

# Vektorové instrukce

---

3. dubna 2019

B4B36PDV – Paralelní a distribuované výpočty

# Osnova

- Opakování z minulého cvičení
- Autovektorizace
- Ruční vektorizace pomocí intrinsics

## Opakování z minulého cvičení

---

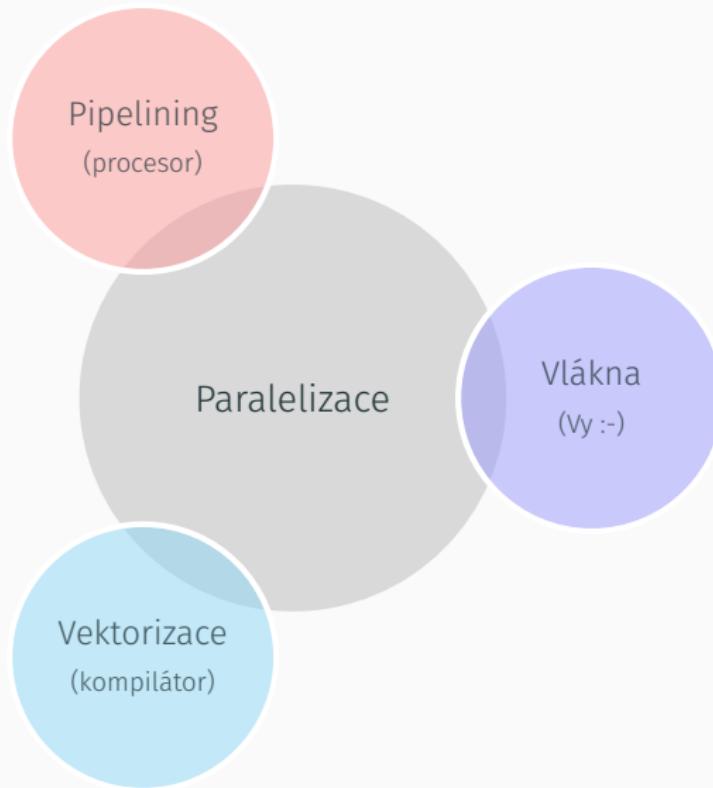
<http://goo.gl/a6BEMb>

Jakým způsobem bude následující kód proveden?

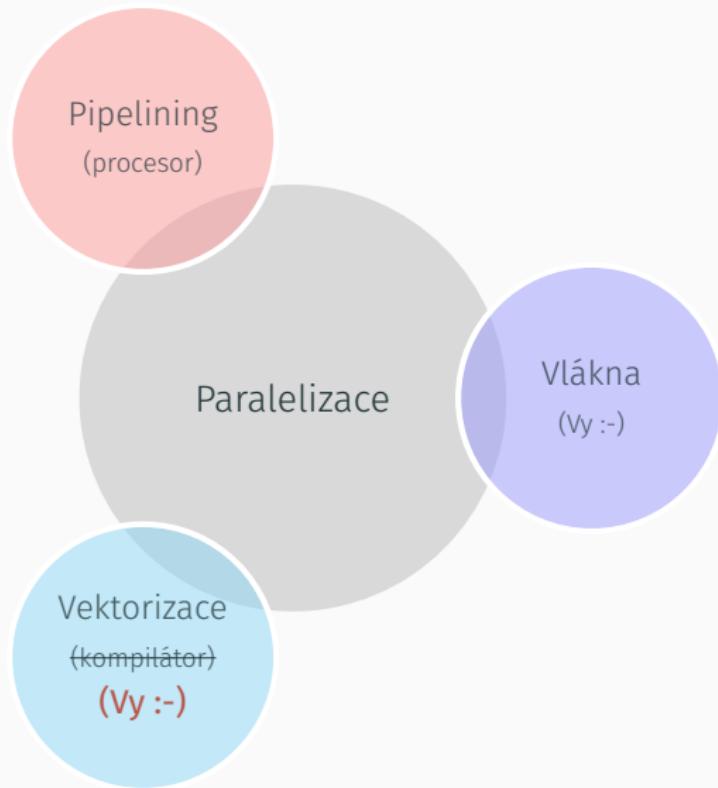
```
bool mat[M][N];
for(int i = 0; i < M; i++) {
    #pragma omp parallel
    #pragma omp for
    for(int j = 0; j < N; j++){
        #pragma omp cancellation point for
        if (mat[i][j]){
            #pragma omp cancel for
        }
    }
}
std::cout << "Finished!" << std::endl;
```

- Výpočet končí okamžitě po nalezení prvního řešení.
- Po nalezení prvního řešení výpočet skončí, až všechna vlákna narazí na 'cancellation point'.
- Ani jedna z předchozích odpovědí není správná.

