Paralelní a distribuované výpočty (B4B36PDV)

Branislav Bošanský, Michal Jakob

bosansky@fel.cvut.cz

Artificial Intelligence Center
Department of Computer Science
Faculty of Electrical Engineering
Czech Technical University in Prague

Paralelní a Distribuované Výpočty

Paralelní programování

- 1 program
- vícero úloh, které spolupracují pro vyřešení problému
- typicky vlákna, sdílená paměť

Rychleji nalézt řešení

Programování v distribuovaných systémech

- vícero programů
- programy spolupracují pro nalezení řešení
- typicky procesy, výpočetní uzly, distribuovaná paměť

Zvýšit robustnost řešení

Kdo jsme

Přednášející

Branislav Bošanský

Michal Jakob

Cvičící

Peter Macejko

Petr Tomášek

Petr Váňa

David Fiedler

Jan Mrkos

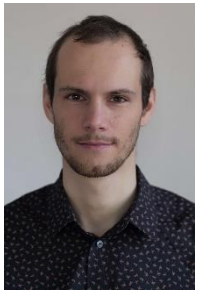

David Milec

Organizace a přehled

- Paralelní část
  - Paralelní programování jednoduchých algoritmů
  - Vliv různých způsobů paralelizace na rychlost výpočtu
- Distribuovaná část
  - Problémy v distribuovaných systémech (shoda, konzistence dat)
  - Navržení robustných řešení

- CourseWare
  - https://cw.fel.cvut.cz/wiki/courses/b4b36pdv/start
- Quizzes
  - https://goo.gl/a6BEMb

Bookmark This Page

Hodnocení

- Domácí úkoly (40%)
  - Malé domácí úkoly (7x)
  - Velké domácí úkoly (2x)
- Praktický test z paralelního programování (20%)
- Teoretický test (40%)

Pro úspěšné ukončení musíte získat alespoň 50% z každé části

Co udělat pro úspěšné zvládnutí PDV?

- programovat
  - zkoušejte si kódy z přednášek, upravujte jej, analyzujte co se stane
  - nechte si čas na vypracování domácích úkolů

- přemýšlet
  - paralelní / distribuované programy se špatně ladí
  - vícevláknové chyby v debug-módu neodhalíte (můžou pomoct ladící výpisy)
  - pokud program nepracuje jak očekáváte (např. není dostatečně rychlý, výsledek není správný), **zastavte se a zamyslete se proč tomu tak je**

Krátká historie paralelních výpočtů

1970s-1980s – vědecké výpočty

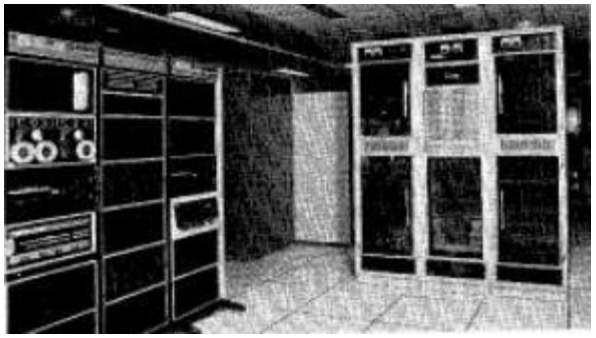

C.mmp (1971)
16 CPUs

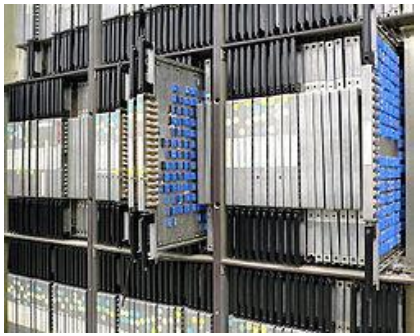

ILLIAC IV
(1975) 64
FPUs, 1 CPUs

Cray X-MP
(1982) parallel
vector CPU

Obrázky převzaty z:

- https://en.wikipedia.org/wiki/ILLIAC_IV
- https://en.wikipedia.org/wiki/Cray_X-MP

Krátká historie paralelních výpočtů

1990s – databáze, superpočítače

Sun Starfire
10000 (1997) 64
UltraSPARC CPUs

Cray T3E
(1996) až 1480
PE

Obrázky převzaty z:
- https://en.wikipedia.org/wiki/Sun_Enterprise
- https://en.wikipedia.org/wiki/Cray_T3E

Krátká historie paralelních výpočtů

Nárůst výkonu jednoho procesoru

- Dlouhé roky rostl výpočetní výkon exponenciálně …

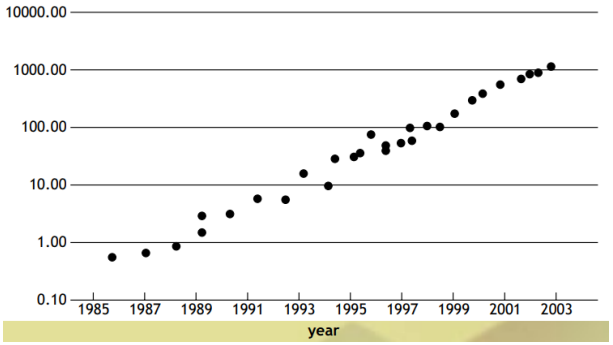

- … až v letech 2004 nebylo možné dále pouze navyšovat frekvenci

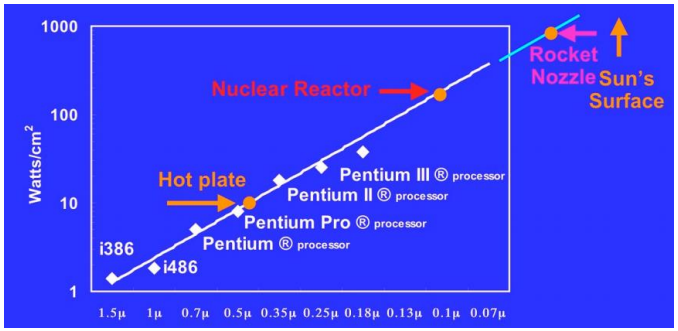

Obrázky převzaty z:

- Olukutun and Hammond, ACM Queue 2005
- http://www.cs.columbia.edu/~sedwards/classes/2012/3827-spring/advanced-arch-2011.pdf

Krátká historie paralelních výpočtů

Nárůst výkonu jednoho procesoru

- Pohled programátora:

Jak zrychlím svůj program/algoritmus?

