Estrutura do tema Avaliação de Desempenho (IA32)

1. A avaliação de sistemas de computação
2. Técnicas de optimização de código (IM)
3. Técnicas de optimização de *hardware*
4. Técnicas de optimização de código (DM)
5. Outras técnicas de optimização
6. Medição de tempos

Análise de técnicas de optimização *(s/w)*

- técnicas de optimização de código (indep. máquina)
  - *já visto...*
- técnicas de optimização de código (dep. máquina)
  - dependentes do processador *(já visto...)*
- **outras técnicas de optimização**
  - **na compilação: optimizações efectuadas pelo `Gcc`**
  - **na identificação dos "gargalos" de desempenho**
    - ***code profiling***
    - **uso dum *profiler* para apoio à optimização**
    - **lei de Amdahl**
  - **dependentes da hierarquia da memória**
    - **a localidade espacial e temporal dum programa**
    - **influência da *cache* no desempenho**


```
Options That Control Optimization
These options control various sorts of optimizations:
-O
-O1
    Optimize. Optimizing compilation takes somewhat more time, and a lot
    more memory for a large function. (...)
    With -O, the compiler tries to reduce code size and execution time,
    without performing any optimizations that take a great deal of
    compilation time.
-O2
    Optimize even more. GCC performs nearly all supported optimizations
    that do not involve a space-speed tradeoff. (...) this option
    increases both compilation time and the performance of the generated
    code.
    -O2 turns on all optional optimizations except for loop unrolling,
    function inlining, and register renaming.
-O3
    Optimize yet more. -O3 turns on all optimizations specified by -O2 and
    also turns on the -finline-functions and -frename-registers options.
-O0
    Do not optimize.
-Os
    Optimize for size. -Os enables all -O2 optimizations that do not
    typically increase code size. It also performs further optimizations
    designed to reduce code size.
```



```
Optimizações para código com arrays e loops:
-funroll-loops
    Unroll loops whose number of iterations can be determined at
    compile time or upon entry to the loop. -funroll-loops implies
    both -fstrength-reduce and -frerun-cse-after-loop. This option
    makes code larger, and may or may not make it run faster.
-funroll-all-loops
    Unroll all loops, even if their number of iterations is
    uncertain when the loop is entered. This usually makes programs
    run more slowly. -funroll-all-loops implies the same options as
    -funroll-loops,
-fprefetch-loop-arrays
    If supported by the target machine, generate instructions to
    prefetch memory to improve the performance of loops that access
    large arrays.
-fmove-all-movables
    Forces all invariant computations in loops to be moved outside
    the loop.
-freduce-all-givs
    Forces all general-induction variables in loops to be strength-
    reduced.
```

Optimizações para inserção de funções em-linha:

-finline-functions

Integrate all simple functions into their callers. The compiler heuristically decides which functions are simple enough to be worth integrating in this way. If all calls to a given function are integrated, and the function is declared static, then the function is normally not output as assembler code in its own right.

-finline-limit=*n*

By default, gcc limits the size of functions that can be inlined. This flag allows the control of this limit for functions that are explicitly marked as inline (ie marked with the inline keyword ...) *n* is the size of functions that can be inlined in number of pseudo instructions (not counting parameter handling). The default value of *n* is 600. Increasing this value can result in more inlined code at the cost of compilation time and memory consumption. Decreasing usually makes the compilation faster and less code will be inlined (which presumably means slower programs).

