

Analiza i modelowanie wydajności obliczeń

Lab 10. Mnożenie macierz-macierz

Cel: Analiza wydajności implementacji algorytmu mnożenia macierz-macierz.

Wstęp.

Laboratorium obecne jest kontynuacją laboratorium 9 dotyczącego optymalizacji (głównie *cache blocking*) implementacji algorytmu mnożenia macierz-macierz. Tym razem implementacje uzyskane w ramach poprzedniego laboratorium poddane zostaną analizie za pomocą narzędzi mierzących wykorzystanie pamięci DRAM i pamięci podręcznych różnych poziomów.

Wyniki badań mają odpowiedzieć na pytanie jakie operacje wykonywane są w kodzie (czy operacje arytmetyczne są realizowane przez rozkazy wektorowe, a jeśli tak to jakie, jakie inne rozkazy są wykonywane, w jaki sposób realizowane są dostępy do pamięci – czy także za pomocą operacji wektorowych, a jeśli tak to jakich), a ponadto ile danych transferowanych jest pomiędzy różnymi poziomami pamięci – DRAM, L3, L2, L1, rejestry.

To ostatnie badanie wymaga użycia narzędzi takich jak **perf stat**, liczniki sprzętowe lub symulacje **valgrind**. Na podstawie oszacowania rozmiaru transferowanych danych, na podstawie maksymalnych szybkości transferu badanych w poprzednich laboratoriach, obliczane są graniczne czasy obliczeń i wydajności w Gflop/s. Graniczne czasy obliczeń i wydajności, z jednej strony podają wielkości, których nie będzie można dla danej implementacji kodu przekroczyć, a z drugiej strony będą wskazywać, w których miejscach powinna być dokonana modyfikacja lub dalsza optymalizacja kodu.

Kroki:

1. Rozpakuj paczkę *matrix_multiplication_papi_gcc.tgz* w nowym katalogu np. *lab_10*.
2. Przejdź do katalogu *matrix_multiplication_gcc* i przeglądaj pliki: *mat_mul_driver.c*, *mat_mul_par_papi.c*, *papi_set_user_events_mth.c*
 - a) pierwszy z nich, zawierający wyłącznie funkcję **main**, alokuje pamięć dla 3 tablic **A**, **B** i **C**, przechowujących macierze kwadratowe o rozmiarze n , a następnie inicjuje tablice zadanymi (dowolnymi) wartościami i wywołuje procedurę **mat_mul_par_papi** obliczającą iloczyn $C = A*B$. Plik może być kompilowany z opcją **-DPAPI_TEST** lub bez niej. Bez opcji **PAPI_TEST** powyższe operacje są jedynymi znaczącymi za względu na wydajność. Można łatwo obliczyć, że jest to kilka (zależnie od optymalizacji) operacji na pojedynczy element tablic **A** i **B** (w sumie liczba rzędu $O(n*n)$ – bez znaczenia dla całości kodu) oraz zapis wszystkich 3 tablic (z czego zapis tablicy **C** może zostać pominięty na skutek optymalizacji). W sumie jest to $k*n*n$ zapisów, gdzie $k = 2$ lub 3 .
 - b) w wariancie ze zdefiniowanym symbolem **PAPI_TEST** program dodatkowo inicjuje zliczanie zdarzeń sprzętowych (wywołując funkcję **papi_driver_mth_init**) i sprawdza wynik zwracany przez funkcję **mat_mul_par_papi**, wykonując dla dodatkowej tablicy **D**, poprawne pętle obliczeniowe $D = A*B$, i porównując **D** z **C**.
 - c) w drugim z plików, *mat_mul_par_papi.c*, znajduje się kilka implementacji mnożenia macierz-macierz, odpowiadających wersjom z poprzedniego laboratorium (w miejsce implementacji nr 3 należy użyć własnego, poprawnego i zoptymalizowanego – co najmniej *cache blocking* – kodu opracowanego w ramach laboratorium 9). Funkcja **mat_mul_par_papi** jest zorganizowana w taki sposób, że na początku i końcu zawiera odpowiednie wywołania funkcji z interfejsu PAPI pozwalające na zliczanie zdarzeń sprzętowych (wywołania są objęte kompilacją warunkową na podstawie definicji symbolu **PAPI_TEST**), natomiast w środkowej części znajdują się implementacje mnożenia macierz-macierz. Wybór implementacji do wykonania odbywa się poprzez zdefiniowanie odpowiedniej wartości dla symbolu **WERSJA** na początku funkcji i kompilację warunkową. Wybrana implementacja przeprowadza obliczenia, dla których zliczane są zdarzenia sprzętowe (tylko w wersji kodu **mat_mul_driver_papi.exe**, wersja **mat_mul_driver.exe** jest kompilowana bez definiowania symbolu **PAPI_TEST** i służy testowaniu jako standardowo wykonywana funkcja). Wykonanie zadań podczas laboratorium będzie polegało na testowaniu kolejnych