- Odpověď před 2004:
  - počkejte půl roku a kupte nový HW
- Odpověď po 2004:
  - přepsat na paralelní verzi

Krátká historie paralelních výpočtů

Dnešní paralelní stroje

Krátká historie paralelních výpočtů

Struktura dnešních CPU

- Intel Skylake (2015)
  - i7 – čtyřjádrové CPU + vícejádrové GPU

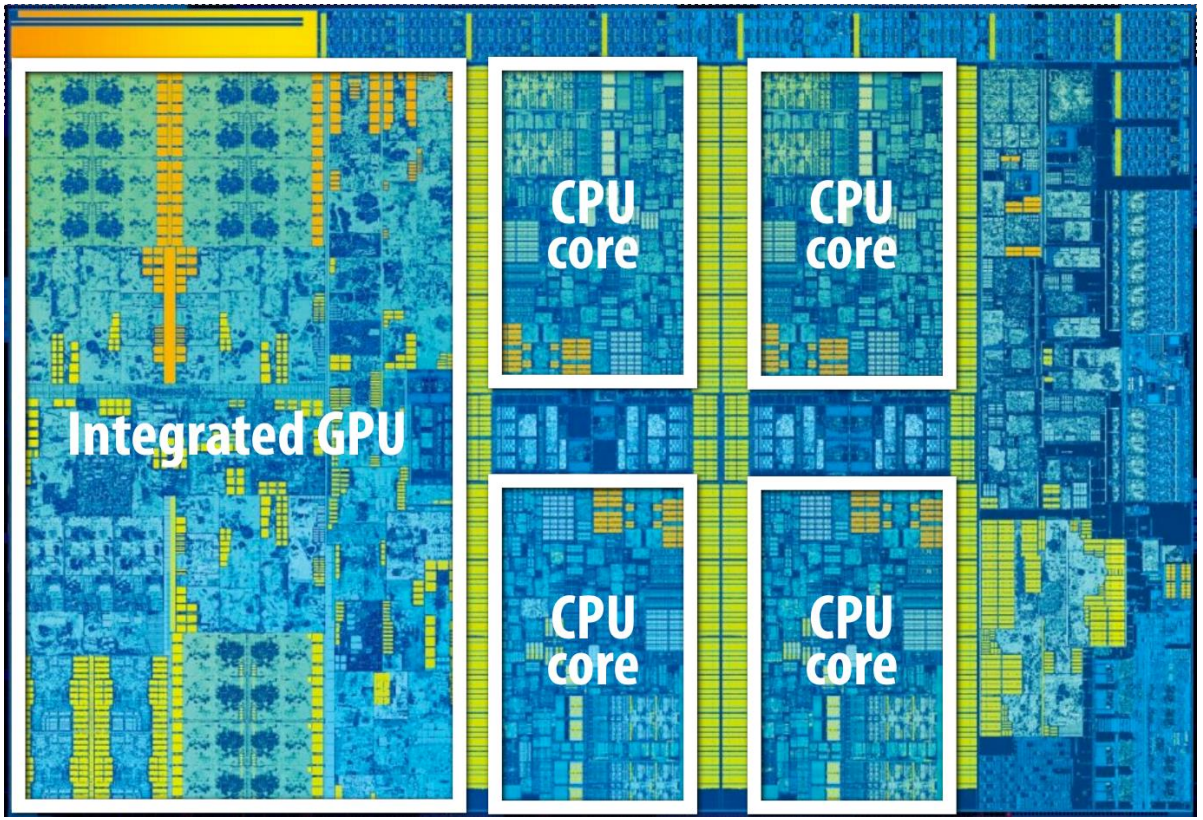

Krátká historie paralelních výpočtů

Alternativní architektury – Intel Xeon Phi

- Intel Xeon Phi
  - x86-64 architektura (61 CPUs, 244 vláken)

Krátká historie paralelních výpočtů

Alternativní architektury – GPU

- NVIDIA GPUs Pascal (GTX 1070)
  - 128 single-precision ALUs

Krátká historie paralelních výpočtů

Výpočetní gridy – TOP 10 superpočítačů

Top 10 positions of the 54th TOP500 in November 2019[25]

Rank	Rmax Rpeak (PFLOPS)	Name	Model	Processor	Interconnect	Vendor	Site country, year	Operating system
1 –	148.600 200.795	Summit	IBM Power System AC922	POWER9, Tesla V100	InfiniBand EDR	IBM	Oak Ridge National Laboratory United States, 2018	Linux (RHEL)
2 –	94.640 125.712	Sierra	IBM Power System S922LC	POWER9, Tesla V100	InfiniBand EDR	IBM	Lawrence Livermore National Laboratory United States, 2018	Linux (RHEL)
3 –	93.015 125.436	Sunway TaihuLight	Sunway MPP	SW26010	Sunway[26]	NRCPC	National Supercomputing Center in Wuxi China, 2016[26]	Linux (Raise)
4 –	61.445 100.679	Tianhe-2A	TH-IVB-FEP	Xeon E5–2692 v2, Matrix-2000[27]	TH Express-2	NUDT	National Supercomputing Center in Guangzhou China, 2013	Linux (Kylin)
5 ▲	23.516 38.746	Frontera	Dell C6420	Xeon Platinum 8280 (subsystems with e.g. POWER9 CPUs and Nvidia GPUs were added after official benchmarking[11])	InfiniBand HDR	Dell EMC	Texas Advanced Computing Center United States, 2019	Linux (CentOS)
6 ▼	21.230 27.154	Piz Daint	Cray XC50	Xeon E5-2690 v3, Tesla P100	Aries	Cray	Swiss National Supercomputing Centre Switzerland, 2016	Linux (CLE)
7 ▼	20.159 41.461	Trinity	Cray XC40	Xeon E5–2698 v3, Xeon Phi 7250	Aries	Cray	Los Alamos National Laboratory United States, 2015	Linux (CLE)
8 ▼	19.880 32.577	AI Bridging Cloud Infrastructure[28]	PRIMERGY CX2550 M4	Xeon Gold 6148, Tesla V100	InfiniBand EDR	Fujitsu	National Institute of Advanced Industrial Science and Technology Japan, 2018	Linux
9 –	19.477 26.874	SuperMUC-NG [29]	ThinkSystem SD530	Xeon Platinum 8174 (plus not benchmarked e.g. 32 cloud GPU nodes with Tesla V100[30])	Intel Omni-Path	Lenovo	Leibniz Supercomputing Centre Germany, 2018	Linux (SLES)
10 ▲	18.200 23.047	Lassen	IBM Power System S922LC	POWER9, Tesla V100	InfiniBand EDR	IBM	Lawrence Livermore National Laboratory United States, 2018	Linux (RHEL)

Zdroj: https://en.wikipedia.org/wiki/TOP500

Krátká historie paralelních výpočtů

Výpočetní gridy – a co u nás?

- RCI ČVUT cluster
  - n01-20 CPU nodes: 24 cores/48 threads 3.2GHz (2 x Intel Xeon Scalable Gold 6146), 384GB RAM,
  - n21-n32 GPU nodes: 36 cores/72 threads 2.7GHz (2 x Intel Xeon Scalable Gold 6150), 384GB RAM, 4 x Tesla V100 with NVLink,
  - n33 multi-CPU node: 192 cores/ 384 threads 2.1GHz (8 x Intel Xeon Scalable Platinum 8160), 1536GB RAM

Krátká historie paralelních výpočtů

Výpočetní gridy – a co u nás?

