Optimalizace CUDA kernelů pomocí fúzí

aneb kterak zrychlit (izolovaně) nezrychlitelné

Jiří Filipovič, Jan Fousek, Matúš Madzin

3. prosince 2012

Obsah prezentace

- fúze jako optimalizační metoda
- fúzovatelnost funkcí
- kompilátor
- aplikace na BLAS

Kernely omezené propustností paměti

GPU vykoná desítky operací na přenos jednoho slova z/do globální paměti

- pokud náš kernel provádí aritmetických operací méně, je rychlost jeho provádění omezena rychlostí paměti
- data se zpravidla nevyskytují ve vyrovnávací paměti od předchozího běhu kernelu (ty jsou příliš malé)

Důvod vzniku kernelů omezených rychlostí paměti

- řešíme paměťově omezený problém (např. $\mathbf{a} + \mathbf{b}$)
  - z principu nelze ovlivnit
- píšeme rozumně znovupoužitelný kód (např. $\mathbf{a} + \mathbf{b} + \mathbf{c}$ voláním kernelů pro součet dvou vektorů)
  - omezení snížíme použitím kernelu sčítajícího tři vektory, mezivýsledky zůstanou uloženy ve sdílené paměti nebo v registrech

Fúze kernelů

Máme-li sekvenci volání paměťově omezených kernelů, které si vzájemně předávají data

- mohou být zpravidla nahrazeny komplexnějšími kernely, které vykazují lepší paměťovou lokalitu (některá data se předávají pomocí rychlejších on-chip pamětí)

„Ruční" vývoj komplexních kernelů je dosti nákladný

- mnoho kombinací, omezená znovupoužitelnost
- od určitého okamžiku nemusí být provádění více výpočtů v jednom kernelu výhodné, nalezení optima složité

Jak z toho ven?

- implementujeme jednoduché, znovupoužitelné kernely
  - každý kernel volá rutiny pro načtení vstupu, výpočet a uložení výsledku
- v závislosti na předávání dat tyto kernely spojujeme ve větší celky
  - lze provádět automaticky

Horní hranice zrychlení

U paměťově omezených kernelů zrychlení zhruba odpovídá procentu ušetřených přenosů paměti.

Např. $\mathbf{a} + \mathbf{b} + \mathbf{c}$

- 2 kernely – čtení 4 vektorů, uložení 2
- fúze – čtení 3 vektorů, uložení 1
- fúze odstraní 1/3 přenosů, tzn. $1.5\times$ zrychlení
- zrychlení může být v praxi větší (overhead spouštění kernelu, maskování latence)

Omezení zrychlení

Jakmile přestane být kernel paměťově omezený

- další redukce paměťových přenosů nezvyšuje rychlost výpočtu (není-li problém latence paměti)
- rychlost výpočtu však může být vyšší (overhead spouštění kernelu, maskování latence, optimalizace sekvenčního kódu)

Konzumace on-chip pamětí

- ve fúzi může být vyšší (mezidata používané dalšími fúzovanými funkcemi)
- vyšší nároky na on-chip paměti omezují dosažitelný stupeň paralelismu, může snižovat výkon

Omezení zrychlení

Rozdílné nároky na paralelismus

- každá instance funkce může běžet ve více vláknech (dosažení vhodného poměru počtu vláken ke spotřebované on-chip paměti)
- pro každou fúzovanou funkci ale může být efektivní jiný počet vláken
- při fúzi funkcí běžících v rozdílném počtu vláken tak musí být přepočítávány koordináty vláken a některá vlákna jsou část výpočtu nevyužita
- vynutíme-li naopak stejné počty vláken pro všechny fúzované funkce, obecně nepoužíváme nejefektivnější dostupné implementace

Výkon rozdílně paralelních implementací

Sčítání 3×3 matic pomocí 1, 3 a 9 threadů, a s 32 floaty alokovanými navíc ke každé funkci.