Acção

`gcc -O2 -pg prog. -o prog`

`./prog`

- executa como habitual/, mas tb gera o ficheiro `gmon.out`

`gprof prog`

- GNU *profiler*: a partir de `gmon.out` gera informação que caracteriza o perfil do programa

Factos

- calcula (aproximadamente) o tempo gasto em cada função
- método para cálculo do tempo (*mais detalhe adiante*)
  - periodicamente (~ cada 10ms) interrompe o programa
  - determina que função está a ser executada nesse momento
  - incrementa o seu temporizador de um intervalo (por ex., 10ms)
- para cada função mantém ainda um contador (nº de vezes que foi invocada)

Uso do `GProf` em 3 passos:

- **compilar com indicação explícita (`-pg`)**
  - ex.: análise do `combine1_sum_int` (vector com 10^7 elementos)

    `gcc -O2 -pg combine1_sum_int.c -o comb1`
- **executar o programa**

  `./comb1`
  - vai gerar automaticamente o ficheiro `gmon.out`
- **invocar o GProf para analisar os dados em `gmon.out`**

  `gprof comb1.exe [ > comb1.txt ]`
  - análise parcial do ficheiro `comb1.txt` a seguir…

Análise da primeira parte de `comb1.txt`:

Flat profile:

Each sample counts as 0.01 seconds.

% time	cumulative seconds	self seconds	calls	self s/call	total s/call	name
39.33	2.58	2.58				_mcount
38.57	5.11	2.53	20000000	0.00	0.00	get_vec_element
12.65	5.94	0.83				mcount
6.40	6.36	0.42	2	0.21	1.57	combine1
3.05	6.56	0.20	20000002	0.00	0.00	vec_length
0.00	6.56	0.00	2	0.00	0.00	access_counter
0.00	6.56	0.00	1	0.00	0.00	get_counter
0.00	6.56	0.00	1	0.00	0.00	new_vec
0.00	6.56	0.00	1	0.00	0.00	start_counter

Análise em árvore da execução do prog. (em `comb1.txt`):

```
 index  % time    self  children    called              name
                  0.42    2.73         2/2                  main [2]
[1]      100.0    0.42    2.73         2                combine1 [1]
                  2.53    0.00 20000000/20000000            get_vec_element [3]
                  0.20    0.00 20000002/20000002            vec_length [4]
-----------------------------------------------
                                                        <spontaneous>
[2]      100.0    0.00    3.15                          main [2]
                  0.42    2.73         2/2                  combine1 [1]
                  0.00    0.00         1/1                  new_vec [11]
                  0.00    0.00         1/1                  start_counter [12]
                  0.00    0.00         1/1                  get_counter [10]
-----------------------------------------------
                  2.53    0.00 20000000/20000000            combine1 [1]
[3]       80.3    2.53    0.00    20000000              get_vec_element [3]
-----------------------------------------------
                  0.20    0.00 20000002/20000002            combine1 [1]
[4]        6.3    0.20    0.00    20000002              vec_length [4]
-----------------------------------------------
                  0.00    0.00         1/2                  start_counter [12]
                  0.00    0.00         1/2                  get_counter [10]
[9]        0.0    0.00    0.00         2                access_counter [9]
…
```

Vantagens

- ajuda a identificar os gargalos de desempenho
- particularmente útil em sistemas complexos com muitos componentes

Limitações

- apenas analisa o desempenho para o conjunto de dados de teste
- a metodologia de medição de tempos é rudimentar
  - apenas usável em programas com tempos de exec > 3 seg

O ganho no desempenho – *speedup* - obtido com a melhoria do tempo de execução de uma parte do sistema, está limitado pela fracção de tempo que essa parte do sistema pode ser utilizada.

$$\textit{Overall speedup} = \frac{Tempo_exec_{antigo}}{Tempo_exec_{novo}} = \frac{1}{(1-f)+f/s}$$

em que **f** – fracção de um programa que é melhorado,
s – *speedup* da parte melhorada

