

# Paralelní a distribuované výpočty (B4B36PDV)

**Branislav Bošanský, Michal Jakob**

[bosansky@fel.cvut.cz](mailto:bosansky@fel.cvut.cz)

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

# Dnešní přednáška

Motivace



# Dnešní přednáška

Motivace





# Dnešní přednáška

## Motivace



# Dnešní přednáška

Další nástroje



# Dnešní přednáška

OpenMP



<http://www.openmp.org/wp-content/uploads/openmp-4.5.pdf>

# OpenMP – úvod, spuštění

V C++11 (podporuje C,C++)

- V rámci C/C++ exportovány hlavičkou „omp.h “
  - rozšíření kompilátoru (různé kompilátory podporují různé verze OpenMP)
  - lze přistoupit pomocí #pragma omp
  - základní použití pro paralelizaci for cyklu

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

int main(int argc, char* argv[]) {
    std::cout << "Hello from the main thread\n";

    #pragma omp parallel for
    for (int i=0; i<10; i++)
        std::cout << "Item " << i << " is processed by thread" << omp_get_thread_num() << std::endl;

    return 0;
}
```

# OpenMP – úvod, spuštění

V C++11 (podporuje C,C++)

- **#pragma omp parallel for** je pouze zkratkou za


- #pragma omp parallel  
  {  
    #pragma omp for  
    for (int i=0; i<MAX; i++)  
  }

```
int main(int argc, char* argv[]) {  
  #pragma omp parallel  
  {  
    std::cout << "this is a line printed by thread" << omp_get_thread_num() << std::endl;  
  
    #pragma omp for  
    for (int i=0; i<10; i++)  
      std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;  
  
  }  
  
  std::cout << "Hello from the main thread\n";  
  
  return 0;  
}
```



# OpenMP – úvod, spuštění

V C++11 (podporuje C,C++)

- **#pragma omp parallel for** je pouze zkratkou za
  - #pragma omp parallel 
    - vytvoří tým vláken, které vykonávají blok
  - {
  - #pragma omp for
  - for (int i=0; i<MAX; i++)
  - }

```
int main(int argc, char* argv[]) {
#pragma omp parallel
{
  std::cout << "this is a line printed by thread" << omp_get_thread_num() << std::endl;

#pragma omp for
  for (int i=0; i<10; i++)
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
}

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

  return 0;
}
```

# OpenMP – úvod, spuštění

V C++11 (podporuje C,C++)

- **#pragma omp parallel for** je pouze zkratkou za
  - #pragma omp parallel ←  
{  
  #pragma omp for ←  
    for (int i=0; i<MAX; i++)  
  }  
}
  - vytvoří tým vláken, které vykonávají blok
  - vezme následující for cyklus a rozdělí jej mezi vlákna v týmu

```
int main(int argc, char* argv[]) {
#pragma omp parallel
{
  std::cout << "this is a line printed by thread" << omp_get_thread_num() << std::endl;

#pragma omp for
  for (int i=0; i<10; i++)
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
}

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

  return 0;
}
```

# OpenMP – úvod, spuštění

V C++11 (podporuje C,C++)

- **#pragma omp parallel for** je pouze zkratkou za
  - #pragma omp parallel ←
    - {
    - #pragma omp for ←
    - for (int i=0; i<MAX; i++)
    - } ←
  - vytvoří tým vláken, které vykonávají blok
  - vezme následující for cyklus a rozdělí jej mezi vlákna v týmu
  - vlákna se připojí k hlavnímu vlákně (join)

```
int main(int argc, char* argv[]) {
#pragma omp parallel
{
    std::cout << "this is a line printed by thread" << omp_get_thread_num() << std::endl;

#pragma omp for
    for (int i=0; i<10; i++)
        std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
}

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

    return 0;
}
```

# OpenMP – základní způsob práce

## Blok parallel

- **#pragma omp parallel**
  - Spustí N vláken, kde N bývá (typicky) počet jader/paralelně zpracovatelných vláken (např. 4 na 2-jádrovém CPU s HT)
  - Pokud chceme počet vláken upravit, použijeme **num\_threads(<číslo>)**

```
const int thread_count = 2;
int main(int argc, char* argv[]) {
#pragma omp parallel num_threads(thread_count)
{
    std::cout << "this is a line printed by thread" << omp_get_thread_num() << std::endl;
}

