Subsistema de Memoria

Organización de computadoras

Universidad Nacional de Quilmes

10 de noviembre de 2014

Introducción

En las últimas décadas, cada 18 meses:

1. la velocidad de proceso (en cantidad de instrucciones ejecutadas por segundo) se duplica
2. el tamaño de la memoria se duplica
3. la velocidad de la memoria crece menos del 10 %

Introducción

En las últimas décadas, cada 18 meses:

1. la velocidad de proceso (en cantidad de instrucciones ejecutadas por segundo) se duplica
2. el tamaño de la memoria se duplica
3. la velocidad de la memoria crece menos del 10 %

Introducción

En las últimas décadas, cada 18 meses:

1. la velocidad de proceso (en cantidad de instrucciones ejecutadas por segundo) se duplica
2. el tamaño de la memoria se duplica
3. la velocidad de la memoria crece menos del 10 %

Introducción

En las últimas décadas, cada 18 meses:

1. la velocidad de proceso (en cantidad de instrucciones ejecutadas por segundo) se duplica
2. el tamaño de la memoria se duplica
3. la velocidad de la memoria crece menos del 10 %

Crece la brecha entre la velocidad del procesador y la velocidad de la memoria

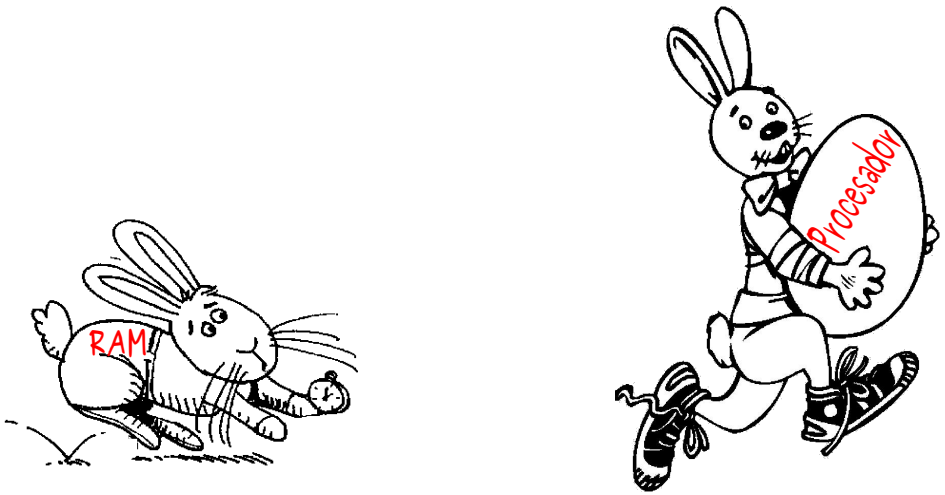

En la ejecución de cada instrucción se accede al menos una vez a memoria

En la ejecución de cada instrucción se accede al menos una vez a memoria

La velocidad de ejecución de instrucciones está limitada por el tiempo de acceso a memoria que es mucho mayor al de la CPU

Jerarquía de memorias

¿Como mejorar la performance del procesador?

Jerarquía de memorias

¿Como mejorar la performance del procesador?

Aumentar la cantidad de instrucciones ejecutadas por segundo

Jerarquía de memorias

¿Como mejorar la performance del procesador?

Aumentar la cantidad de instrucciones ejecutadas por segundo

\+ Disminuir el tiempo de acceso a memoria

El dilema: ¿Cuánta? ¿Cuán rápida? ¿Cuán costosa?

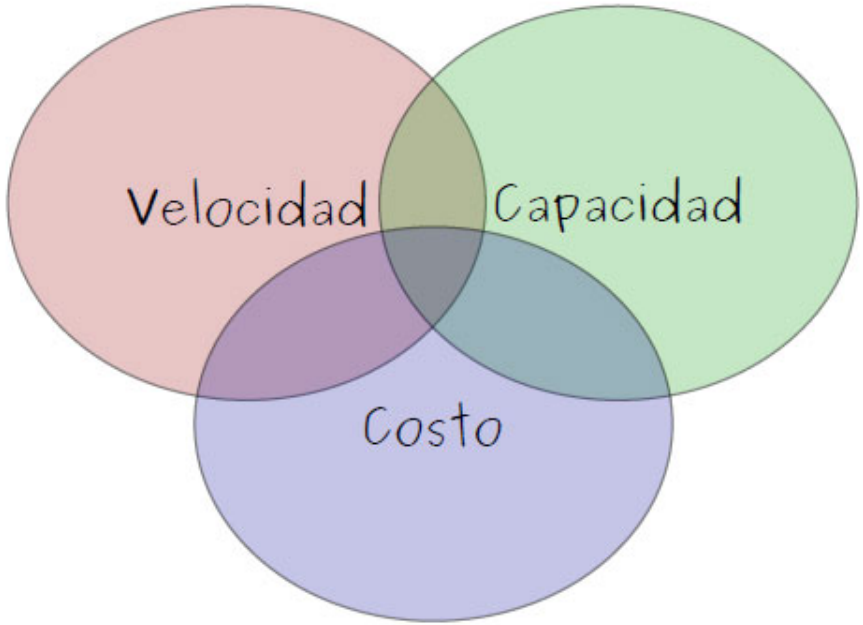

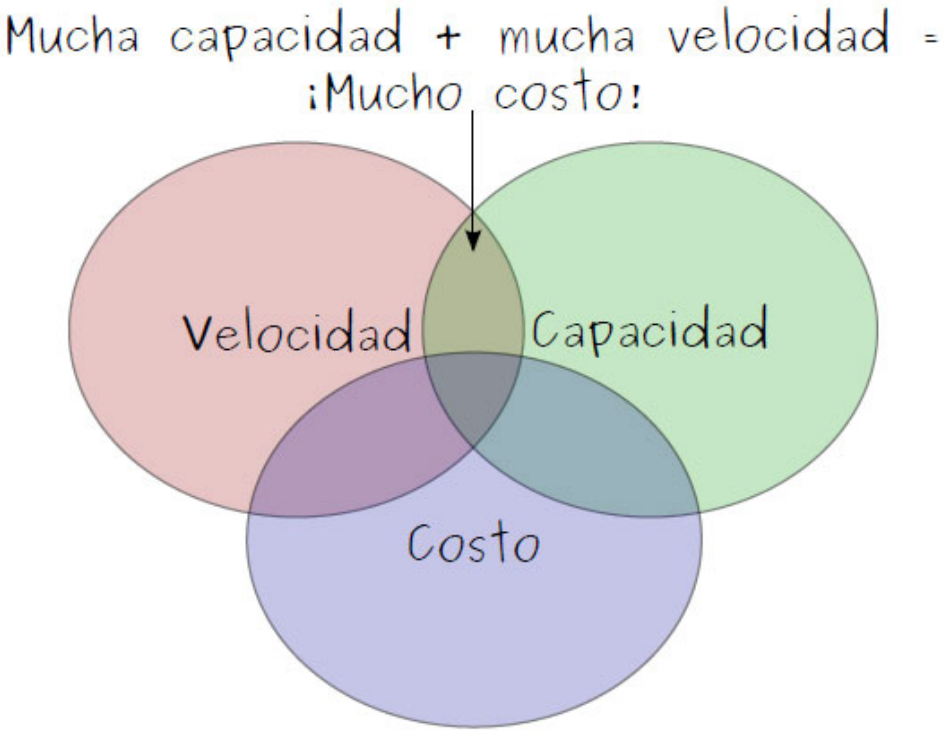
Mucha capacidad + mucha velocidad =
¡Mucho costo!
Velocidad
Capacidad
Costo

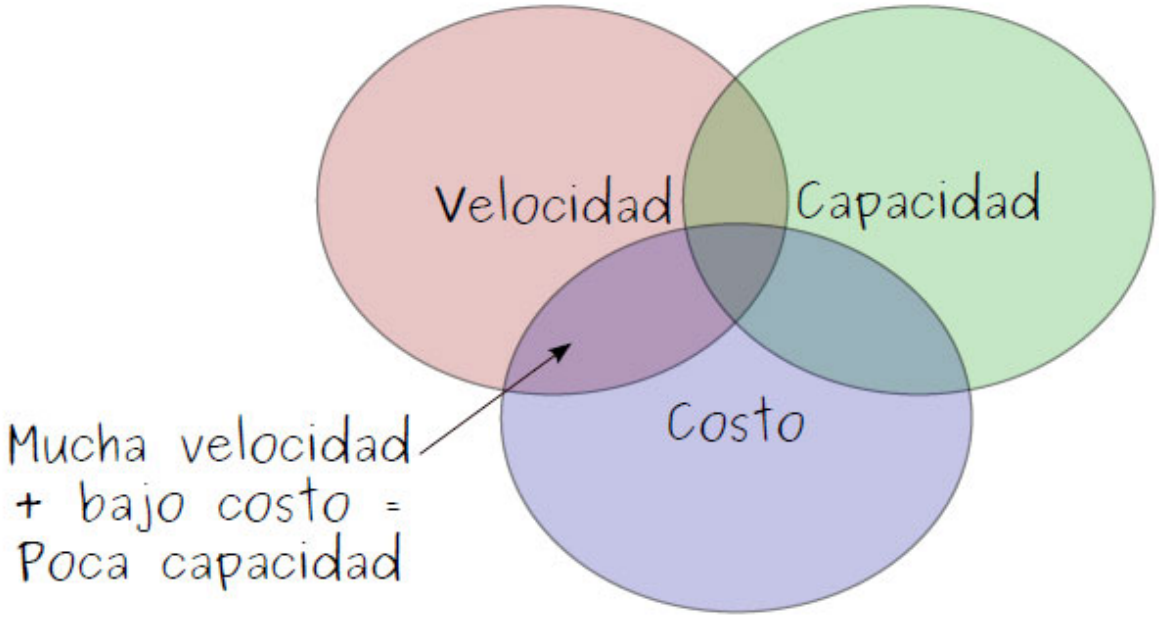
Velocidad
Capacidad
Costo
Mucha velocidad
+ bajo costo =
Poca capacidad

