

GPU akcelerace aplikací v METACentru

Jiří Filipovič
fila@mail.muni.cz

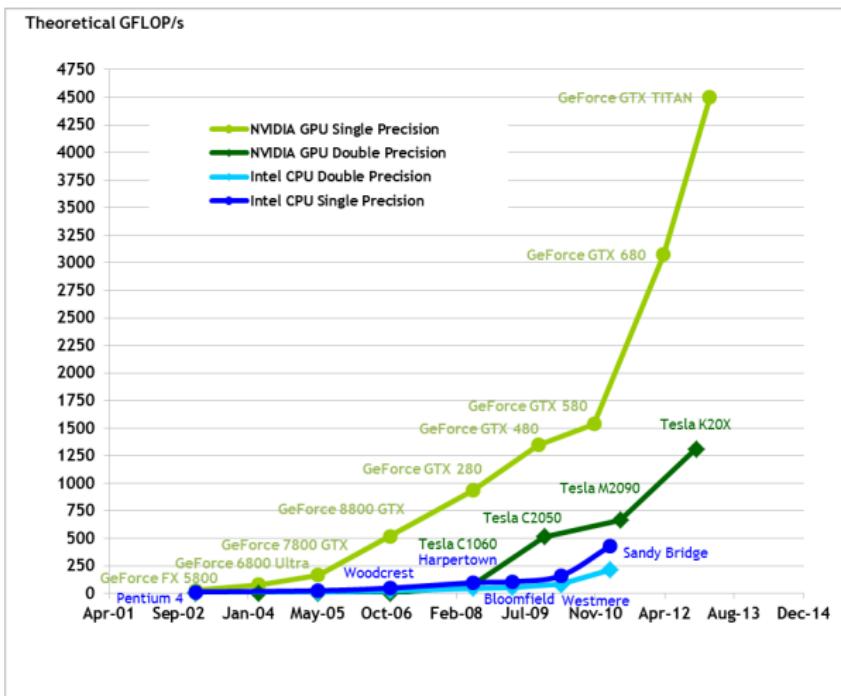
25. 11. 2013

Proč GPU akcelerace?

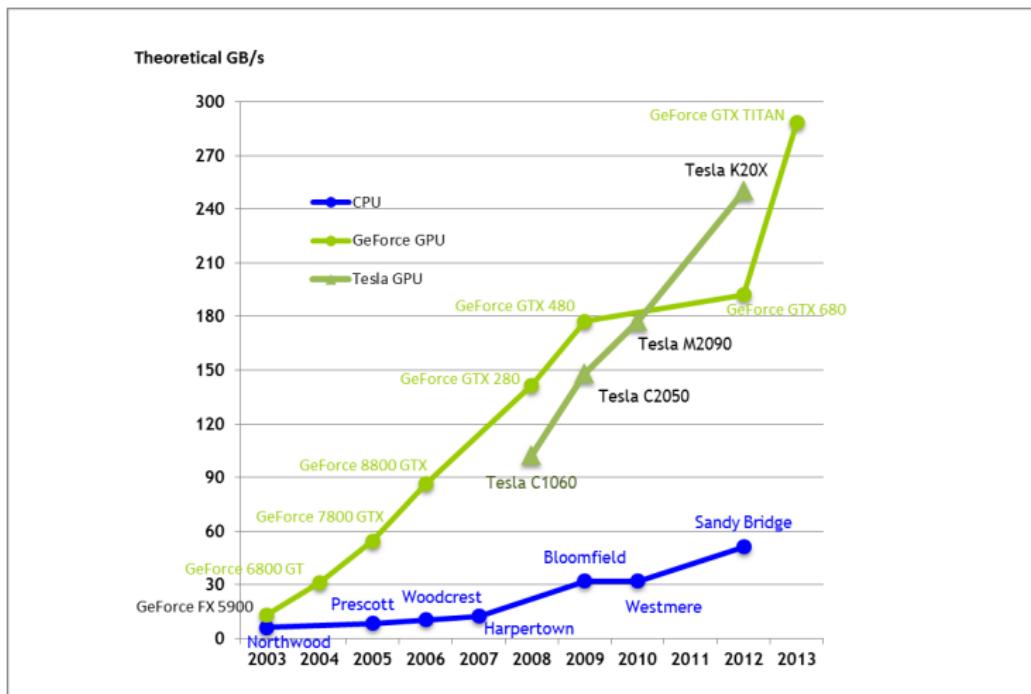
GPU jsou výkonné masivně paralelní procesory, ve srovnání s CPU

- nabízejí tisíce výpočetních jader, celkově řádově vyšší aritmetický výkon (jednotky TFlops)
- vyšší přenosová kapacita pamětí (stovky GB/s)

Proč GPU akcelerace?