#pragma omp for
for (int i=0; i<10; i++)
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;

}

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

return 0;
}
```



# OpenMP – základní způsob práce

## Blok parallel

- **#pragma omp parallel**

- Spustí N vláken, kde N bývá (typicky) počet jader/paralelně zpracovatelných vláken (např. 4 na 2-jádrovém CPU s HT)
- Pokud chceme počet vláken upravit, použijeme **num\_threads(<číslo>)**

```
const int thread_count = 2;
int main(int argc, char* argv[]) {
#pragma omp parallel num_threads(thread_count)
{
    std::cout << "this is a line printed by thread" << omp_get_thread_num() << std::endl;

#pragma omp for
    for (int i=0; i<10; i++)
        std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
}

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

    return 0;
}
```

- vypíše se 2x

- pro jedno i se vypíše pouze jednou
- každé vlákno vypíše 5

# OpenMP – základní způsob práce

## Blok for

- Rozdělí iterace na bloky, které vlákna zpracují
  - Není garantované pořadí, ve kterém se jednotlivé iterace provedou
- Existuje několik možností pro úpravu způsobu rozvržení iterací
  - Statické (**static**) – iterace se zařadí do bloků, bloky se přiřadí vláknům (výchozí možnost; bloky jsou přibližně stejně velké)
  - Dynamické (**dynamic**) – iterace se zařadí do bloků (jejich velikost lze ovlivnit, výchozí hodnota je 1), vlákna si vždy vyžádají blok ke zpracování
  - Guided – podobně jak dynamické, ale velikost bloků se postupně zmenšuje
  - Auto – bude zvoleno automaticky
  - Runtime – lze ovlivnit za běhu nastavením proměnné v prostředí
- Pokud chceme, aby se nějaká část cyklu vykonala přesně v pořadí iterací, můžeme použít modifikátor **ordered**
- Pokud máme více vnořených cyklů, můžeme je paralelizovat použitím modifikátoru **collapse(<počet\_for\_cykklů>)**

# OpenMP – základní způsob práce

## Blok for

```
#pragma omp parallel for schedule(static) num_threads(4)
  for (int i=0; i<20; i++) {
    std::this_thread::sleep_for(std::chrono::milliseconds((i%2)*i*300));
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
  }
}
```

```
#pragma omp parallel for schedule(dynamic) num_threads(4)
  for (int i=0; i<20; i++) {
    std::this_thread::sleep_for(std::chrono::milliseconds((i%2)*i*300));
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
  }
}
```

```
#pragma omp parallel for schedule(guided) num_threads(4)
  for (int i=0; i<20; i++) {
    std::this_thread::sleep_for(std::chrono::milliseconds((i%2)*i*300));
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
  }
}
```

# OpenMP – základní způsob práce


## Blok for

```
#pragma omp parallel for schedule(static) num_threads(4)
  for (int i=0; i<20; i++) {
    std::this_thread::sleep_for(std::chrono::milliseconds((i%2)*i*300));
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
  }
}
```

```
#pragma omp parallel for schedule(dynamic) num_threads(4)
  for (int i=0; i<20; i++) {
    std::this_thread::sleep_for(std::chrono::milliseconds((i%2)*i*300));
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
  }
}
```

```
#pragma omp parallel for schedule(guided) num_threads(4)
  for (int i=0; i<20; i++) {
    std::this_thread::sleep_for(std::chrono::milliseconds((i%2)*i*300));
    std::cout << "for-loop line " << i << " printed by thread" << omp_get_thread_num() << std::endl;
  }
}
```

- Která varianta bude nejrychlejší?



<https://goo.gl/a6BEMb>



# OpenMP – základní způsob práce

## Blok sections

- Můžeme paralelizovat pouze for cykly?
  - Můžeme paralelizovat libovolné metody/úkoly.
  - Použijeme sekce (**sections**)

# OpenMP – základní způsob práce

## Blok sections

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

const int thread_count = 2;

void method(const int& i) {
    int my_rank = omp_get_thread_num();
    int thread_count = omp_get_num_threads();
    std::cout << "Hello from method " << i << " by thread " << my_rank << std::endl;
}

int main(int argc, char* argv[]) {

#pragma omp parallel num_threads(thread_count)
    {
        method(1);
#pragma omp sections
        {
#pragma omp section
            {
                method(2);
                method(3);
            }
#pragma omp section
            { method(4); }
        }
    }

    return 0;
}
```

