

Arquitetura de Computadores

MIEI – 2021/22

DI-FCT/UNL

Hierarquia de Memória
Introdução à memória Cache

Sumário

- Hierarquia de níveis de memória
- Tecnologias de Memória
- Localidade
- Conceito de Cache

Bibliografia:

Bryant, O'Hallaron Computer Systems: A Programmer's Perspective, 2nd ou 3rd Ed, secções 6.1.1, 6.2, 6.3, 6.5 e 6.6

Desempenho dos sistemas

- Um sistema tem melhor desempenho se produzir os mesmos resultados em menos tempo
- A melhoria introduzida num sistema (***speedup***) é dada por:

$$S = \text{tempo antigo} / \text{novo tempo}$$

Exemplo: um programa passou a executar em 5s quando antes executava em 6s:

$$S = 6/5 = 1,2 \text{ (corresponde a 1,2x mais rápido)}$$

- $S = 1$ significa que não há alteração
- $S = 2$ significa que passou a metade do tempo
- $S < 1$ significa que piorou

Influência dos componentes

- Componentes software:
 - Programa (algoritmos e estruturas de dados), linguagens, bibliotecas, S.O., etc...
- Componentes hardware:
 - CPU, Memória, Buses, Periféricos, etc...
- Então... **exemplo:**
 - Um programa não executa 2x mais rápido só porque usamos um CPU 2x mais rápido!
 - O *speedup* obtido será proporcional ao tempo de execução do CPU no tempo total do programa...
 - os tempos de espera pela memória, periféricos, etc. mantêm-se

Exemplo – o que é melhor?

- Considere um sistema que distribui o tempo total de execução nas actividades A e B:



- Se actividade B é tornada 5x mais rápida:




- Se actividade A é tornada 2x mais rápida:




Na arquitectura de computadores

- Procura-se otimizar os vários componentes na medida do respectivo peso nos tempos de execução dos nossos sistemas



Hierarquia de níveis de memória

- Maior capacidade → maior o tempo de acesso



Tecnologia de memória

- Todas as memórias rápidas são baseadas em semicondutores
- *Dynamic Random Access Memory* (DRAM)
 - DRAM oferece a melhor relação preço/desempenho, mas necessita de refrescamento periódico e após cada leitura
- *Static Random Access Memory* (SRAM)
 - SRAM é mais rápida mas muito mais cara, consome mais energia e ocupa mais espaço
- A memória RAM dos computadores é DRAM

Tendências


SRAM	1980	1985	1990	1995	2000	2005	2010	2020	2010:1980
\$/MB	19 200	2 900	320	256	100	75	60	0.5	320x
access (ns)	300	150	35	15	3	2	1.5	1 200x	

DRAM	1980	1985	1990	1995	2000	2005	2010	2020	2020 vs 1980
\$/MB	8 000	880	100	30	1	0.1	0.06	0.006	1300 000x
access (ns)	375	200	100	70	60	50	40	10	37.5x
typical size (MB)	0.064	0.256	4	16	64	2 000	8 000	16 000	250 000x

Disk	1980	1985	1990	1995	2000	2005	2010	2010:1980
\$/MB	500	100	8	0.30	0.01	0.005	0.0003	1 600 000x
access (ms)	87	75	28	10	8	4	3	29x
typical size (MB)	1	10	160	1000	20 000	160 000	1 500 000	1 500 000x


CPU-Memory Gap

As diferenças de velocidade entre RAM ou disco e o CPU têm aumentado



Hierarquia de níveis de memória

- Procura-se ter os dados a usar na memória mais rápida → mais “perto” do CPU



Migração dos dados para “cima”

- Porquê de usar registos? Porque não executar sempre em memória?
- Porquê trazer os programas para memória? Porque não executar diretamente do disco?
- Desempenho vs. possibilidade tecnológica e custos
- O SO tenta trazer para memória o que está no disco
 - As aplicações e os dados que as aplicações leem
- O código nos programas procura tirar o melhor partido dos registos
 - Variáveis são copiadas para os registos

Princípio da Localidade

- Os programas têm padrões de acesso a memória:
 - **Localidade temporal**: items referenciados recentemente tendem a voltar a sê-lo.
 - **Localidade espacial**: items com endereços próximos tendem a ser referenciados em conjunto.

Exemplo:

Dados

Elementos do array são referenciados em sequência: **Localidade espacial**

`sum` referenciado em cada iteração:

Instruções

Instruções referenciadas em sequência: **Localidade espacial**

Ciclo : **Localidade temporal**

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

Localidade

- Os compiladores de C guardam as matrizes, na memória, linha a linha.
- Esta função tem boa localidade?

```
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;  
}
```

Resposta: Sim. Neste caso o percurso na matriz é feito linha a linha. Portanto faz-se sempre acesso a posições de memória contíguas.

Localidade

- Os compiladores de C guardam as matrizes, na memória, linha a linha.
- Esta função tem boa localidade?

```
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  
}
```


Resposta: Não. Neste caso o percurso da matriz é feito coluna a coluna; a sequência é $a[0][0]$, $a[1][0]$..., $a[M][0]$, $a[0][1]$... Portanto dois acessos consecutivos não fazem acesso a posições de memória contíguas.

Hierarquia de memória

- Propriedades fundamentais:
 - As tecnologias mais rápidas custam mais por byte e têm menor capacidade.
 - O fosso entre o CPU e a memória central está a aumentar.
 - Os bons programas tendem a ter boa localidade.
- Estas propriedades suportam:
 - abordagem do armazenamento como uma hierarquia de memória
 - Introduzir mais um nível de memória para tirar partido da localidade: queremos memória central DRAM com o desempenho da SRAM

Hierarquia de níveis de memória

- Poderemos ter mais um nível para que o programa que está a executar seja mais rápido?



Ideia da *Cache*

- **Cache:** Um dispositivo “invisível” que atua como zona temporária para armazenamento de dados de outro dispositivo mais lento mas maior.
- Ideias fundamentais:
 - No nível L, o dispositivo menor e mais rápido, guarda parte do conteúdo do dispositivo maior e mais lento do nível L+1
 - Baseado na localidade, procura-se ter no nível L os dados de L+1 mais prováveis de serem brevemente usados
 - A atualização dos dados em L deve ser transparente para o utilizador desse nível


Ideia da Cache

- Vantagens esperadas:
 - A localidade leva a que a maior parte dos acessos (leitura/escrita) sejam aos dados já no nível L em vez de ter de ir ao nível $L+1$.
 - O armazenamento no nível $L+1$ pode ser mais lento, e assim mais barato e muito maior.
 - Efeito global: Um grande conjunto de memória de custo semelhante ao nível mais baixo, mas que permite o acesso a um ritmo semelhante à do nível mais elevado.

Utilização da ideia

- O mesmo princípio é explorado a outros níveis
- Exemplos nos *browsers Web*:
 - Procuram manter no disco local os dados remotos
 - Mantém em memória os dados que estão a usar ou que podem vir a usar brevemente

Cache de memória



- Funcionamento:


CPU referencia memória:

se está em cache
accede à cache

senão
accede à memória
e actualiza cache

Hierarquia de níveis de memória

- Poderemos ter um, 2, ou 3 níveis de memória cache, gerida pelo *hardware*



A cache resulta?

```
/* ij */  
sum = 0.0;  
for (i=0; i<n; i++) {  
    for (j=0; j<n; j++) {  
        sum += a[i][j];  
    }  
}
```

```
/* ji */  
sum = 0.0;  
for (j=0; j<n; j++) {  
    for (i=0; i<n; i++) {  
        sum += a[i][j];  
    }  
}
```

