


Sistema de Memoria

Jerarquía de Memoria




El Cache

- ✓ El mecanismo más utilizado para compensar por la diferencia en velocidades entre el CPU y la memoria primaria (factor 1 a 10 típico)
- ✓ Es una memoria, mucho más rápida y mucho más pequeña que la memoria primaria
- ✓ Mantiene los valores de las localizaciones de memoria más frecuentemente accedidos por el CPU
- ✓ Puede ser invisible para el CPU


Efectividad del Cache





- ✓ El cache es efectivo por dos razones principales:
 - *Localidad temporera* - En un periodo de tiempo dado los accesos a memoria se concentran en un grupo relativamente pequeño de operandos.
 - *Localidad de espacio* - En un periodo de tiempo dado los accesos a memoria se concentran en grupos de operandos alojados en localizaciones adyacentes.

Patrón de Accesos a Memoria Generado por Programas



Organización de un Cache de 2048 Words y una Memoria de 64K Words





Cache Miss

Cuando no existe en el cache una copia de la localización generada por el CPU

- Se utiliza un algoritmo de reemplazo para escoger un bloque del cache (la víctima) para alojar el bloque de memoria donde se encuentra la localización generada por el CPU.
- Si el bloque víctima ha sido alterado por el cache, entonces ese bloque se escribe nuevamente a la memoria primaria.
- Se transfiere al cache el bloque de memoria que contiene la localización generada por el CPU.

Algoritmos de Reemplazo

- ✓ **First-In-First-Out (FIFO)** - Reemplaza el bloque que llegó primero al cache.
- ✓ **Least Recently Used (LRU)** - Reemplaza el bloque del cache que más tiempo lleva sin ser accedido.
- ✓ **Least Frequently Used (LFU)** - Reemplaza el bloque que menos veces se ha accedido.
- ✓ **Random** - Reemplaza un bloque al azar.
- ✓ **Optimo** - Reemplaza el bloque del cache que más tiempo va a pasar en ser accedido.

Ejemplos de Algoritmos de Reemplazo

| Bloque | 1 | 2 | 3 | 4 | 2 | 5 | 6 | 2 | 7 | 8 | 2 | 4 | 9 | 2 |
|--------|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| FIFO | 1 | 2 | 3 | 4 | 4 | 5 | 6 | 2 | 7 | 8 | 8 | 4 | 9 | 2 |
| Hit | | | | | | | | | | | | | | |
| LRU | 1 | 2 | 3 | 4 | 2 | 5 | 6 | 2 | 7 | 8 | 2 | 4 | 9 | 2 |
| Hit | | | | | | | | | | | | | | |
| Miss | | | | | | | | | | | | | | |
| DMAP | 1 | 2 | 2 | 2 | 1 | 5 | 5 | 5 | 5 | 5 | 5 | 9 | 9 | 9 |
| Hit | | | | | | | | | | | | | | |
| Miss | | | | | | | | | | | | | | |
| OPTIMO | 1 | 1 | 1 | 1 | 5 | 5 | 5 | 7 | 7 | 7 | 7 | 9 | 9 | 9 |
| Hit | | | | | | | | | | | | | | |
| Miss | | | | | | | | | | | | | | |

Consistencia de la Data en Memoria

- ✓ Debido a mecanismos como DMA la data en el cache no siempre es igual a la correspondiente data en memoria primaria (memoria y cache no son consistentes).
- ✓ Para mantener la consistencia de la data es necesario refrescar la memoria periódicamente con los bloques alojados en el "cache" que han sido alterados por el CPU.

Mecanismos para Mantener Consistencia entre Memoria y Cache

- ✓ **Write-back**
 - Se refresca la memoria cuando el bloque, que ha sido alterado, es reemplazado del cache.
 - Más conveniente para caches en microprocesadores, pues reduce el tráfico entre memoria primaria y el microprocesador.
- ✓ **Write-through**
 - Se refresca la memoria cuando se altera el bloque en el cache.
 - Más conveniente para sistemas que permiten accesos a la memoria mediante DMA, pues mantiene la memoria consistente con el cache todo el tiempo.

Mecanismos para Mantener Consistencia entre Memoria y Cache

- ✓ **Snooping**
 - El cache es notificado cuando alguna unidad trata de acceder directamente un bloque de memoria que tiene una copia en el cache.
 - El cache toma una acción dependiendo del tipo de acceso (read/write) y del tipo de snooping.
 - Existen dos tipos de snooping
 - Write- invalidate
 - Write-update

Snooping Write-Invalidate

- ✓ **Write Access:**
La otra unidad escribe en el bloque de memoria directamente y el correspondiente bloque en el cache se invalida.
- ✓ **Read Access:**
Si el bloque en el cache difiere del correspondiente bloque en memoria el cache lo envía a memoria y luego la otra unidad procede a accederlo.