- Můžeme paralelizovat pouze for cykly?
  - Můžeme paralelizovat libovolné metody/úkoly.
  - Použijeme sekce (**sections**)

# OpenMP – základní způsob práce

## Blok sections

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

const int thread_count = 2;

void method(const int& i) {
    int my_rank = omp_get_thread_num();
    int thread_count = omp_get_num_threads();
    std::cout << "Hello from method " << i << " by thread " << my_rank << std::endl;
}

int main(int argc, char* argv[]) {

#pragma omp parallel num_threads(thread_count)
    {
        method(1);
#pragma omp sections
        {
#pragma omp section
            {
                method(2);
                method(3);
            }
#pragma omp section
            { method(4); }
        }
    }

    return 0;
}
```

- Můžeme paralelizovat pouze for cykly?
  - Můžeme paralelizovat libovolné metody/úkoly.
  - Použijeme sekce (**sections**)

- vytvoří se tým 2 vláken
- každé vlákno vykoná method(1)
- sekce se rozdělí mezi vlákna v týmu
- každá z method(2)-(4) se vykoná pouze 1x
- method(2) a method(3) se musí vykonat sekvenčně
- 2 sekce mohou být vykonané paralelně

# OpenMP – základní způsob práce

## Blok tasks

- Můžeme paralelizovat pouze for cykly?
  - Můžeme paralelizovat libovolné metody/úkoly.
  - Použijeme úkoly (**tasks**)

```
const int thread_count = 4;

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

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



# OpenMP – základní způsob práce

## Blok tasks

- Můžeme paralelizovat pouze for cykly?
  - Můžeme paralelizovat libovolné metody/úkoly.
  - Použijeme úkoly (**tasks**)

```
const int thread_count = 4;

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

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

- vytvoří se tým 4 vláken
- pouze 1 vlákno bude vykonávat blok *single*
- (jiné) 1 vlákno bude vykonávat task Hello

# OpenMP – základní způsob práce

## Synchronizace vláken

- Můžeme vynutit čekání vláken
  - barrier
  - některé bloky (na konci) obsahují implicitní bariéru
    - parallel, sections, for, single
    - pokud chceme implicitní bariéru zrušit, použijeme nowait

# OpenMP – základní způsob práce

## Synchronizace vláken

- Můžeme vynutit čekání vláken
  - barrier
  - některé bloky (na konci) obsahují implicitní bariéru
    - parallel, sections, for, single
    - pokud chceme implicitní bariéru zrušit, použijeme nowait

```
std::mutex m;
#pragma omp parallel num_threads(2)
{
    #pragma omp single
    {
        m.lock();
        #pragma omp task
        {
            m.lock();
            Hello();
            m.unlock();
        }
    }
    Hello();
    m.unlock();
}
```

Co udělá tento kód?

<https://goo.gl/a6BEMb>



# OpenMP – základní způsob práce

## Synchronizace vláken

- Můžeme vynutit čekání vláken
  - barrier
  - některé bloky (na konci) obsahují implicitní bariéru
    - parallel, sections, for, single
    - pokud chceme implicitní bariéru zrušit, použijeme nowait

```
std::mutex m;
#pragma omp parallel num_threads(2)
{
    #pragma omp single
    {
        m.lock();
        #pragma omp task
        {
            m.lock();
            Hello();
            m.unlock();
        }
    }
    Hello();
    m.unlock();
}
```

- dojde k deadlocku, jelikož druhé vlákno, které chce zmknout **m** čeká na první vlákno, které zámek vlastní
- první vlákno čeká na ukončení druhého vlákna



# OpenMP – základní způsob práce

## Synchronizace vláken

- Můžeme vynutit čekání vláken
  - barrier
  - některé bloky (na konci) obsahují implicitní bariéru
    - parallel, sections, for, single
    - pokud chceme implicitní bariéru zrušit, použijeme nowait