Proč GPU akcelerace?



Proč GPU akcelerace?

Výkon GPU lze využít v mnoha výpočetně náročných aplikacích

- mnoho aplikací využívaných v METACentru umí GPU akceleraci
- v METACentru máme 3 clustery osazeny GPU
 - doom.metacentrum.cz
 - gram.zcu.cz
 - konos.fav.zcu.cz

V přednášce se zaměřím na obecné vysvetlení, co lze na GPU akcelerovat a demonstruji GPU akceleraci u nejpoužívanějších aplikací v METACentru.

Dostupná GPU

GeForce 465

- 2x v každém uzlu konos.fav.zcu.cz (celkem 9 uzlů)
- architektura Fermi, 855 GFlops, 102,6 GB/s
- herní GPU, několik významných omezení
 - výkon v DP redukován na 1/8 výkonu SP
 - paměť 1 GB
 - není ECC, správa GPU, GPU Direct

Dostupná GPU

Tesla M2090

- 4x v každém uzlu gram.zcu.cz (celkem 10 uzlů)
- architektura Fermi, 1332 GFlops, 177 GB/s
- výpočetní GPU
 - výkon v DP redukován na 1/2 výkonu SP
 - paměť 6 GB
 - ECC (volitelně), správa GPU, GPU Direct

Dostupná GPU

Tesla K20M

- 2x v každém uzlu doom.metacentrum.cz (celkem 30 uzelů)
- architektura Kepler, 3.52 TFlops, 208 GB/s
- výpočetní GPU
 - výkon v DP redukován na 1/3 výkonu SP
 - paměť 5 GB
 - ECC (volitelně), správa GPU, GPU Direct

Jak s GPU pracovat

Job si musí o GPU zažádat

- např. pomocí `-l nodes=1:gpu=4:ppn=16`
- specializované fronty (`gpu`, `gpu_long`)
- vidíte jen ty GPU, které vám systém přidělil

Manuální nastavení viditelnosti GPU

- používejte opatrně
- buďto lze zadat přímo spouštěné aplikaci, nebo pomocí proměnné `CUDA_VISIBLE_DEVICES` (seznam ID viditelných GPU)

V čem jsou GPU jiná?

Hlavní rozdíly oproti CPU

- masivně paralelní procesor, GPU kód běží v desítkách tisíc vláken
- určité skupiny vláken běží v lock-step módu
- koprocessor s vlastní pamětí, připojený přes PCI-E
- paměť GPU relativně malá

Nyní se podíváme na jejich důsledky...

V čem jsou GPU jiná?

Masivně paralelní procesor

- výpočetní problém musí být dostatečně „velký“
 - násobení matic 10×10 vs. 1000×1000
 - systém s 50 vs. systém s 100 000 atomy
- výpočetní problém musí jít dostatečně paralelizovat
 - velký systém vs. simulace dlouhého vývoje malého systému

V čem jsou GPU jiná?

Lock-step mód

- skupiny vláken by měly následovat stejnou cestu v kódu a přistupovat do spojitéch paměťových oblastí
- efektivita GPU akcelerace horší pro „nepravidelné“ výpočty, např.
 - husté vs. řídké matice
 - dlouhý (či žádný) vs. krátký cutoff u nevazebných sil
 - metoda konečných diferencí vs. metoda konečných prvků
 - graf s vrcholy stejného vs. různého stupně

V čem jsou GPU jiná?

Komunikace přes PCI-E

- GPU má velmi rychlou paměť, vstup a výstup je však třeba přenášet po PCI-E sběrnici
- má smysl akcelerovat jen takové algoritmy, které provedou dostatek výpočtů na přenesená data
 - násobení vs. sčítání matic
 - nevazebné vs. vazebné síly
- problém může být zesílen v případě běhu na více GPU
 - citlivější než v případě více CPU

V čem jsou GPU jiná?

