知能制御システム学

画像処理の高速化

東北大学 大学院情報科学研究科
鏡 慎吾
swk(at)ic.is.tohoku.ac.jp
http://www.ic.is.tohoku.ac.jp/ja/swk/
2009.07.28

今日の内容

ビジュアルサーボのようなリアルタイム応用を考える場合，画像処理を高速に実装することも重要となる．

いくつかの基本的な知識を押さえておかないと，同じアルゴリズムを実行しているのに性能が上がらないということがしばしば生じる．

今日は，あくまで普通のPC上での「プログラムの書き方」のレベルで，高速化を考慮する際に知っておくべき基本的な考え方を学ぶ．

リアルタイム処理と高速化

- 「リアルタイム」=「高速」ではない
- 目標となる時間制約が定められているのがリアルタイム処理である
  - 34 ms → 33 ms
  - 33 ms → 32 ms
  - どちらも 1 ms の短縮だが，例えばビデオレートでのリアルタイム処理が目的なのであれば，両者の意味は大きく違う
- 平均実行時間 ←→ 最悪実行時間
- 計算時間を短くするには計算量を減らすのが基本．**だがそれだけではない**

実行時間を手軽に測る (Windows)

```
#include <windows.h>

LARGE_INTEGER freq;
LARGE_INTEGER cn1, cn2;
double elapsed_time_in_microseconds;

if (QueryPerformanceFrequency(&freq) == 0) {
        fprintf(stderr, "cannot use performance counter¥n");
        return 1;
}

QueryPerformanceCounter(&cn1);

// do something

QueryPerformanceCounter(&cn2);

elapsed_time_in_microseconds =
 (1000000.0 * (cn2.QuadPart – cn1.QuadPart)) / freq.QuadPart);
```

例: ガウス平滑化

- m × n のフィルタマスクによるガウス平滑化は，単純に実行すると 1 画素当たり O(mn) の計算量が必要

$$G_{x,y} = \sum_i \sum_j w_{i,j} F_{m+i,n+j}$$

$$w_{x,y} = \frac{1}{2\pi\sigma^2} \exp\{-\frac{x^2+y^2}{2\sigma^2}\}$$

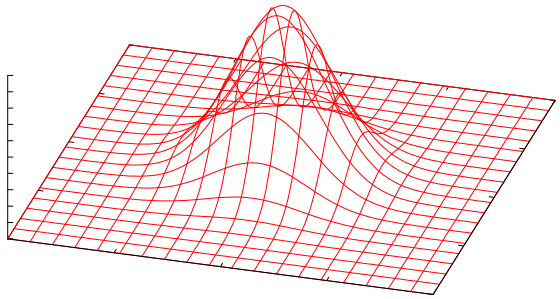

- X方向･Y方向それぞれ1次元ガウス平滑化に分解できることに気づけば，1画素当たり O(max(m,n)) の計算量で実行可能

$$w_{x,y} = \frac{1}{\sqrt{2\pi}\sigma} \exp\{-\frac{x^2}{2\sigma^2}\} \cdot \frac{1}{\sqrt{2\pi}\sigma} \exp\{-\frac{y^2}{2\sigma^2}\}$$

- このような性質を持つフィルタを「分離可能 (separable)」という

実行例

- time_gauss.cpp
  (時間計測は PerformanceCounter を用いている. ソースコードは perftimer.cpp)

```
//#define OPT_NOSEP
#define OPT_SEP
```

で，分離型，非分離型を切り替え

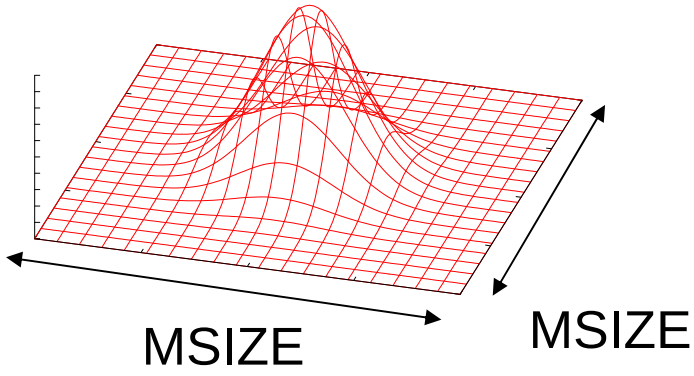


```
#define MARGIN 7
```

でフィルタマスクのサイズを指定

MSIZE = 2 * MARGIN + 1

ただし:

- 計算量が減ったからといって，そのまま計算時間の減少につながるわけではない
- それどころか，条件によっては遅くなる場合すらある
(2年前の PC では実際にそのようなケースが見られた．今回のPCでは見られない)

以下で，もう少しシンプルな画像処理について，計算時間に影響を及ぼしそうな代表的な例を見ていく

サンプルプログラム

- time_framediff.cpp
  (同様に perftimer.cpp が必要)