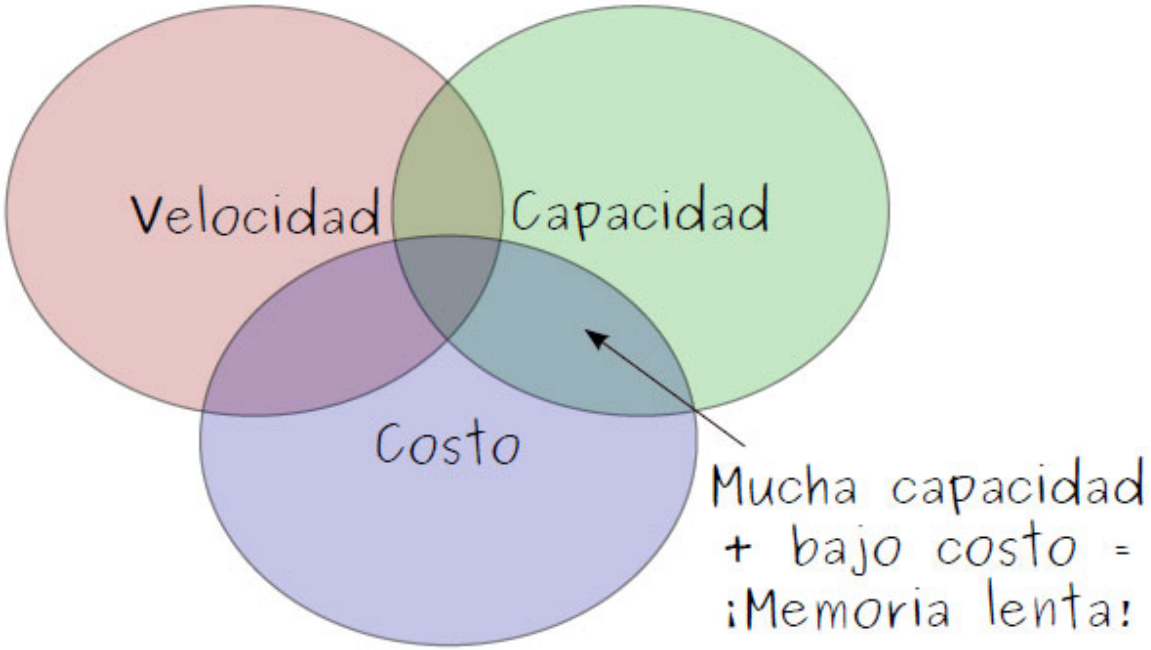
Velocidad
Capacidad
Costo
Mucha capacidad
+ bajo costo =
¡Memoria lenta!

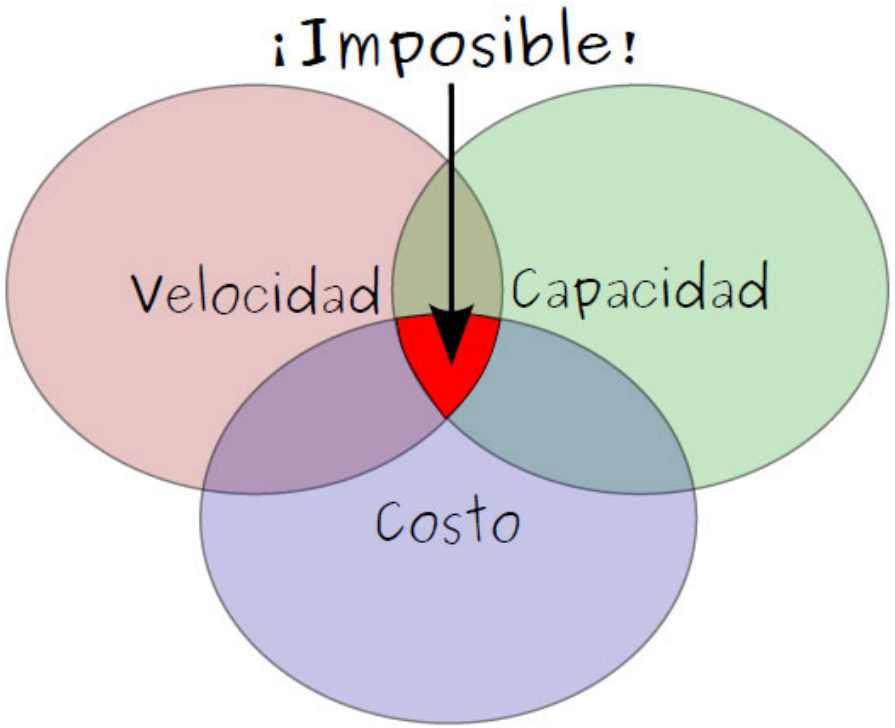

Se necesita que la memoria tenga: gran capacidad y gran velocidad

Jerarquía de memorias

Relación de compromiso entre el costo, la capacidad y el tiempo de acceso

Jerarquía de memorias

Relación de compromiso entre el costo, la capacidad y el tiempo de acceso

- menor tiempo de acceso  mayor costo por bit

Jerarquía de memorias

Relación de compromiso entre el costo, la capacidad y el tiempo de acceso

- menor tiempo de acceso  mayor costo por bit
- mayor capacidad  menor costo por bit

Jerarquía de memorias

Relación de compromiso entre el costo, la capacidad y el tiempo de acceso

- menor tiempo de acceso → mayor costo por bit
- mayor capacidad → menor costo por bit
- mayor capacidad → mayor tiempo de acceso

Caminos hacia la solución:

1. Se incorpora memoria interna a la CPU (Registros)

Caminos hacia la solución:

1. Se incorpora memoria interna a la CPU (Registros)
2. Se incorpora memoria externa al sistema (operada a través de un módulo de E/S)

Caminos hacia la solución:

1. Se incorpora memoria interna a la CPU (Registros)
2. Se incorpora memoria externa al sistema (operada a través de un módulo de E/S)
3. Se utilizan muchos tipos de memoria combinados

Caminos hacia la solución:

1. Se incorpora memoria interna a la CPU (Registros)
2. Se incorpora memoria externa al sistema (operada a través de un módulo de E/S)
3. Se utilizan muchos tipos de memoria combinados

Subsistema de memoria: muchas memorias combinadas

Subsistema de memoria: muchas memorias combinadas

La interacción se optimiza para funcionar como una única memoria, grande y rápida

Subsistema de memoria: muchas memorias combinadas

La interacción se optimiza para funcionar como una única memoria, grande y rápida

Se organizan en una jerarquía

Antes, definiciones previas

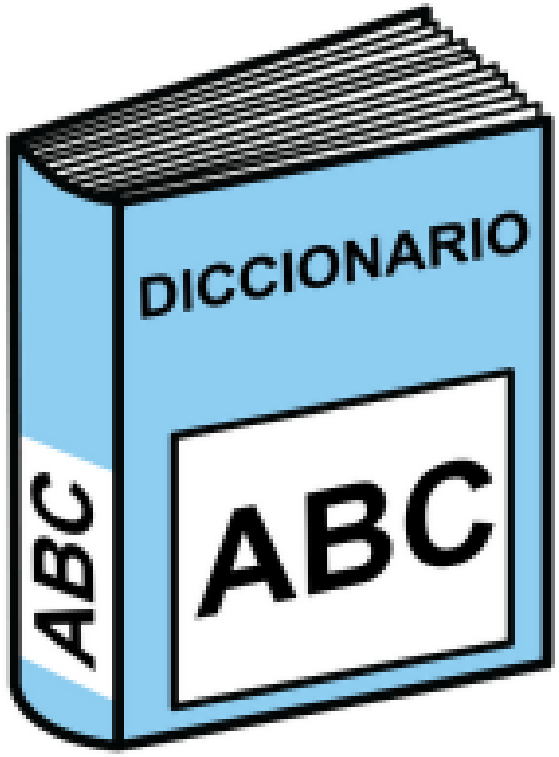

Caracterización

Cada componente de almacenamiento puede caracterizarse según las dimensiones:

- Ubicación
- Unidad de transferencia
- Volatilidad
- Capacidad de escritura
- Método de acceso

Ubicación Interna o Externa al sistema de cómputos.

