


GPGPU

Provádění vědeckých výpočtů prostřednictvím grafických karet osobních počítačů

Jan Vacata




Motivace

3.0 GHz Intel Core2 Quad (QX6850)

- Výkon: 96 GFLOPS
- Propustnost paměti: 21 GB/s
- Orientační cena: 1100 USD

NVIDIA GeForce 8800 GTX

- Výkon: 330 GFLOPS
- Propustnost paměti: 55.2 GB/s
- Orientační cena: 550 USD



Obrázek: Sledování změn výkonu

Motivace - pokračování

Srovnání poměrného ročního nárůstu výkonu:

- Pro CPU: přibližně 1.4
- Pro GPU: přibližně 1.7 ve zpracování fragmentů(pixelů), asi 2.3 ve zpracování vrcholů


Proč jsou GPU tak rychlé?

- Technologický důvod: Specializace GPU pro rychlé provádění nezávislých paralelních výpočtů
- Ekonomický důvod: Obrovský trh s počítačovými hrami

Základní otázky

- 1 Bylo by možné využít ohromující výkon GPU pro výpočty, které nemají s grafikou vůbec nic společného?
- 2 Pokud ano, jak to lze provést?

Grafická pipeline, architektura GPU



Obrázek: Abstraktní pohled na grafickou pipeline

- 5 generací grafických karet (pevná vs. programovatelná pipeline)
- Programovatelné procesory: vertex procesor, fragment procesor (*fp32* aritmetika, SIMD/MIMD charakter, *scatter/gather*, ...)
- Vertex/fragment programy/shadery

Programovací model I

Návrh a implementaci GPGPU¹ aplikace shrneme do několika bodů, pokusíme se vysvětlit na jednoduchém příkladu (násobení všech elementů rozsáhlého pole známou konstantou):

- ❶ Identifikace paralelizovatelných částí problému, jejich implementace prostřednictvím uživatelských fragment programů
- ❷ Nahrání vstupních dat do textur
 - Analogie pole $\longleftrightarrow$ textura

¹z angl. General-Purpose computation on Graphics Processing Units

Programovací model II


- 3 Renderování vhodné geometrie zajistí aplikaci požadovaného programu na fragmenty
 - Analogie tělo smyčky $\longleftrightarrow$ fragment programy

tělo smyčky na CPU

```
for (i=0;i<height;i++) {  
    for (j=0;j<width;j++) {  
        grid[i][j] *= k;  
    }  
}
```

Programovací model II

- 3 Renderování vhodné geometrie zajistí aplikaci požadovaného programu na fragmenty
 - Analogie tělo smyčky $\longleftrightarrow$ fragment programu



Programovací model II

- 3 Renderování vhodné geometrie zajistí aplikaci požadovaného programu na fragmenty
 - Analogie tělo smyčky $\longleftrightarrow$ fragment programy

tělo smyčky na CPU

```
for (i=0;i<height;i++) {  
    for (j=0;j<width;j++) {  
        grid[i][j] *= k;  
    }  
}
```

fragment program na GPU

```
struct SInput {  
    uniform samplerRECT tex;  
    float2 cr : TEXCOORD0;  
};  
  
float main(SInput in) : COLOR {  
    flout out;  
    out = texRECT(in.tex,in.cr)*k;  
    return out;  
}
```


Programovací model III

- ④ Rasterizér rozdělí vstupní geometrii na fragmenty, hodnoty ve vrcholech jsou interpolovány
- ⑤ Každý fragment potom nezávisle zpracován fragment programem
- ⑥ Výsledek ve framebufferu, následuje zpracování výsledku nebo další renderování
 - Analogie zpětná vazba $\longleftrightarrow$ renderování do textury

Další informace o programování GPU

- Které problémy lze efektivně mapovat na GPU?
 - Aritmetická intenzita
 - Sekvenční přístup do paměti
- Omezení vyplývající z architektury (mnohá odpadají u nejnovější generace GPU)
 - Scattering/gathering
 - Řízení toku programu
 - Celočíselná aritmetika
- Jazyky vyšší úrovně pro programování shaderů (Cg, HLSL, GLSL)