  簡単なフレーム間差分(が一定量以上の画素を緑色に表示)

  `#define OPT_BASELINE`
  … OpenCVの画像処理関数を(一部)使用した実装

  `#define OPT_NAIVE`
  … OpenCVの画像処理関数を使用せずに，素朴に書いた実装．baseline に比べてだいぶ遅い．これを基本として手を加えていく

  `#define OPT_BASELINE_NAIVEDIFF`
  … 差分処理のみ素朴に書き，他の部分 (色変換と画像コピー) は OpenCV の関数を使用．

例: ループ交換

#define OPT_INTERCHANGE

… まず基本中の基本，メモリアクセスのパターンによって速度が変わる例を示す

```
for (j = 0; j < height; j++) {
    for (i = 0; i < width; i++) {
        PIXVAL(img, i, j) = ...

    }
}
```

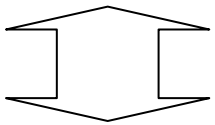

```
for (i = 0; i < width; i++) {
    for (j = 0; j < height; j++) {
        PIXVAL(img, i, j) = ...
    }
}
```

記憶階層

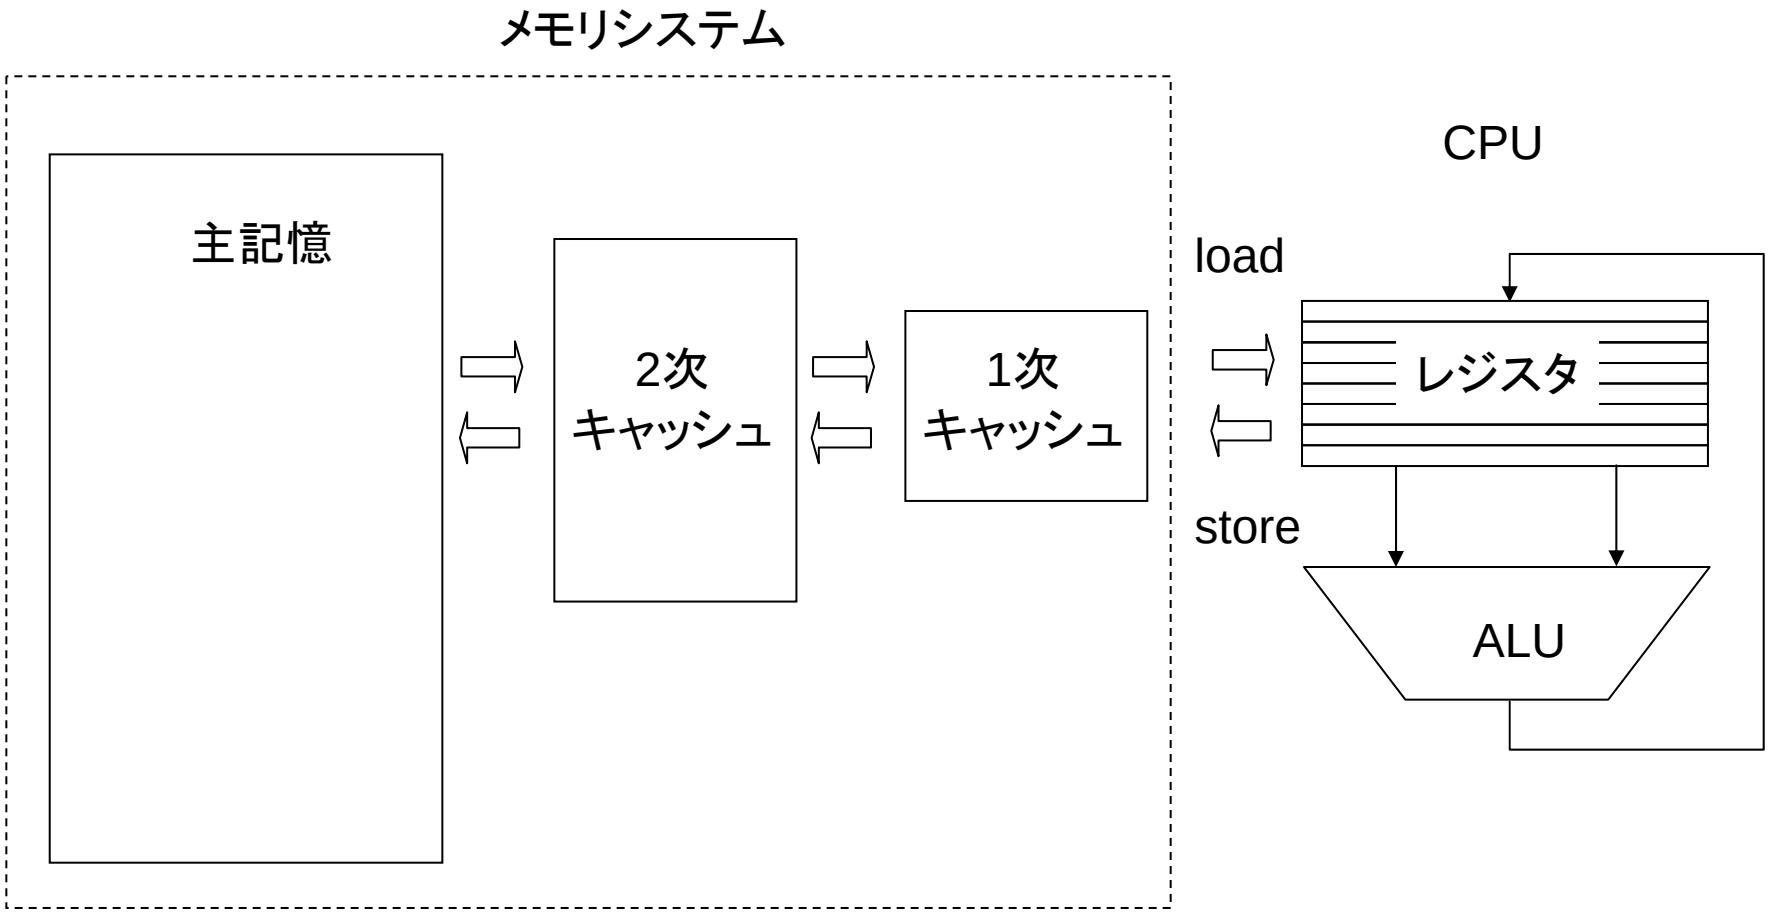

- プログラム（プログラマ）から見た場合，キャッシュの存在は見えない（制御が自動的に行われる）

キャッシュメモリの動作例

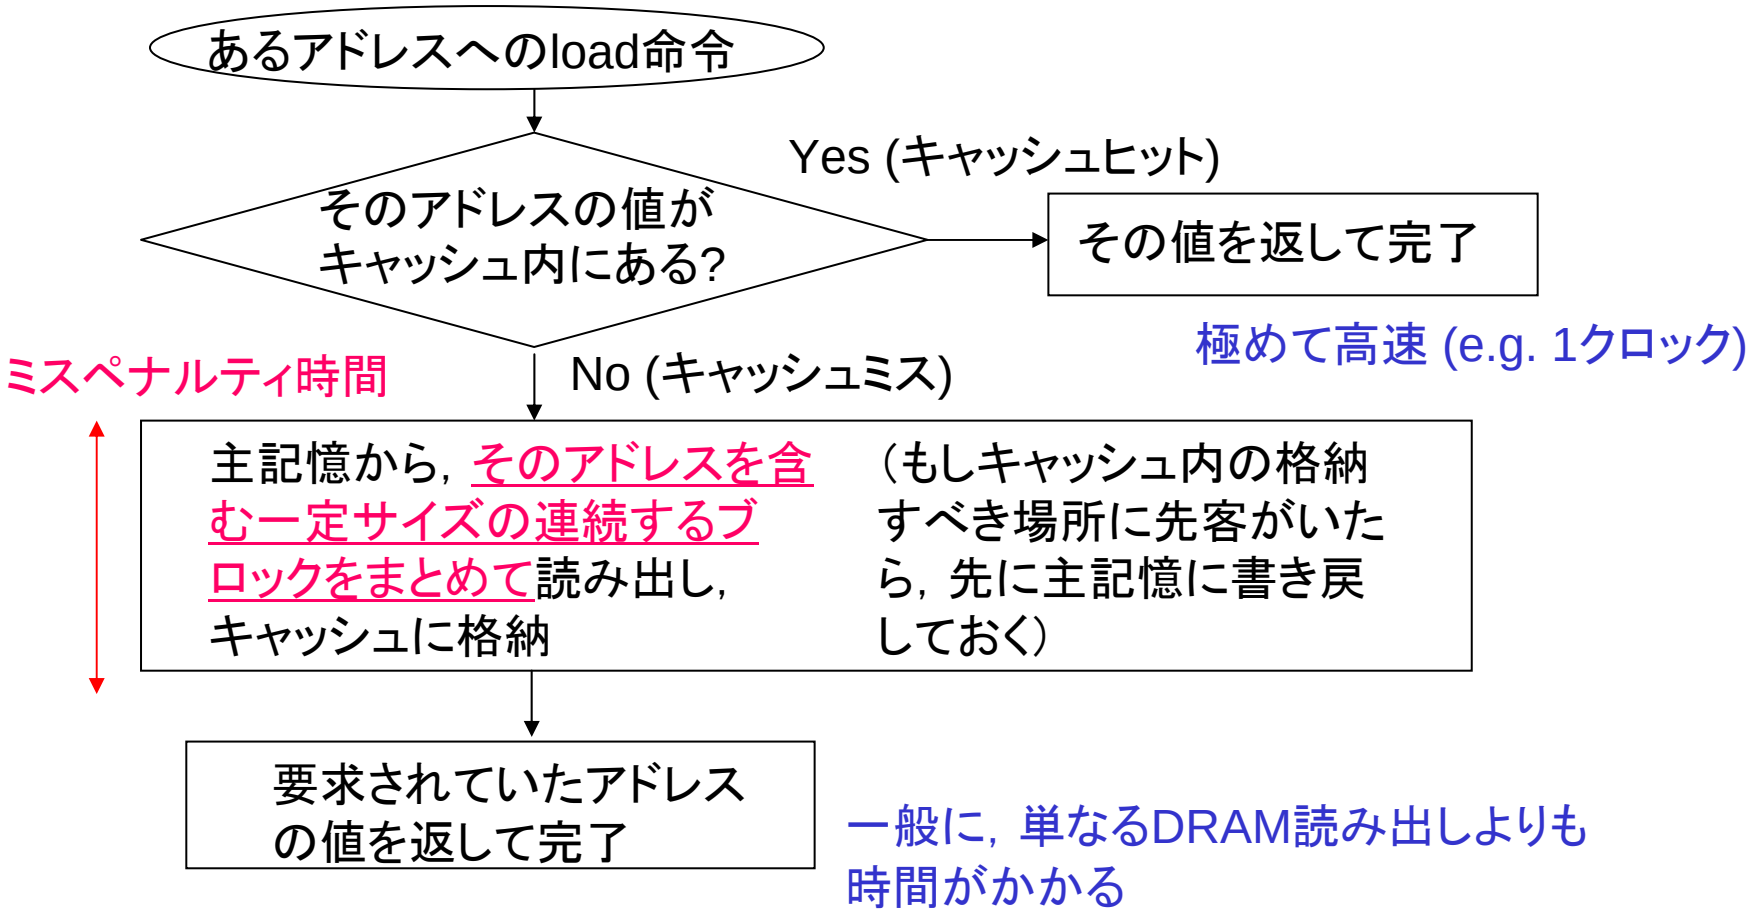

平均メモリアクセス時間 = ヒット時間 ＋ キャッシュミス率 × ミスペナルティ時間

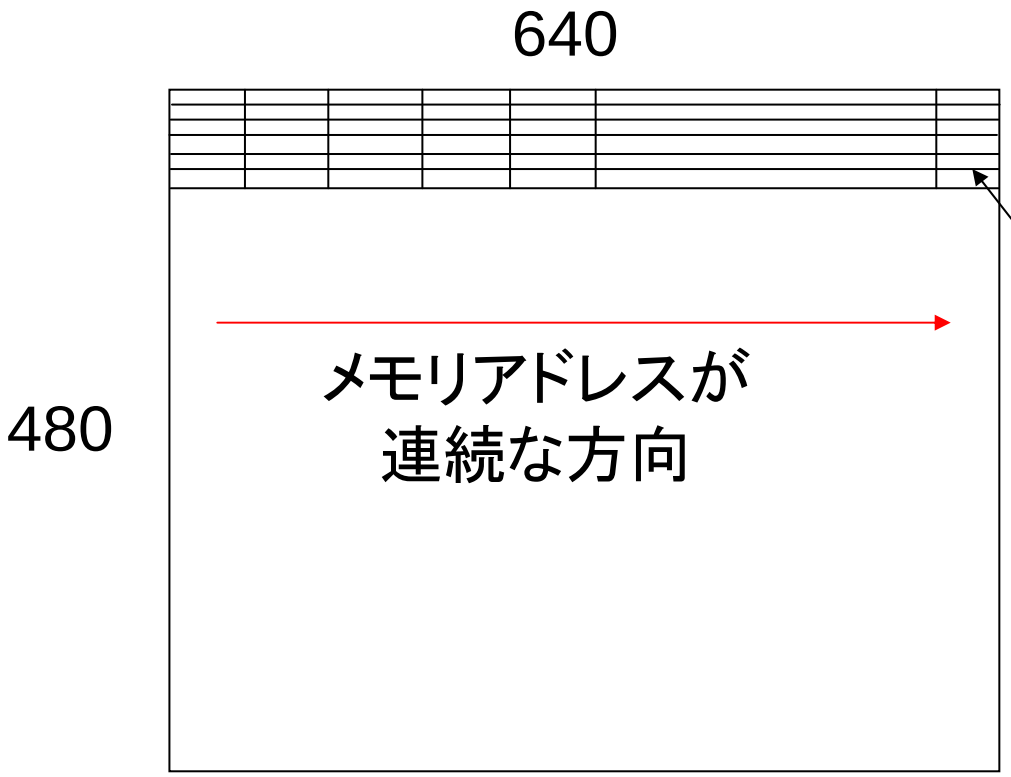

640x480画素，8ビットモノクロ画像が1枚で約 300 KB

連続する N 画素が
キャッシュ1ライン
(ハードウェアによる)