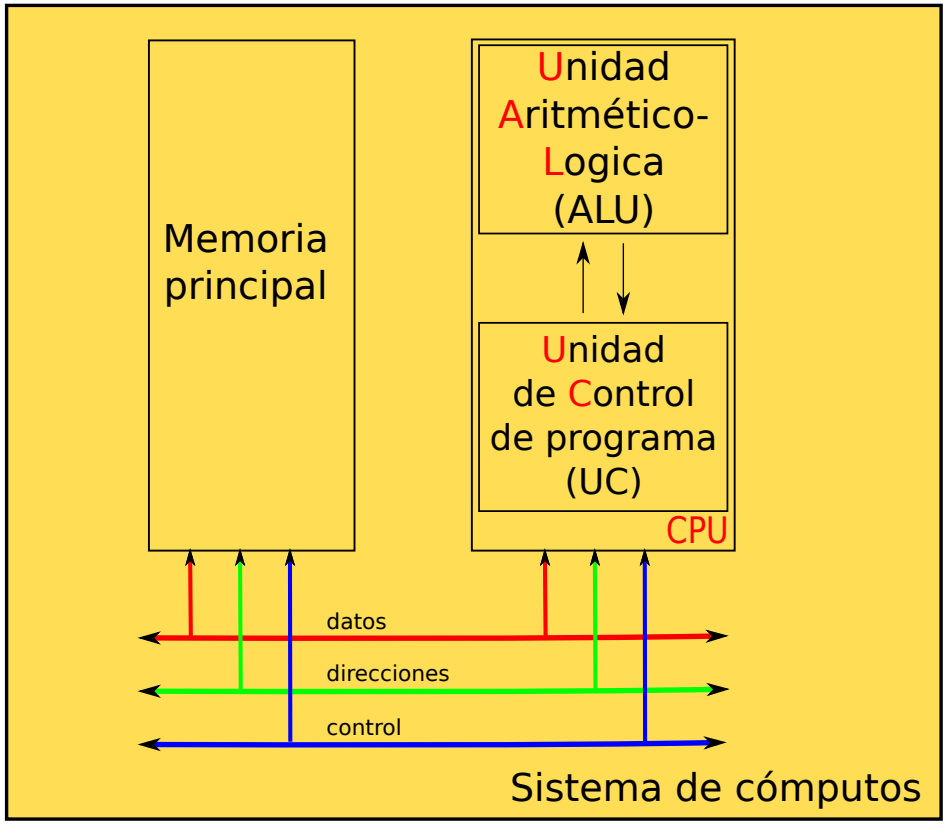

Caracterización

Volatilidad Una memoria es volátil cuando necesita alimentación eléctrica para mantener la información. Una memoria no volátil almacena información sin necesidad de tener alimentación y esa información no se deteriora.

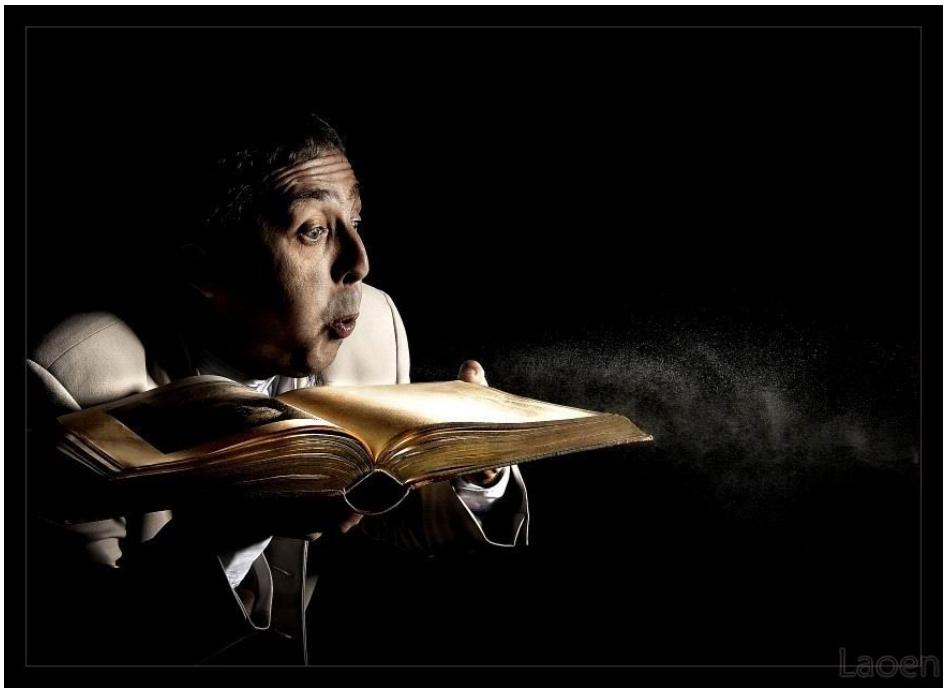

Caracterización

Capacidad de escritura Las memorias de solo lectura NO pueden ser alteradas luego de ser escritas. Necesariamente deben ser también NO volátiles.

Read Only Memory (ROM)

Cuando un programa se carga en memoria permanece ahí hasta que

a. La memoria es sobreescrita
b. La computadora se apaga

ROM: Memoria de sólo lectura

1. Para algunas aplicaciones, el programa no necesita ser cambiado y entonces puede ser 'hardwired' en una memoria de sólo lectura
2. Las ROMs se utilizan para almacenar programas en videojuegos, calculadoras, hornos de microondas, computadoras de vehículos, etc.

ROM: Memoria de sólo lectura

1. Para algunas aplicaciones, el programa no necesita ser cambiado y entonces puede ser 'hardwired' en una memoria de sólo lectura
2. Las ROMs se utilizan para almacenar programas en videojuegos, calculadoras, hornos de microondas, computadoras de vehículos, etc.

¿Algún otro ejemplo?

Métodos de acceso

Caracterización: Método de acceso

Secuencial La dirección de cada dato está almacenada junto con él. Debe recorrerse secuencialmente para buscar el dato. tiempo de acceso variable

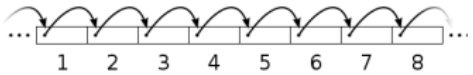

Directo

Aleatorio

Asociativo

Caracterización: Método de acceso

Secuencial

Directo

La dirección de cada dato se basa en su ubicación física. Etapas del acceso:

1. acceder directamente a la zona próxima del registro a buscar
2. buscar secuencialmente dentro de esa zona.

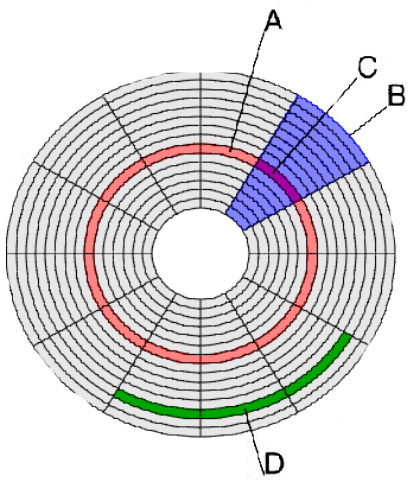

Aleatorio

Asociativo

Caracterización: Método de acceso

Secuencial	
Directo	
Aleatorio	Cada dato tiene un mecanismo de acceso único y cableado físicamente  tiempo de acceso constante e independiente de los accesos anteriores. [1]
Asociativo	

[1] Random:(Statistics) governed by or involving equal chances for each item.

Caracterización: Método de acceso

Secuencial

Directo

Aleatorio

Asociativo Cada celda es recuperada en función de su contenido en lugar de su dirección:

- Se busca un determinado patrón (clave) en **cierto conjunto de bits** de cada celda.
- Las comparaciones son simultáneas.
- El tiempo de acceso es constante.