implementacji (dostarczonych lub własnych) i poddawanie ich analizie, między innymi przy użyciu liczników sprzętowych.

- pierwsza implementacja naiwnie implementuje wzór matematyczny w potrójnej pętli *ijk*
 - druga implementacja poprawia pierwszą tak, aby dostępy do pamięci w najbardziej wewnętrznej pętli dotyczyły kolejnych elementów w tablicach przechowujących macierze, jest to osiągnięte przez zmianę kolejności pętli, prowadzącą do wersji *ikj*
 - trzecia implementacja (własna) powinna dodać co najmniej optymalizację *cache blocking*, z rozmiarem bloku zdefiniowanym w pliku *sizes.h*
 - dwie ostatnie wersje dodają do *cache blocking* ręcznie wykonaną optymalizację *register blocking* połączoną z wektoryzacją (wersja 4 z bločkami 4x4x4 – jest to wersja *avx_1* z laboratorium 9, a wersja 5 z bločkami 4x12x4 – wersja *avx_2* z laboratorium 9)
- d) trzeci z plików, *papi_set_user_events_mth.c*, zawiera wybór zdarzeń zliczanych w trakcie wykonywania mnożenia macierz-macierz, zgodnie z przyjętą konwencją interfejsu z biblioteką PAPI. Jako domyślne ustawione są zdarzenia:

event 0: PAPI_REF_CYC

event 1: PAPI_TOT_CYC

event 2: MEM_UOPS_RETIRED.ALL_LOADS

event 3: L1D.REPLACEMENT

event 4: L2_LINES_IN.ALL

które powinny zliczać odpowiednio: liczbę taktów referencyjnych (z częstotliwością nominalną), liczbę taktów rzeczywistych (z częstotliwością rzeczywistą), liczbę rozkazów pobrania danych, liczbę podmian linii w L1 (związaną z transferem danych z L2 do L1 lub z L3 do L1), liczbę zaalokowanych linii L2 (związaną z transferem danych z L3 do L2 lub z L1 do L2)

[oprócz wymienionych zdarzeń w pliku znajduje się wiele innych możliwych wyborów, opracowany interfejs umożliwia zdefiniowanie 6 zdarzeń, dla których zliczane będą liczby wystąpień, przy czym sprzętowo zrealizowane może być tylko zliczanie 4 zdarzeń użytkownika i dodatkowo 2 spośród domyślnie zliczanych każdorazowo przez rdzeń (jak np. całkowita liczba wykonanych rozkazów, której odpowiada predefiniowane zdarzenie PAPI: **PAPI_TOT_INS** i referencyjna liczba taktów **PAPI_REF_CYC** (jest ona używana do obliczenia częstotliwości pracy zegara, różni się od rzeczywistej liczby taktów **PAPI_TOT_CYC** proporcjonalnie tak jak częstotliwość rzeczywista różni się od częstotliwości nominalnej procesora)]

[zdarzenia uwzględnione w pliku *papi_set_user_events_mth.c*, poza wieloma dotyczącymi pamięci podręcznych L1 i L2, zawierają także zdarzenia dotyczące pamięci L3 i DRAM; problem z wykorzystaniem tych ostatnich zdarzeń polega na tym, że elementy sprzętowe, których dotyczą znajdują się poza rdzeniem dokonującym zliczania w swoich rejestrach, stopień złożoności tych elementów (zwłaszcza dla maszyn wieloprocesorowych z pamięcią ccNUMA) powoduje trudności z dokonywaniem pomiarów, a także ich późniejszą interpretacją; uwzględniając te zastrzeżenia, jako zdarzenia, które mogą pomóc w szacowaniu transferów pomiędzy L3 i DRAM mogą zostać wykorzystane:

MEM_LOAD_UOPS_RETIRED.L3_MISS

MEM_LOAD_UOPS_L3_MISS_RETIRED.LOCAL_DRAM

OFFCORE_RESPONSE_0:ANY_DATA:ANY_RFO:L3_MISS_LOCAL:SNP_ANY]

[zliczanie zdarzeń odbywa się indywidualnie dla każdego z wątków realizujących obliczenia, interpretacja jest łatwiejsza w przypadku obliczeń jednowątkowych – takie obliczenia są podstawą zadań obowiązkowych laboratorium, analiza wykonania wielowątkowego jest pozostawiona jako zadanie dodatkowe]

3. Zbuduj bibliotekę interfejsu PAPI (**make recreate_papi_lib_mth**)
4. Program, łącznie z funkcją **mat_mul_par_papi** jest napisany w wersji równoległej OpenMP. Na potrzeby badań wydajności, w pierwszej kolejności analizowane jest wykonanie sekwencyjne, uzyskiwane przez ustawienie liczby wątków na 1 (**export OMP_NUM_THREADS=1**) lub zakomentowanie (tak jak w przesłanej paczce) dyrektyw zrównoleglenia (kod OpenMP różni się w pewnych miejscach wewnątrz funkcji **mat_mul_par_papi** od kodu sekwencyjnego)

5. Sprawdź poprawność instalacji poprzez uruchomienie programu poleceniem **make** (w dostarczanej wersji kodu jako domyślna uruchamiana jest najbardziej wydajna, dla kompilatora *gcc*, wersja *avx_2*)

6. Zanotuj wyniki raportowane przez narzędzie **perf stat** w liniach:

```
...      cycles:u          #    ... GHz
...      instructions:u    #    ... insn per cycle
...      L1-dcache-loads:u #    ... M/sec
...      L1-dcache-load-misses:u #    ... of all L1-dcache hits
...      LLC-loads:u      #    ... M/sec
...      LLC-load-misses:u #    ... of all LL-cache hits
```

oraz przez funkcje z biblioteki PAPI, a także wydajność obliczeń w Gflops/s (obie wersje programu: **mat_mul_driver_papi.exe** i **mat_mul_driver.exe** mierzą wydajność funkcji **mat_mul_par_papi**, pierwsza z włączonym zliczaniem zdarzeń, druga bez)

[wyniki umieść w sprawozdaniu - można je porównać z innymi wersjami kodu badanymi szczegółowo w ramach laboratorium]

7. **Zasadnicza część ćwiczenia polega na badaniu wydajności dla dwóch wersji implementacji mnożenia macierz-wektor: wersji *ikj* (druga implementacja w pliku *mat_mul_par_papi.c*) oraz wersji z optymalizacją *cache blocking* (własna wersja podstawiona w miejsce trzeciej implementacji w pliku *mat_mul_par_papi.c*)** - badanie pozostałych dwóch wersji (*ijk* oraz wersji z ręczną wektoryzacją) stanowi zadanie dodatkowe

8. Dla każdej z (dwóch) wersji implementacji mnożenia macierz-macierz należy przeprowadzić następujące kroki badania wydajności:

a) ustalenie właściwej wersji implementacji w pliku *mat_mul_par_papi.c* za pomocą symbolu WERSJA (przykładowe oznaczenia: *v2_ikj*, *v3_cb*)

b) otrzymanie wersji asemlera, np. za pomocą

```
gcc -S -O3 -fopenmp -march=core-avx2 -D'NOMINAL_FREQUENCY=2.2'
mat_mul_par_papi.c -o mat_mul_par_v2_ikj.s
-I/home/students_wo/common_files/papi-6.0.0/src
-I../papi_driver_mth
```

odnalezienie bloku podstawowej pętli obliczeniowej (zawierającej najprawdopodobniej pewną wersję operacji **fma**), zapisanie kodu asemlera dla pojedynczej iteracji pętli