- 可能な限りメモリアドレスに対して連続にアクセスする方がよい
- キャッシュ内のデータの配置には制約があるので，キャッシュ容量ギリギリまで画像を読み込んでおけるわけではない

例: 表引き (table lookup)

事前計算の結果をメモリに保存しておき，実行時に参照する

```
#define OPT_LUT
```

… 色変換の計算を表引きに置き換える

メモリがボトルネックになり，速度を稼げない場合もある

例: データ転送・コピーの効率化

```
#define OPT_MEMCPY
```

… 現フレームの保存を for ループで1画素ずつコピーする代わりに memcpy() 関数で行う

可能な場合は memcpy(), memset() などを用いる方が高速になることが多い

例: 画素アドレス計算の最適化

```
#define OPT_INDEX
```

… 画素データが格納されているアドレスを毎回計算するのは（特にシーケンシャルにアクセスする場合は）無駄であり，可読性を犠牲にすればより高速化可能

```
#define PIXVAL(img, i, j)
(*(uchar *)((img)->imageData + (y) * (img)->widthStep + (x)))
```

```
for (j = 0; j < height; j++) {
    for (i = 0; i < width; i++) {
        PIXVAL(img, i, j) = ...
    }
}
```

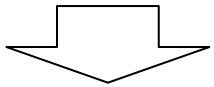

```
uchar *ptr;
int gap = img->widthStep – width;

for (j = 0, ptr = img->imageData; j < height; j++, ptr += gap) {
    for (i = 0; i < width; i++, ptr++) {
        *ptr = ...
    }
}
```

例: ループ融合

```
#define OPT_FUSION
```

… 複数のループを，ひとつのループに融合

条件分岐のオーバヘッドが減る効果もあるが，メモリアクセスの局所化による貢献も大きい

逆に，ループ内が独立した複数の処理で構成されているは，複数のループに分解する方が高速化される場合もある（ループ分散）

```
for (j = 0; j < img->height; j++) {
    for (i = 0; i < img->width; i++) {
        f(PIXVAL(img, i, j));
    }
}
for (j = 0; j < img->height; j++) {
    for (i = 0; i < img->width; i++) {
        g(PIXVAL(img, i, j));
    }
}
```

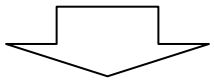

```
for (j = 0; j < img->height; j++) {
    for (i = 0; i < img->width; i++) {
        f(PIXVAL(img, i, j));
        g(PIXVAL(img, i, j));
    }
}
```

例: ループ展開

```
#define OPT_UNROLL
```

… 繰り返し回数の多いループを，一部手動で展開する．(例えば1000回のループを100回のループに置きかえ，1ループ内に10回分の処理を手書きする)

分岐命令のオーバヘッドの削減と，1ループ内での命令スケジューリングの自由度向上に貢献する

各変更内容の説明

0. baseline
  OpenCV 標準関数を使用
1. baseline_naivediff
  OpenCV 標準関数を使うが，フレーム間差分のみ素朴な実装
2. naive
  OpenCV 標準関数を使用せず，素朴な実装
3.interchange
  ループ交換により，Y方向にスキャン
4. lut
  色変換で表引きを行う
5. memcpy
  表引き + コピー時に memcpy() を使う
6. index
  表引き + memcpy() + ループインデックスの最適化
7. fusion
  表引き + memcpy() + ループインデックスの最適化 + ループ融合
8. unroll
  表引き + memcpy() + ループインデックスの最適化 + ループ融合 + ループ展開