# Moderní procesor



# Moderní procesor



# Skalární zpracování dat

**float**  $x =$

**float**  $y =$

---

(**float**)  $x + y =$

# Vektorové zpracování dat

`_m256 x =`

0.5f	0.2f	0.6f	0.0f	1.5f	1.3f	2.5f	0.3f
------	------	------	------	------	------	------	------

`_m256 y =`

1.2f	1.8f	0.2f	0.0f	1.2f	0.3f	2.4f	0.3f
------	------	------	------	------	------	------	------

---

`(_m256) _mm256_add_ps(x, y) =`

1.7f	2.0f	0.8f	0.0f	2.7f	1.6f	4.9f	0.6f
------	------	------	------	------	------	------	------

## Vektorové zpracování dat

$$\text{--m256 } x = \boxed{0.5f \quad 0.2f \quad 0.6f \quad 0.0f \quad 1.5f \quad 1.3f \quad 2.5f \quad 0.3f}$$

$$\text{--m256 } y = \boxed{1.2f \quad 1.8f \quad 0.2f \quad 0.0f \quad 1.2f \quad 0.3f \quad 2.4f \quad 0.3f}$$

---

$$(\text{--m256}) \text{ mm256_add_ps}(x, y) = \boxed{1.7f \quad 2.0f \quad 0.8f \quad 0.0f \quad 2.7f \quad 1.6f \quad 4.9f \quad 0.6f}$$

Není to až taková magie, jak to vypadá :-)

## Vektorové zpracování dat (pomocí AVX / AVX2)

```
#include <immintrin.h>
```

- `__m256` - datový typ „vektor délky 256 bitů“  
(`float` má 32 bitů, a proto se do takového vektoru vejde 8x)

# Vektorové zpracování dat (pomocí AVX / AVX2)

```
#include <immintrin.h>
```

- `__m256` - datový typ „vektor délky 256 bitů“  
(`float` má 32 bitů, a proto se do takového vektoru vejde 8x)
- `_mm256_add_ps(x,y)`
  - Nad dvěma 256-bitovými vektory `x` a `y`... (`_mm256_`)
  - ...provádím operaci sčítání... (`add`)
  - ...při čemž vektory obsahují elementy typu *packed-single* (`_ps`).

# Vektorové zpracování dat (pomocí AVX / AVX2)

```
#include <immintrin.h>
```

- `__m256` - datový typ „vektor délky 256 bitů“  
(`float` má 32 bitů, a proto se do takového vektoru vejde 8x)
- `_mm256_add_ps(x,y)`
  - Nad dvěma 256-bitovými vektory `x` a `y`... (`_mm256_`)
  - ...provádí operaci sčítání... (`add`)
  - ...při čemž vektory obsahují elementy typu *packed-single* (`_ps`).
- *packed* – vektor „zabaluje“ více prvků stejného typu
- *single* – *single-precision number* aka `float`

Level 1: Autovektorizace GCC 

Moderní kompilátor se snaží zdetektovat **for** smyčky, které lze vektorizovat...

Například:

```
float a[1024], b[1024], c[1024];
for(int i = 0 ; i < 1024 ; i++) {
    a[i] = b[i] + c[i];
}
```

lze převést na

```
for(int i = 0 ; i < 1024 ; i += 8) {
    _mm256_storeu_ps(&a[i],
                      _mm256_add_ps(
                          _mm256_loadu_ps(&b[i]),
                          _mm256_loadu_ps(&c[i]))
    );
}
```

## Vyzkoušejte si autovektorizaci GCC

Zkomplilujte soubor **autovec.cpp** s parametry komplikace:

1. **-std=c++11 -march=native -O2 a**
2. **-std=c++11 -march=native -O2 -ftree-vectorize**

Jak se program zrychlí, pokud použijete autovektorizaci  
**(-ftree-vectorize)**?