- postać asemlera może wskazać potrzebę dokonania klasycznych optymalizacji - kompilator może ich, z niewiadomych przyczyn, nie przeprowadzić
- w przypadku modyfikacji należy uzyskać nową wersję asemlera i porównać postać najbardziej wewnętrznej pętli algorytmu w starej i nowej wersji

c) uruchomienie programu (w wersji zoptymalizowanej) za pomocą **make**

d) zanotowanie wyników podawanych przez **perf stat** (wstępne uruchomienie **make**, a następnie powtórzenia: **numactl -C MY_CORE perf stat -d -d -d ./mat_mul_driver.exe**), PAPI (uruchomienie **numactl -C MY_CORE ./mat_mul_driver_papi.exe**), i **valgrind** (uruchomienie **numactl -C MY_CORE valgrind --tool=cachegrind ./mat_mul_driver.exe**)

[**MY_CORE** jest przydzielonym podczas zajęć numerem rdzenia mikroprocesora]

• **w sprawozdaniu należy zamieścić wszystkie dane dotyczące wykonania:**

- **symbol implementacji**
- **rozmiar tablicy i liczba operacji [Gflop] z kodu źródłowego i wydruku**
- **czas wykonania i wydajność ([Gflop/s] oraz [flop/cycle]) z wydruku**
- **kod asemlera najbardziej wewnętrznej pętli algorytmu**
- **wyniki perf stat (jak w p.6 - cycles, instructions, L1-dcache-loads, L1-dcache-load-misses, LLC-loads, LLC-load-misses)**

• **wyniki PAPI w formacie:**

```
PAPI_REF_CYC          ....
PAPI_TOT_CYC          ....
MEM_UOPS_RETIRED.ALL_LOADS  ....
L1D.REPLACEMENT      ....
```

```
L2_LINES_IN.ALL      ....
L3_MISS_LOCAL:SNP_ANY  ....
```