Malá paměť GPU

- velikost problému, který lze celý zpracovávat na GPU, je relativně omezená
- v případě, že data odkládáme do CPU paměti, jsme omezeni propustností PCI-E (viz předchozí slide)

Akcelerace Amber

Válka část funkcionality pmemd je akcelerována (nepodporovány některá nastavení).

Simulovaný systém se musí vejít do GPU paměti

- větší systémy musíme počítat na CPU (v závislosti na konfiguraci simulace a paměti GPU okolo 2M atomů)
- neškáluje s počtem GPU

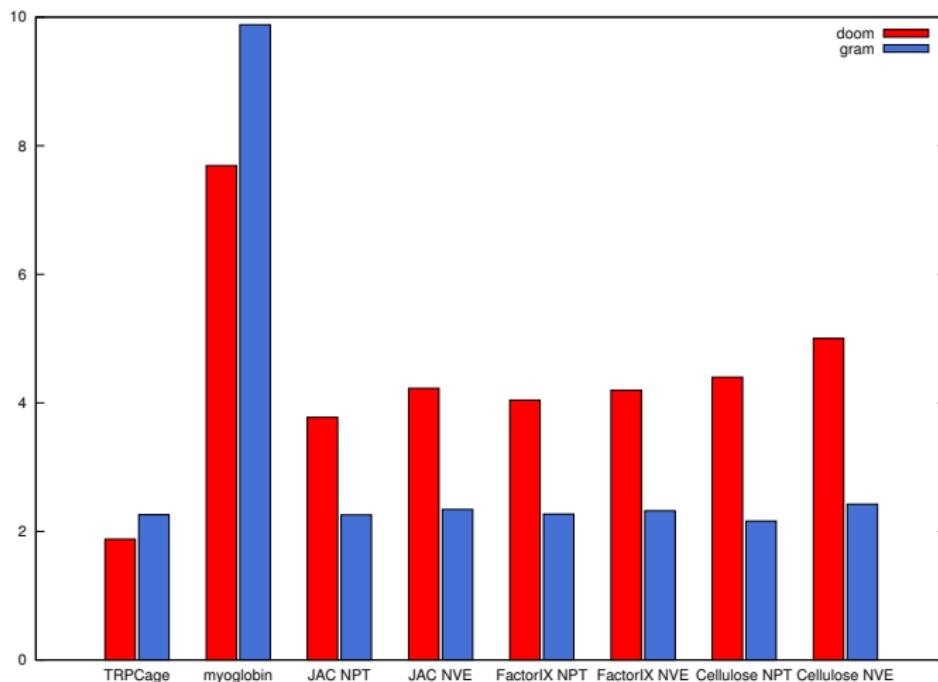
V METACentru v současné době není k dispozici komplikace pro více GPU.

Měření rychlosti

Standardní testovací balík Amberu

- implicitní solvent: TRPCage (304 atomů), myoglobin (2 492 atomů)
- explicitní solvent: Cellulose (NPT/NVE, 23 558 atomů), FactorIX (NPT/NVE, 90 906 atomů), JAC (NPT/NVE, 408 609 atomů)

Zrychlení oproti CPU*



*zrychlení měřeno oproti 2x 8-jádrový Xeon 2.6GHz.

Co jsme naměřili?

Pozorování

- u menších molekul dosáhneme vyššího zrychlení na M2090 (zřejmě souvisí s nedostatečnou saturací K20M, implicitní solvent může být lépe optimalizován pro Fermi)
- u explicitního solventu Keper citelně rychlejší ($1.67 \times - 1.95 \times$)
- nemohli jsme změřit škálování na více GPU, ale dle autorů Ambergu není ideální (doporučují běh více nezávislých instancí)
- Amber používá téměř výhradně GPU
 - jednotlivé instance využívající rozdílná GPU se nespomalují (nevzniká úzké hrdlo na straně výkonu CPU a propustnosti PCI-E)
 - na clusteru gram můžeme tedy využít čtyřnásobek výkonu, na clusteru doom dvojnásobek (+ stále máme volných většinu CPU jader)

Akcelerace Gromacs

Válka část funkcionality je akcelerována (je třeba používat Verlet scheme).

Při spouštění je třeba

- alespoň kolik MPI vláken, kolik chceme použít GPU
 - celkový počet vláken pomocí -nt, nebo -ntmpi a -ntomp pro explicitní nastavení MPI a OpenMP vláken na MPI vlákno
 - použité GPU definujeme pomocí -gpu_id XYZ (ID GPU pro každé MPI vlákno)
- příliš mnoho OpenMP vláken špatně škáluje (do 4 u AMD, do 8 u Intelu)

Ladění vytížení CPU a GPU

AkcelEROVány jsou nevazebné síly do cutoffu.

