

## Organização de Computadores


### Aula 17

### Memória cache segunda parte


## Memória cache segunda parte

1. Mapeamento completamente associativo
2. Mapeamento direto
3. Mapeamento conjunto - associativo

### 1. Mapeamento completamente associativo



### Mapeamento completamente associativo



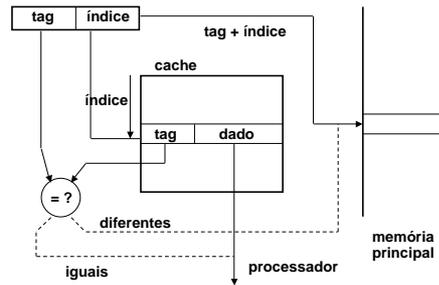
### Mapeamento completamente associativo

- vantagem: máxima flexibilidade no posicionamento de qualquer palavra (ou linha) da memória principal em qualquer palavra (ou linha) da cache
- desvantagens
  - custo em hardware da comparação simultânea de todos os endereços armazenados na cache
  - algoritmo de substituição (em hardware) para selecionar uma linha da cache como consequência de um miss
- utilizado apenas em memórias associativas de pequeno tamanho
  - tabelas

INF01113 - Organização de Computadores

### 2. Mapeamento direto

endereço gerado pelo processador



INF01113 - Organização de Computadores


### Mapeamento direto

- endereço é dividido em 2 partes
  - parte menos significativa: índice, usado como endereço na cache onde será armazenada a palavra
  - parte mais significativa: tag, armazenado na cache junto com o conteúdo da posição de memória
- quando acesso é feito, índice é usado para encontrar palavra na cache
  - se tag armazenado na palavra da cache é igual ao tag do endereço procurado, então houve hit
- endereços com mesmo índice são mapeados sempre para a mesma palavra da cache




INF01113 - Organização de Computadores

### Mapeamento direto

- mapeamento: endereço é o módulo do número de blocos na cache



INF01113 - Organização de Computadores



### Tamanho da linha

- em geral, uma linha maior aproveita melhor a localidade espacial MAS
  - linha maior significa maior miss penalty
    - demora mais tempo para preencher a linha
  - se tamanho da linha é grande demais em relação ao tamanho da cache, miss ratio vai aumentar
    - muito poucas linhas
- em geral, tempo médio de acesso =
 
$$\text{Hit Time} \times (1 - \text{Miss Ratio}) + \text{Miss Penalty} \times \text{Miss Ratio}$$

Miss Penalty vs Tamanho da linha: linear increase.

Miss Ratio vs Tamanho da linha: U-shaped curve, minimum at optimal line size.

Tempo médio de acesso vs Tamanho da linha: U-shaped curve, minimum at optimal line size.

explora localidade espacial, poucas linhas: compromete localidade temporal, Miss Penalty & Miss Ratio aumentam

INF01113 - Organização de Computadores

### Quantos bits tem a cache no total?

- supondo cache com mapeamento direto, com 64 KB de dados, linha com uma palavra, endereços de 32 bits
- 64 KB -> 16 Kpalavras,  $2^{14}$  palavras, neste caso  $2^{14}$  linhas
- cada linha tem 32 bits de dados mais um tag (32-14-2 bits) mais um bit de validade:  
 $2^{14} \times (32 + 32 - 14 - 2 + 1) = 2^{14} \times 49 = 784 \times 2^{10} = 784 \text{ Kbits}$
- 98 KB para 64 KB de dados, ou 50% a mais


INF01113 - Organização de Computadores

### Mapeamento direto

- vantagens
  - não há necessidade de algoritmo de substituição
  - hardware simples e de baixo custo
  - alta velocidade de operação
- desvantagens
  - desempenho cai se acessos consecutivos são feitos a palavras com mesmo índice
  - *hit ratio* inferior ao de caches com mapeamento associativo
- demonstra-se no entanto que *hit ratio* aumenta com o aumento da cache, aproximando-se de caches com mapeamento associativo
  - tendência atual é de uso de caches grandes

INF01113 - Organização de Computadores

### 3. Mapeamento conjunto – associativo



INF01113 - Organização de Computadores

### Mapeamento conjunto – associativo

- mapeamento direto: todas as palavras armazenadas na cache devem ter índices diferentes
- mapeamento associativo: linhas podem ser colocadas em qualquer posição da cache
- compromisso: um n° limitado de linhas, de mesmo índice mas diferentes tags, podem estar na cache ao mesmo tempo (num mesmo conjunto)
- n° de linhas no conjunto = associatividade

INF01113 - Organização de Computadores


### Mapeamento conjunto – associativo

- vantagem em relação ao mapeamento completamente associativo: comparadores são compartilhados por todos os conjuntos
- algoritmo de substituição só precisa considerar linhas dentro de um conjunto
- muito utilizado em microprocessadores
  - Motorola 68040: 4-way set associative
  - Intel 486: 4-way set associative
  - Pentium: 2-way set associative

INF01113 - Organização de Computadores


### Desvantagem da cache conjunto-associativo

- conjunto-associativa N-way X mapeamento direto
  - dado tem atraso extra do multiplexador
  - dado vem DEPOIS da decisão *Hit/Miss* e da seleção do conjunto
- numa cache com mapeamento direto, linha da cache está disponível ANTES da decisão *Hit/Miss*
  - possível assumir um *hit* e continuar. Recuperar depois se for *miss*.



INF01113 - Organização de Computadores

### Impacto da associatividade da cache




INF01113 - Organização de Computadores

### Fontes de misses

- **compulsórios (cold start ou chaveamento de processos, primeira referência):** primeiro acesso a uma linha
  - é um “fato da vida”: não se pode fazer muito a respeito
  - se o programa vai executar “bilhões” de instruções, *misses* compulsórios são insignificantes
- **de conflito (ou colisão)**
  - múltiplas linhas de memória acessando o mesmo conjunto da cache conjunto-associativa ou mesma linha da cache com mapeamento direto
  - solução 1: aumentar tamanho da cache
  - solução 2: aumentar associatividade
- **de capacidade**
  - cache não pode conter todas as linhas acessadas pelo programa
  - solução: aumentar tamanho da cache
- **invalidação: outro processo (p.ex. I/O) atualiza memória**

INF01113 - Organização de Computadores



### Quantidade de *misses* segundo a fonte

	Mapeam. direto	Conj.-associat. N-way	Complet. associativa
<b>Tamanho da cache</b>	Grande	Médio	Pequeno
<b><i>Misses</i> compulsórios</b>	Mesmo	Mesmo	Mesmo
<b><i>Misses</i> de conflito</b>	Alto	Médio	Zero
<b><i>Misses</i> de capacidade</b>	Baixo	Médio	Alto
<b><i>Misses</i> de invalidação</b>	Mesmo	Mesmo	Mesmo

INF01113 - Organização de Computadores