- **wyniki valgrind**
 - niektóre z wyników oraz obliczone na ich podstawie pochodne parametry i miary należy umieścić w tabeli o strukturze zamieszczonej w p. 10
 - przed umieszczeniem danych w tabeli w sprawozdaniu należy zamieścić obliczenia miar pochodnych na podstawie danych powyżej (czasem przyjmując jedną z nich – kiedy różne narzędzia się różnią, lub wybierając wartość przybliżoną zbliżoną do danych pomiarowych – np. na podstawie kodu źródłowego)
- e) weryfikacja kolejnych parametrów:
- **liczba taktów podczas wykonania: perf stat** dotyczy całego programu, natomiast PAPI tylko funkcji **mat_mul_par_papi**, jednak w wersji **mat_mul_driver.exe**, dla której podawane są wyniki **perf stat**, czas poza funkcją jest pomijalny
 - podzielenie liczby taktów rzeczywistych przez czas (raportowany na wydruku dla funkcji **mat_mul_par_papi**) daje w wyniku średnią częstotliwość pracy procesora (rdzenia) w trakcie wykonywania obliczeń, wartość tę można porównać z wartością obliczoną w programie na podstawie liczby taktów rzeczywistych i referencyjnych oraz nominalnej częstotliwości pracy rdzenia (możliwa różnica wynika z faktu, że w kodzie nie da się zmierzyć niezależnie i czasu wykonania (procedurami systemowymi), i wartości liczników sprzętowych (jeden z pomiarów musi być wewnątrz drugiego) – **w sprawozdaniu zamieść odpowiednie obliczenia**
 - **liczba wykonanych rozkazów:** liczba wykonanych rozkazów (*instructions*) będzie (z dużym przybliżeniem) równa liczbie rozkazów w bloku asemblera odpowiadającym najbardziej wewnętrznej pętli kodu pomnożonej przez wielokrotność wykonania bloku w programie. Biorąc liczbę rozkazów z **perf stat** lub **valgrind (I refs)** (obie powinny być bardzo zbliżone) oraz liczbę rozkazów w bloku asemblera oblicz liczbę wykonań bloku asemblera. Porównaj liczbę wykonań bloku asemblera z liczbą iteracji w najbardziej wewnętrznej pętli implementacji wynikającą z kodu źródłowego ($n*n*n$). Ewentualne różnice mogą wynikać z rozwinięcia najbardziej wewnętrznej pętli implementacji przez kompilator (*loop unrolling*). **W sprawozdaniu zamieść odpowiednie obliczenia: liczby wykonań bloku asemblera oraz wnioski z porównania jej z teoretyczną wartością $n*n*n$**
 - w przypadku rozwinięcia pętli przez kompilator zaobserwuj, czy zostało ono jednocześnie wykorzystane do wektoryzacji. **Jeśli tak, podaj w sprawozdaniu jakie wektorowe operacje wykonywane są w bloku asemblera**
 - dla rozkazów operacji arytmetycznych oblicz ilu standardowym matematycznym operacjom (mnożeniom i dodawaniom) odpowiada jedna operacja wektorowa – w połączeniu z liczbą rozkazów w bloku asemblera i liczbą wykonań bloku asemblera, oblicz całkowitą liczbę operacji zmiennoprzecinkowych (dodawania i mnożenia) w trakcie wykonania. **W sprawozdaniu zamieść odpowiednie obliczenie liczby operacji zmiennoprzecinkowych oraz porównanie jej z wartością wynikającą z algorytmu i kodu źródłowego**
 - **liczba rozkazów dostępu do danych (perf stat i PAPI podają tylko liczbę odczytów, valgrind podaje niezależnie liczbę odczytów i liczbę zapisów):** porównaj wartości raportowane przez programy profilujące z wartościami obliczonymi na podstawie postaci kodu asemblera (w konwencji AT&T używanej przez gcc pierwszym argumentem rozkazu jest źródło, a drugim cel) i liczby wykonań bloku asemblera (dostęp do danych realizowany jest jawnie przez rozkazy takie jak **mov** i **broadcast**, lub niejawnie – jeśli argumentem operacji arytmetycznej jest lokalizacja w pamięci). **W sprawozdaniu zamieść odpowiednie obliczenia liczby operacji odczytu i zapisu oraz porównanie z wynikami profilerów**
 - w kodzie asemblera zaobserwuj ilu pobranym bajtom odpowiada każdy rozkaz dostępu (rozkazy kończące się na **sd** dotyczą 64 bitów, kończące się na **pd** 128, 256 lub 512 bitom, zależnie od typu rejestru z którym związana jest operacja). Oblicz ile (giga)bajtów danych pobieranych jest do rejestrów, a ile zapisywanych, w pojedynczym wykonaniu bloku asemblera oraz w trakcie całego wykonania obliczeń (zapisy i odczyty poza blokiem asemblera odpowiadającym najbardziej wewnętrznej

pętli implementacji stanowią pomijalnie mały udział). **W sprawozdaniu zamieść odpowiednie obliczenia liczby odczytywanych do rejestrów i zapisywanych z rejestrów bajtów danych**