- krátký cutoff vede k nevyužívání plného potenciálu GPU
 - Gromacs automaticky nastaví větší cutoff a zpřesní výpočet
- dlouhý cutoff vede k nevyužití CPU jader
 - můžeme ubrat CPU jádra
 - můžeme použít rychlejší GPU
 - můžeme ubrat cutoff

Měření rychlosti

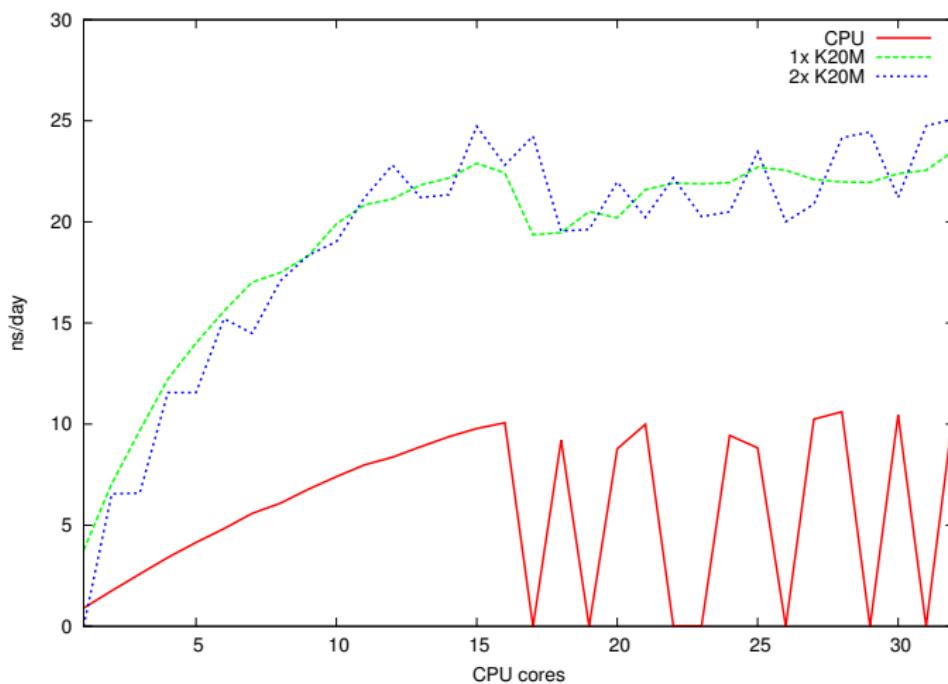
Alkoholdehydrogenáza

- ve vodě, celkem 97 602 atomů.
- měřen výkon simulace v ns/den

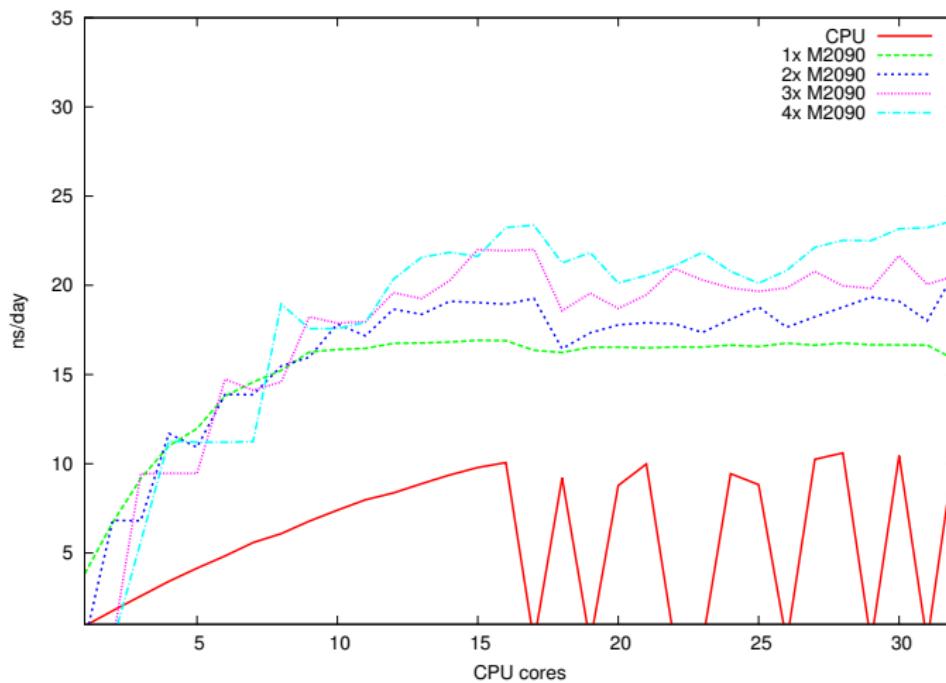
RNáza ZF-1A

- ve vodě, celkem 16 948 atomů.
- měřen výkon simulace v ns/den

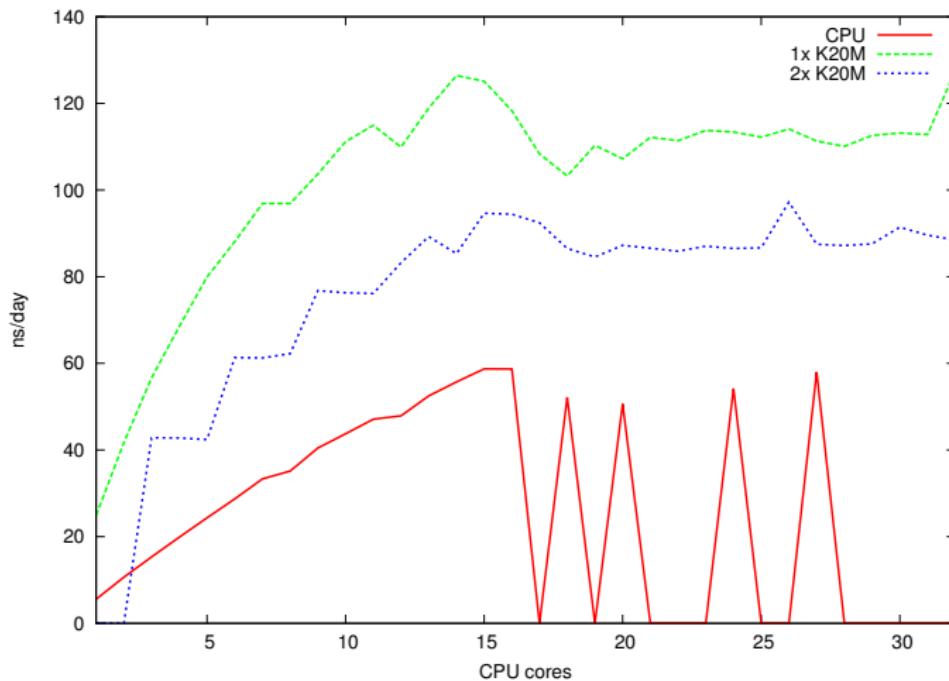
doom.metacentrum.cz, ADH



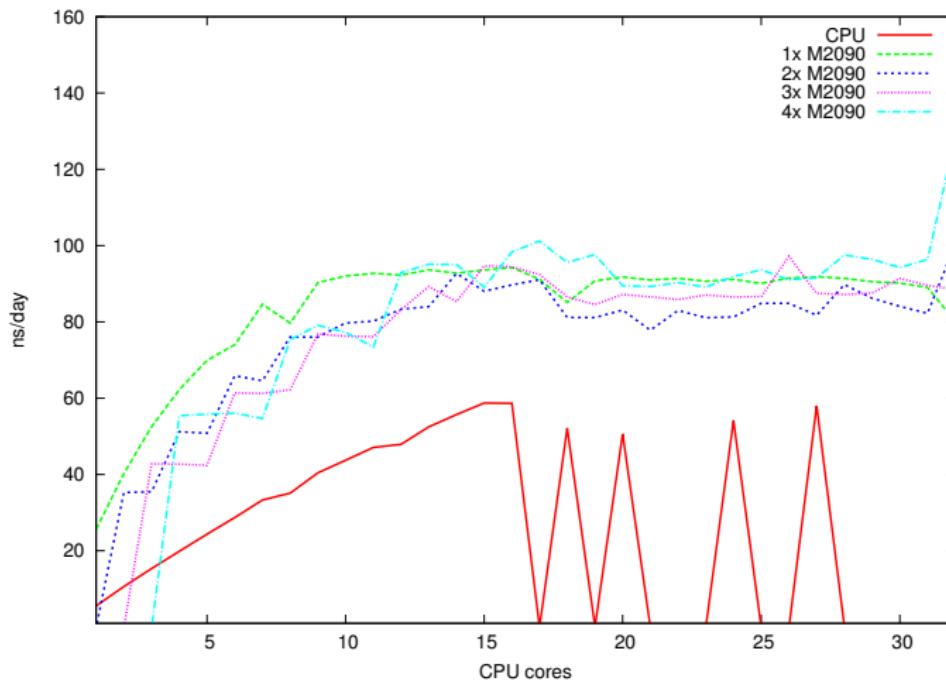
gram.zcu.cz, ADH



doom.metacentrum.cz, RNáza



gram.zcu.cz, RNáza



Co jsme naměřili?

Pozorování

- škálování pro více GPU není ideální
 - gram: pomalejší GPU, více zvýší výkon
 - doom: velmi slabé či záporné zvýšení rychlosti
 - u větší instance by mohlo být lepší
- i s použitím 1 GPU dokážeme dobře saturovat dostupná jádra
- Kepler neposkytuje očekávané zvýšení výkonu ($1.39\times$ ADH, 1.35 RNáza, běh s jedním GPU)

Akcelerace NAMD

Válka část funkcionality je akcelerována.

Při spouštění je třeba

- nastavit outputEnergies na dostatečně vysokou hodnotu (alespoň 100, lépe více)
- nastavit parametr +idlepoll (aktivní doptávání se GPU na výsledky)
- nakonfigurovat počet GPU a CPU jader (parametry +p +devices)
 - tím lze pomněrně výrazně ovlivnit výkon
- pokud budete benchmarkovat, nechte při změně CPU jader proběhnout jeden krátký běh mimo měření (autotuning)

Ladění počtu CPU jader k počtu GPU

Obecně je doporučováno 1-2 GPU na 1 CPU socket.