結果一覧

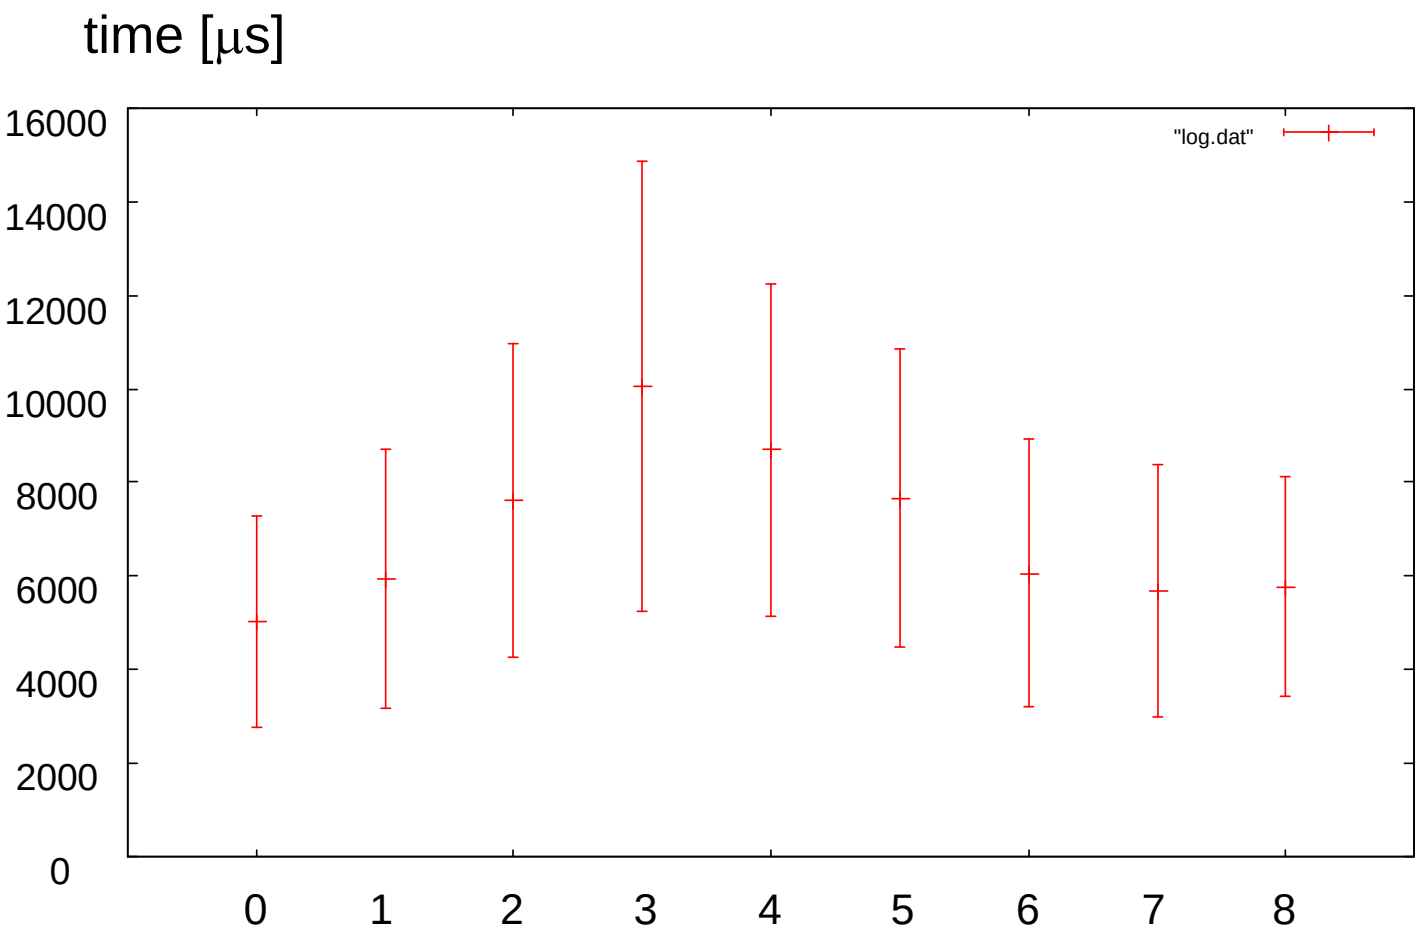

- Core i7-2640M
  2.8 GHz
- L1 I-Cache
  64 KB?
- L1 D-Cache
  64 KB?
- L2 Cache
  512 KB?
- Smart Cache
  4 MB? (L3?)