- IT4Innovations (www.it4i.cz)
  - 180x 16 Core CPUs, 23x Kepler GPUs, 4x Xeon Phi
  - 1008x 2x12 Core CPUs
  - komerční výpočty, lze zažádat a získat výpočetní čas pro výzkum

- Metacentrum
  - spojení výpočetních prostředků akademické sítě
  - volně dostupné pro akademické pracovníky, studenty
  - mnoho dostupných strojů (CPU, GPU, Xeon Phi)
    - https://metavo.metacentrum.cz/pbsmon2/hardware

Vliv architektury

Cache

- Proč je důležité vědět o architektuře?
  - Uvažme příklad násobení matice vektorem

```
int x[MAXIMUM], int y[MAXIMUM], int A[MAXIMUM*MAXIMUM]
```

Varianta A

```
for ( int i = 0; i < MAXIMUM ; i ++)
    for ( int j = 0; j < MAXIMUM ; j ++)
        y[i] += A->at(i * MAXIMUM + j)*x[j];
```

Varianta B

```
for ( int j = 0; j < MAXIMUM ; j ++)
    for ( int i = 0; i < MAXIMUM ; i ++)
        y [i] += A->at(i * MAXIMUM + j)*x[j];
```

Který kód bude rychlejší?

https://goo.gl/a6BEMb

Vliv architektury

Cache

```
for ( int i = 0; i < MAXIMUM ; i ++)
    for ( int j = 0; j < MAXIMUM ; j ++)
        y[i] += A->at(i * MAXIMUM + j)*x[j];
```

```
for ( int j = 0; j < MAXIMUM ; j ++)
    for ( int i = 0; i < MAXIMUM ; i ++)
        y [i] += A->at(i * MAXIMUM + j)*x[j];
```

- Pole jsou v paměti uložena sekvenčně (po řádcích)
- CPU při přístupu k A[0][0] načte do cache vícero hodnot (cache line)

Cache Line	Elements of A			
0	A[0][0]	A[0][1]	A[0][2]	A[0][3]
1	A[1][0]	A[1][1]	A[1][2]	A[1][3]
2	A[2][0]	A[2][1]	A[2][2]	A[2][3]
3	A[3][0]	A[3][1]	A[3][2]	A[3][3]

- Při přístupu k A[1][0] se změní celý řádek

V rámci paralelních programů může k podobným problémům docházet častěji

Paralelizace

Jednoduchý příklad

- Suma vektoru čísel

0	1	2	3	4	5	6	…	…	$5x10^9$
17	2	9	4	22	0	1			8

Jak paralelizovat?

- Mějme 4 jádra – každé jádro může sečíst čtvrtinu vektoru, pak sečteme částečné součty

Vláken	1	2	3	4
Čas	0.389s	0.262s	0.258s	0.244s

Měřeno na 8 jádrovém (16 vláknovém) Intel Xeon v4 E5-2620

Paralelizace

Jednoduchý příklad

- Suma vektoru čísel

Co když máme tisíce jader?

- Pokud částečné součty sčítá pouze jedno jádro, kód není velmi efektivní

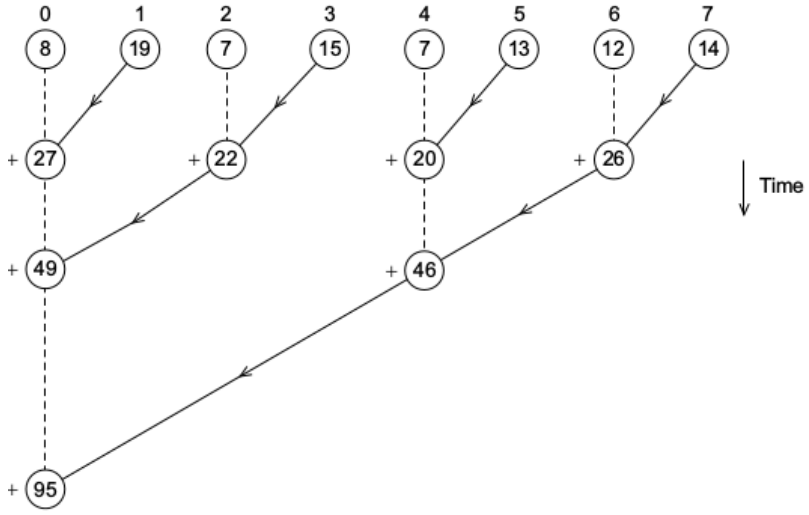

Obrázek převzat z knihy Parallel Programming (by Peter Pacheco)

Hlavní cíl paralelní části

- Paralelizace úkolů / dat
  - Rozdělení úkolu na jiné součásti a jejich paralelizace
  - Rozdělení dat a jejich (téměř) stejné paralelní zpracování
    - Opravovaní písemky (rozdělení po otázkách/studentech)
- Komunikace a synchronizace mezi vlákny/procesy
  - Přístup ke společné paměti

Získat základní informace a prostor pro praktické zkušenosti v oblasti programování efektivních paralelních programů

Přehled paralelní části

- Základní úvod
  - Vlákna, synchronizace, mutexy
  - Pthread (již by jste měli znát), C++11 thready
- OpenMP
  - nadstavba nad C kompilátorem pro zjednodušení implementace paralelních programů
- Techniky dekompozice
- Datové struktury umožňující přístup vícero vláken
- Základní paralelní řadící algoritmy a vektorové instrukce
- Základní paralelní maticové algoritmy

Pthready vs. C++11 vs. OpenMP

Ochutnávka (pthreads)

```
#include <stdio.h>
#include <stdlib.h>
#include <pthread.h>

const int thread_count = 10;
void* Hello(void* rank);

int main(int argc, char* argv[]) {
   long thread;
   pthread_t *thread_handles;
   thread_handles = (pthread_t*)malloc(thread_count * sizeof(pthread_t));
   for (thread = 0; thread < thread_count; thread++)
      pthread_create(&thread_handles[thread], NULL,
                     Hello, (void *) thread);
   printf("Hello from the main thread\n");
   for (thread = 0; thread < thread_count; thread++)
      pthread_join(thread_handles[thread], NULL);

   free(thread_handles);
   return 0;
}

void* Hello(void* rank) {
   long my_rank = (long) rank;
   printf("Hello from thread %ld of %d\n", my_rank, thread_count);
   return NULL;
}
```

Pthready vs. C++11 vs. OpenMP

Ochutnávka (C++11)

```
#include <iostream>
#include <thread>
#include <vector>

const int thread_count = 10;
void Hello(long my_rank);

int main(int argc, char* argv[]) {
   std::vector<std::thread> threads;
   for (int thread=0; thread < thread_count; thread++) {
      threads.push_back(std::thread(Hello, thread));
   }

   std::cout << "Hello from the main thread\n";

   for (int thread=0; thread < thread_count; thread++) {
      threads[thread].join();
   }

   return 0;
}

void Hello(long my_rank) {
   std::cout << "Hello from thread " << my_rank << " of " << thread_count << std::endl;
}
```

Pthready vs. C++11 vs. OpenMP

Ochutnávka (OpenMP)

```
#include <iostream>
#include <vector>
#include "omp.h"

const int thread_count = 10;

void Hello() {
    int my_rank = omp_get_thread_num();
    int threads = omp_get_num_threads();
    std::cout << "Hello from thread " << my_rank << " of " << threads << std::endl;
}

int main(int argc, char* argv[]) {
#pragma omp parallel num_threads(thread_count)
    Hello();
    return 0;
}
```

- nutno překládat s přepínačem –fopenmp
  - (např. **g++ -fopenmp openmp-hello.cpp -o openmp-hello**)

