize;

cl_program hProgram;
hProgram = clCreateProgramWithSource(hContext, 1, sProgramSource
  ,0, 0);
clBuildProgram(hProgram, 0, 0, 0, 0, 0);

cl_kernel hKernel;
hKernel = clCreateKernel(hProgram, "addvec", 0);

clSetKernelArg(hKernel, 0, sizeof(cl_mem), (void *)&hdA);
clSetKernelArg(hKernel, 1, sizeof(cl_mem), (void *)&hdB);
clSetKernelArg(hKernel, 2, sizeof(cl_mem), (void *)&hdC);

clEnqueueNDRangeKernel(hQueue, hKernel, 1, 0, &cnDimension
  , &cnBlockSize, 0, 0, 0);
```

Součet vektorů – úklid

```
clReleaseKernel(hKernel);
clReleaseProgram(hProgram);
clReleaseMemObj(hdA);
clReleaseMemObj(hdB);
clReleaseMemObj(hdC);
clReleaseCommandQueue(hQueue);
clReleaseContext(hContext);
```

Architektura AMD VLIW GPU

Starší procesory

- Evergreen a Northern Islands

Budeme se věnovat jen zásadním rozdílům oproti nVidia GPU

- ostatní aspekty shodné nebo velmi podobné

Hlavní rozdíly

- VLIW architektura
- explicitně odděleny dvě cesty do paměti (rychlá a obecná)
- méně citlivé na nezarovnaný přístup, více citlivé na analogii partition campingu
- wavefront (analogie warpu) velikosti 64 vláken

VLIW architektura

AMD GPU jsou VLIW procesory

- instrukční slovo obsahuje několik paralelně proveditelných operací
- statické plánování instrukcí (závislosti analyzovány v době kompilace)
- umožňuje vyšší hustotu ALU
- vlákna musí nabízet dostatek ,,instrukčního paralelismu" a kompilátor jej musí rozpoznat
- AMD GPU implementují VLIW-5 nebo VLIW-4, 1 instrukce SFU

Optimalizace pro VLIW

Explicitní užití vektorů

- pracujeme s vektorovými datovými typy (např. float4)
- generování VLIW instrukcí je pro kompilátor přímočaré

Implicitní převod na VLIW

- můžeme psát také skalární kód
- kompilátor se snaží seskupit nezávislé instrukce
- můžeme mu v tom pomoci (unrolling a seskupení stejných operací)

Optimalizace pro VLIW

Problémy spojené s VLIW

- větší spotřeba on-chip paměti (unrolling, vektorové typy)
- nemusíme mít dost nezávislých instrukcí
  - např. podmíněné výrazy
- spolu s velikostí wavefrontu dost citlivé na divergenci

Přístup do globální paměti

Fast path vs. complete path

- fast path je výrazně rychlejší
- fast path používaná pro load/store 32-bitových čísel
- complete path používaná pro čísla jiné velikosti a atomické operace
- při operacích s globální pamětí musí explicitně rozlišit použitou cestu kompilátor
  - cesta je stejná pro celý buffer, můžeme snadno znemožnit kompilátoru použít rychlou variantu

Fast path vs. complete path