Método de acceso aleatorio

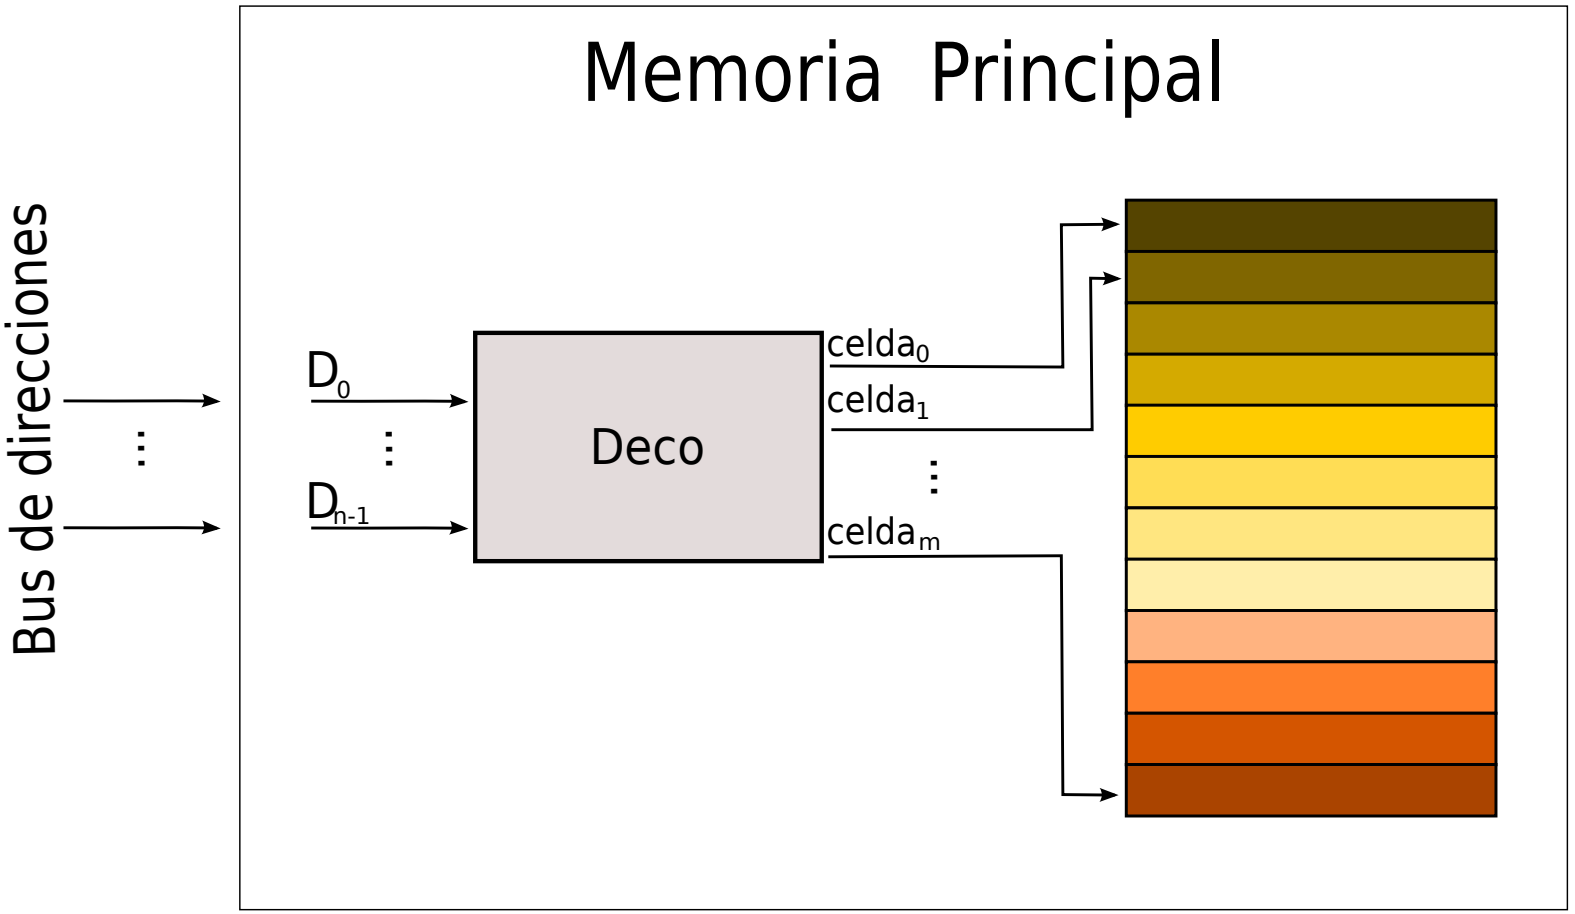

Volvamos a la jerarquía de memorias

Jerarquía de memorias

Solución: se emplea una jerarquía de memoria donde se complementan:

- costo por bit
- capacidad
- tiempo de acceso

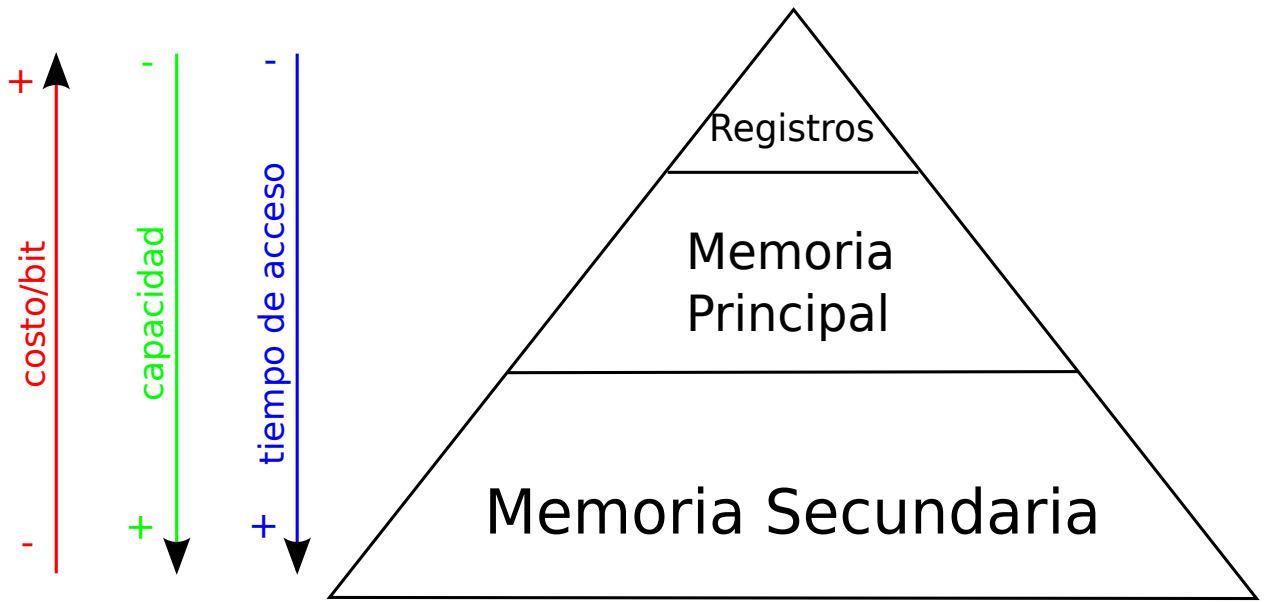

Jerarquía de memorias

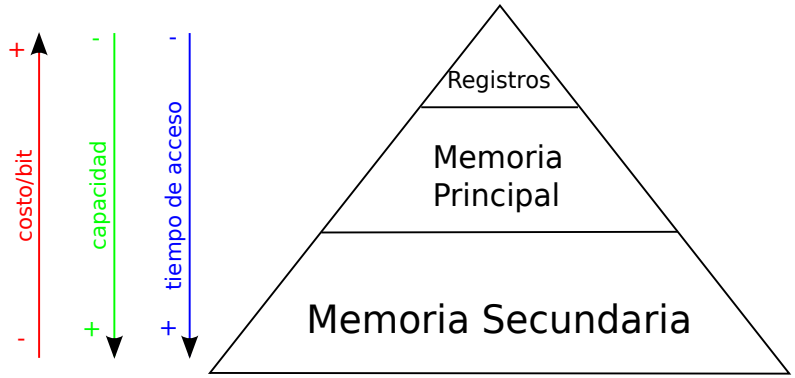

- Registros: de velocidad igual a la cpu.
- Memoria principal: es volátil.
- Memoria secundaria: no volátil (ej: discos rígidos, tarjetas de memoria)

Jerarquía de memorias

- ¿Porqué la memoria principal es volátil?
- ¿Porqué la memoria secundaria es no volátil?
- ¿Porqué las memorias principal y secundaria son de diferente tamaño?

Jerarquía de memorias

¿Construir la memoria principal a base de registros?

Jerarquía de memorias

¿Construir la memoria principal a base de registros?

¡NO!

Principios de localidad

Principios de localidad

Localidad espacial
las posiciones de memoria mas cercanas a alguna referenciada recientemente son mas probables de ser referenciada que las mas distantes.

Principios de localidad

Localidad espacial
las posiciones de memoria mas cercanas a alguna referenciada recientemente son mas probables de ser referenciada que las mas distantes.

0000	ADD R0,R1
0001	**SUB R1,R3**
0002	AND R1,...
0003	... 0x0F0F

Principios de localidad

Localidad espacial
las posiciones de memoria mas cercanas a alguna referenciada recientemente son mas probables de ser referenciada que las mas distantes.

0000	ADD R0,R1
0001	SUB R1,R3
0002	**AND R1,...**
0003	**... 0x0F0F**

Principios de localidad

Localidad espacial
las posiciones de memoria mas cercanas a alguna referenciada recientemente son mas probables de ser referenciada que las mas distantes.

0000	ADD R0,R1
0001	SUB R1,R3
0002	AND R1,...
0003	... 0x0F0F

Principios de localidad

Localidad temporal
cuando un programa hace referencia de una posición de memoria, se espera que vuelva a hacerlo en poco tiempo

Principios de localidad

Localidad temporal
cuando un programa hace referencia de una posición de memoria, se espera que vuelva a hacerlo en poco tiempo

0000	ADD R0,R1
0001	SUB R1,R3
0002	JMP -3

Principios de localidad

Localidad temporal
cuando un programa hace referencia de una posición de memoria, se espera que vuelva a hacerlo en poco tiempo

0000	ADD R0,R1
0001	SUB R1,R3
0002	JMP -3

Principios de localidad

Localidad temporal
cuando un programa hace referencia de una posición de memoria, se espera que vuelva a hacerlo en poco tiempo

0000	ADD R0,R1
0001	SUB R1,R3
0002	JMP -3

Principios de localidad

Localidad temporal
cuando un programa hace referencia de una posición de memoria, se espera que vuelva a hacerlo en poco tiempo

0000	ADD R0,R1
0001	SUB R1,R3
0002	JMP -3

Principios de localidad

Las celdas mas usadas se las quiere mas a mano

Principios de localidad

Las celdas mas usadas se las quiere mas a mano

¿Cómo se relaciona esto con la jerarquía de memoria que propusimos?

Principios de localidad

Las celdas mas usadas se las quiere mas a mano

¿Cómo se relaciona esto con la jerarquía de memoria que propusimos?