Potřebný HW základ

Von Neumannova architektura

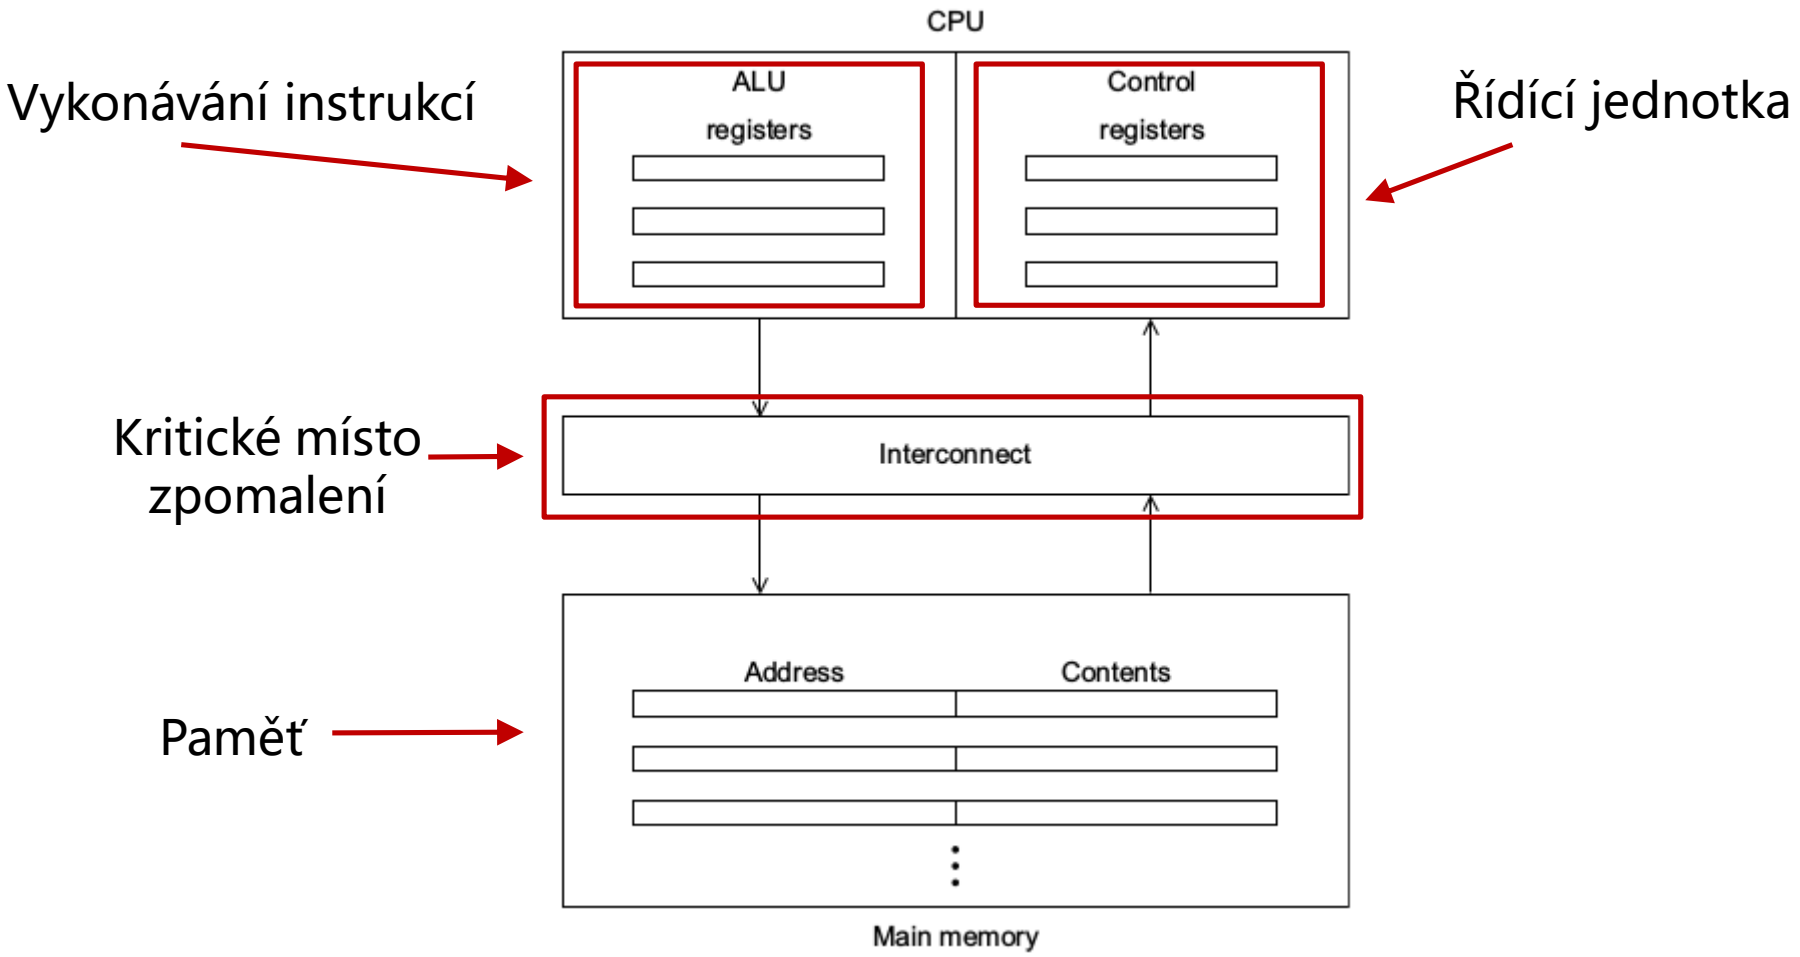

Obrázek převzat z knihy Parallel Programming (by Peter Pacheco)

Potřebný HW základ

Pipelines

- Paralelizace na úrovni instrukcí (ILP)
- Příklad:
  - Chceme sečíst 2 vektory reálných čísel (float [1000])
  - 1 součet – 7 operací
    - Fetch
    - Porovnání exponentů
    - Posun
    - Součet
    - Normalizace
    - Zaokrouhlení
    - Uložení výsledku
  - Bez ILP – 7x1000x(čas 1 operace; 1ns)

Potřebný HW základ

Pipelines

- Paralelizace na úrovni instrukcí (ILP)
- Příklad:
  - Chceme sečíst 2 vektory reálných čísel (float [1000])
  - 1 součet – 7 operací
  - Bez ILP – 7x1000x(čas 1 operace; 1ns)
  - S ILP (a 7 jednotek) – 1005 ns

Table 2.3 Pipelined Addition. Numbers in the Table Are Subscripts of Operands/Results

Time	Fetch	Compare	Shift	Add	Normalize	Round	Store
0	0						
1	1	0					
2	2	1	0				
3	3	2	1	0			
4	4	3	2	1	0		
5	5	4	3	2	1	0	
6	6	5	4	3	2	1	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
999	999	998	997	996	995	994	993
1000		999	998	997	996	995	994
1001			999	998	997	996	995
1002				999	998	997	996
1003					999	998	997
1004						999	998
1005							999

Obrázek převzat z knihy Parallel Programming (by Peter Pacheco)

Potřebný HW základ

Superskalární procesory

- Současné vyhodnocení vícero instrukcí
  - uvažme cyklus

```
for (i=0; i<1000; i++)
    z[i]=x[i]+y[i];
```

  - jedna jednotka může počítat z[0], druhá z[1], …
- Spekulativní vyhodnocení

```
z = x + y;
if (z > 0)
    w = x;
else
    w = y;
```

