



Model pamięci w OpenMP

OpenMP wspiera model pamięci współdzielonej.

Wszystkie wątki współdzielą pewną przestrzeń adresową, ale co w przypadku, gdy pewna zmienna jest w pamięci współdzielonej, oraz jest w pamięci podręcznej? Jaką zmienną np. odczyta Proc1?



Spójność operacji



Uporządkowanie na poziomie:

- kodu źródłowego
- kodu skompilowanego
- kodu wykonywanego w środowisku wielowątkowym / współdzielonym

Uporządkowanie: zmiana kolejności w dostępie do pamięci

- kompilator zmienia kolejność zapisaną w kodzie źródłowym na kolejność kodu skompilowanego
- komputer (system operacyjny) zmienia kolejność z kodu skompilowanego na kolejność w pamięci
- w danym momencie tymczasowy wygląd pamięci może się różnić od wyglądu pamięci współdzielonej

Modele spójności: oparte o uporządkowanie operacji typu odczyt Reads (R), zapis Writes (W), synchronizacja Synchronizations (S):
R->R, W->W, R->W, R->S, S->S, W->S

Spójność

Spójność sekwencyjna:

- w środowisku wieloprocessorowym operacje (R, W, S) są sekwencyjnie spójne, jeśli:
 - pozostają w porządku programu dla każdego procesora
 - są widziane w takim samym ogólnym porządku przez każdy z procesorów
 - porządek programu = porządek kodu = porządek wykonania
 - koszt: **ogromny spadek wydajności**

Poluzowana spójność:

- usunięcie części uwarunkowań (obostrzeń co do) spójności dla operacji R, W, S

OpenMP definiuje spójność jako wariant tzw. słabej spójności:

- operacje S muszą być w uporządkowanej kolejności pomiędzy wątkami
- nie można zmieniać kolejności operacji S z operacjami R lub W w tym samym wątku
 - "słaba" spójność gwarantuje: S->W, S->R, R->S, W->S, S->S

Niskopoziomowa synchronizacja: **flush**

Flush

- Definiuje punkt, w którym wątek ma zagwarantowany spójny widok pamięci w odniesieniu do "flush set".
- Flush set:
 - zbiór zmiennych widocznych w wątku dla bloku flush (użytym bez listy argumentów)
 - lista zmiennych w przypadku gdy użyta jest konstrukcja flush(list)
- Działanie flush gwarantuje, że:
 - wszystkie operacje R, W, przekrywające się z blokiem flush i mające miejsce przed flush, są wykonane wcześniej
 - wszystkie operacje R, W, przekrywające się z blokiem flush i mające miejsce po flush, są wykonane później
 - flush przekrywające się z innymi blokami flush nie mogą mieć zmienionej kolejności

Synchronizacja: flush

- flush gwarantuje konsystencję w tym, co widzą różne wątki

```
double A; // jakaś współdzielona zmienna
A = duze_obliczenie();
#pragma omp flush(A)
```

- w OpenMP flush zasadniczo jest używane najczęściej niejawnie:
 - przy wejściu / wyjściu do bloku zrównoleglonego
 - na jawnych / niejawnych barierach
 - przy wejściu / wyjściu do sekcji krytycznych
 - gdy blokada (zamek lock) jest ustawiana / zdejmowana (set / unset)
 - uwaga: używanie flush(list) ryzykowne gdy zmienne z list nie przekrywają się z flush, kompilator może zmienić kolejność wykonania

Producent - konsument

Klasyczny przykład programowania wielowątkowego: relacja producent-konsument, która wymaga synchronizacji pomiędzy dwoma wątkami.

```
#include <iostream>
#include <random>
#include <thread>
#include <omp.h>
using namespace std;

void fill_rand(const int n, double* arr) {
    random_device rd;
    uniform_int_distribution<int> dist(1,20);
    for (int i = 0; i < n; ++i) {
        this_thread::sleep_for(0.02s);
        arr[i] = dist(rd);
    }
}

double sum_array( const int n, double* arr) {
    double s = 0;
    for (int i=0; i<n; ++i) s += arr[i];
    return s;
}
```

Punkt wyjściowy: kod sekwencyjny

```
int main() {

    const int N = 100;
    double sum = 0, runtime;
    int flag = 0;
    double* A = new double[N];

    runtime = omp_get_wtime();
    fill_rand(N, A);           // Producent: wypelnia tablice
    sum = sum_array(N, A);     // Konsument: liczy sume
    runtime = omp_get_wtime() - runtime;
    cout << "Po chwili: " << runtime << " suma = " << sum << endl;

    delete [] A;

}
```

Producent-konsument

```
int main() {  
  
    const int N = 100;  
    double sum = 0, runtime;  
    int flag = 0;  
    double* A = new double[N];  
  
    runtime = omp_get_wtime();  
    #pragma omp parallel sections num_threads(2)  
    {  
        #pragma omp section  
        {  
            fill_rand(N, A);           // Producent  
            #pragma omp flush  
            flag = 1;  
            #pragma omp flush(flag)  
        }  
        #pragma omp section  
        {  
            #pragma omp flush(flag)  
            while (flag==0) {  
                #pragma omp flush(flag)  
            }  
            #pragma omp flush  
            sum = sum_array(N, A);    // Konsument  
        }  
    }  
  
    runtime = omp_get_wtime() - runtime;  
    cout << "Po chwili: " << runtime << " suma = " << sum << endl;  
}
```

W tym przykładzie jest
zagrożenie **data race**

- w pierwszej sekcji flag przypisana jest wartość 1
- w drugiej sekcji czytana jest wartość flag

Rozwiązanie:

#pragma omp atomic [read|write|update|capture]

Producent-konsument

```
int main() {
    const int N = 100;
    double sum = 0, runtime;
    int flag = 0, flg_tmp;
    double* A = new double[N];

    runtime = omp_get_wtime();
#pragma omp parallel sections num_threads(2)
{
    #pragma omp section
    {
        fill_rand(N, A);           // Producent
        #pragma omp flush
        #pragma omp atomic write   ←
        flag = 1;
        #pragma omp flush(flag)
    }
    #pragma omp section
    {
        while (true) {
            #pragma omp flush(flag)
            #pragma omp atomic read ←
            flg_tmp = flag;
            if (flag==1) break;
        }
        #pragma omp flush
        sum = sum_array(N, A);     // Konsument
    }
}

runtime = omp_get_wtime() - runtime;
cout << "Po chwili: " << runtime << " suma = " << sum << endl;
}
```

ta wersja jest całkowicie poprawna,
operacje na zmiennej flag są
zabezpieczone jako atomowe

w przykładzie, konsument rzeczywiście
czeka na sygnał od producenta

jest to przykład na "współbieżne"
(concurrent) programowanie

niemniej, sam przykład nie do końca
odzwierciedla zysk z relacji producent-
konsument, gdzie spodziewalibyśmy
się raczej quasi-równoległej (parallel)
relacji, podczas której konsument
(prawie) od razu używa to, co
wyprodukuje producent