Se puede agregar una memoria mas pequeña pero mas rápida que la principal, para almacenar estas celdas

Jerarquía mejorada

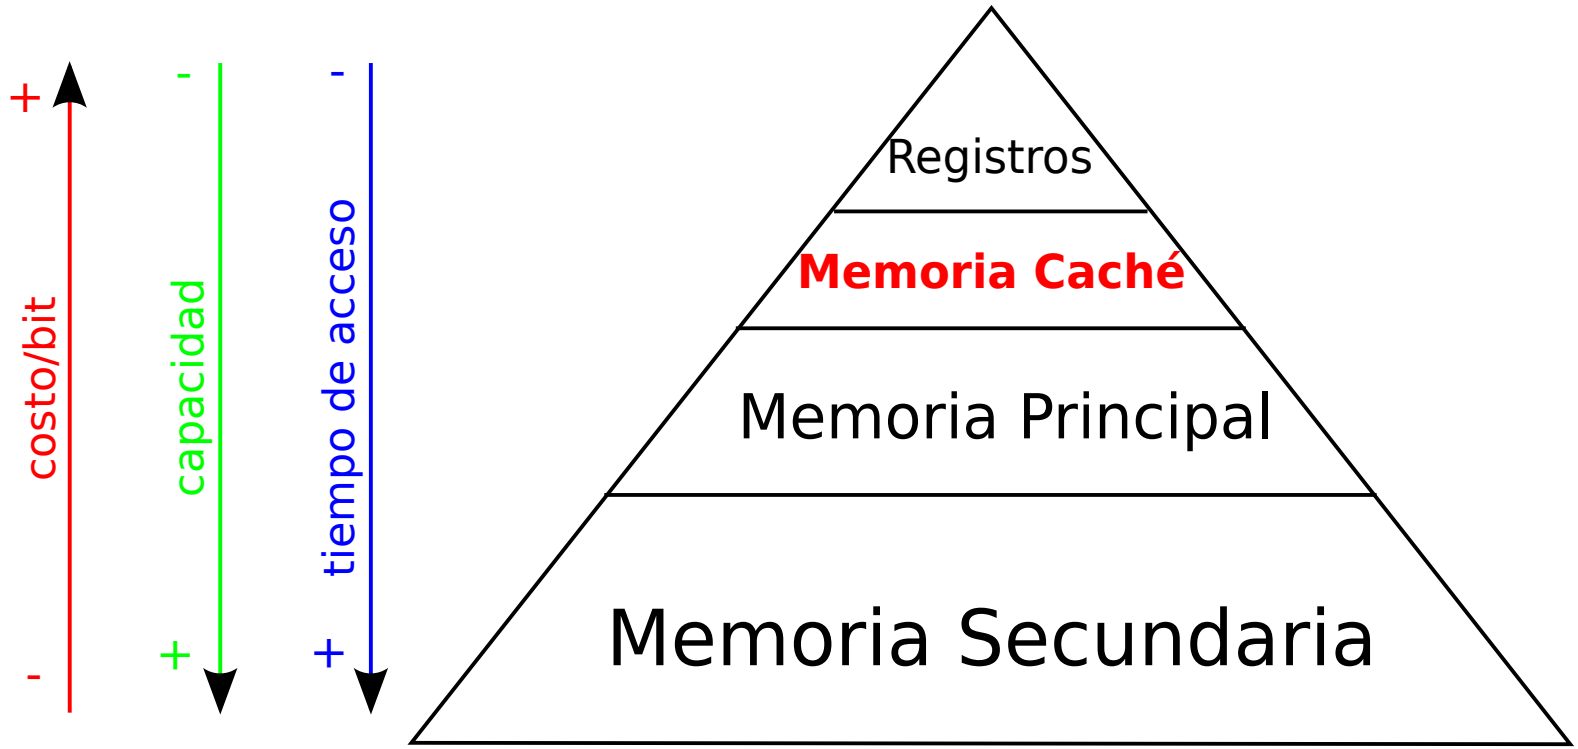

Objetivos

La memoria caché tiene como objetivo

La memoria caché tiene como objetivo

- proveer una velocidad de acceso cercana a la de los registros
- pero al mismo tiempo proveer un mayor tamaño de memoria

La memoria caché tiene como objetivo

- proveer una velocidad de acceso cercana a la de los registros
- pero al mismo tiempo proveer un mayor tamaño de memoria

Para esto la caché contiene una copia de porciones de la memoria principal

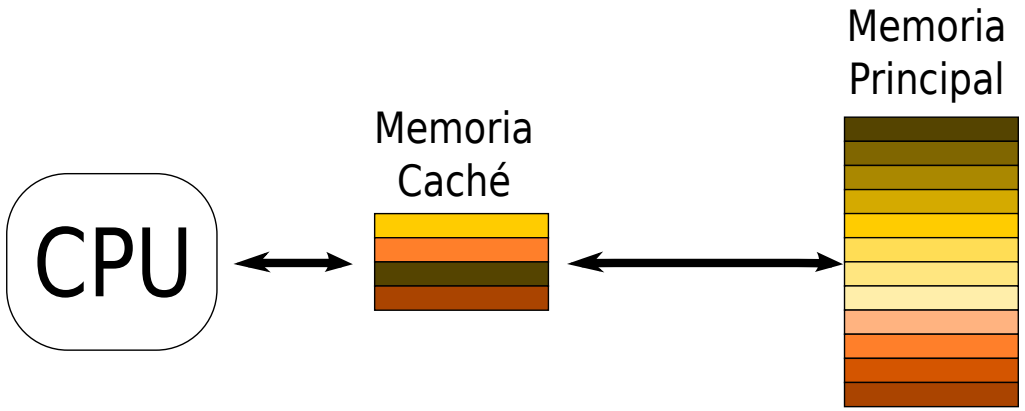

Pero... ¿Cómo es una lectura?

Algoritmo de lectura

(1) La CPU pide una celda X

Algoritmo de lectura

(1) La CPU pide una celda X

(2) La cache controla si X está *cacheada*

Algoritmo de lectura

(1) La CPU pide una celda X

(2) La cache controla si X está *cacheada*

- √ **Si está cacheada (hit o acierto): se otorga X a la CPU**

Algoritmo de lectura

(1) La CPU pide una celda X

(2) La cache controla si X está *cacheada*

- √ Si está cacheada (hit o acierto):
  se otorga X a la CPU
- × **Si NO está cacheada (fault o fallo):**
  1. **Se lee un bloque de memoria principal que contiene X**
  2. Se cachea el bloque
  3. se otorga X a la CPU

Algoritmo de lectura

(1) La CPU pide una celda X

(2) La cache controla si X está *cacheada*

- √ Si está cacheada (hit o acierto):
  se otorga X a la CPU
- × **Si NO está cacheada (fault o fallo):**
  1. Se lee un bloque de memoria principal que contiene X
  2. **Se cachea el bloque**
  3. se otorga X a la CPU

Algoritmo de lectura

(1) La CPU pide una celda X

(2) La cache controla si X está *cacheada*

- √ Si está cacheada (hit o acierto):
  se otorga X a la CPU
- × **Si NO está cacheada (fault o fallo):**
  1. Se lee un bloque de memoria principal que contiene X
  2. Se cachea el bloque
  3. **se otorga X a la CPU**

Ajá... ¿Y la escritura?

Algoritmo de escritura

(1) La CPU pide la escritura del valor V en la celda X

Algoritmo de escritura

(1) La CPU pide la escritura del valor V en la celda X

(2) La cache controla si X está *cacheada*

Algoritmo de escritura

(1) La CPU pide la escritura del valor V en la celda X

(2) La cache controla si X está *cacheada*

- √ **Si está cacheada (hit o acierto):**
  se escribe V en la copia de X en la cache

Algoritmo de escritura

(1) La CPU pide la escritura del valor V en la celda X

(2) La cache controla si X está *cacheada*

- √ Si está cacheada (hit o acierto):
  se escribe V en la copia de X en la cache
- × **Si NO está cacheada (fault o fallo):**
  1. **Se lee un bloque de memoria principal que contiene X**
  2. Se cachea el bloque
  3. se escribe V en la copia de X en la cache

Algoritmo de escritura

(1) La CPU pide la escritura del valor V en la celda X

(2) La cache controla si X está *cacheada*

- √ Si está cacheada (hit o acierto):
  se escribe V en la copia de X en la cache
- × **Si NO está cacheada (fault o fallo):**
  1. Se lee un bloque de memoria principal que contiene X
  2. **Se cachea el bloque**
  3. se escribe V en la copia de X en la cache

Algoritmo de escritura

(1) La CPU pide la escritura del valor V en la celda X

(2) La cache controla si X está *cacheada*

- √ Si está cacheada (hit o acierto):
  se escribe V en la copia de X en la cache
- × **Si NO está cacheada (fault o fallo):**
  1. Se lee un bloque de memoria principal que contiene X
  2. Se cachea el bloque
  3. **se escribe V en la copia de X en la cache**

¿Cómo comprueba la caché si X está cacheada?

¿Cómo registra la caché qué celdas están cacheadas?

¿Cómo registra la caché qué celdas están cacheadas?

Almacena una etiqueta (tag) que identifica cada celda

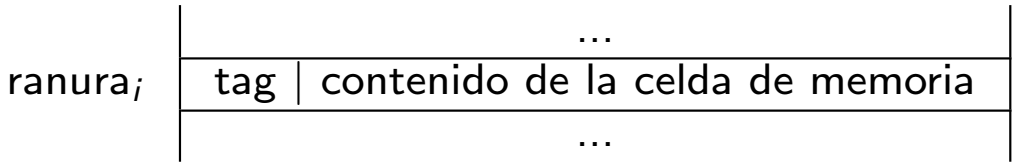

Memoria asociativa

¿Cómo registra la caché qué celdas están cacheadas?

