

Administración de memoria: Funciones y operaciones

Gunnar Wolf



Índice

- 1 Introducción
- 2 Espacio de direccionamiento
- 3 EI MMU
- 4 Espacio en memoria
- 5 Resolución de direcciones



El administrador de memoria

- Es otra de las partes *fundamentales* de un sistema operativo
- En toda computadora basada en von Neumann, la memoria es el *único* almacenamiento a que tiene acceso directo el procesador
 - Todo otro almacenamiento tiene que pasar a través de controladores externos
 - Típicamente manejado a través de *memoria mapeada* o de *acceso directo*
- Todo proceso que ejecutemos debe estar *en* memoria
 - El administrador de memoria es el encargado de permitir que varios procesos la compartan



La memoria caché

- El manejo del caché es *casi* transparente para el sistema operativo
- Busca resolver el diferencial (creciente) de velocidad entre el CPU y la memoria
 - La memoria de alta velocidad que maneja el caché es mucho más cara
 - Comienza a entrar en juego la velocidad de los electrones sobre pistas de cobre
- Vimos ya que el OS tiene que saber al respecto: *Afinidad* de procesos a CPU
- Cuando se produce una *falla de caché* (no tiene copia de la dirección solicitada), es necesario *detener* al CPU
 - Insertando una *burbuja* o NOOP → *stall* (detención)



¿Por qué el caché?: Localidad de referencia

Se ha observado que prácticamente todos los procesos responden al principio de *localidad de referencia*:

Localidad temporal Es probable que un recurso que fue empleado recientemente vuelva a ser empleado en un futuro cercano.

Localidad espacial La probabilidad de que un recurso *aún no requerido* sea accesado es mucho mayor si fue requerido algún recurso cercano.

Localidad secuencial Un recurso, y muy particularmente la memoria, tiende a ser requerido de forma secuencial.
(Caso especial de *Localidad espacial*)



Ilustrando la localidad de referencia




Figura: Patrones de acceso a memoria (Silberschatz, p.350)



Índice

- 1 Introducción
- 2 Espacio de direccionamiento
- 3 El MMU
- 4 Espacio en memoria
- 5 Resolución de direcciones



Abstracción de la memoria

- La memoria se presenta ante el CPU como un arreglo direccionable
- Cada byte tiene una dirección única y consecutiva
 - En algunas arquitecturas, las solicitudes deben estar *alineadas* (por ejemplo, a 64 bits), y no estarlo causa una *trampa* o *falta*, incurriendo en demoras
 - Sin embargo, las direcciones siguen siendo de cada *byte*
- Para operar sobre *bits* específicos, tenemos que pedir el byte, trabajar sobre de él y enviarlo de vuelta — Como una unidad.



Espacio de direccionamiento: ¿Hasta dónde puedes contar?

- Cada arquitectura de procesador tiene un *espacio de direccionamiento* determinado
 - Siempre es una potencia de 2, y *casi siempre* en números cerrados (8, 16, 32, 64)
- Es el máximo de memoria que dicho procesador puede ver
 - Virtual* Lo máximo que la arquitectura ofrece como una dirección de memoria
 - Físico* Lo máximo que *un procesador específico* puede direccionar (limitado por su número de pines)



Procesadores de 16 bits

- Un procesador con *espacio de direccionamiento* de 16 bits puede referirse *directamente* a hasta 2^{16} (65,536) bytes.
- Principales procesadores de este tipo: Intel 8080 y 8085, Zilog Z80, MOS 6502 y 6510
- Intel 8086/8088: Direcciona hasta 20 bits (1024KB)
 - Pero al ser una arquitectura *real* de 16 bits, requiere emplear *segmentación* para alcanzar toda su memoria
- Intel 80286: espacio de direccionamiento de 24 bits (16 MB)
 - Pero su mercado era el mismo que el del 8086/8088, y por ciertas restricciones de su arquitectura, casi nunca se utilizó en estos modos



Procesadores de 32 bits

- Hoy en día, los procesadores dominantes son de 32 o 64 bits
- Un procesador de 32 bits puede direccionar hasta 4GB — 2^{32} bytes (4,294,967,296 bytes)
 - Hoy ya está dentro del rango de lo *alcanzable*
 - Por medio de *PAE* (Extensión de Direcciones Físicas, *Physical Address Extension*), puede extenderse hasta 2^{52} (aunque típicamente 2^{36} , 64GB)
 - PAE requiere un nivel adicional de *indirección* (lo veremos cuando cubramos *paginación*), por lo que pierde *un poco* de rendimiento, y cada proceso sigue viendo sólo hasta 4GB.