```
std::mutex m;
#pragma omp parallel num_threads(2)
{
    #pragma omp single nowait
    {
        m.lock();
        #pragma omp task
        {
            m.lock();
            Hello();
            m.unlock();
        }
    }
    Hello();
    m.unlock();
}
```

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- V rámci bloku `omp parallel` můžeme určovat viditelnost proměnných
  - `shared(<proměnná1>, <proměnná2>, ...)`
    - sdílené proměnné
  - `private(<proměnná1>, <proměnná2>, ...)`
    - privátní proměnné
    - vytvoří se nenainicializovaná lokální kopie

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- V rámci bloku `omp parallel` můžeme určovat viditelnost proměnných
  - `shared(<proměnná1>, <proměnná2>, ...)`
    - sdílené proměnné
  - `private(<proměnná1>, <proměnná2>, ...)`
    - privátní proměnné
    - vytvoří se nenainicializovaná lokální kopie

```
const int thread_count = 2;
int main(int argc, char* argv[]) {
    int a = 42, b = 1;
    #pragma omp parallel num_threads(thread_count) shared(a) private(b)
    {
        b = omp_get_thread_num()+b+2;
        #pragma omp critical
        {
            a = a / b;
            std::cout << "Variable 'b' = " << b << " by thread " << (omp_get_thread_num()) << std::endl;
            std::cout << "Variable 'a' = " << a << " by thread " << (omp_get_thread_num()) << std::endl;
        }
    }
    std::cout << "Variable 'a' = " << a << " after omp " << std::endl;
    std::cout << "Variable 'b' = " << b << " after omp " << std::endl;
    return 0;
}
```

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- V rámci bloku `omp parallel` můžeme určovat viditelnost proměnných
  - `firstprivate(<proměnná1>, <proměnná2>, ...)`
    - lokální kopie proměnné se nainicializuje dle původní hodnoty

```
const int thread_count = 2;
int main(int argc, char* argv[]) {
    int a = 42, b = 1;
    #pragma omp parallel num_threads(thread_count) shared(a) firstprivate(b)
    {
        b = omp_get_thread_num()+b+2;
        #pragma omp critical
        {
            a = a / b;
            std::cout << "Variable 'b' = " << b << " by thread " << (omp_get_thread_num()) << std::endl;
            std::cout << "Variable 'a' = " << a << " by thread " << (omp_get_thread_num()) << std::endl;
        }
    }
    std::cout << "Variable 'a' = " << a << " after omp " << std::endl;
    std::cout << "Variable 'b' = " << b << " after omp " << std::endl;
    return 0;
}
```

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- V rámci OpenMP můžeme využít známých technik pro synchronizaci přístupu k sdíleným proměnným
  - kritické sekce - `#pragma omp critical([<název_sekce>])`
    - pouze 1 vlákno může být v kritické sekci
  - zámky
    - existuje `omp_lock_t`
    - lze použít standardní (C++11) mutexy
  - atomické operace
    - `#pragma omp atomic`
  - `flush(<proměnná1>, ...)`
    - zabezpečí synchronizaci sdílených proměnných
    - před každým čtením, po každém zápise
    - pomalé z důvodu zabezpečení konzistence

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- pro agregaci výsledků lze použít **reduction variable**
  - **#pragma omp parallel reduction(<operace>:<proměnná>)**
  - přístup ke sdílené proměnné
  - zabezpečí atomickou exekuci, nicméně pouze jedné předem definované operace
  - vhodné pro agregaci parciálních výsledků dílčích úkolů

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- pro agregaci výsledků lze použít **reduction variable**
  - **#pragma omp parallel reduction(<operace>:<proměnná>)**
  - přístup ke sdílené proměnné
  - zabezpečí atomickou exekuci, nicméně pouze jedné předem definované operace
  - vhodné pro agregaci parciálních výsledků dílčích úkolů

```
long x=0;
#pragma omp parallel for num_threads(thread_count) reduction(+:x)
for (int i=0; i<SIZE; i++) {
    x += vector_to_sum[i];
}
```

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- pro agregaci výsledků lze použít **reduction variable**
  - `#pragma omp parallel reduction(<operace>:<proměnná>)`
  - přístup ke sdílené proměnné
  - zabezpečí atomickou exekuci, nicméně pouze jedné předem definované operace
  - vhodné pro agregaci parciálních výsledků dílčích úkolů