参考: 以前の結果1

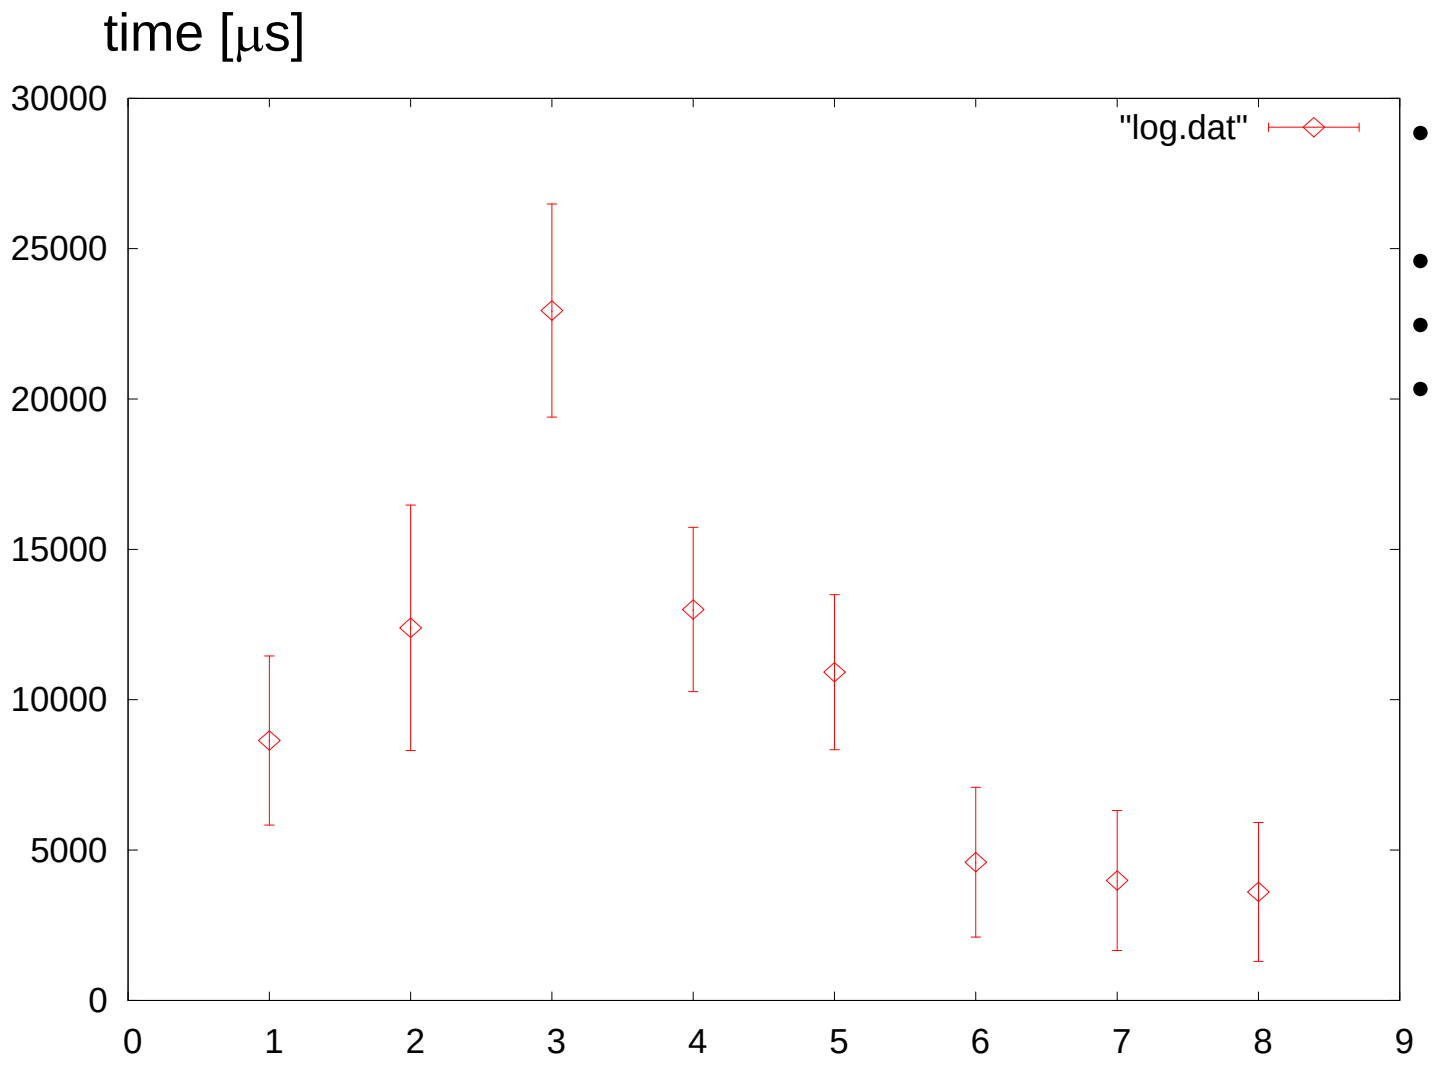

- Core2 Duo U9300 1.2 GHz
- L1 I-cache 32 KB
- L1 D-cache 32 KB
- L2 cache 3 MB?

ただし 0: baseline はデータ無し (次ページも同じ)