Potřebný HW základ

Paralelní hardware – Flynnova taxonomie

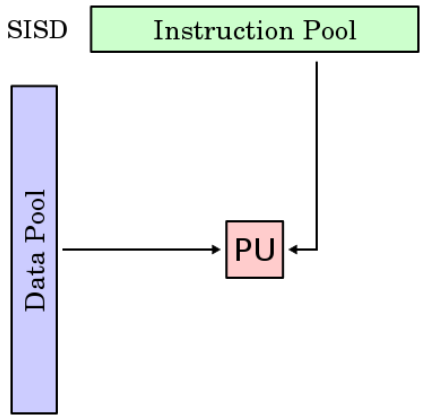

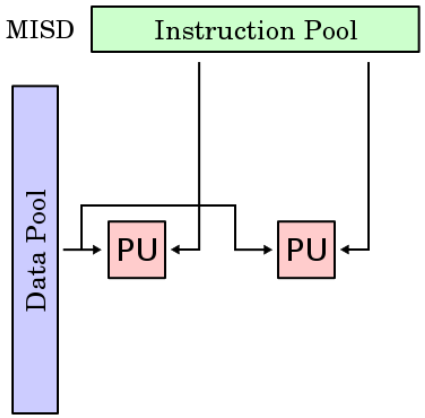

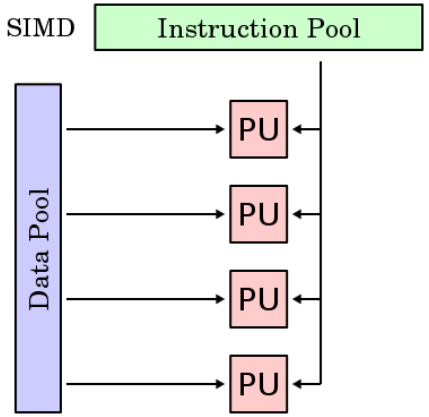

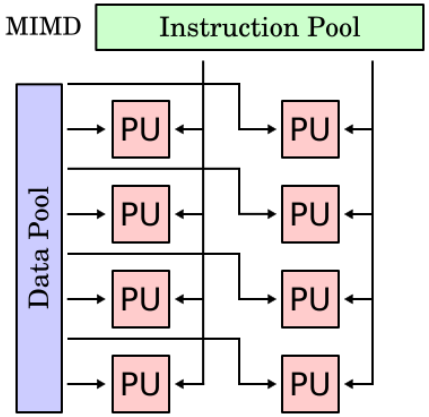

Obrázky převzaty z https://en.wikipedia.org/wiki/Flynn%27s_taxonomy

Potřebný HW základ

Paralelní hardware – Flynnova taxonomie

- SIMD (Single Instruction Multiple Data)
  - Jedna řídící jednotka, vícero ALU jednotek
  - Datový paralelizmus
  - Vektorové procesory, GPU
  - Běžné jádra CPU podporují SIMD paralelizmus
    - instrukce SSE, AVX
- Větvení na SIMD

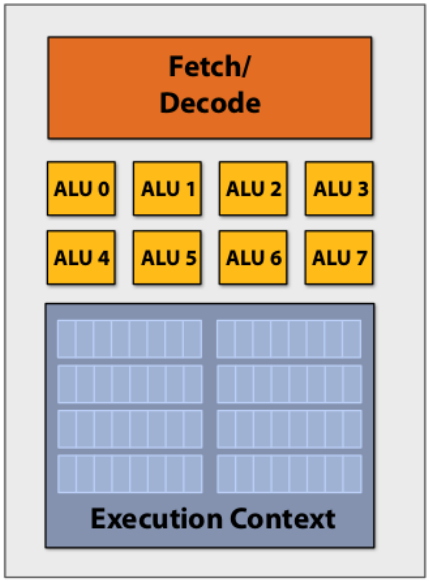

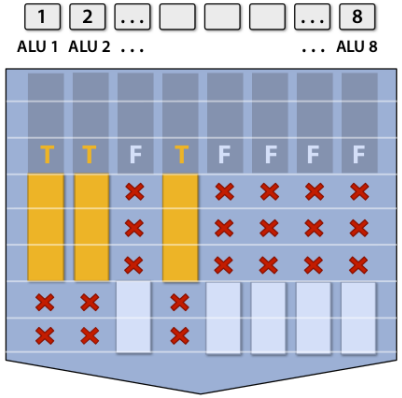

Obrázky převzaty z kurzu CMU 15-418/618 na CMU.edu

Potřebný HW základ

Paralelní hardware – Flynnova taxonomie

- MIMD (Multiple Instruction Multiple Data)
  - Více-jádrové procesory
  - Různé jádra vykonávají různé instrukce
  - Víceprocesorové počítače

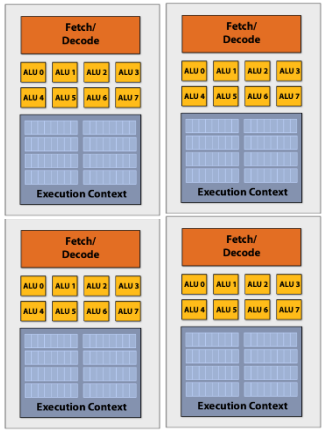

- A co paměť?

Obrázky převzaty z kurzu CMU 15-418/618 na CMU.edu

Potřebný HW základ

Systémy se sdílenou pamětí

- Uniform Memory Access (UMA)

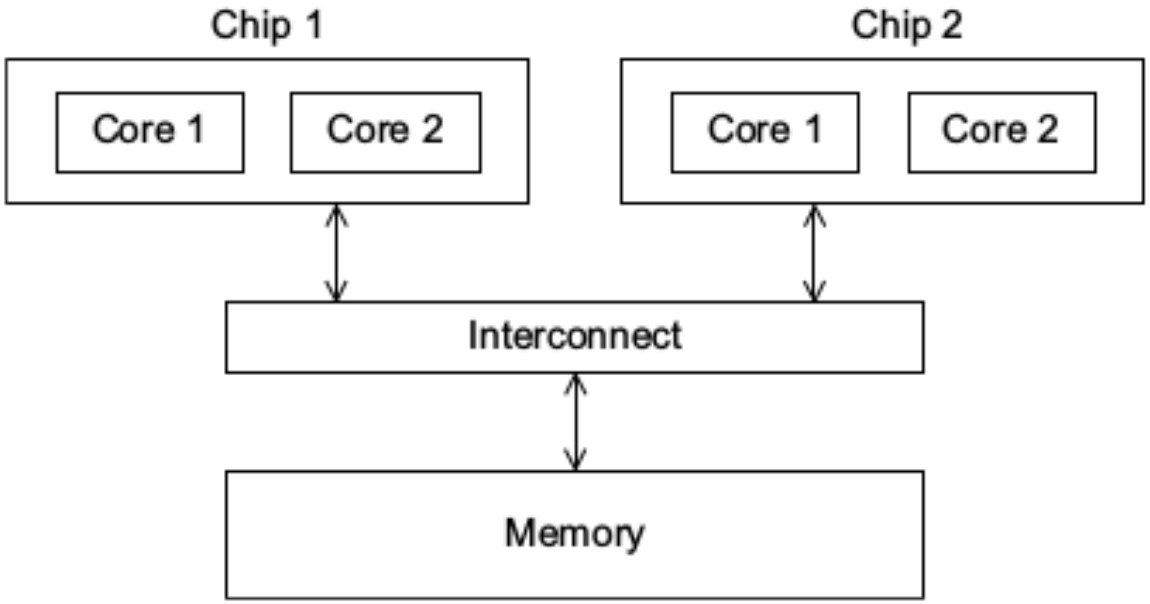

Obrázek převzat z knihy Parallel Programming (by Peter Pacheco)