- **liczba chybień w L1** (podawana przez **perf stat** i **valgrind**), **liczba podmian linii w L1** (podawana przez PAPI - **L1D.REPLACEMENT**):
 - porównanie liczby chybień z liczbą operacji daje informacje, co który z dostępuów kończy się chybieniem
 - przy parametrach pamięci podręcznych uzyskanych w poprzednich laboratoriach (m.in. szerokość linii 64 bajty) i rozmiarze danych podwójnej precyzji 8 bajtów, wczytanie pojedynczej, odpowiednio długiej, tablicy jednowymiarowej (a więc np. jednego wiersza macierzy przechowywanej wierszami) powinno powodować chybiecie przy co ósmym (**skalarnym**) dostępie do pamięci (w przypadku dostępuów wektorowych należy rozmiar linii podzielić przez liczbę bajtów w pojedynczej operacji dostępu)
 - liczba chybień w L1 (podmian linii) może służyć do obliczenia liczby bajtów transferowanych pomiędzy pamięcią L1 i pozostałymi poziomami pamięci – należy pomnożyć liczbę chybień przez rozmiar linii. **W sprawozdaniu zamieść odpowiednie obliczenia liczby bajtów odczytywanych do L1 (analiza wyników valgrind wskazuje, że liczba danych zapisywanych z L1 jest, w analizowanych wersjach implementacji, pomijalnie mała)**
 - w tabeli znajdują się osobno wiersze zakładające, że całość transferu odbywa się z L2 (tak byłoby w przypadku klasycznych exclusive caches) oraz że całość odbywa się z L3 (tak mogłoby być w szczególnych przypadkach dla mechanizmu inclusive caches, np. victim caches). Nie rozstrzygając, która z sytuacji ma miejsce (są jeszcze możliwe przypadki pośrednie, część podmian z L2, a część z L3, dokładna analiza wymagałaby badania większej liczby zdarzeń sprzętowych) należy w tabelce wypełnić oba wiersze. W sprawozdaniu, na podstawie analizy pozostałych zdarzeń sprzętowych, kodu źródłowego i kodu asemblera, można podjąć próbę zbadania jak wygląda rzeczywisty ruch danych pomiędzy poziomami pamięci podręcznej i jaki wpływ ma to na czas obliczeń i uzyskaną wydajność wykonania
- **liczba linii alokowanych w pamięci L2**
 - raportowana tylko przez PAPI (**L2_LINES_IN.ALL**), służąca do szacowania wielkości transferu z pamięci L3 (po pomnożeniu przez rozmiar linii)
 - podobnie jak dla liczby podmian linii w L1 źródłem danych umieszczanych w L2 może być L1 lub L3. Dla uproszczenia zakładane jest, że podmiana linii w L2 związana jest z transferem z L3 (nawet w przypadku victim cache może tak być, jeśli źródłem danych dla L2 jest L1, ale linia z L1 jest przenoszona na skutek transferu z L3)
 - w szczególności ostatni mechanizm (victim cache) może powodować, że liczba podmian linii w L1 i w L2 jest zbliżona (każde chybiecie w L1 jest chybieniem w L2, co powoduje transfer z L3 do L1 i transfer podmienianej linii z L1 do L2)
- **liczba chybień w L3**
 - kwestia chybień w L3 jest zjawiskiem najbardziej złożonym, ze względu na porównywalność rozmiaru wszystkich tablic (dla małych zadań, takich jak badane w ramach laboratorium) z pojemnością L3 oraz kwestie strategii podmiany linii w L3 (problem komplikuje się jeszcze bardziej przy obliczeniach równoległych, szczególnie dla maszyny złożonej z dwóch mikroprocesorów, jak serwer Honorata)
 - wartości zwracane przez **perf stat** i **valgrind** mogą znacznie się różnić (**valgrind** może raportować więcej chybień niż **perf stat**), także zawodne są wyniki PAPI dotyczące zdarzeń związanych z chybieniami w L3 (można włączyć ich zliczanie w pliku `papi_set_user_events_mth.c`, pamiętając o ograniczonej liczbie liczników sprzętowych w procesorze (rdzeniu) – nowe zdarzenia muszą zastąpić zdarzenia zliczane dotychczas).
 - dla obu zwracanych (przez **perf stat** i **valgrind**) liczb chybień można obliczyć liczbę bajtów transferowanych do L3.

W sprawozdaniu zamieść odpowiednie obliczenia liczby bajtów odczytywanych do L3 (liczba bajtów zapisywanych będzie zawsze mało znacząca dla czasu wykonania kodu, także dla większych tablic)

9. Wypełnij poniższą tabelę danymi uzyskanymi z pomiarów i parametrami obliczonymi na ich podstawie:

	rozmiar pobranych danych [GB]	maksymalna szybkość transferu danych (lab 5) [GB/s]	minimalny czas transferu [s]	maksymalna wydajność [Gflop/s]
symbol metody np. ikj, rozmiar tablicy: np. 1080 i liczba operacji [Gflop]				
zdarzenie i odpowiadający typ transferu danych, np.:				
L1 loads (L1 -> rejestry)				
L1 misses (L2 -> L1)				
L1 misses (L3 -> L1)				
L2 misses (line in) (L3 -> L2)				
L3 (LLC) misses – perf (DRAM -> L3)				
L3 (LLC) misses – valgrind (DRAM -> L3)				
symbol metody np. cb_108, rozmiar tablicy: np. 1080 i liczba operacji [Gflop]				
itd.				

uwagi:

- przeliczenia wartości na miary kilo, mega, giga należy dokonywać z mnożnikami 1024 (np. Gflop = flop/1024/1024/1024)
- rozmiar pobranych danych należy obliczać:
 - dla transferu do rejestrów: na podstawie asemblera – liczby i typu rozkazów dostępu do danych (łącznie odczytów i zapisów),
 - dla transferu do L1, L2, L3: na podstawie liczby chybień (podmian linii) i długości linii w B
 - dla transferu do L3: dla wyników **perf stat** tylko odczyty, dla wyników **valgrind** łącznie odczyty i zapisy
- maksymalne szybkości transferu danych należy wziąć z wyników laboratorium 5 [dla serwera Honorata powinny być zbliżone do wartości z tabeli - podanych dla częstotliwości zbliżonej do nominalnej, 2.2 GHz]
- czas transferu danych (obliczony jako stosunek rozmiaru danych do maksymalnej wydajności) jest minimalnym czasem, jaki musi zająć transfer do rejestrów lub określonej pamięci w trakcie wykonania programu – czas wykonania całości programu, ze względu na współbieżne działanie sprzętu nie jest sumą czasów składowych, jednak nie może być krótszy niż najdłuższy z czasów składowych
- maksymalna wydajność w ostatniej kolumnie [Gflop/s] może być obliczona jako iloraz liczby operacji i czasu transferu
 - maksymalną wydajność należy rozumieć jako ograniczenie wydajności spowodowane konkretnym typem transferu danych, czyli sytuacją kiedy program wykonuje rozmaite operacje, ale czas wykonania wynika z czasu realizacji tego transferu
 - wydajności wynikające z transferu danych należy także porównać z maksymalną wydajnością potoków przetwarzania (laboratorium 3 – wydajność dla obliczeń wektorowych – takich jak w asemblerze)

- wydajność rzeczywista nie może być wyższa od żadnej z wydajności składowych, a w przypadku kiedy wykonanie różnych transferów nie jest w pełni współbieżne (czas jest większy od maksymalnego czasu poszczególnych transferów) będzie jeszcze niższa
- tabela zakłada maksymalne szybkości transferu danych (uzyskane w laboratorium 5), w przypadku różnych implementacji rzeczywiste przepustowości mogą być niższe (dotyczy to np. wariantu *ijk*, gdzie dostęp do tablicy jest realizowany ze skokiem *n* elementów, co powoduje nie tylko znacznie większy rozmiar przekazywanych danych (chybienie przy każdym dostępie do tablicy **B**, ale także prawdopodobnie niższą przepustowość transferu do pamięci każdego z poziomów)

Na podstawie tabeli wyciągnij wnioski jakie są czynniki ograniczające wydajność wykonania programu – czy jest on ograniczany przez wydajność potoków przetwarzania, czy przez wydajność pamięci, a w przypadku pamięci, który poziom pamięci jest decydujący. Spróbuj w analizie uwzględnić niedokładności pomiarów i ewentualne odstępstwa od poczynionych założeń, spróbuj uszeregować różne czynniki ograniczające wydajność programu pod kątem ich znaczenia – dla różnych badanych implementacji mnożenia macierz-macierz. Swoje analizy umieść w sprawozdaniu.

10. Po wykonaniu wszystkich pomiarów i obliczeń, dokonaj porównania obu wariantów implementacji mnożenia macierz-macierz, z optymalizacją *cache blocking* i bez niej – na które parametry optymalizacja ma wpływ, a na które nie? **Porównanie i wynikające z niego wnioski umieść w sprawozdaniu**

Dalsze kroki:

11. Powtórz powyższe kroki dla wersji zvektoryzowanych oraz błędnej implementacji (*ijk*) powodującej nadmierną liczbę chybień (dla badanego rozmiaru tablic będzie to dotyczyć tylko chybień w L1, dla tablic większych także w L3)
12. Po wykonaniu wszystkich pomiarów i obliczeń, dokonaj porównania badanych wariantów implementacji mnożenia macierz-macierz – w jaki sposób przeprowadzane optymalizacje wpływają na parametry wykonania programu? **Porównanie i wynikające z niego wnioski umieść w sprawozdaniu**
13. **Przeprowadź badanie dla wersji wielowątkowej (za pomocą `perf stat` i PAPI) – czy w tej wersji zmieniają się czynniki ograniczające wydajność programu?**