

Urychlování výpočtů, paralelizace a profiling

Ing. Filip Vaverka

Brno University of Technology, Faculty of Information Technology
Božetěchova 1/2. 602 00 Brno - Královo Pole

ivaverka@fit.vutbr.cz



- Zkrácení doby výpočtu
 - Umožnit běh aplikací pracujících v reálném čase (řídící systémy, hry, ...)
 - Zajištění užitečnosti výsledků (simulace, predikce, ...)
 - Včasné zpracování přichozích dat
 - Zajištění pohodlí uživatele
- Snížení množství energie potřebné pro výpočet
 - Primárně mobilní a energeticky omezená zařízení
 - ale také vysoce náročné počítání

- Hledání vhodné formulace problému
- Volba vhodné platformy pro řešení daného problému
- Efektivní využití dostupných zdrojů pro řešení daného problému

- 1 Hrubá formulace problému, způsobu řešení a požadavků
 - Prvotní analýza umožňující odhad výpočetní náročnosti řešení problému
- 2 Volba platformy vhodné pro zvolený způsob řešení
 - Bude CPU dostačující? Je úloha vhodná pro akcelerátory?
 - Kolik paměti je třeba?
- 3 Návrh a implementace řešení pro zvolenou platformu
 - Rozdělení úlohy mezi výpočetní jednotky
 - Volba/Návrh konkrétních algoritmů
- 4 Optimalizace implementovaného řešení
 - Hledání kritických míst v programu
 - Analýza využití HW prostředků
 - Modifikace implementace pro zlepšení využití HW

- Většina problémů má více možných formulací a přístupů k řešení (algoritmů)


- Většina problémů má více možných formulací a přístupů k řešení (algoritmů)
- Např.: Nalezení minima v poli
 - Porovnání doposud nejmenšího prvku s následujícími
 - Seřazení celého pole a výběr prvního prvku

- Většina problémů má více možných formulací a přístupů k řešení (algoritmů)
- Základním ukazatelem je **asymptotická složitost** algoritmu
 - Obvykle uvažujeme **časovou**, lze ale určit i **paměťovou**
 - Značíme $\mathcal{O}(n)$, kde n je počet vstupních prvků
 - Funkce vyjadřující počet nutných operací pro vstup délky n

- Většina problémů má více možných formulací a přístupů k řešení (algoritmů)
- Základním ukazatelem je **asymptotická složitost** algoritmu
 - Obvykle uvažujeme **časovou**, lze ale určit i **paměťovou**
 - Značíme $\mathcal{O}(n)$, kde n je počet vstupních prvků
 - Funkce vyjadřující počet nutných operací pro vstup délky n
- Je třeba pamatovat na vlastnosti zvolené platformy!
 - Obsahuje více-jádrový procesor?
 - Obsahuje GPU?

- Bogosort

- $T_{\text{worst}}: \infty$
- $T_{\text{avg}}: \mathcal{O}((n+1)!)$
- $S_{\text{worst}}: \mathcal{O}(n)$



- Bogosort

- $T_{\text{worst}}: \infty$
- $T_{\text{avg}}: \mathcal{O}((n+1)!)$
- $S_{\text{worst}}: \mathcal{O}(n)$

- Bubble-Sort

- $T_{\text{worst}}: \mathcal{O}(n^2)$
- $T_{\text{avg}}: \mathcal{O}(n^2)$
- $S_{\text{worst}}: \mathcal{O}(1)$

6	1	2	3	4	5
---	---	---	---	---	---

unsorted

6	1	2	3	4	5
---	---	---	---	---	---

6 > 1, swap

1	6	2	3	4	5
---	---	---	---	---	---

6 > 2, swap

1	2	6	3	4	5
---	---	---	---	---	---

6 > 3, swap

1	2	3	6	4	5
---	---	---	---	---	---

6 > 4, swap

1	2	3	4	6	5
---	---	---	---	---	---

6 > 5, swap

1	2	3	4	5	6
---	---	---	---	---	---

1 < 2, ok

1	2	3	4	5	6
---	---	---	---	---	---

2 < 3, ok

1	2	3	4	5	6
---	---	---	---	---	---

3 < 4, ok

1	2	3	4	5	6
---	---	---	---	---	---

4 < 5, ok

1	2	3	4	5	6
---	---	---	---	---	---

sorted

- Bogosort


- $T_{\text{worst}}: \infty$
- $T_{\text{avg}}: \mathcal{O}((n+1)!)$
- $S_{\text{worst}}: \mathcal{O}(n)$