Můžete si i vyzkoušet použití parametru **-fopt-info-vec-all** (detailní výstup o proběhlé vektorizaci).

- + Je to „zadarmo“ (kompilátor se pokusí vektorizaci provést za Vás)

- + Je to „zadarmo“ (kompilátor se pokusí vektorizaci provést za Vás)
- Ne vždy se to kompilátoru musí povést...

- + Je to „zadarmo“ (kompilátor se pokusí vektorizaci provést za Vás)
- Ne vždy se to komplilátoru musí povést...
  - Kompilátor vám nemusí „rozumět“  
(často dokáže vektorizovat jenom smyčky v určitém tvaru)

- + Je to „zadarmo“ (kompilátor se pokusí vektorizaci provést za Vás)
- Ne vždy se to komplilátoru musí povést...
  - Kompilátor vám nemusí „rozumět“  
(často dokáže vektorizovat jenom smyčky v určitém tvaru)
  - Kompilátor musí zajistit, že výsledek programu bude identický, jako kdyby nevektorizoval **i za těch nejhorších možných podmínek**
    - Musí uvažovat, že může dojít k datovým závislostem
    - Musí zajistit, že dojde ke stejnému zaokrouhlení při floating-point operacích

- + Je to „zadarmo“ (kompilátor se pokusí vektorizaci provést za Vás)
  - Ne vždy se to komplilátoru musí povést...
    - Kompilátor vám nemusí „rozumět“ (často dokáže vektorizovat jenom smyčky v určitém tvaru)
    - Kompilátor musí zajistit, že výsledek programu bude identický, jako kdyby nevektorizoval i za těch nejhorších možných podmínek
      - Musí uvažovat, že může dojít k datovým závislostem
      - Musí zajistit, že dojde ke stejnému zaokrouhlení při floating-point operacích
- 

```
float x;
float y1 = x * x * x * x * x * x * x * x * x;

float y2 = x * x;
y2 = y2 * y2;
y2 = y2 * y2;

assert(y1 == y2);
```

Level 2: Intel SPMD Compiler (a jiné) 

Tušíte co znamená zkratka SPMD?

Tušíte co znamená zkratka SPMD?

---

**SPMD = *single-program multiple-data***

Napíšete jeden program, který ale pomocí vektorizace poběží na více daty současně. Kompilátor za vás rozhodne, jak má vektorizace proběhnout.

## Intel SPMD Compiler (ISPC)

- Nadstavba jazyka C
- Od základu uvažuje o programu jako o paralelním!

## Intel SPMD Compiler (ISPC)

- Nadstavba jazyka C
- Od základu uvažuje o programu jako o paralelním!

Bohužel nemáme čas se ISPC na PDV věnovat :-(

Level 3: Intrinsics



**Intrinsics** – Funkce a datové typy, které zpřístupňují nativní instrukce procesoru **bez nutnosti programovat v assembleru**

Instrukční sada: AVX / AVX2

**Intrinsics** – Funkce a datové typy, které zpřístupňují nativní instrukce procesoru **bez nutnosti programovat v assembleru**

## Instrukční sada: AVX / AVX2

<https://intel.ly/2GOHp7r> (Intel Intrinsics Guide)

Výborná reference! Využívejte, když si nebudete jistí!

```
#include <immintrin.h>
```

**A** Všechny kódy komplujte s **-march=native** !

## AVX / AVX2 intrinsics

Datový typ vektor: `__m256...`

- `__m256` – vektor obsahující 8 x 32bit `float`
- `__m256d` – vektor obsahující 4 x 64bit `double`
- `__m256i` – vektor obsahující celočíselné typy

Načtení a zápis 256 bitů (8 x 32bit `float`) z/do adresy `float * x`:

```
__m256 data = _mm256_loadu_ps(x);
_mm256_storeu_ps(x, data);
```

## AVX / AVX2 intrinsics

Datový typ vektor: `__m256...`

- `__m256` – vektor obsahující 8 x 32bit `float`
- `__m256d` – vektor obsahující 4 x 64bit `double`
- `__m256i` – vektor obsahující celočíselné typy

Načtení a zápis 256 bitů (8 x 32bit `float`) z/do adresy `float * x`:

```
__m256 data = _mm256_loadu_ps(x);
_mm256_storeu_ps(x, data);
```

**Doimplementujte načtení a zápis dat do metody `normaldist_vec(...)`**

Do těla `for` smyčky v metodě `normaldist_vec(...)` v souboru `prob.cpp` doimplementujte načtení a zpětný zápis `__m256` vektoru z adresy `&data[i]`.