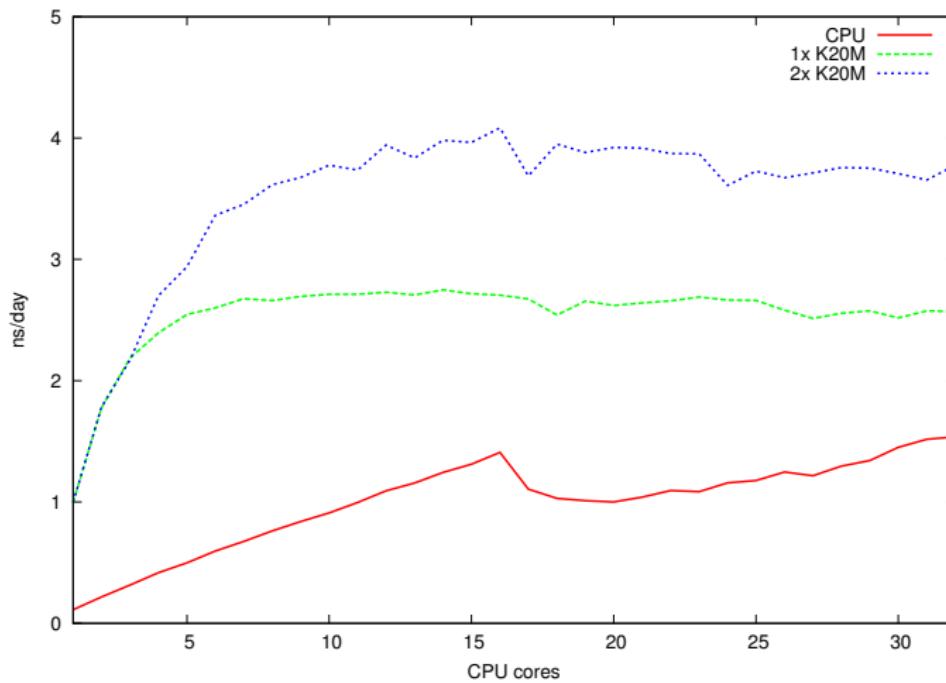
V praxi

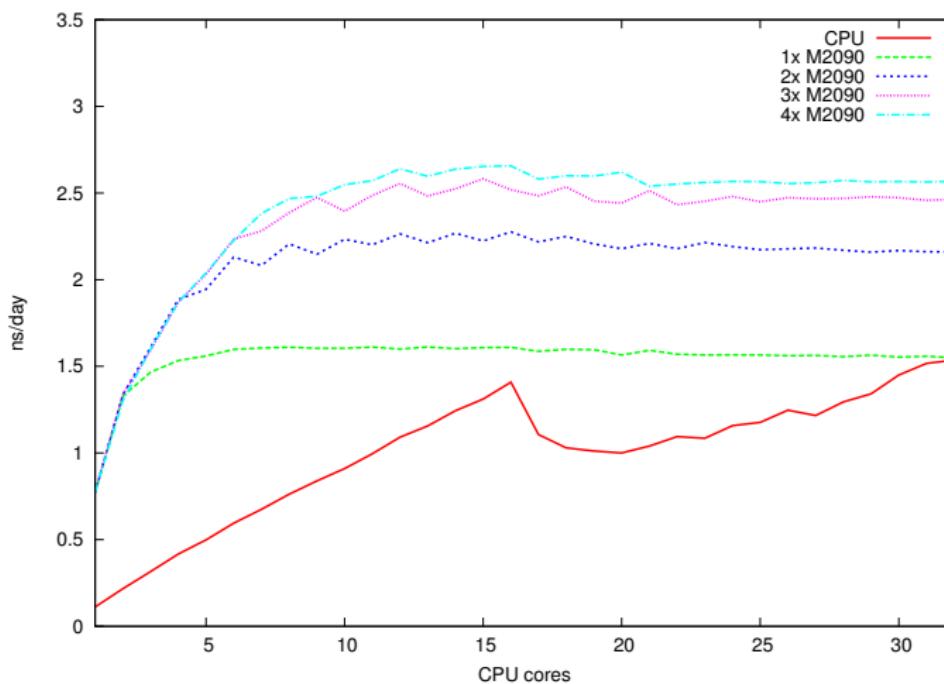
- využívání hyperthreadingu téměř nemá význam
- příliš mnoho CPU jader na GPU může spomalit výpočet
- škálování pro více GPU není ideální

Měření rychlosti

Apolipoprotein A1

- ve vodě, celkem 92 224 atomů.
- outputEnergies 500
- měřen výkon v ns/den





Co jsme naměřili?

Pozorování

- škálování pro více GPU není ideální
 - gram: $1.41 \times 1.57 \times 1.65 \times$
 - doom: $1.49 \times$
 - u větší instance by mohlo být lepší
- výpočtu stačí relativně málo CPU jader
 - pro výkonnější GPU je třeba více
 - vhodný počet CPU jader neroste úměrně počtu GPU
 - při běhu více nezávislých simulací se vzájemně nespomalují
- Kepler poskytuje citelné zvýšení výkonu ($1.71 \times$ běh s jedním GPU)

Co jsme naměřili?

Doporučení

- není vždy nutné (ani žádoucí) přiřazovat dostupným GPU všechna dostupná CPU jádra
- oddělené instance (pro každé GPU jedna, popř. jedna pro zbytek CPU jader) přinášejí lepší výkon, než jedna multi-GPU