Ex.1
Se 10% de um prog executa 90x mais rápido, então

Overall speedup **= 1.11**

Ex.2
Se 90% de um prog executa 90x mais rápido, então

Overall speedup **= 9.09**

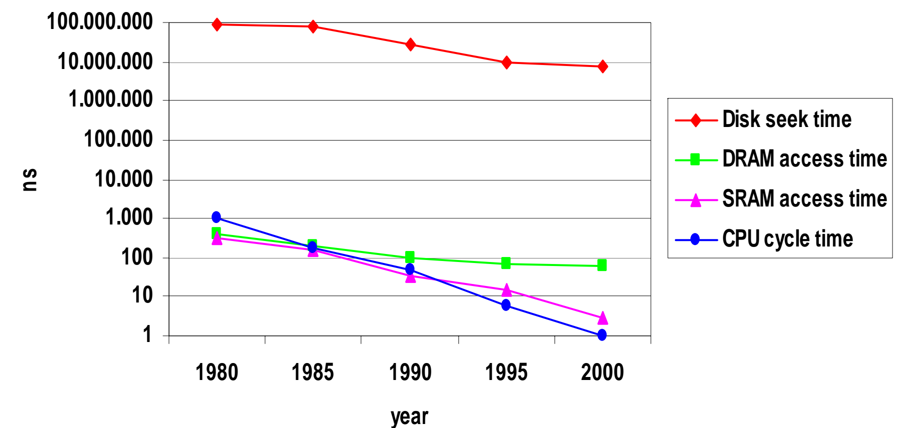

Princípio da Localidade:

– programas tendem a reusar dados e instruções próximos daqueles que foram recentemente usados, ou que foram recentemente referenciados por eles

- **Localidade Espacial** : itens em localizações contíguas tendem a ser referenciados em tempos próximos
- **Localidade Temporal** : itens recentemente referenciados serão provavelmente referenciados no futuro próximo

Exemplo da Localidade :

```
sum = 0;
for (i = 0; i < n; i++)
    sum += a[i];
return sum;
```

•Dados

– os elementos do *array* são referenciados em instruções sucessivas: **Localidade Espacial**