```
__kernel void
CopyComplete(__global const float * input, __global float* output)
{
  int gid = get_global_id(0);
  if (gid < 0){
    atom_add((__global int *) output,1);
  }
  output[gid] = input[gid];
  return ;
}
```

Rozdíl rychlosti na Radeon HD 5870: 96 GB/s vs. 18 GB/s.

Nezarovnaný přístup

Permutace mapování vlákno-element v rámci wavefrontu

- penalizace, ale malá ($< 10\,\%$)
- lepši než c.c. < 1.2, mírně horší než c.c. ≥ 1.2

Posun v rámci wavefrontu

- malá penalizace ($< 10\,\%$)
- lepší než nVidia, pokud není využita cache

Výhodnější přístup po 128-bitových elementech

- např. používáme-li float4
- kopírování 122 namísto 96 GB/s u HD 5870

Konflikty bank a kanálů

Analogie partition campingu

- do paměti přistupujeme přes banky a kanály
- v rámci wavefrontu je paralelní přístup přes stejný kanál (jinak serializujeme)
- mezi work-groupami je třeba přistupovat přes různé kanály
- Radeony řady 5000 mají kanály prokládané po 256 bytech
  - wavefront čtoucí souvislý blok 32-bitových elementů čte paralelně z téhož kanálu
  - jednotlivé wavefronty pak čtou z rozdílných kanálů čtou-li souvislou oblast
- uspořádání bank závisí na počtu kanálů
  - např. 8 kanálů – banky se střídají každé 2 KB
- vysoká penalizace za čtení ze stejného kanálu a stejné banky (např. 0.3 vs 93 GB/s)

Lokální paměť

Lokální paměť velmi podobná sdílené paměti u nVidie

- organizována do 32 nebo 16 bank
- je třeba přistupovat ve čtvrtinách wavefrontu do rozdílných bank
  - jinak vzniká konflikt bank
  - v případě 32 bank používat efektivně i float2
- broadcast je podporován pro jednu hodnotu (analogie c.c. 1.x)

Architektura AMD GCN GPU

Aktuální architektura (Sourthern Islands, také Graphic Core Next). Významná změna oproti předchozí generaci

- není VLIW, compute unit obsahuje 1 skalární procesor a 4 vektorové procesory
  - kód vláken píšeme skalárně, vektorové operace se obvykle nevyplatí
  - podmíněné výrazy přináši menší penalizaci
- L1 cache pro čtení i zápis
- na GPU může běžet více kernelů současně

CPU a OpenCL

Dnešní CPU z pohledu OpenCL

- compute units odpovídají jádrům
- processing elements elementům ve vektorových registrech
  - počet processing elements v compute unit tedy určuje použitý datový typ (2-16 pro SSE)
  - tomu odpovídá i počet vláken běžících v lock-step (analogie warpu/wavefrontu)
- jedna work-group se mapuje na jedno CPU vlákno
  - je vhodné mít minimálně tolik work-group, kolik máme jader
  - více work-group usnadňuje balancování zátěže, ale vytváří overhead
- jednotlivé work-item běží ve vektorových instrukcích, nebo sériově
- úlohový paralelismus – využíváme více front

Implicitní a explicitní vektorizace

Implicitní vektorizace

- píšeme kód podobně jako pro GPU
- kompilátor sám vytváří vektorové instrukce ze skupin work-item
- potenciálně lépe přenositelné (nezajímá nás délka vektorů u konkrétního CPU, ani bohatost instrukční sady)
- podporuje OpenCL od Intelu, AMD zatím neumí

Explicitní vektorizace

- v kódu explicitně používáme vektorové datové typy
- méně pohodlné a více svázané s konkrétní architekturou
- potenciálně vyšší výkon (nejsme omezeni tím co rozliší kompilátor)

Paralelismus na úrovni work-group

Jak zvolit velikost work-group

- nepotřebujeme větší paralelismus pro maskování latence paměti
- počet work-items alespoň na úrovni šířky vektoru (pro implicitní vektorizaci)
- více work-items v principu nevadí, pokud nepoužíváme bariéry
  - Intel doporučuje 64-128 work-items bez synchronizací, pokud synchronizujeme tak 32-64
- v současné implementaci implicitní vektorizace Intelu musí být velikost work-group dělitelná 4 pro Nahalem a 8 pro Sandy Bridge
- velikost work-group lze nespecifikovat, určí ji pak kompilátor

Další rozdíly oproti CPU

Images

- CPU nepodporuje funkce texturových jednotek, ty jsou emulovány
- pokud nepotřebujeme, je lepší nepoužívat

Lokální paměť

- pro CPU neodpovídá žádné HW paměťi
- používání přináší overhead (kopírování tam a zpět)
- má smysl používat podobné vzory přístupu do paměťi, jako kdybychom lokální paměť měli (cache lokalita)

Další rozdíly oproti CPU

Přístup do globální paměti

- velké cache, je třeba správně využívat

Lokalita

- chceme co nejvíce využívat data uložená v cache
- více úrovní cache, lze využít hierarchické shlukování přístupu

Organizace cache

- velikost řádku cache (kolik dat čteme současně)
- velikost celé cache (kolik dat udržíme)
- asociativita (jak efektivně jsme schopni mapovat paměť do cache)