Načítat a ukládat stejná data je nuda...

### Doimplementujte výpočet hustoty normálního rozdělení

Pro každý prvek načteného vektoru spočtěte hodnotu funkce

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

`__m256 _mm256_set1_ps(x)`

Nastaví všechny prvky vektoru na x

`__m256 _mm256_add_ps(x, y), __m256 _mm256_sub_ps(x, y)`

`__m256 _mm256_mul_ps(x, y), __m256 _mm256_div_ps(x, y)`

Vypočte součet, rozdíl, součin a podíl vektorů x a y

---

Pro aproximaci  $\exp(x)$  (vektorově) použijte `__m256 exp_vec(x)`

$$\exp(x) \approx \frac{(x + 3)^2 + 3}{(x - 3)^2 + 3} \quad (2, 2)\text{-Padé approximátor}$$

## Podmíněné zpracování

Občas chceme zpracovat různé prvky různým způsobem...

```
size_t half = N / 2;
for(unsigned int i = 0 ; i < half ; i++) {
    if(data[i] > data[i+half])
        std::swap(data[i], data[i+half]);
}
```

## Podmíněné zpracování

Občas chceme zpracovat různé prvky různým způsobem...

```
size_t half = N / 2;  
for(unsigned int i = 0 ; i < half ; i++) {  
    if(data[i] > data[i+half])  
        std::swap(data[i], data[i+half]);  
}
```

---

`_mm256_mm256_blendv_ps(x, y, mask):`

`_mm256 x =` 

0.5f	0.2f	0.6f	0.0f	1.5f	1.3f	2.5f	0.3f
------	------	------	------	------	------	------	------

`_mm256 y =` 

1.2f	1.8f	0.2f	0.0f	1.2f	0.3f	2.4f	0.3f
------	------	------	------	------	------	------	------

`_mm256 mask =` 

1	0	0	1	1	1	0	0
---	---	---	---	---	---	---	---

---

`_mm256_blendv_ps(x, y, mask) =` 

1.2f	0.2f	0.6f	0.0f	1.2f	0.3f	2.5f	0.3f
------	------	------	------	------	------	------	------

## Doimplementujte tělo metody **condswap\_vec(...)**

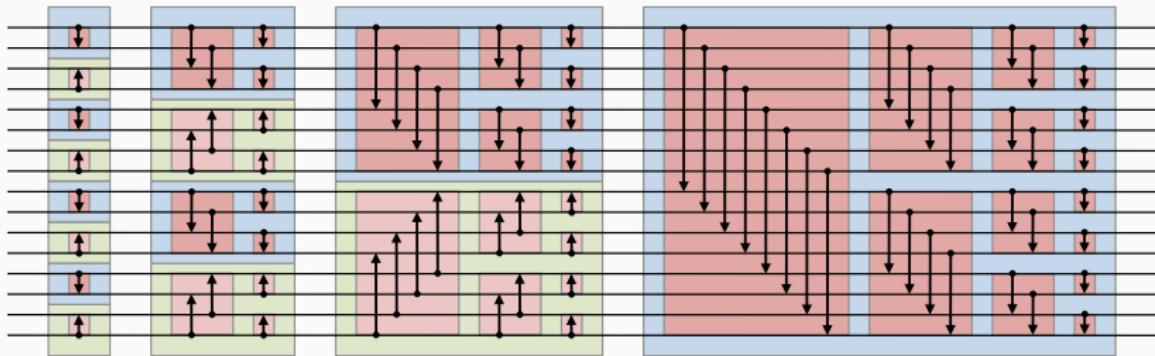
Doimplementujte tělo metody **condswap\_vec(...)** v souboru **cond.cpp**, která bude vektorově vykonávat následující kód

```
size_t half = N / 2;
for(unsigned int i = 0 ; i < half ; i++) {
    if(data[i] > data[i+half])
        std::swap(data[i], data[i+half]);
}
```

Pro implementaci podmínky využijte **\_mm256\_blendv\_ps(x,y,mask)**.