Potřebný HW základ

Systémy se sdílenou pamětí

- Nonuniform Memory Access (NUMA)

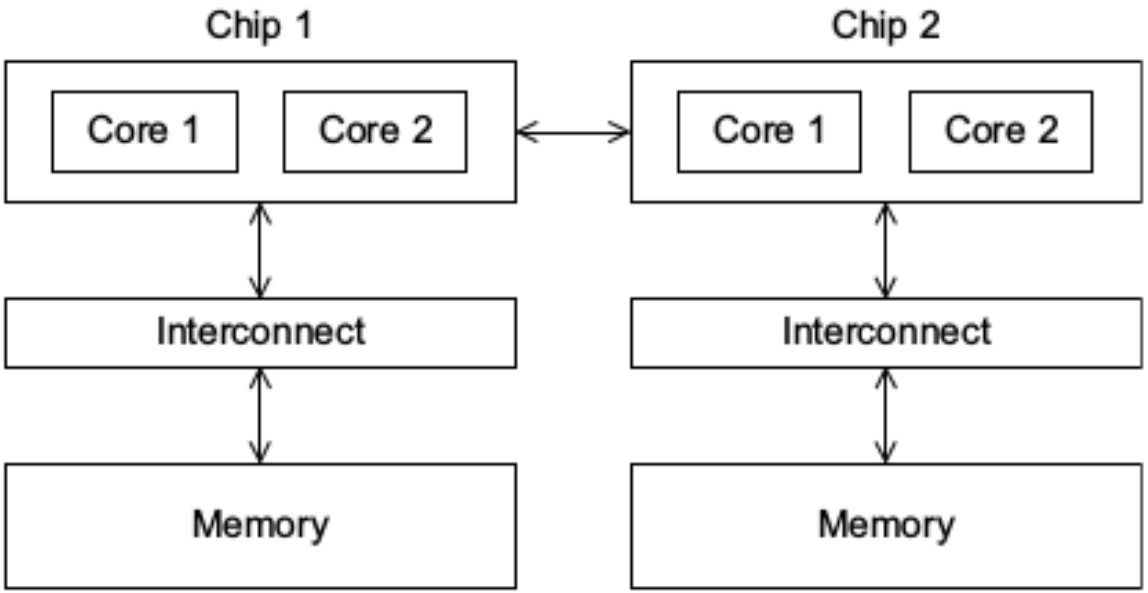

Obrázek převzat z knihy Parallel Programming (by Peter Pacheco)

Potřebný HW základ

Systémy se sdílenou pamětí – typy přístupů k paměti

- Sběrnice
- Mřížka

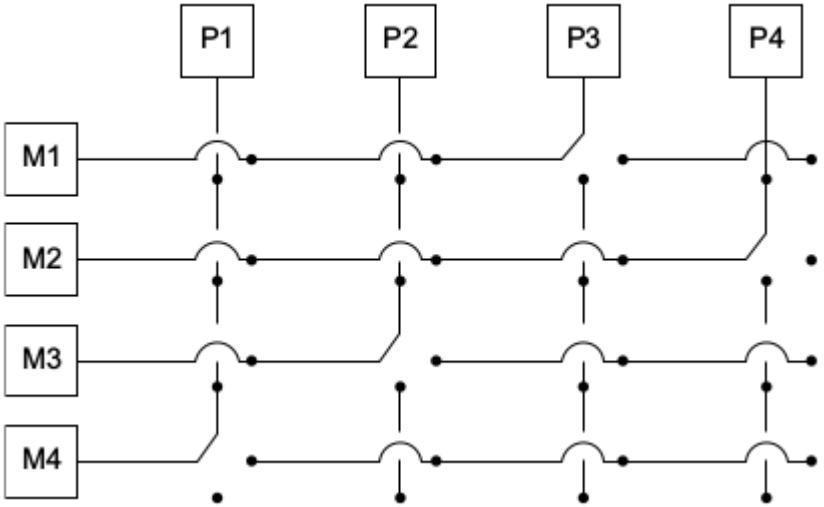

- Síť/Kruh

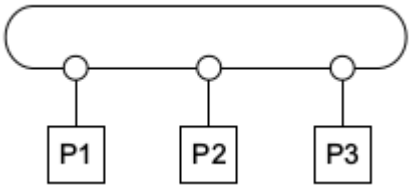

- …

Obrázek převzat z knihy Parallel Programming (by Peter Pacheco)

Potřebný HW základ

Základy Cache

- CPU cache
  - Programy často přistupují k paměti lokálně (lokalita v prostoru a čase)
  - Cache se upravuje po řádcích
- Každé jádro má vlastní cache + existuje společná cache

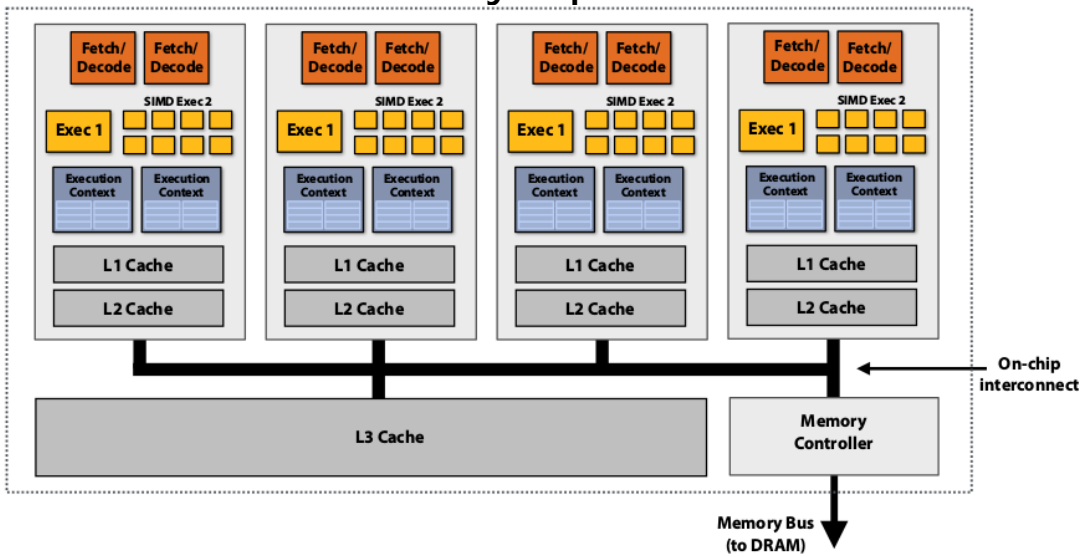

A co když jádra přistupují ke stejné adrese?