Postupné cíle této práce

- ❶ Pochopit architekturu GPU a způsob jejího využití pro obecné výpočty
- ❷ Nastudovat nutné principy OpenGL API
- ❸ Pochopit vlastní GPGPU implementaci a ukázat ji na jednoduchém případě
 - Ukázkové GPGPU řešení operace konvoluce
- ❹ Studovat a naučit se používat tuto techniku na složitější aplikace, hledat další možnosti využití
- ❺ Provést úvodní průzkum v oblasti nejnovějšího HW a moderního GPGPU pojetí

Rovnice vedení tepla

Formulace problému

Hledáme řešení rovnice

$$\frac{\partial u}{\partial t} = k \Delta u \quad \text{na} \quad \Omega \times (0, T)$$

za podmínek

$$u|_{\partial\Omega} = \gamma, \quad \gamma : \partial\Omega \longrightarrow \mathbb{R}, \quad u(\cdot, 0) = u_0$$


Řešení metodou přímek:

- Metoda konečných diferencí pro prostorovou diskretizaci
- Runge-Kuttova-Mersonova metoda 4. řádu s automatickou volbou integračního kroku pro diskretizaci časovou

GPGPU implementace

Hlavní znaky GPGPU implementace:

- Mapování na GPU velmi přirozené
 - Diskrétní 2D mřížka
 - Sekvenční přístup k datům
 - Laplaceův operátor a pětibodové schéma (příznivé vzhledem k 2D organizaci cache paměti na GPU)
 - Malá aritmetická intenzita
- Ping-pong technika
- Operace redukce (maximum z absolutních hodnot)



LU rozklad husté matice

Formulace problému

Hledáme rozklad

$$\mathbf{A} = \mathbf{LU},$$

kde $\mathbf{L}$ je dolní trojúhelníková matice s jedničkami na diagonále a $\mathbf{U}$ je horní trojúhelníková matice.

Základní verze algoritmu bez pivotingu

```
for k = 1,...,n-1 {  
    for i = k+1,...,n  
        a(i,k) = a(i,k) / a(k,k);  
    for i = k+1,...,n  
        for j = k+1,...,n  
            a(i,j) = a(i,j) - a(i,k)*a(k,j);  
}
```

GPGPU implementace

První krok LU rozkladu

T_source

$$\begin{array}{ccc} a_{11} & \cdots & a_{1n} \\ \vdots & & \vdots \\ a_{n1} & \cdots & a_{nn} \end{array}$$

GPGPU implementace

První krok LU rozkladu


T_source **copy** T_target

a_{11}	$\dots$	a_{1n}
$\vdots$		$\vdots$
a_{n1}	$\dots$	a_{nn}

a_{11}	$\dots$	a_{1n}
0	0	$\dots$ 0
$\vdots$	$\vdots$	$\vdots$
0	0	$\dots$ 0


GPGPU implementace

První krok LU rozkladu




GPGPU implementace

První krok LU rozkladu




GPGPU implementace

První krok LU rozkladu



GPGPU implementace

První krok LU rozkladu



Hlavní znaky GPGPU implementace:

- Aritmetická intenzita
- Lze překonat optimalizované CPU implementace

Závěr

- Moderní GPGPU pojetí
 - NVIDIA CUDA
- Plánované pokračování práce
 - Měření výkonu a efektivity
 - Hledání dalších komplexnějších problémů, které lze efektivně řešit na GPU

Literatura

-  Jan Vacata. *GPGPU - Provádění vědeckých výpočtů prostřednictvím grafických karet osobních počítačů*. výzkumný úkol, 2007.
-  Matt Pharr (Ed.). *GPU Gems 2: Programming Techniques for High-Performance Graphics and General-Purpose Computation*. Addison-Wesley, 2005.
-  John D. Owens et al. *A Survey of General-Purpose Computation on Graphics Hardware*. Computers Graphics Forum 26(1):80-113, 2007.
-  <http://www.gpgpu.org>