Almacena una etiqueta (tag) que identifica cada celda

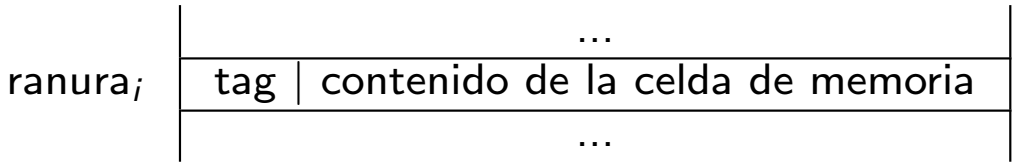

Memoria Asociativa

Organización de la memoria caché

- La memoria principal se organiza en **M** bloques de **K** celdas cada uno.
-

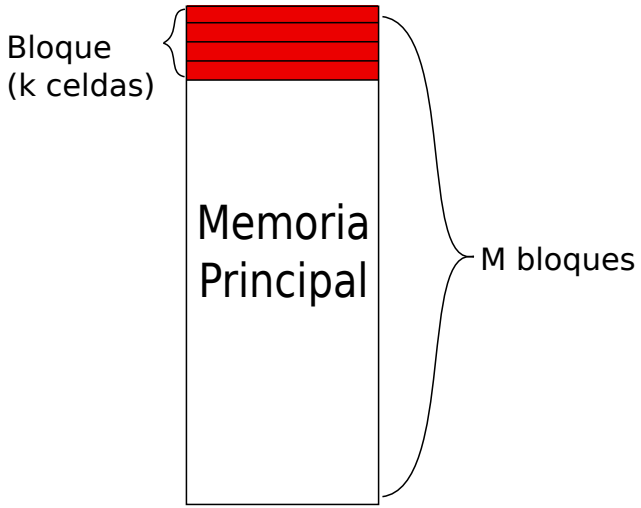

Organización de la memoria caché

- La memoria principal se organiza en **M** bloques de **K** celdas cada uno.
- La memoria caché tiene **C** líneas (ranuras) de **K** celdas.

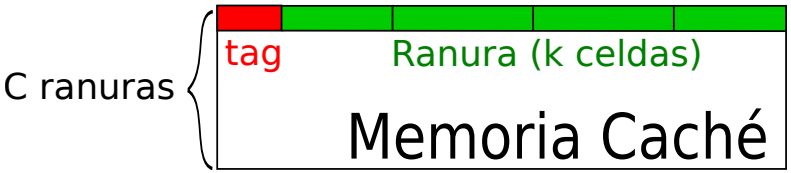

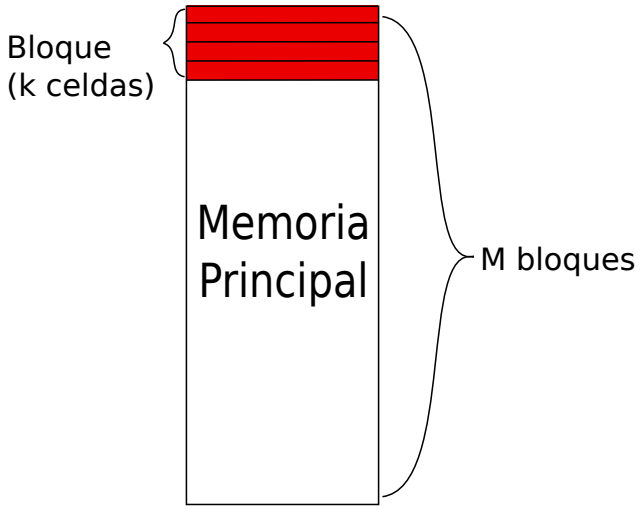

Organización de la memoria caché

- La memoria principal se organiza en **M** bloques de **K** celdas cada uno.
- La memoria caché tiene **C** líneas (ranuras) de **K** celdas.

$C < M$ cada bloque no tienen ranura permanente se necesita identificar cada bloque en cada ranura

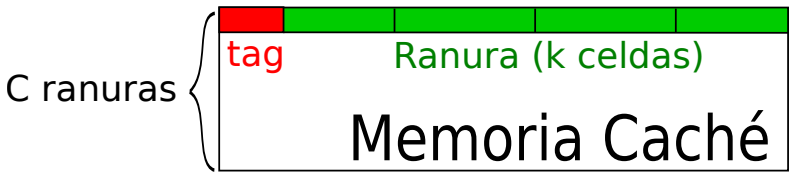

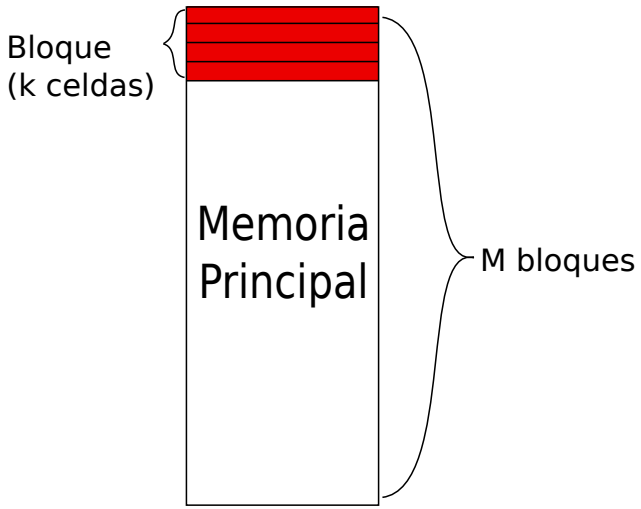

Organización de la memoria caché

- La memoria principal se organiza en **M** bloques de **K** celdas cada uno.
- La memoria caché tiene **C** líneas (ranuras) de **K** celdas.

$C < M$ cada bloque no tienen ranura permanente se necesita identificar cada bloque en cada ranura

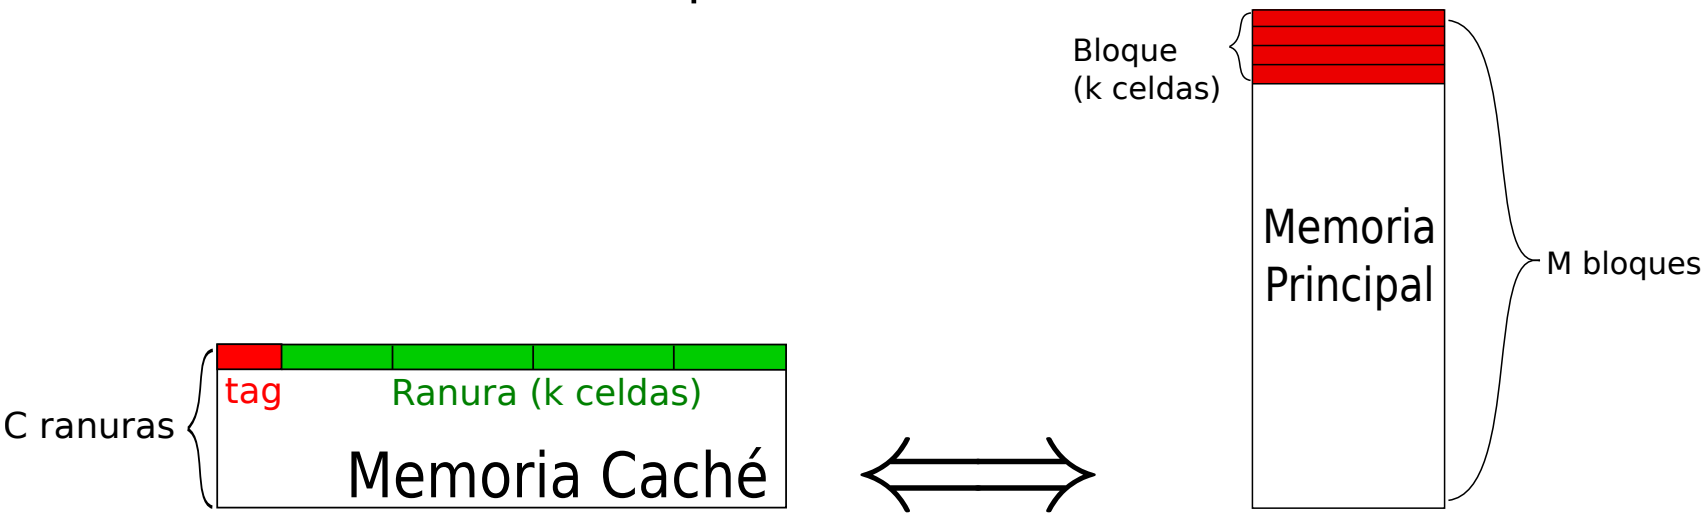

Diseño de una caché: Tamaño

Debe ser:

- suficientemente pequeña para que el costo global se asemeje al de la memoria principal sola
- suficientemente grande para que el tiempo de acceso global se acerque al de la caché

Además, una caché mas grande tiende a ser un poco mas lenta.

Función de correspondencia

Diseño de una caché: Función de correspondencia

La función de correspondencia (mapeo) asocia los bloques de memoria con ranuras de la caché.