Obrázky převzaty z kurzu CMU 15-418/618 na CMU.edu

Potřebný HW základ

Distributed memory

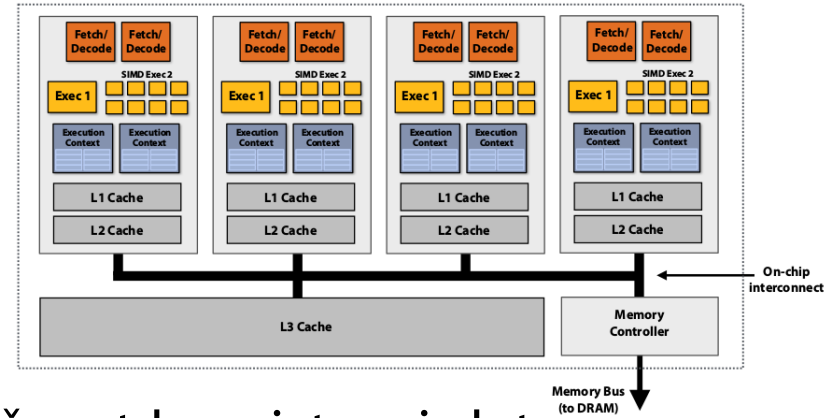

- Musíme udržovat konzistenci dat

V dnešních moderních CPU je nutno řešit řadu paralelních a distribuovaných problémů

Pokud budeme implementovat naše algoritmy bez ohledu na architekturu, zrychlení nemusí být dostatečné

Pokročilejší příklad

- Vraťme se k příkladu se sčítáním vektoru čísel
  - (teď budeme sčítat celou část druhých odmocnin)

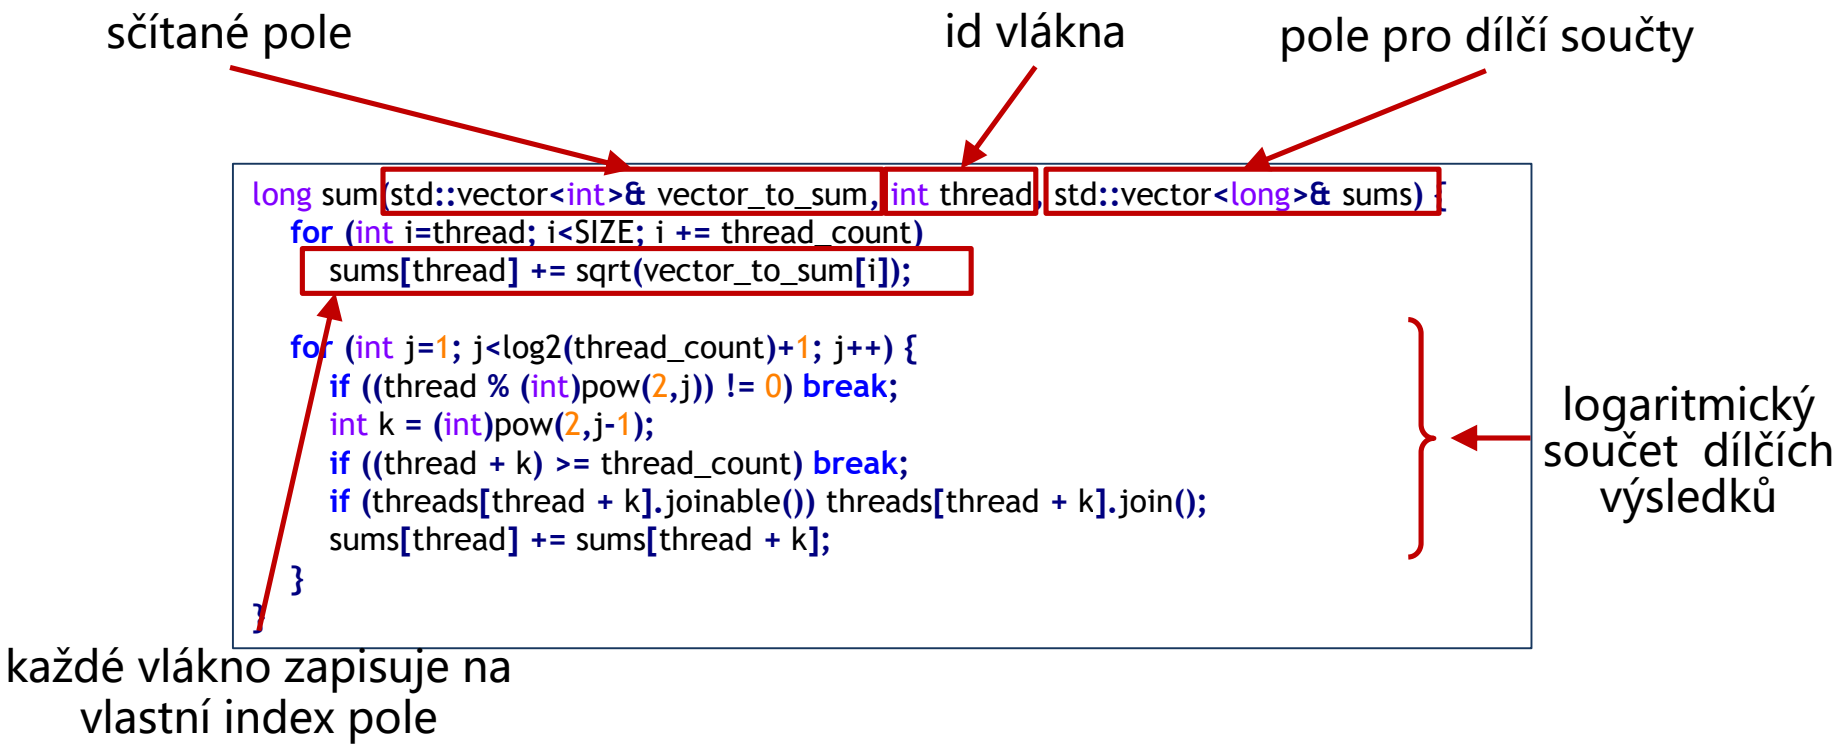

Pokročilejší příklad

Jak nám to bude fungovat?

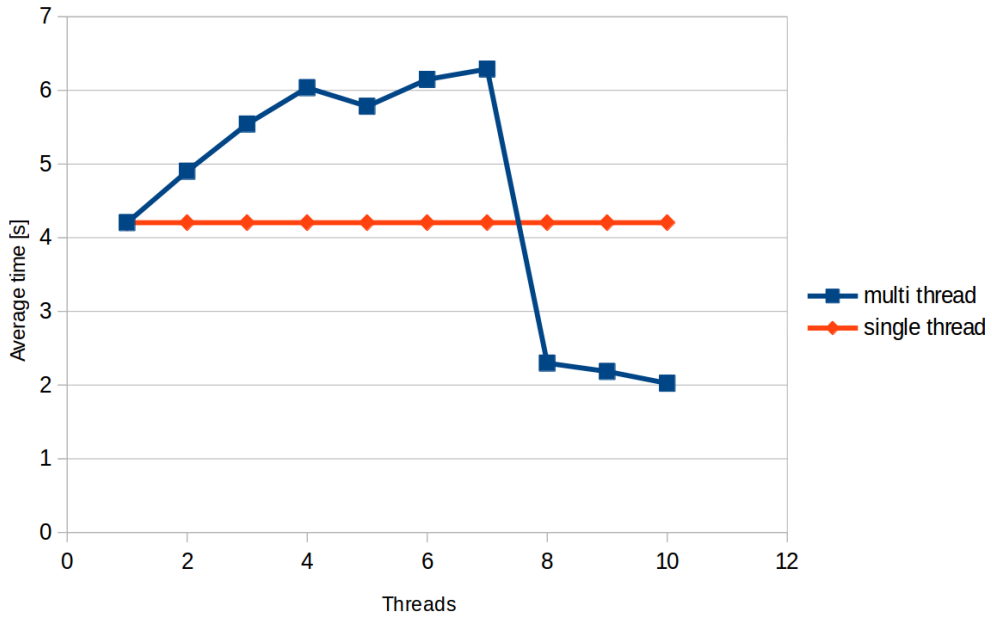

Nic moc :(

Měřeno na 8 jádrovém (16 vláknovém) Intel Xeon v4 E5-2620

Pokročilejší příklad

Kde je chyba?

```
long sum(std::vector<int>& vector_to_sum, int thread, std::vector<long>& sums) {
    for (int i=thread; i<SIZE; i += thread_count)
        sums[thread] += sqrt(vector_to_sum[i]);

    for (int j=1; j<log2(thread_count)+1; j++) {
        if ((thread % (int)pow(2,j)) != 0) break;
        int k = (int)pow(2,j-1);
        if ((thread + k) >= thread_count) break;
        if (threads[thread + k].joinable()) threads[thread + k].join();
        sums[thread] += sums[thread + k];
    }
}
```