Procesadores de 64 bits

- Un procesador de 64 bits puede direccionar hasta 16 exabytes — 2^{64} bytes (18,446,744,073,709,551,616 bytes)
- El hardware actual está limitado por un criterio económico a entre 2^{34} y 2^{48} bits, 16GB y 256TB
 - El costo de más de 256TB RAM hace extremadamente improbable que sea requerido en suficientes procesadores de propósito general
 - En un sistema *actual* de escritorio, es muy poco probable llegar a requerir incluso más de 16GB
 - Cada bit de direccionamiento necesario requiere un pin en el CPU, por tanto, tiene un costo económico directo



¿Más allá?

- ¿Qué tan lejos podemos llegar?
- El número total de átomos en el universo está estimado en cerca de 2^{80}
- ¿Cuánto espacio (físico) necesitamos para nuestra memoria?
 - Por más que avance la miniaturización
- ¿Cuánto ancho de banda podemos esperar tener?
 - ¿Cómo podemos esperar llenar 64 bits de datos?



Índice

- 1 Introducción
- 2 Espacio de direccionamiento
- 3 El MMU**
- 4 Espacio en memoria
- 5 Resolución de direcciones



¿Qué es / qué hace el MMU?

- Casi todos los sistemas operativos modernos *requieren* de una *unidad de manejo de memoria* (MMU)
 - Hardware, hoy es parte integral del CPU
- Trabaja *muy* de cerca con el sistema operativo
- Encargado de funciones de control de permisos, seguridad, y traducción de direcciones
- “Vigilando” todos los accesos a memoria que ejecuta el código
- Existen sistemas operativos multitarea que pueden funcionar sin MMU
 - Pagan como precio la confiabilidad del sistema



¿Traducción de direcciones?

- Es común que un sistema requiera más memoria *de la que está directamente disponible*
 - Más memoria de la que existe
 - Más memoria de la que el hardware puede direccionar
- Un proceso no tiene por qué conocer los detalles de la asignación de memoria — Le damos una vista virtual simplificada
 - ¿Cuántos bloques de memoria me asignaron?
 - ¿Cuál es la ubicación de cada uno de ellos?
 - ¿Qué pasa si intento escribir (o leer) de donde tengo prohibido?
- A lo largo de esta unidad iremos viendo las estrategias para responder a esto.



Permisos

- El MMU verifica que un proceso no tenga acceso a datos de otro
 - A menos que sea *expresamente permitido* (vía el sistema operativo)
 - Hacer esta verificación desde el sistema operativo mismo incurriría en costos demasiado grandes
 - Una verificación estática no puede ser suficientemente exhaustiva
 - Direcciones construidas al vuelo
 - Modos indirectos de referencia a memoria
 - ...



Protección de acceso: Primera aproximación

La arquitectura nos ofrece dos registros de uso *específico*, y su modificación requiere una operación privilegiada / *modo supervisor*:

Registro base Apunta a la primer dirección de memoria que pertenece a este proceso

Registro límite Cantidad de memoria que pertenece a este proceso a partir del registro base

NOTA: Esto asume que los bloques de memoria asignados a cada proceso sean *contiguos*



Registros base y límite: Ejemplo (1)

- A un proceso le fue asignado un espacio de 64K (65535 bytes)
- A partir de la dirección 503808 (492K)

Esto se traduce a:

- El *registro base* contiene 503808 (0x7B000)
- El *registro límite* contiene 65535 (2^{16} , 0xFFFF)



Registros base y límite: Ejemplo (2)




Figura: Espacio de direcciones válidas para el proceso 3 definido por un registro base y un registro límite



Registros base y límite: Ejemplo (3)

Comportamiento del MMU

- Solicita acceso a $direcc < 503808 \rightarrow$ **Falla:**
 - Violación de segmento (*segmentation fault*)
- Solicita acceso a $503808 \leq direcc \leq 569343 \rightarrow$ **OK**
 - Se otorga acceso a la dirección
- Solicita acceso a $569343 < direcc \rightarrow$ **Falla:**
 - Violación de segmento (*segmentation fault*)



Índice


- 1 Introducción
- 2 Espacio de direccionamiento
- 3 El MMU
- 4 Espacio en memoria**
- 5 Resolución de direcciones