Suponer:

- una memoria de $2^6 = 64$ celdas
- un tamaño de bloque de 4 celdas $\rightarrow$ 16 bloques
- una caché de 8 ranuras de 4 celdas cada una

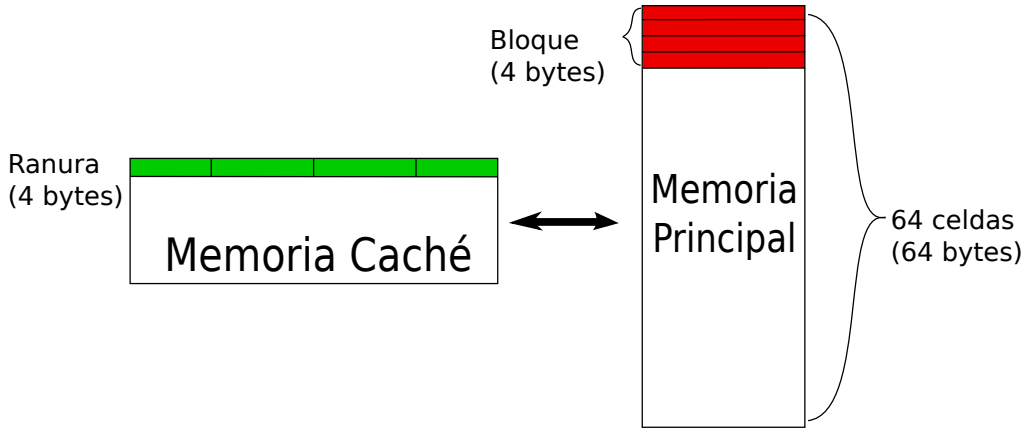

Correspondencia directa

Correspondencia directa

- Cada ranura se corresponde con un determinado conjunto de bloques de memoria, y cada bloque puede estar en solo una ranura.
- En cada ranura puede cargarse uno de 16/8=2 bloques de memoria.
- Para saber cual está cargado, se utiliza una etiqueta de 1 bit, y las direcciones de memoria se parten en los siguientes campos:

tag(1b)	ranura (3b)	palabra (2b)

Correspondencia directa

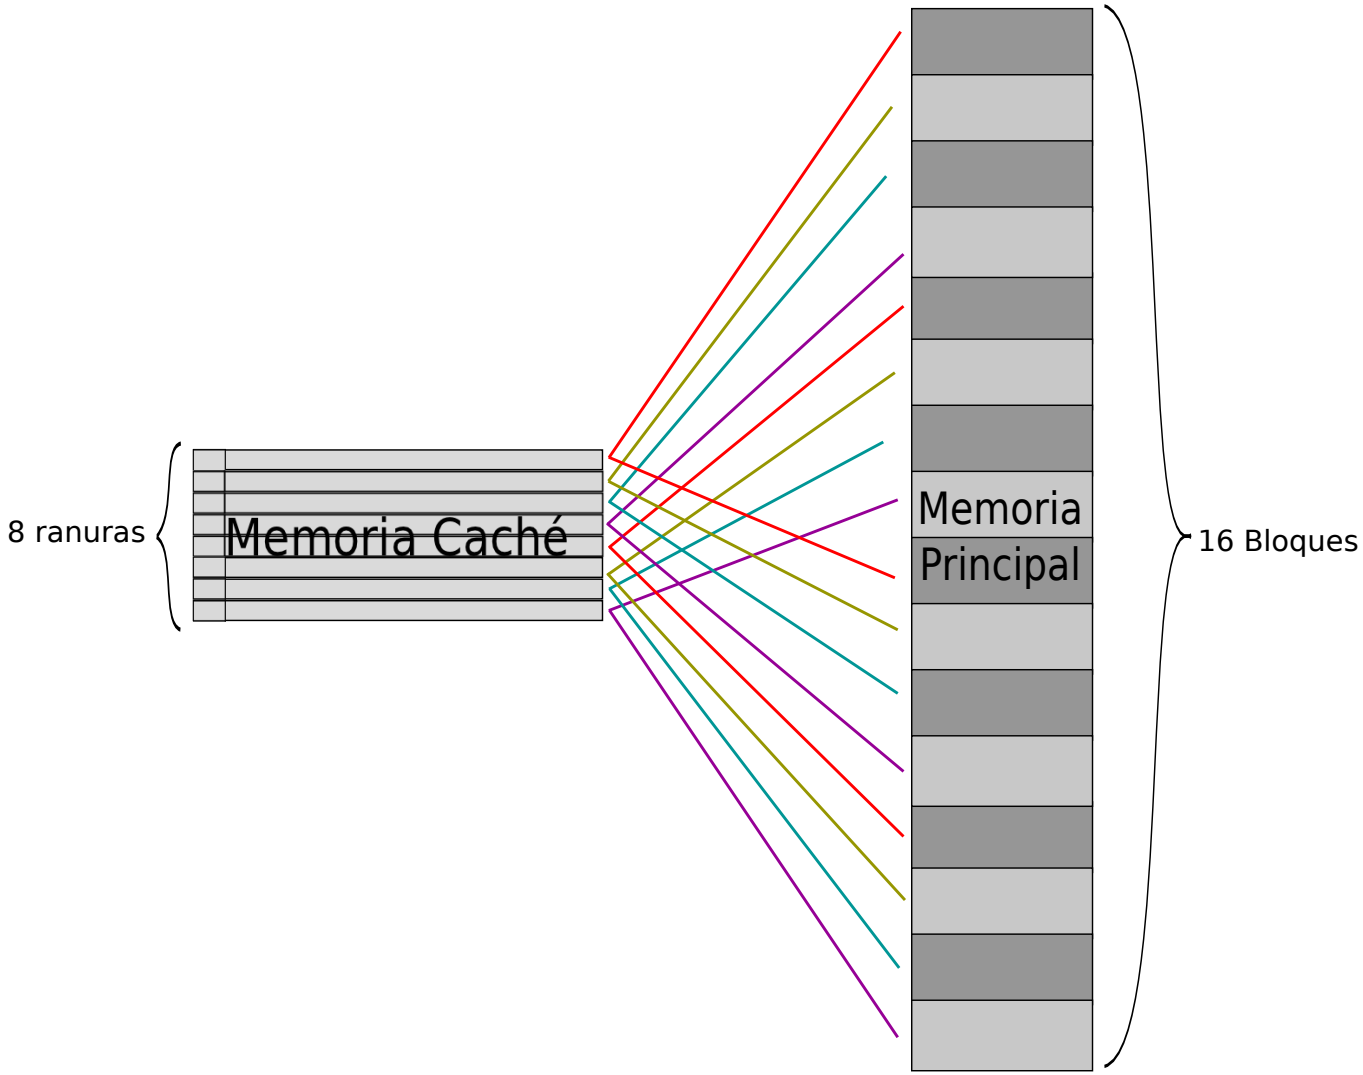

Resolvemos entre todos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda
- Función de correspondencia directa

¿Qué tamaño tiene el tag?

Resolvemos entre todos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda
- Función de correspondencia directa

¿Qué tamaño tiene el tag?

16 celdas = 16 bloques repartidos en 4 líneas
16/4=4 bloques por línea
Se debe distinguir cuál de esos 4 bloques es el que está almacenado
tag=2bits

Correspondencia directa

Para una dirección de memoria dada:

1. se identifica la ranura
2. se compara el primer bit con el tag de la ranura
3. si coinciden se recupera la palabra dentro del bloque según los últimos 2 bits

Ventajas: simple y económico para implementar. No requiere memoria de acceso aleatorio.

Desventajas: si un programa accede reiteradamente a palabras en diferentes bloques pero que se corresponden a la misma ranura ocurren muchos fallos.

Ahora a trabajar solos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda
- Función de correspondencia directa

¿En que línea debo buscar la dirección 1010 ?

Ahora a trabajar solos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda
- Función de correspondencia directa

¿En que línea debo buscar la dirección 1010 ?

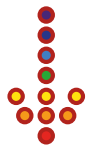

(tag) 10	10 (línea)

Correspondencia asociativa

Correspondencia asociativa

- Cualquier bloque puede almacenarse en cualquier ranura.
- El tag corresponde al número de bloque

Correspondencia asociativa

- Cualquier bloque puede almacenarse en cualquier ranura.
- El tag corresponde al número de bloque
- entonces la dirección se divide en:

tag(4b)	palabra (2b)

Correspondencia asociativa

- Cualquier bloque puede almacenarse en cualquier ranura.
- El tag corresponde al número de bloque
- entonces la dirección se divide en:

tag(4b)	palabra (2b)

Ventajas: Flexibilidad

Desventajas: La política de reemplazo es compleja, requiriendo hardware y tiempo. Además, necesita una memoria de acceso aleatorio y un tag "grande".

Resolvemos entre todos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda
- Función de correspondencia asociativa

¿Qué tamaño tiene el tag?

Resolvemos entre todos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda
- Función de correspondencia asociativa

¿Qué tamaño tiene el tag?

No hay patrón de asignación cualquier bloque en cualquier línea
16 celdas = 16 bloques
Se debe distinguir cuál de esos 16 bloques es el que
está almacenado en cada línea
tag=4bits

Ahora a trabajar solos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda
- Función de correspondencia asociativa

¿En que línea debo buscar la dirección 1010 ?

Ahora a trabajar solos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda
- Función de correspondencia asociativa

¿En que línea debo buscar la dirección 1010 ?