každé vlákno zapisuje na vlastní index pole

0	1	2	3	4	5	6	7	8	9
17	2	9	4	22	0	1	0	0	8

Pokročilejší příklad

Kde je chyba?

```
long sum(std::vector<int>& vector_to_sum, int thread, std::vector<long>& sums) {
    for (int i=thread; i<SIZE; i += thread_count)
        sums[thread] += sqrt(vector_to_sum[i]);

    for (int j=1; j<log2(thread_count)+1; j++) {
        if ((thread % (int)pow(2,j)) != 0) break;
        int k = (int)pow(2,j-1);
        if ((thread + k) >= thread_count) break;
        if (threads[thread + k].joinable()) threads[thread + k].join();
        sums[thread] += sums[thread + k];
    }
}
```

- vlákno 0 upraví hodnotu
- jenže vlákno 0 má celý vektor **sums** v cache jádra
- a podobně i jiné vlákna
- při změně 1 hodnoty se musí zabezpečit konzistence

0	1	2	3	4	5	6	7	8	9
17	2	9	4	22	0	1	0	0	8

False Sharing

False Sharing

možné řešení

```
long sum_local(std::vector<int>& vector_to_sum, int thread, std::vector<long>& sums) {
    long local = 0;
    for (int i=thread; i<SIZE; i += thread_count) {
        local += sqrt(vector_to_sum[i]);
    }
    sums[thread] = local;

    for (int j=1; j<log2(thread_count)+1; j++) {
        if ((thread % (int)pow(2,j)) != 0) break;
        int k = (int)pow(2,j-1);
        if ((thread + k) >= thread_count) break;
        if (threads[thread + k].joinable()) threads[thread + k].join();
        local += sums[thread + k];
    }
    sums[thread] = local;
}
```

každé vlákno zapisuje do lokální proměnné

pouze finální výsledek se zapíše do vektoru

Potřebný HW základ

False Sharing

lokální proměnná – opravdu to pomůže?

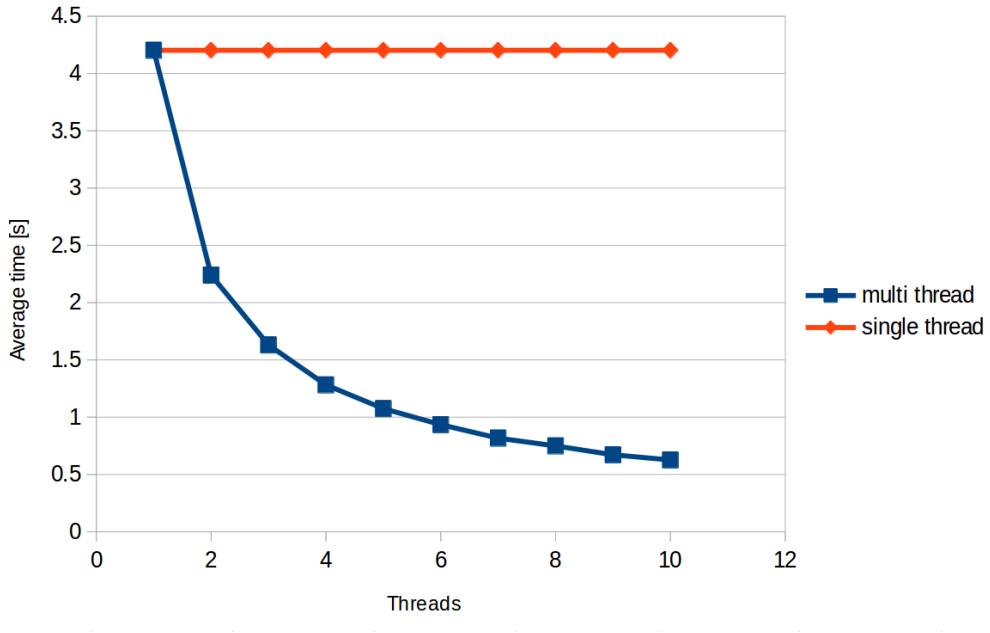

Paralelní programování

Měření zrychlení

Je dané zrychlení dostatečné? Můžeme být rychlejší?

- V optimálním případě se paralelní verze zrychluje proporčně s počtem jader

Vláken	1	2	3	4
Čas	x	x/2	x/3	x/4

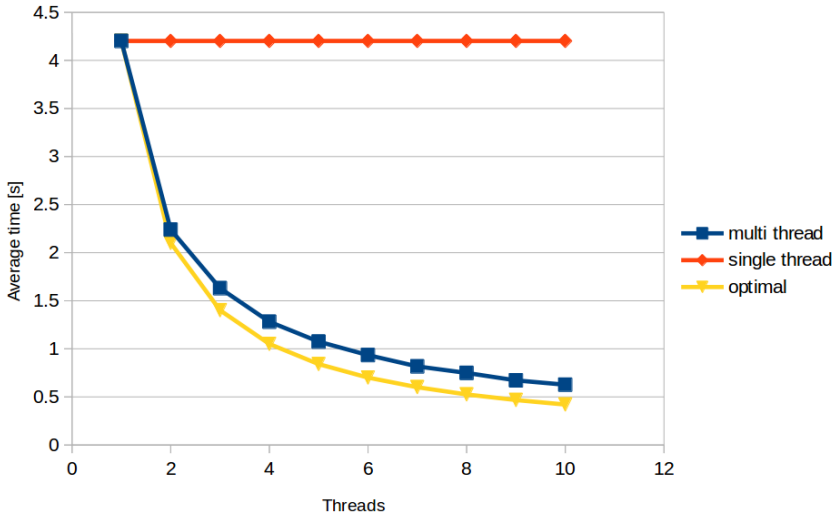

Často vyjádřeno jako zrychlení:

$$S = \frac{T_{serial}}{T_{parallel}}$$

Paralelní programování

Měření zrychlení

Můžeme se vždy dostat k lineárnímu zrychlení?

- Paralelní verze algoritmů mají (téměř) vždy další režii
  - spouštění vláken
  - zámky
  - synchronizace
  - …
- Program/algoritmus často vyžaduje určitou sériovou část
  - Nechť jsme schopni přepsat 90% kódu s lineárním zrychlením
  - $S = \frac{T_{serial}}{0.9 \times \frac{T_{serial}}{p} + 0.1 \times T_{serial}} \leq \frac{T_{serial}}{0.1 \times T_{serial}}$
  - To znamená, že pokud sériový program trvá 20 sekund, nikdy nedosáhneme zrychlení větší než 10

Amdahlův zákon