- Bubble-Sort

- $T_{\text{worst}}: \mathcal{O}(n^2)$
- $T_{\text{avg}}: \mathcal{O}(n^2)$
- $S_{\text{worst}}: \mathcal{O}(1)$

- Quick-Sort

- $T_{\text{worst}}: \mathcal{O}(n^2)$
- $T_{\text{avg}}: \mathcal{O}(n \log n)$
- $S_{\text{worst}}: \mathcal{O}(\log n)$



- Bogosort

- $T_{\text{worst}}: \infty$
- $T_{\text{avg}}: \mathcal{O}((n+1)!)$
- $S_{\text{worst}}: \mathcal{O}(n)$

- Bubble-Sort


- $T_{\text{worst}}: \mathcal{O}(n^2)$
- $T_{\text{avg}}: \mathcal{O}(n^2)$
- $S_{\text{worst}}: \mathcal{O}(1)$

- Quick-Sort

- $T_{\text{worst}}: \mathcal{O}(n^2)$
- $T_{\text{avg}}: \mathcal{O}(n \log n)$
- $S_{\text{worst}}: \mathcal{O}(\log n)$

- Merge-Sort

- $T_{\text{worst}}: \mathcal{O}(n \log n)$
- $T_{\text{avg}}: \mathcal{O}(n \log n)$
- $S_{\text{worst}}: \mathcal{O}(n)$



- Bogosort

- $T_{\text{worst}}: \infty$
- $T_{\text{avg}}: \mathcal{O}((n+1)!)$
- $S_{\text{worst}}: \mathcal{O}(n)$

- Bubble-Sort


- $T_{\text{worst}}: \mathcal{O}(n^2)$
- $T_{\text{avg}}: \mathcal{O}(n^2)$
- $S_{\text{worst}}: \mathcal{O}(1)$

- Quick-Sort



- $T_{\text{worst}}: \mathcal{O}(n^2)$
- $T_{\text{avg}}: \mathcal{O}(n \log n)$
- $S_{\text{worst}}: \mathcal{O}(\log n)$

- Merge-Sort

- $T_{\text{worst}}: \mathcal{O}(n \log n)$
- $T_{\text{avg}}: \mathcal{O}(n \log n)$
- $S_{\text{worst}}: \mathcal{O}(n)$




- Zvyšování pracovní frekvence
 - Limitováno příkonem: $P = C_L (U_{dd}^2 / 2) f_{clk} SW$
 - Pracovní napětí U_{dd} roste s frekvencí f_{clk}




- Rozšiřování úrovně paralelismu
 - Na úrovni instrukcí (super-skalární architektury – IPC)
 - Na úrovni dat (SIMD – MMX, SSE, AVX)
 - Na úrovni vláken (SMT) a jader (MIMD)


- Skrytý paralelismus




- Skrytý paralelismus
 - Lze rozpracovat až 5 instrukcí v cyklu




- Skrytý paralelismus
 - Lze rozpracovat až 5 instrukcí v cyklu
 - Až 224 rozpracovaných μ -operací
 - 7 paralelně pracujících jednotek
- Nelze donekonečna




- Jak nejlépe využít stále rostoucí počet tranzistorů?



- Explicitní paralelismus
 - SMT (Hyper-threading)
 - Vektorové operace (SIMD)




SIMD Mode



Scalar Mode



- Explicitní paralelismus
 - SMT (Hyper-threading)
 - Vektorové operace (SIMD)
 - Více jader se sdílenou pamětí (MIMD)



- Mobilní CPU
 - Obvykle 64-bit ARM architektura
 - až 8 jader/vláken (často 4+4)
 - až 2.5 GHz
 - Cache: 2 MB L2 cache (bez L3)
- Desktop CPU
 - Nejčastěji 64-bit x86 architektura
 - až 10 jader (20 vláken)
 - až 4.0 GHz
 - Cache: 256 KB/jádro L2 + 25 MB L3
- Server/Cluster CPU
 - Nejčastěji 64-bit x86 architektura
 - až 32 jader (64 vláken)
 - až 2.8 GHz
 - Cache: 512 KB/jádro L2 + 64 MB L3