参考: 以前の結果2

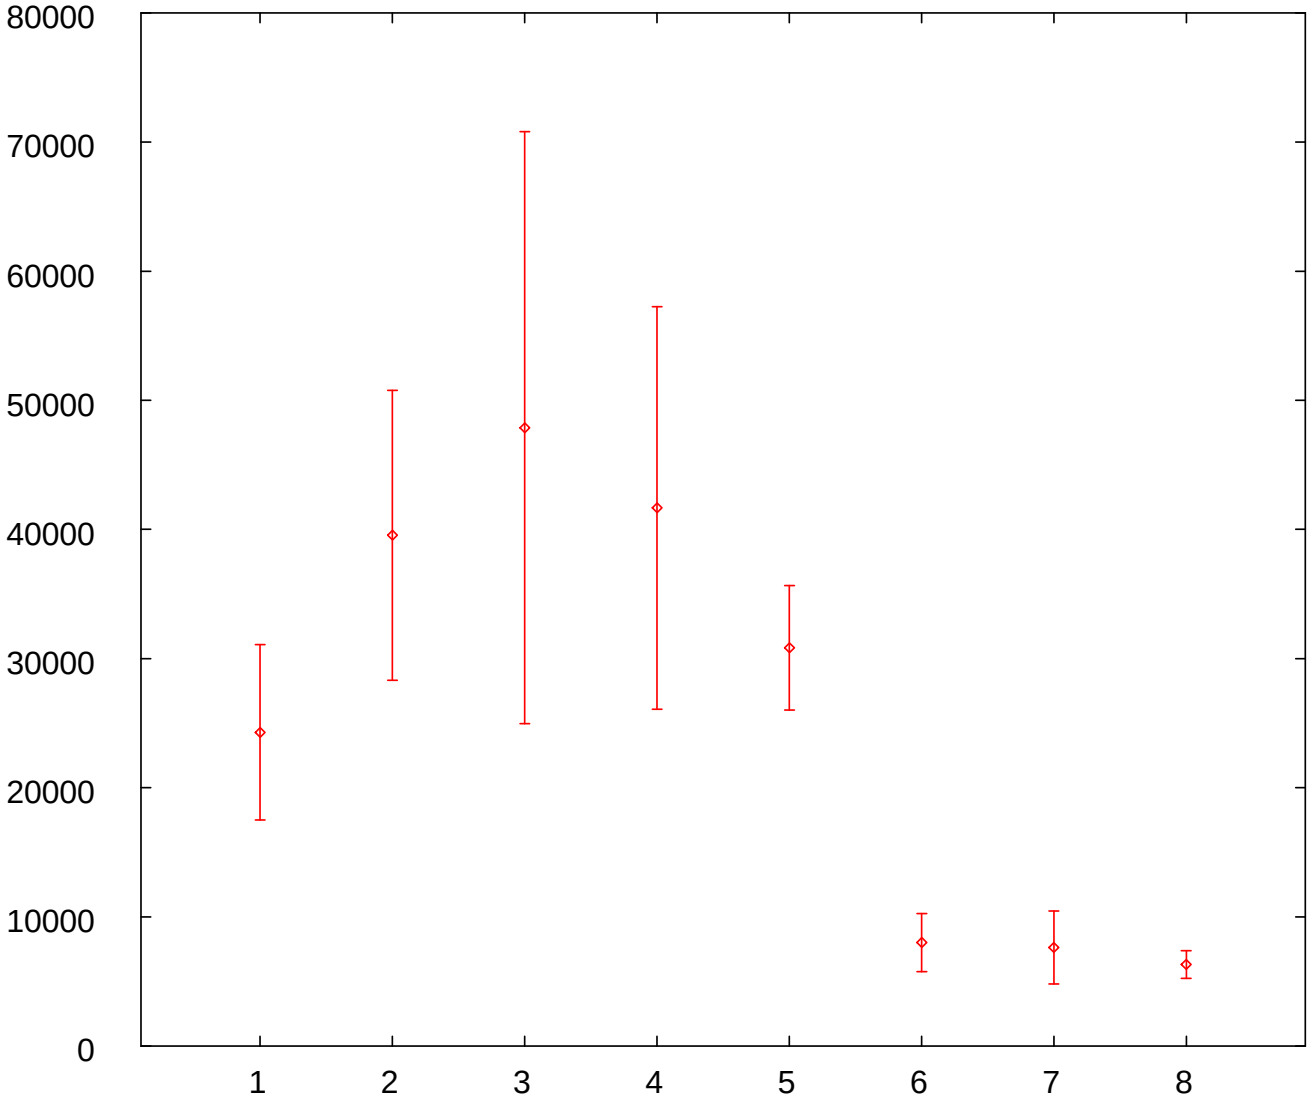

- Pentium M 1.3 GHz
- L1 I-cache 32 KB
- L1 D-cache 32 KB
- L2 cache 2 MB

まとめ

- まず，以上の結果はあくまでも，今回の処理に対して，今回のハードウェアでは結果的にこうだった，というだけである点に注意する．(2年前の結果とは激変している)

- 表引き，memcpy，画素アクセスインデックスの最適化はそこそこの効果．ループ方向の x, y 交換の影響もそこそこ．しかし2年前ほど劇的な効果は出ていない．
- そもそも Core2 Duo 1.2 GHz の頃と比べて高速化しにくくなっている? (その代わり極端に遅くもなりにくい?) おそらくそろそろ真面目に並列化に取り組まないと性能は見込めなさそうな気配．

- 一般に，計算の高速化とコードの保守性・可読性を両立するのは簡単ではないため，バランス感覚が重要．

さらなる高速化のために

さらなる高速化のためには，並列化の利用が重要.

- SIMD命令 (MMX, SSE, AVX)
- グラフィックプロセッサ (GPU) の利用
- マルチスレッド化によって複数のコアに処理を割り当てる