

Ubrzavanje izvođenja primjenom koncepata MIMD i SIMD

Matija Folnović

Zagreb, 23.01.2015.

Uvod

- Množenje matrica - vrlo važan problem
- Klasičan način ($O(N^3)$)
- OpenMP
 - API unutar većine prevodioca za C, C++ i Fortran
 - Služi kao jednostavno i fleksibilno sučelje za razvoj aplikacija koje koriste paralelizam
- MKL (engl. Intel Math Kernel Library)
 - Pruža **jako puno** gotovih, optimiziranih, paraleliziranih implementacija matematičkih izračuna (linearna algebra itd.)
- OpenBLAS (engl. BLAS - Basic Linear Algebra Subprograms)
 - C++ Omotač (engl. wrapper) oko najstarije i najrazvijenije biblioteke BLAS - pisane u Fortranu
 - Dodatno paralelizira BLAS-ove (Fortran) procedure

Gdje?

- ① 24x Intel(R) Xeon(R) CPU E52620 @ 2.00GHz
 - Dva procesora (2×12 jezgri)
 - 6 fizičkih jezgri (Hyperthreading \Rightarrow 12 virtualnih)
 - ② Xeon Phi
 - \sim 1GHz po jezgri
 - Ali, 60 fizičkih jezgri (240 virtualnih)
- Jedna od ideja je usporedba: "malo" jakih jezgri VS puno "slabih" jezgri

Klasičan način

- Najjednostavnija varijanta množenja matrica!
- A i B su matrice koje množimo, C je rezultatna matrica
- Sve matrice su dimenzija $N \times N$
- Evaluacija se odvija nad matricama dimenzija 2000×2000

```
for (int i = 0; i < N; i++)  
    for (int j = 0; j < N; j++)  
        for (int k = 0; k < N; k++)  
            C[i][j] += A[i][k] * B[k][j];
```

- 1 13.65 s (ICC) / 15.09 s (GCC)
- 2 ~ 190 s

Paralelizacija

- Dodana jedna linija (OpenMP ♡)!

```
int i, j, k;
#pragma omp parallel for shared (A, B, C) private (i, j, k)
    for (i = 0; i < N; i++)
        for (j = 0; j < N; j++)
            for (k = 0; k < N; k++)
                C[i][j] += A[i][k] * B[k][j];
```

- 1 1.43 s (ICC) / 1.66 s (GCC) \simeq 9.5x ubrzanje
- 2 3.35 s \simeq 57x ubrzanje

Vektorizacija (SIMD)

- Dodano još (par) linija

```

int i, j, k;
#pragma omp parallel for shared (A, B, C) private (i, j, k)
    for (i = 0; i < N; i++)
        for (j = 0; j < N; j++) {
            double sum = 0.0;
#pragma omp simd reduction(+:sum)
                for (k = 0; k < N; k++) {
                    sum += A[i][k] * B[k][j];
                }
            C[i][j] = sum;
        }

```

- 1.07 s (ICC) \simeq 12.75x ubrzanje (u odnosu na klasičan način)
- 2.56 s \simeq 74x ubrzanje (u odnosu na klasičan način)