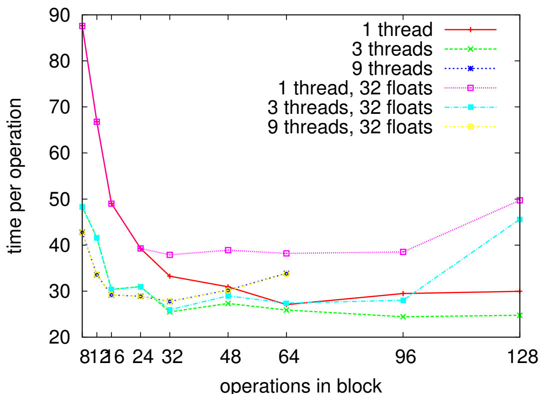

Vztah výkonu a zvýšené alokace paměti

Sčítání 3×3 matic pomocí 3 threadů.

operations per block
128
64
32
16
8
4
2
0
76
156
236
316
396
476
additionally allocated floats
350
300
250
200
150
100
50
0

Automatizace fúzí

Obecné kernely se fúzují špatně

- libovolné mapování vláken a bloků na data
  - abychom mohli nechat data v on-chip paměti, musí být totožné
  - jak jej analyzovat? či upravit?
- globální bariéra mezi běhy kernelů
  - nelze implementovat uprostřed běhu kernelu
  - lze ji nahradit lokální? či vypustit?

Můžeme fúzovat kernely provádějící konkrétní funkci vyššího řádu.

Map

Definice map

- Nechť $map(f, L) = [f(e1), \ldots, f(e_n))]$.
- Kde $L = [e_1, e_2, \ldots, e_n]$ je seznam n elementů $e_1, \ldots, e_n$.
- Funkce f
  - může být provedena více vlákny
  - musí být proveditelná v jednom bloku

Důsledky pro fúzovatelnost

- spustíme stejný počet instancí fúzovaných funkcí na blok
  - pak můžeme nahradit globální bariéru lokální (i-tá instance zpracovává i-tý element)
- pokud zároveň předáváme data přes sdílenou paměť
  - není problém s mapováním vláken na data

Reduce

Definice reduce

- $reduce(\oplus, L) = e_1 \oplus e_2 \oplus \cdots \oplus e_n$, kde $L = [e_1, e_2, \ldots, e_n]$
- $\oplus$ je asociativní

Pro získání výsledku musíme zpracovat celý L

- neobejdeme se bez globální bariéry

Důsledky pro fúzovatelnost

- Díky asociativitě $\oplus$ můžeme ale fúzovat parciální redukce
  - redukujeme vše, co máme lokálně dispozici
  - redukce je dokončena až po doběhnutí redukujícího kernelu, její výsledek tedy nemůžeme použít v kernelu, který ji provádí

  Mapování na data triviální
  - vstup redukce musí být ve sdílené paměti či registrech, pak lze redukovat vše v bloku

Vyjádření BLAS funkcí jako map a reduce

BLAS (Basic Linear Algebra Subprograms)

- standard pro knihovny implementující základní funkce z lineární algebry na maticích a vektorech
- hojně využívaný (nejen) ve vědeckém software
- obecně velmi dobře optimalizované implementace
- jakékoliv zrychlení zajímavé

Výkon některých funkcí omezený rychlostí paměti

- BLAS-1 (vektor-vektor), lze vyjádřit pomocí map a reduce
- BLAS-2 (matice-matice), část lze vyjádřit pomocí vnořených map a reduce

Sekvence volání BLAS-1 a BLAS-2 lze zrychlit fúzema

- není možno v izolovaných BLAS funkcích
- obecné zrychlení BLAS, navíc obecnou metodou

Příklad vyjádření BLAS-2 funkce

Násobení matice vektorem $y = Ax$ vyjádříme jako

$$y = map(reduce(+, map(\cdot, A_i, x)), A)$$

kde $A = [A_1, \ldots, A_m]$, $A_i = [a_{i,1}, \ldots, a_{i,n}]$ a $x = [x_1, \ldots, x_n]$.