```
long x=0;
#pragma omp parallel for num_threads(thread_count) reduction(+:x)
for (int i=0; i<SIZE; i++) {
    x += vector_to_sum[i];
}
```

- vytvoří lokální kopii proměnné
- na konci použije definovanou operaci pro sjednocení parciálních výsledků ze všech vláken



# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- pro agregaci výsledků lze použít **reduction variable**
  - co když chceme agregovat výsledky v poli (případně v jiné datové struktuře)
  - můžeme si definovat vlastní operace redukce
    - `#pragma omp declare reduction(name:type:expression) initializer(expression)`
    - např. se může hodit agregace (suma) čísel ve vektoru

```
#pragma omp declare reduction(vec_int_plus : std::vector<int> : \  
    std::transform(omp_out.begin(), omp_out.end(), omp_in.begin(), omp_out.begin(), std::plus<int>())) \  
    initializer(omp_priv = omp_orig)
```

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- pro agregaci výsledků lze použít **reduction variable**
  - co když chceme agregovat výsledky v poli (případně v jiné datové struktuře)
  - můžeme si definovat vlastní operace redukce
    - `#pragma omp declare reduction(name:type:expression) initializer(expression)`
    - např. se může hodit agregace (suma) čísel ve vektoru

```
#pragma omp declare reduction(vec_int_plus : std::vector<int> : \  
std::transform(omp_out.begin(), omp_out.end(), omp_in.begin(), omp_out.begin(), std::plus<int>())) \  
initializer(omp_priv = omp_orig)
```

výslední (výstupní) proměnná

lokální kopie proměnné (vstupní z hlediska redukce)

# OpenMP – přístup k proměnným

## Privátní a sdílené proměnné

- pro agregaci výsledků lze použít **reduction variable**
  - co když chceme agregovat výsledky v poli (případně v jiné datové struktuře)
  - můžeme si definovat vlastní operace redukce
    - `#pragma omp declare reduction(name:type:expression) initializer(expression)`
    - např. se může hodit agregace (suma) čísel ve vektoru

```
#pragma omp declare reduction(vec_int_plus : std::vector<int> : \  
    std::transform(omp_out.begin(), omp_out.end(), omp_in.begin(), omp_out.begin(), std::plus<int>())) \  
    initializer(omp_priv = omp_orig)
```

výslední (výstupní) proměnná

lokální kopie proměnné (vstupní z hlediska redukce)

inicializace výstupní proměnné

původní hodnota proměnné, na kterou aplikujeme redukci

# OpenMP – histogram

```
long nlocks(std::vector<int>& vector, std::vector<int>& histogram) {
    int j;
    #pragma omp parallel for private(j) shared(vector,histogram) num_threads(thread_count)
    for (int i=0; i<SIZE; i++) {
        j = vector[i] % PARTS;
        histogram[j]++;
    }
}
```

```
long local_locks(std::vector<int>& vector, std::vector<int>& histogram) {
    int j;
    #pragma omp parallel for private(j) shared(vector,histogram) num_threads(thread_count)
    for (int i=0; i<SIZE; i++) {
        j = vector[i] % PARTS;
        hist_part_mutex[j].lock();
        histogram[j]++;
        hist_part_mutex[j].unlock();
    }
}
```

# OpenMP – histogram

```
long local_atomic(std::vector<int>& vector, std::vector<int>& histogram) {
    int j;
    #pragma omp parallel for private(j) shared(vector, histogram) num_threads(thread_count)
    for (int i=0; i<SIZE; i++) {
        j = vector[i] % PARTS;
        #pragma omp atomic
        histogram[j]++;
    }
}
```

```
long local_reduction(std::vector<int>& vector, std::vector<int>& histogram) {
    #pragma omp declare reduction(vec_int_plus : std::vector<int> : \
        std::transform(omp_out.begin(), omp_out.end(), omp_in.begin(), omp_out.begin(), std::plus<int>())) \
        initializer(omp_priv = omp_orig)

    int j;
    #pragma omp parallel for private(j) shared(vector) num_threads(thread_count) reduction(vec_int_plus:histogram)
    for (int i=0; i<SIZE; i++) {
        j = vector[i] % PARTS;
        histogram[j]++;
    }
}
```