Gotove implementacije

1 MKL

```
cblas_sgemm(CblasRowMajor, CblasNoTrans, CblasNoTrans, N,
            N, N, 1.0, A, N, B, N, 0.0, C, N);
```

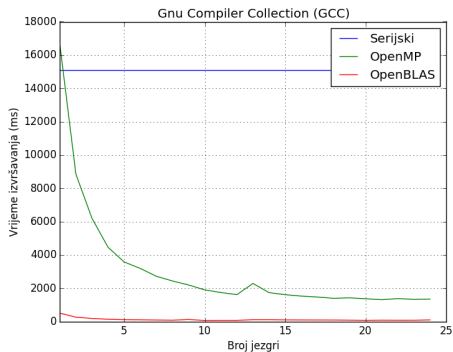
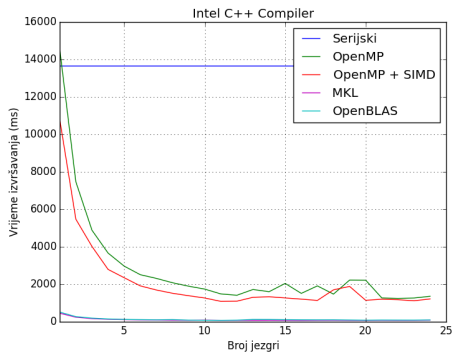
- 1 53.40 ms (ICC) \simeq 255x ubrzanje (u odnosu na klasičan način)
- 2 51.10 ms \simeq 3558x ubrzanje (u odnosu na klasičan način)

2 OpenBLAS

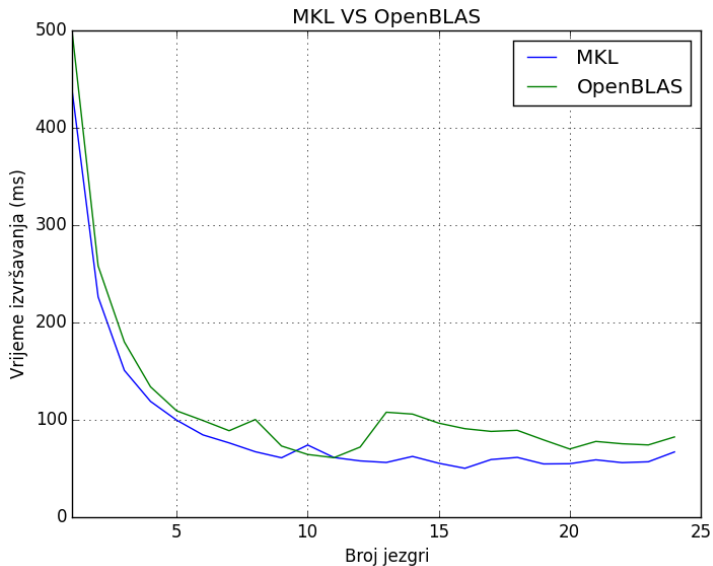
```
cblas_sgemm(CblasRowMajor, CblasNoTrans, CblasNoTrans, N,
            N, N, 1.0, A, N, B, N, 0.0, C, N);
```

- 1 69.50 ms (ICC) / 68.30 ms (GCC) \simeq 200x ubrzanje (u odnosu na klasičan način)

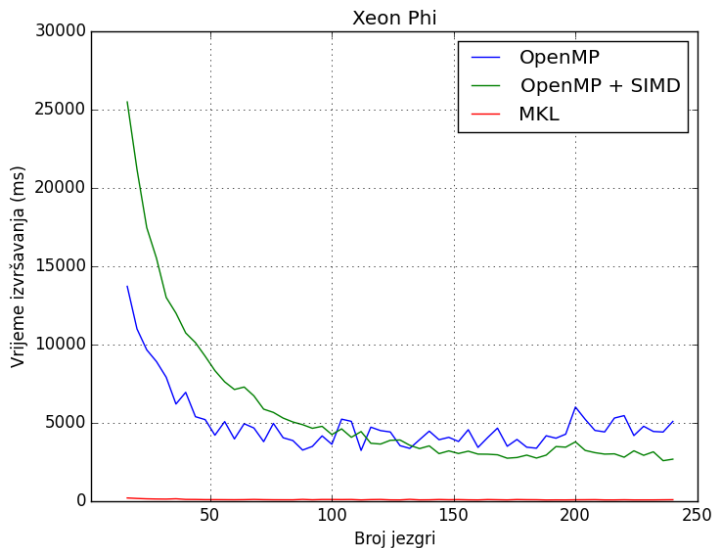
Grafovi - 24x Intel(R) Xeon(R) CPU E52620 @ 2.00GHz



Grafovi - MKL VS OpenBLAS



Grafovi - Xeon Phi



Kraj

Hvala na pažnji!

Kraj

Hvala na pažnji!
Pitanja, Komentari?