Pozn. proč ne $y = map(dotprod(A_i, x), A)$?

Schéma kompilátoru

Co kompilátor potřebuje?

- knihovnu elementárních funkcí (v CUDA)
- script definující sekvenci jejich volání

Co musí údělat?

- analýzu kódu
  - správně rozpoznat, jaké má k dispozici funkce a jak je použít
  - přečíst vysokoúrovňový kód a na jeho základě vybudovat DAGy volání a předávání parametrů
- optimalizace
  - prohledat a prořezat prostor fúzí nad každým DAGem
  - pro každou fúzi prohledat a prořezat prostor jejích implementací
  - na základě predikce výkonu zkombinovat implementace fúzí a nefúzovaných kernelů pro maximalizaci výkonu
- vygenerovat CUDA kód s fúzema

GEMVER

$$B \leftarrow A + u_1 v_1^T + u_2 v_2^T$$
$$x \leftarrow \beta B^T y + z$$
$$w \leftarrow \alpha B x$$

GEMVER

```
TILE32x32 A, B, C;
subvector32 u1, u2, v1, v2, w, x, y, z;
globalscalar alpha, beta;

input A, u1, u2, v1, v2, y, z, alpha, beta;

C = sger(u1, v1);
B = smadd(A, C);
C = sger(u2, v2);
B = smadd(B, C);

x = sgemtv(B, y);
x = sax(beta, x);
x = sxpy(x, z);

w = sgemv(B, x);
w = sax(alpha, w);

return B, x, w;
```

GEMVER

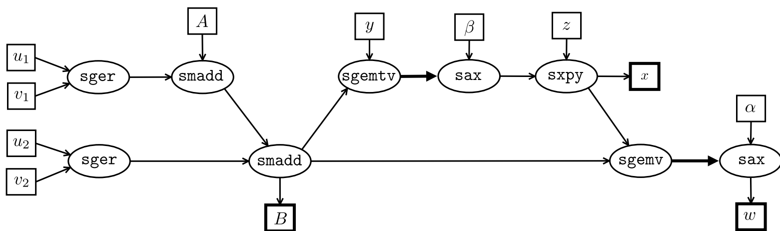

Prostor optimalizací

Optimalizace mají mnoho stupňů volnosti

- fúzovatelné podgrafy DAGu tvoří *fúze*
- linearizace fúzí určuje pořadí volání funkcí ve fúzi a tím i spotřebu paměti
- implementace elementárních funkcí ve fúzi a paralelismus (spolu s předchozím) *implementace fúze*
- *kombinace implementací fúzí* určuje, které fúze použijeme

Fúze

Podgrafy DAGu, pro které platí

- indukovaný podgraf
- neexistuje cesta, která vede ven z fúze a zase se do ní vrací
- pokud se provádí redukce, její výstup je zpracován mimo fúzi

Fúzí je velké množství

- v nejhorším případě $\mathcal{O}(|2^V|)$, v nejlepším $\mathcal{O}(|n^2|)$

Fúze – prořezávání prostoru

Fúze musí tvořit souvislou komponentu

- jinak nešetříme datové přenosy

Velikost fúzí lze omezit

- čím větší fúze, tím méně ušetříme paměťových přenosů přidáním další funkce
- s velikostí fúze roste šance, že nepůjde implementovat efektivně
- omezení velikosti na k funkcí snižuje složitost nejhoršího případu na $\sum_{i=0}^{k} \binom{|V|}{i}$, popř. $\mathcal{O}(k|V|)$
- výrazně zjednoduší prohledávání prostoru implementaci fúzí

Linearizace fúze

Každá fúze obsahuje podgraf DAGu, pro implementaci je třeba určit pořadí spouštění funkcí

- to je důležité, jelikož ovlivňuje množství alokované on-chip paměti
- máme až $\mathcal{O}(|V|!)$ linearizací, pro každou z nich existuje exponenciálně mnoho možnost jak alokovat paměť