Vektorová instrukce pro porovnání vektorů  $x < y$  typu *packed-single*:  
**\_mm256\_cmp\_ps(x, y, \_CMP\_LT\_OQ)**

# Bitonic sort



## Bitové operace

S primitivními vektorovými instrukcemi jste se setkali už dříve!

například  $x \& y$  nebo  $x ^ y$

## Bitové operace

S primitivními vektorovými instrukcemi jste se setkali už dříve!

například  $x \& y$  nebo  $x ^ y$

My se podíváme na něco zajímavějšího...

## Bitové operace

```
_lzcnt_u64(uint64_t x)  
_tzcnt_u64(uint64_t x)
```

Počet *leading*, resp. *trailing zeros* v čísle x

Například:

```
_lzcnt_u64(0b00001000 ... 00011100) = 4
```

```
_tzcnt_u64(0b00001000 ... 00011100) = 2
```

## Bitové operace

```
_lzcnt_u64(uint64_t x)  
_tzcnt_u64(uint64_t x)
```

Počet *leading*, resp. *trailing* zeros v čísle x

Například:

```
_lzcnt_u64(0b00001000 ... 00011100) = 4
```

```
_tzcnt_u64(0b00001000 ... 00011100) = 2
```

**Doimplementujte tělo metody log2\_lzcnt(...)**

Doimplementujte tělo metody `log2_lzcnt(...)` v souboru `lzcnt.cpp`.  
Pro  $x > 0$  má tato metoda provést výpočet ekvivalentní `(int)log2(x)`.

Tip: Jaký vztah má pozice nejvyššího jedničkového bitu k hodnotě logaritmu o základu 2?

## Bitové operace

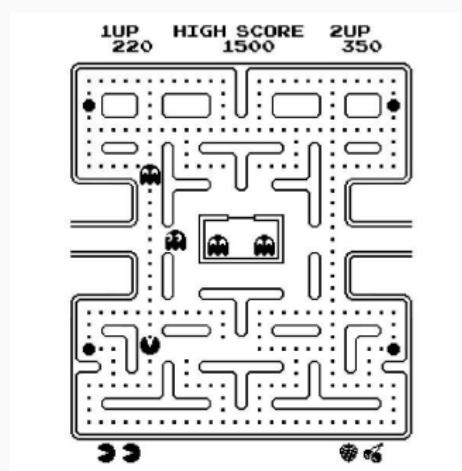
\_mm\_popcnt\_u64(**uint64\_t** x)

Počet jedničkových bitů v čísle x

## Semestrální úloha

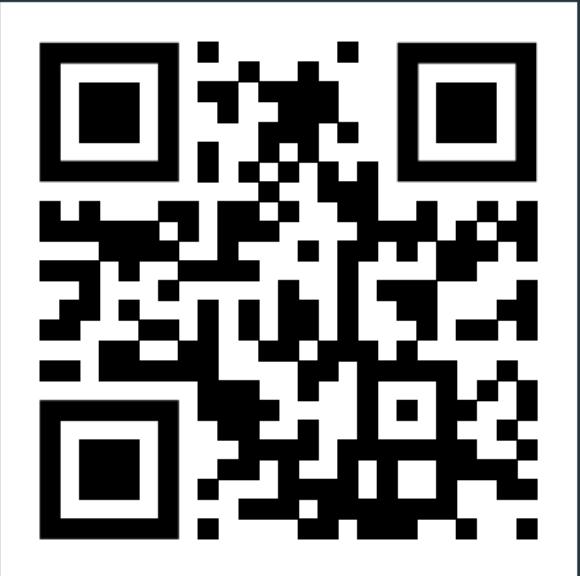
---

## Prohledávání stavového prostoru



Díky za pozornost!

Budeme rádi za Vaši  
zpětnou vazbu! →



<http://bit.ly/2FFZsdm>