– a variável `sum` é acedida em cada iteração: **Localidade Temporal**

•Instruções

– as instruções são acedidas sequencial/: **Localidade Espacial**

– o ciclo é repetidamente acedido: **Localidade Temporal**

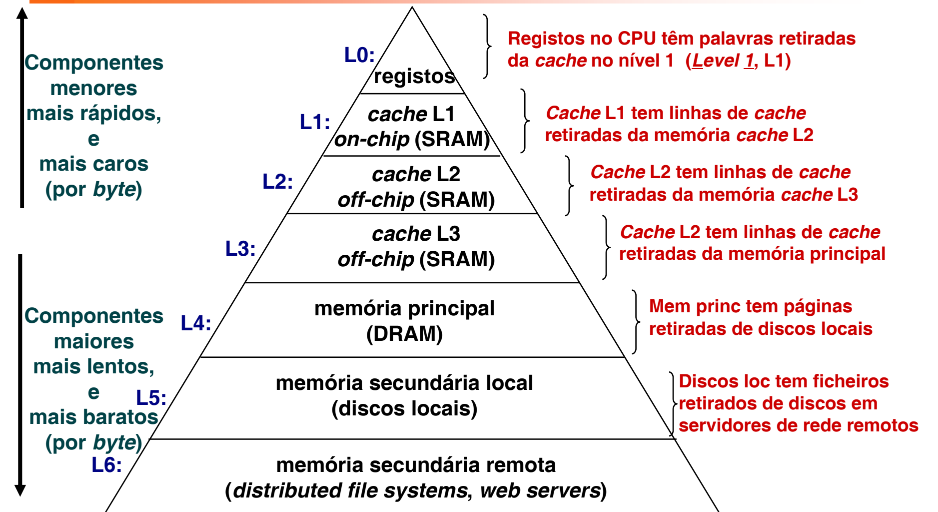

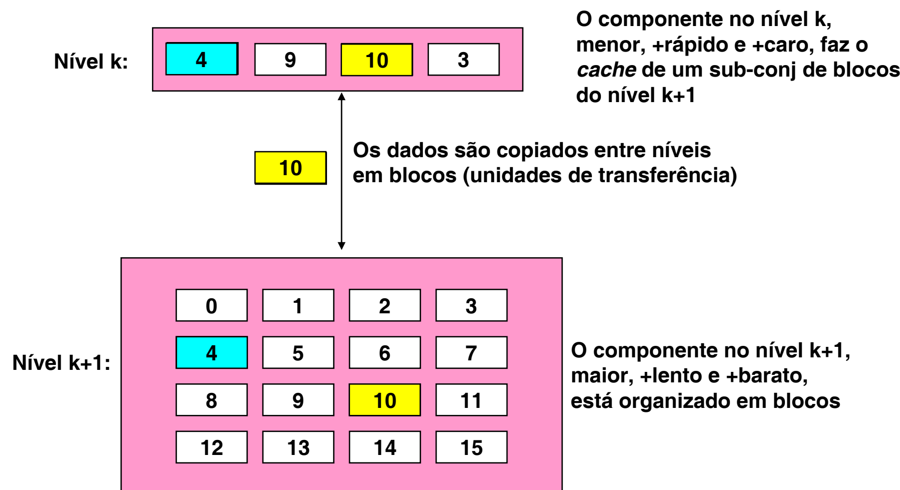

O componente no nível k, menor, +rápido e +caro, faz o *cache* de um sub-conj de blocos do nível k+1

Os dados são copiados entre níveis em blocos (unidades de transferência)

O componente no nível k+1, maior, +lento e +barato, está organizado em blocos

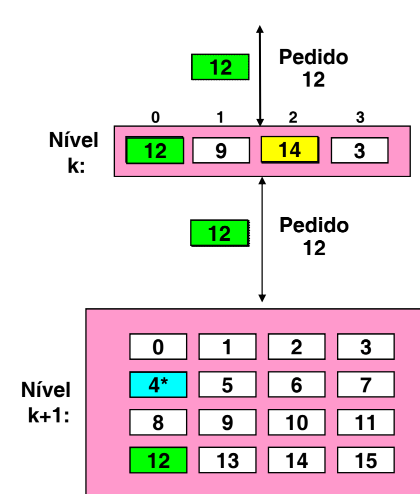

Um programa pede pelo objecto **d**, que está armazenado num bloco **b**

Cache hit

– o programa encontra **b** na *cache* no nível k. Por ex., bloco 14

Cache miss

– **b** não está no nível k, logo a cache do nível k deve buscá-lo do nível k+1. Por ex., bloco 12

– se a *cache do* nível k está cheia, então um dos blocos deve ser substituído (retirado); qual?

- *Placement policy*: onde colocar o novo bloco? Por ex., `b mod 4`
- *Replacement policy:* que bloco deve ser retirado? Por ex., LRU

Miss Rate

- percentagem de referências à memória que não tiveram sucesso na *cache* (*misses* / acessos)
- valores típicos:
  - 3-10% para L1
  - pode ser menor para L2 (< 1%), dependendo do tamanho, etc.

Hit Time

- tempo para a *cache* entregar os dados ao processador (inclui o tempo para verificar se a linha está na *cache*)
- valores típicos :
  - 1 ciclo de *clock* para L1
  - 3-8 ciclos de *clock* para L2

Miss Penalty

- tempo extra necessário para ir buscar uma linha após *miss*
  - tipicamente 25-100 ciclos para aceder à memória principal

Referenciar repetidamente uma variável é positivo!
(localidade temporal)

Referenciar elementos consecutivos de um *array* é positivo!
(localidade espacial)

Exemplos:

- ***cache* fria, palavras de 4-*bytes*, blocos (linhas) de *cache* com 4-palavras**

```
int sumarrayrows(int a[M][N])
{
    int i, j, sum = 0;

    for (i = 0; i < M; i++)
        for (j = 0; j < N; j++)
            sum += a[i][j];
    return sum;
}
```

Miss rate = 1/4 = 25%

```
int sumarraycols(int a[M][N])
{
    int i, j, sum = 0;

    for (j = 0; j < N; j++)
        for (i = 0; i < M; i++)
            sum += a[i][j];
    return sum;
}
```

Miss rate = 100%