Linearizace fúze

Linearization

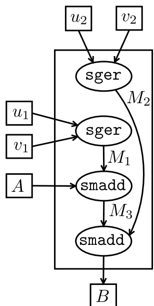

Allocation

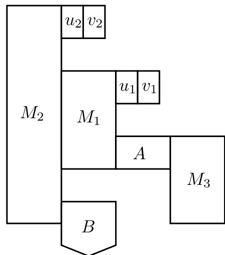

Linearization

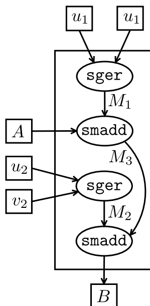

Allocation

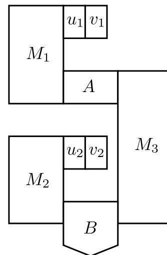

Linearizace fúze – prořezávání prostoru

Vybereme linearizaci s nejnižším dolním odhadem alokované paměti

- jedná se tedy o aproximaci, nepostihneme fragmentaci paměti
- pro vybranou linearizaci spočítáme precizně alokaci paměti pomocí branch-and-bound algoritmu v $\mathcal{O}(m^n)$ kde m je celková velikost alokované paměti a n počet funkcí

V praxi

- linearizací bývá výrazně méně, než určuje horní mez
- před branch-and-bound algoritmem najdeme počáteční řešení polynomiálním greedy algoritmem, ten často najde optimum
- i ve zlomyslném případě je řešení dosažitelné díky omezení velikosti fúzí

Výběr implementací elementárních funkcí

Dále je třeba vybrat konkrétní implementace elementárních funkcí

- projdeme všechny přiřazení konkrétních implementací elementárních funkcí: $\prod_{i=0}^{n} \#f_i$, kde $\#f_i$ je počet implementací i-té funkce
- pro každé přiřazení odhadneme výkon pomocí predikce výkonu

Výběr kombinací fúzí

Máme-li seznam implementací fúzí s odhadem jejich výkonu, je ještě zapotřebí určit, které budou použity

- ze všech kernelů (implementace fúzí a samostatné elementární funkce) vybíráme ty, které dohromady tvoří celý DAG a maximalizujeme odhadnutý výkon
- problém pokrytí množin
- řešeno pomocí lineárního programování

Generování kódu

Elementární funkce mají předepsanou strukturu „load-compute-store"

- fúze realizujeme serializací funkcí a odstranění přebytečných load a store rutin
- a také dogenerováním dalšího kódu, jako je alokace proměnných, cykly, výpočet indexů vláken či omezení paralelismu

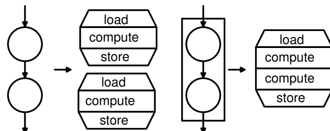

Generování kódu

Každá funkce pracuje s různými vstupy a výstupy v různé paralelní granularitě

- knihovna obsahuje vedle kódu elementárních funkcí také metadata
- umožňují silnou typovou kontrolu
- generátor kódu dokáže spojovat funkce s rozdílnými nároky na paralelismus přepočítáním koordinát threadu a omezením paralelismu pro některé fúzované funkce

Příklad generování kódu

Ukážeme si fúzi $q = Ap$

$$q = map(reduce(+, map(\cdot, A_i, p)), B)$$

a $s = A^T r$

$$s = map(reduce(+, map(\cdot, A_i^T, r)), B)$$

Příklad generování kódu

Jak to bude fungovat?