Estructura de un proceso en memoria

- Para ejecutar un proceso, el SO *casi nunca* se limita a volcar el ejecutable a memoria
 - Excepto en sistemas antiguos: Formato `.COM` de MS-DOS, archivos `.out` *reales* de Unixes antiguos
- Un proceso tiene diversas *regiones* de memoria, con usos muy diferentes:

- Pila de llamadas
- Espacio de *libres*
- Sección de datos
- Sección de texto



Sección de texto

- Imagen en memoria de las instrucciones
- Las direcciones más *bajas* del espacio asignado
- El procesador va *avanzando* sobre este espacio mediante el registro de instrucción
- Su contenido *normalmente* no debería cambiar
 - Aunque hay código legal auto-modificable. . .
 - Afortunadamente, cada vez menos



Sección de datos

- Espacio fijo preasignado para variables *globales*
- Se fija en *tiempo de compilación*
- Su tamaño no puede cambiar
 - Aunque los *datos* sí cambien



Espacio de *libres* (*Heap*)

- Espacio empleado para la asignación dinámica de memoria
- Asignado *en tiempo de ejecución*
- En lenguajes que requieren *manejo manual* de la memoria, aquí se manejan todas las estructuras dinámicas
 - En C: malloc, free
 - En C++: new, delete
- En lenguajes con *gestión automática*, es monitoreado por los *recolectores de basura*
- *Crece hacia arriba*



Pila de llamadas (*Stack*)

- Estructuras representando la serie de funciones que han sido llamadas dentro del proceso, incluyendo:
 - Parámetros
 - Direcciones de *retorno*
 - Variables locales
 - etc.
- Ocupa la parte *más alta* del espacio en memoria
- *Crece hacia abajo*
- Indica *el punto actual de ejecución* del programa
 - Equivalente a decir «*aquí*»



Índice

- 1 Introducción
- 2 Espacio de direccionamiento
- 3 El MMU
- 4 Espacio en memoria
- 5 Resolución de direcciones



¿Qué es la *resolución de direcciones*?

- Cuando escribimos un programa, sus funciones y variables son referidas por *nombre*
- El compilador va substituyendo los nombres por la *dirección en memoria* a donde debe referirse
 - Excepto en bibliotecas de ligado dinámico... Que abordaremos más adelante
- Pero en un sistema multiproceso, el compilador no necesariamente sabe dónde estará el espacio de memoria asignado al proceso
- Las direcciones indicadas en el *texto* del programa deben ser *traducidas* (o *resueltas*) a su ubicación definitiva
- Esto puede ocurrir en tres momentos...



En tiempo de compilación

- El texto de programa tiene la dirección *absoluta* de datos y funciones
- Muy común en arquitecturas no multiprocesadas
- En las PC tempranas, el formato ejecutable `.COM` es un *volcado de memoria* con las direcciones absolutas
 - Formato limitado a *un segmento* de memoria (64K — 16 bits, ¿Recuerdan?)
- Hoy en día vemos esto en sistemas embebidos, microcontroladores, o de función específica
 - p.ej. Arduino
- P.ej. la variable `contador` queda traducida en la imagen *en disco* como su dirección: 510200



En tiempo de carga

- El sistema operativo tiene una rutina llamada *cargador* (*loader*)
 - Le asiste frecuentemente el *ligador* (*linker*), para incluir en la *sección de texto* todas las bibliotecas externas que requiera
- Analiza el texto del programa que va cargando, y actualiza a las referencias a memoria para apuntar al lugar correcto
 - Agregando el *desplazamiento* (*offset*) necesario (la dirección *base*)
- Depende de que el compilador indique la ubicación de cada una de las variables y funciones
- P.ej. `contador` queda traducida como un desplazamiento:
`inicio + 5986`
 - Al cargarse, `inicio` es *resuelto* a 504214



En tiempo de ejecución

- El programa *nunca* hace referencia a ubicaciones absolutas de memoria
 - El código generado por el compilador siempre indica *base* y *desplazamiento (offset)*
- Permite que el proceso sea reubicado en la memoria *incluso estando ya en ejecución*
- Requiere de apoyo en hardware (MMU)
- P.ej. la variable `contador` queda traducida como un desplazamiento: `inicio + 5986`
 - `inicio` se mantiene como etiqueta *durante la ejecución* y es resuelta cada vez que se requiera



Proceso de compilación y carga




Figura: Proceso de compilación y carga de un programa, indicando el tipo de resolución de direcciones (Silberschatz, p.281)