Matematický software

V METACentru je často používaný software Matlab a Mathematica

- obojí umí v omezené míře využívat GPU
 - Mathematica má předdefinované funkce, lze pouštět uživatelský CUDA kód
 - Matlab má GPU akceleraci v Parallel Computing Toolbox, lze používat další toolboxy, předdefinované i uživatelské funkce
- nestačí jen „spustit GPU verzi“, je nutné GPU aktivně využívat

Mathematica

Předdefinované funkce

- práce se seznamy
- filtrování obrazu
- lineární algebra, FFT

```
In[1]:=Needs["CUDALink`"]  
In[2]:=CUDASort[Reverse@Range[10]]  
Out[2]={1,2,3,4,5,6,7,8,9,10}
```

Lze také explicitně zanechat v paměti GPU a tu vyzvednout až jsou data potřeba.

Matlab

Předdefinované funkce

- spousta funkcí se použije transparentně
- mnoho skalárních funkcí, lze je aplikovat na elementy polí

Explicitně říkáme, co je v GPU paměti.

```
>> A = rand(1024); gA = gpuArray(A);
>> tic, C = A * A; toc
Elapsed time is 0.075396 seconds.
>> tic, gC = gA * gA; toc
Elapsed time is 0.008621 seconds.
```

Děkuji za pozornost.