- násobení matice vektorem tvoří elementární funkci
- základním datovým elementem je blok matice či vektoru (v našem případě 32×32, respektive 32)
- každý blok může být zpracováván samostatně, ale výstup je doredukován mimo kernel realizující fúzi
- pokud využijeme sériové zpracování několika bloků, některé operace lze přesunout mimo cyklus
  - při vertikálním směru iterací stačí jednou načítat p a jednou ukládat s
  - analogicky při horizontálním

$y = Ax$

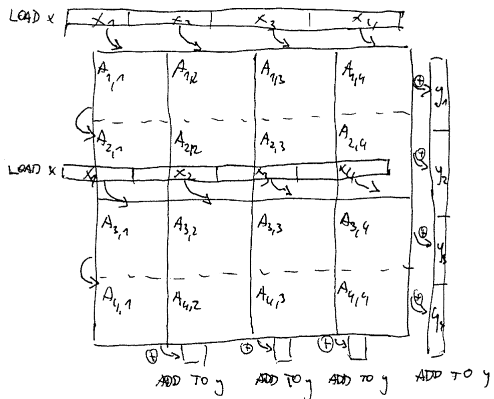

Příklad generování kódu

Fúze $q = Ap, s = A^T r$

```
alokuj A_l, p_l, q_l, r_l, s_l ve sdílené paměti
spočítej indexy x, y
p_l ← load(p, x)
s_l ← 0
for (i = y; i < min(n, y + s)) {
    r_l ← load(r, i)
    A_l ← load(A, x, i)
    s_l ← compute_gemtv(A_l, r_l, x, i)
    q_l ← 0
    q_l ← compute_gemv(A_l, p_l, x, i)
    q ← store(q_l, i)
}
s ← store(s_l, x)
```

Zrychlení oproti CUBLAS

Název	Operace	Zrychlení	Tag
AXPYDOT	$z \leftarrow w - \alpha v$ $r \leftarrow z^T u$	1.97×	FS
BiCGK	$q \leftarrow Ap$ $s \leftarrow A^T r$	2.12×	FE
GEMVER	$B \leftarrow A + u_1 v_1^T + u_2 v_2^T$ $x \leftarrow \beta B^T y + z$ $w \leftarrow \alpha Bx$	2.63×	FS
GESUMMV	$y \leftarrow \alpha Ax + \beta Bx$	1×	(F)
VADD	$x \leftarrow w + y + z$	2.35×	FS
WAXPBY	$w \leftarrow \alpha x + \beta y$	2.54×	FS

Tabulka: Tagy: F=zlepšitelné fúzí, S=zlepšitelné specializací kernelu, E=používá efektivnější $A^T x$.

Škálování BiCGK

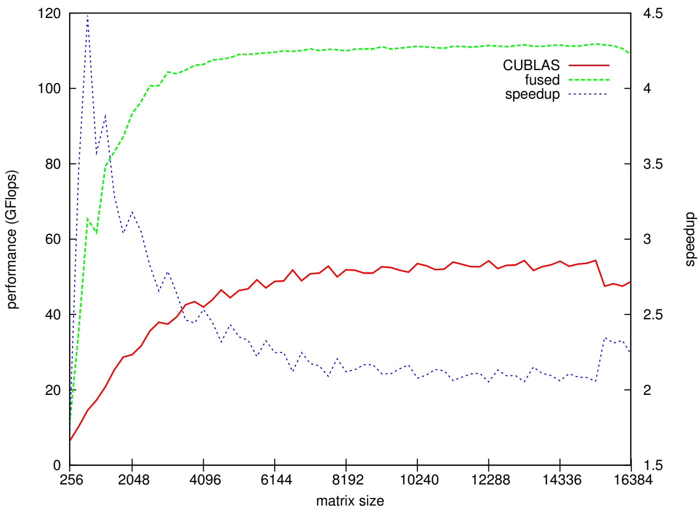

Škálování GEMVER

Prostor implementací

Název implementace	Celkem implementací	Nejlepší nalezena	Výkon první	Výkon nejhorší
AXPYDOT	19	2.	77.1 %	35 %
BiCGK	5	1.	100 %	68 %
GEMVER	2443	72.	96.8 %	30 %
GESUMMV	164	17.	99.8 %	90 %
VADD	34	17.	94.7 %	52 %
WAXPBY	104	7.	94.6 %	32 %