Snooping Write-Update

- ✓ **Write Access:**
La otra unidad escribe directamente en el bloque de memoria y se envía una copia al cache.
- ✓ **Read Access:**
Si el bloque en el cache difiere del correspondiente bloque en memoria el cache lo envía a memoria y luego la otra unidad procede a accederlo.

Prefetching

Se alojan bloques en el cache antes de que se necesiten


- Se puede implementar via software mediante una instrucción de prefetch
(El compilador debe insertar en el código estas instrucciones)
- Puede tener los siguientes efectos:
 - mejorar el hit ratio
 - resultar en transferencias innecesarias cuando los bloques no son accedidos por el programa
 - reducir el hit ratio

Lockup-Free Caches

- ✓ Permiten acceso al CPU aún mientras procesan uno o más misses
- ✓ El CPU no se estanca cuando ocurre un miss
- ✓ Reducen pipeline interlocks causados por accesos a memoria


Memoria Virtual


- ✓ Permite al sistema operativo administrar la transferencia de data entre memoria primaria y memoria secundaria.
- ✓ Provee un mecanismo al sistema operativo para proteger la data entre usuarios y restringir su uso.
- ✓ Permite la ejecución de programas más grandes que la memoria primaria físicamente instalada.
- ✓ Facilita el multiprocesamiento.



Paging

- ✓ Las transferencias entre memoria primaria y memoria secundaria se hacen en bloques de words denominados páginas
- ✓ Los tamaños típicos de páginas son de 4KB a 16K (32KB a 64KB para nuevos micros)
- ✓ La páginas se transfieren a memoria primaria en demanda (cuando el programa las necesita).
- ✓ Utiliza un tabla de páginas ubicar las páginas de un programa en memoria física o en memoria secundaria.
- ✓ Cuando las páginas no se encuentran en memoria física se genera un "page fault" (un interrupt que entrega control al sistema operativo).






- ### Page Fault
- ✓ Genera un interrupt que entrega control de ejecución al sistema operativo
 - ✓ Cambia de modo de operación de usuario a modo de operación supervisor
 - ✓ Realiza un procedimiento para traer a memoria física la página que contiene la localización virtual que generó el programa

- ### Procedimiento del Sistema Operativo para Atender Page Faults
1. Detiene la ejecución del programa y pone a correr otros programas (context switch).
 2. Selecciona mediante un algoritmo de reemplazo una página de memoria física para ubicar la página solicitada.
 3. Si la página a ser reemplazada ha sido alterada por el CPU, instruye a un puerto para transferirla a la unidad de almacenamiento secundaria correspondiente.
 4. Utiliza la tabla de página del programa para ubicar la página en la unidad de almacenamiento secundaria.
 5. Instruye a un puerto a transferir la página solicitada a la página de memoria física seleccionada.
 6. Pone a correr el programa luego que la página es transferida a memoria física.

- ### Bits de Control
- ✓ **Valid Bit** - Indica si la página virtual se encuentra alojada en memoria física.
 - ✓ **Dirty Bit** - Indica si la página virtual ha sido alterada en la memoria física.
 - ✓ **Read Bit** - Indica si la página puede ser leída por el programa que trata de tener acceso a la misma.
 - ✓ **Write Bit** - Indica si la página puede ser escrita por el programa que trata de tener acceso a la misma.
 - ✓ **Execute Bit** - Indica si el código alojado en la página puede ser ejecutado por el programa que intenta ejecutarlo.

- ### Translation Lookaside Buffer (TLB)
- ✓ Es un cache "fully associative" de traducciones de páginas virtuales a físicas
 - ✓ Acelera la traducción de páginas



Segmentación

- ✓ Los programas se rompen en secciones de largo variable que se pueden ubicar en cualquier lugar de memoria
- ✓ La ubicación de segmentos en memoria se puede hacer utilizando estrategias como "first fit", "best fit" o "worst fit"
- ✓ Cada proceso tiene una tabla de segmentos
- ✓ Es propenso a fragmentación


141

Estrategias de Ubicación de Segmentos

- ✓ **First Fit** - ubicar el segmento en el primer espacio libre de memoria en que quepa
- ✓ **Best Fit** - ubicar el segmento en el espacio libre de memoria más pequeño en que quepa
- ✓ **Worst Fit** - ubicar el segmento en el espacio libre de memoria más grande en que quepa


142

Efecto de Estrategias de Ubicación de Segmentos



143

Fragmentación



144