- Optimalizace sekvenčního programu (1 vlákno)
- Primárně využívat schopností překladače
 - Přepínače jako: `-O3`, `-march=native`, `-msseX`, `-mavxX`
- Pozor na “premature optimization”
 - Nejdříve profilovat, pak optimalizovat (kde je třeba)
- Asembler a “intrinsic funkce”
 - Jen v krajních případech – znemožňují přenositelnost kódu


- Na základě běhu, nebo simulace běhu aplikace umožňuje vyhodnotit vlastnosti jednotlivých částí kódu
- Mezi takto získaná data patří
 - Počet provedených instrukcí (a rozdělení do kategorií)
 - Počet instrukcí vykonaných během jednoho cyklu (IPC)
 - Počet vykonaných skoků a úspěšnost jejich předpovídání
 - Počet přístupů do paměti cache L1, L2, L3
 - Úspěšnost hledání dat v pamětech cache (hit/miss ratio)
- Pomocí těchto informací lze určit jak dobře je daný procesor využíván
- Cílem je nalézt části aplikace, které vykazují nízkou efektivitu (a odhalit příčinu)


- Simulací provádění programu umí získat:
 - Informace o počtu provedených instrukcí

```
> valgrind --tool=callgrind <cesta-k-bin>
```
 - Informace o práci s pamětí cache

```
> valgrind --tool=cachegrind <cesta-k-bin>
```
- Výstup (soubor `callgrind.out.<PID>`) lze zobrazit nástrojem KCachegrind
- Velkou nevýhodou je nízká rychlost simulace









- Přístup do paměti (a tedy efektivní využití cache) významně ovlivňuje rychlost programu
- V profilovacích nástrojích obvykle vyjádřeno jako “Cache-Hit” a “Cache-Miss”
- Vliv modifikace každé K-té hodnoty:

```
for(int i = 0; i < LENGTH; i += K)  
    arr[i] *= 3
```



- Přístup do paměti (a tedy efektivní využití cache) významně ovlivňuje rychlost programu
- V profilovacích nástrojích obvykle vyjádřeno jako “Cache-Hit” a “Cache-Miss”
- Vliv velikosti paměti cache:

```
for(int i = 0; i < STEPS; i++)  
    arr[i % (SIZE - 1)]++;
```



- Umožňuje využít vektorové instrukce CPU (SIMD)
 - MMX, SSE, SSE2, AVX, AVX2, AVX-512, ...
- Často ji dokáže provést překladač (ICC, GCC, ...)
- V ostatních případech je nutné “napovědět” překladači pomocí direktiv
 - Nejlépe pomocí OpenMP 4.0+ (`#pragma omp simd ...`)
 - Nebo specializovaných pro daný překladač
 - Je třeba dávat pozor na závislosti v datech
- Příklad direktiv OpenMP
 - Sečtení polí “a” a “b”

```
for(int i = 0; i < N; ++i)
    c[i] = a[i] + b[i];
```
 - Suma pole “arr”

```
for(int i = 0; i < N; ++i)
    s += arr[i];
```





- Umožňuje využít vektorové instrukce CPU (SIMD)
 - MMX, SSE, SSE2, AVX, AVX2, AVX-512, ...
- Často ji dokáže provést překladač (ICC, GCC, ...)
- V ostatních případech je nutné “napovědět” překladači pomocí direktiv
 - Nejlépe pomocí OpenMP 4.0+ (`#pragma omp simd ...`)
 - Nebo specializovaných pro daný překladač
 - Je třeba dávat pozor na závislosti v datech
- Příklad direktiv OpenMP
 - Sečtení polí “a” a “b”

```
#pragma omp simd aligned(a,b,c:16)
for(int i = 0; i < N; ++i)
    c[i] = a[i] + b[i];
```


- Suma pole “arr”

```
#pragma omp simd reduction(+:s)
for(int i = 0; i < N; ++i)
    s += arr[i];
```



- Rozdělení výpočtu na více částí
- Minimalizace závislostí a komunikace mezi částmi
- Výpočet nad každou částí zvlášť



- Vykonání **stejně** operace nad velkým množstvím dat
- Data lze snadno rozdělit mezi vlákna a zpracovávat paralelně
- Paralelizace omezená množstvím dat




- Vykonání několika **různých** operací nad nějakou množinou dat (mohou ale nemusí být sdílené)
- Každé vlákno může vykonávat jinou úlohu
- Paralelizace omezená počtem **nezávislých** úloh



- **Amdahlův zákon** umožňuje určit maximální dosažitelné zrychlení S úlohy, pro kterou platí:
 - Její část αW lze provádět jediňě sekvenčně (1 CPU)
 - Část $(1 - \alpha)W$ lze provádět paralelně (P CPU)

Amdahlův zákon


$$S(P) = \frac{T_s}{T(P)} = \frac{W/R}{W(\frac{\alpha}{R} + \frac{1-\alpha}{PR})} = \frac{P}{1+\alpha(P-1)}$$



- Amdahlův zákon předpokládá pevnou velikost řešené úlohy, maximální zrychlení je tedy limitováno sekvenční částí
- Gustafsonův zákon předpokládá, že velikost úlohy roste (lineárně) s počtem CPU
 - α_G udává část doby, kdy pracoval pouze 1 CPU

Gustafsonův zákon

$$S(P) = P - \alpha_G(P - 1)$$



- Vlákna
 - Primitiva operačního systému reprezentující 1 tok instrukcí
 - Uvnitř 1 procesu, sdílejí paměťový prostor
 - OpenMP
- Procesy
 - Primitiva operačního systému
 - Odělený paměťový prostor s možností využít sdílenou paměť
 - Rychlost vytvoření a přepínání procesů je nižší než v případě vláken
 - OpenMPI (komunikace přes sdílenou paměť)
- Počítače
 - Procesy běžící na fyzicky odělených strojích
 - Fyzicky odělené paměti (nelze efektivně sdílet)
 - OpenMPI (komunikace přes síť)

- Standardizované rozšíření jazyků C/C++ o direktivy pro práci s vláknovým paralelismem
 - Podpora pro datový i úlohový paralelismus
 - Definuje chování proměnných ve vztahu k vláknům
 - Definuje synchronizační a atomická primitiva
 - Standard tvořen direktivami tvaru `#pragma omp ...` a funkcemi v hlavičkovém souboru `"omp.h"`

- Standardizované rozšíření jazyků C/C++ o direktivy pro práci s vláknovým paralelismem
 - Podpora pro datový i úlohový paralelismus
 - Definuje chování proměnných ve vztahu k vláknům
 - Definuje synchronizační a atomická primitiva
 - Standard tvořen direktivami tvaru `#pragma omp ...` a funkcemi v hlavičkovém souboru `"omp.h"`
- Paralelní region

```
#pragma omp parallel  
{  
    // Tento kód vykoná N vláken  
}
```

- Standardizované rozšíření jazyků C/C++ o direktivy pro práci s vláknovým paralelismem
 - Podpora pro datový i úlohový paralelismus
 - Definuje chování proměnných ve vztahu k vláknům
 - Definuje synchronizační a atomická primitiva
 - Standard tvořen direktivami tvaru `#pragma omp ...` a funkcemi v hlavičkovém souboru "omp.h"
- Jednoduchá paralelizace smyčky

```
#pragma omp parallel for  
for(int i = 0; i < N; ++i)  
    c[i] = a[i] + b[i];
```


- Standardizované rozšíření jazyků C/C++ o direktivy pro práci s vláknovým paralelismem
 - Podpora pro datový i úlohový paralelismus
 - Definuje chování proměnných ve vztahu k vláknům
 - Definuje synchronizační a atomická primitiva
 - Standard tvořen direktivami tvaru `#pragma omp ...` a funkcemi v hlavičkovém souboru `"omp.h"`
- Úlohový paralelismus

```
#pragma omp parallel sections
{
    #pragma omp section
    { // Tento kód vykoná vlákno A
    }


    #pragma omp section
    { // Tento kód vykoná vlákno B
    }
}
```

- Knihovna se standardizovaným rozhraním pro komunikaci a synchronizaci procesů (s odděleným paměťovým prostorem)
 - Model komunikace založený na zasílání zpráv
 - Komunikace přes sdílenou paměť, nebo síť

- Knihovna se standardizovaným rozhraním pro komunikaci a synchronizaci procesů (s odděleným paměťovým prostorem)
 - Model komunikace založený na zasílání zpráv
 - Komunikace přes sdílenou paměť, nebo síť



- Knihovna se standardizovaným rozhraním pro komunikaci a synchronizaci procesů (s odděleným paměťovým prostorem)
 - Model komunikace založený na zasílání zpráv
 - Komunikace přes sdílenou paměť, nebo síť



ivaverka@fit.vutbr.cz