¡En todas!

Correspondencia asociativa por conjuntos

Correspondencia asociativa por conjuntos

- Combina la flexibilidad del mapeo asociativo y la simplicidad del directo.
- Las ranuras se agrupan en conjuntos

Correspondencia asociativa por conjuntos

- Combina la flexibilidad del mapeo asociativo y la simplicidad del directo.
- Las ranuras se agrupan en conjuntos

Suponer conjuntos de 2 ranuras $\rightarrow$ la cache tiene 4 conjuntos.

1. Se usa el mapeo directo para encontrar el conjunto correspondiente a la dirección de memoria
2. Se usa mapeo asociativo dentro del conjunto para encontrar el bloque.

Correspondencia asociativa por conjuntos

Para una dirección de memoria dada:

1. se identifica la ranura
2. se compara el primer bit con el tag de la ranura
3. si coinciden se recupera la palabra dentro del bloque según los últimos 2 bits

Ventajas: simple y económico para implementar. No requiere memoria de acceso aleatorio.

Desventajas: si un programa accede reiteradamente a palabras en diferentes bloques pero que se corresponden a la misma ranura ocurren muchos fallos.

Correspondencia asociativa por conjuntos

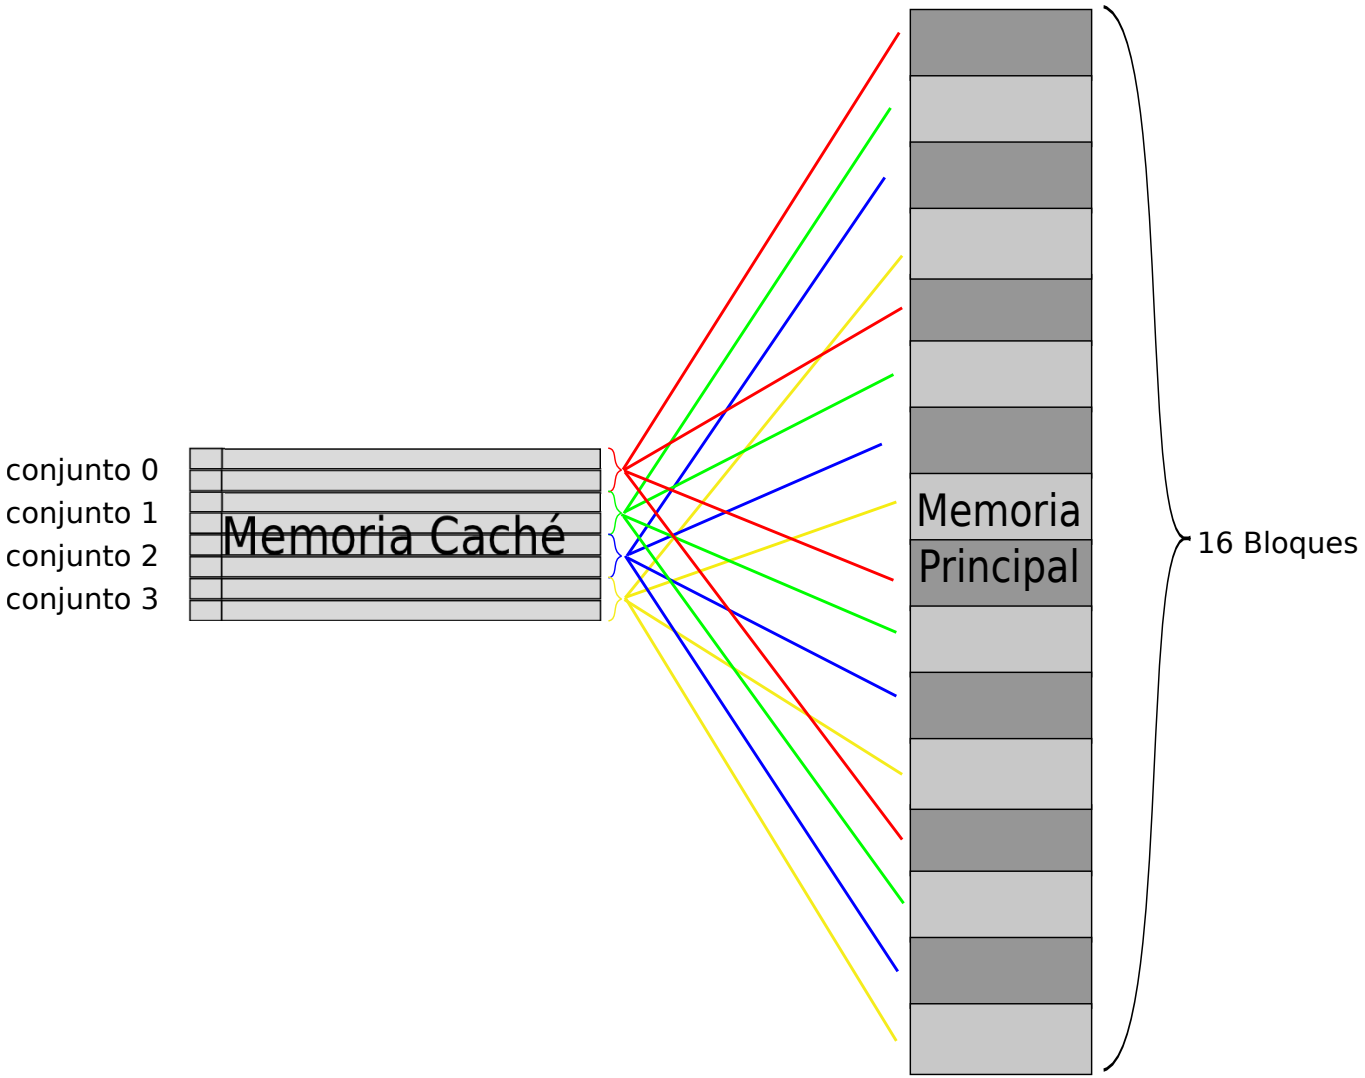

Correspondencia asociativa por conjuntos

La dirección se divide en:

tag(2b)	conjunto (2b)	palabra (2b)

Para una dirección de memoria dada:

1. se identifica el conjunto
2. se comparan los primeros 2 bits con los tags de **las ranuras del conjunto**
3. si hay coincidencia se recupera la palabra dentro del bloque según los últimos 2 bits

Resolvemos entre todos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda y conjuntos de 2 líneas
- Función de correspondencia asociativa por conjuntos

¿Qué tamaño tiene el tag?

Resolvemos entre todos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda y conjuntos de 2 líneas
- Función de correspondencia asociativa por conjuntos

¿Qué tamaño tiene el tag?

16 celdas = 16 bloques. Conj de 2 líneas 4/2= 2 conj
16 bloques/2 conjuntos= 8 bloques por conjunto
¿cuál de los 8 bloques está almacenado en cada línea del conjunto?
tag=3bits

Ahora a trabajar solos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda y conjuntos de 2 líneas
- Función de correspondencia asociativa por conjuntos

¿En que línea debo buscar la dirección 1010 ?

Ahora a trabajar solos

- Memoria principal de 16 celdas de 1 byte cada una
- Memoria caché de 4 líneas
- Bloques de 1 celda y conjuntos de 2 líneas
- Función de correspondencia asociativa por conjuntos

¿En que línea debo buscar la dirección 1010 ?

(tag) 101	0 (conjunto)

En todas las líneas del conjunto 0

Algoritmos de reemplazo

Algoritmos de reemplazo

Cuando se produce un fallo y un nuevo bloque debe ser cargado en la caché, debe elegirse una ranura (donde generalmente ya hay un bloque) para ocupar.

- Para el mapeo directo hay solo una posible ranura para un determinado bloque, así que no hay que elegir nada
- Para los mapeos **asociativo** y **asociativo por conjuntos** se necesita un algoritmo de reemplazo.

Algoritmo LRU (Least Recently Used)

Menos recientemente usado

Se reemplaza el bloque que ha estado mas tiempo en la caché y sin referencias.

Algoritmo LRU (Least Recently Used)

Menos recientemente usado

Se reemplaza el bloque que ha estado mas tiempo en la caché y sin referencias.

Esto es facil de implementar en un caché asociativo por conjunto a 2 ranuras por conjunto:

- Cada ranura tiene un bit de USO.
- Cuando se hace referencia a un determinado bloque, su ranura se marca con USO=1 y la otra ranura con USO=0
- Cuando se trae un nuevo bloque se utiliza la ranura marcada USO=0.

Según el principio de localidad, este enfoque dará una buena tasa de aciertos.

Algoritmo FIFO (First In-First Out)

El primero que llega es el primero que se va.

Se reemplaza el bloque que ha estado en la caché por mas tiempo.

Algoritmo FIFO (First In-First Out)

El primero que llega es el primero que se va.

Se reemplaza el bloque que ha estado en la caché por mas tiempo.

Se implementa con una lista circular:

- Las referencias a los bloques no computan nada
- Cuando se trae un nuevo bloque:
  1. se pone en el lugar del primero de la lista
  2. se actualiza la lista para que el nuevo quede al final.

Algoritmo LFU (Least Frequently Used)

Menos frecuentemente usado.

- Se reemplaza el bloque que ha sido usado menos veces.

Algoritmo LFU (Least Frequently Used)

Menos frecuentemente usado.

- Se reemplaza el bloque que ha sido usado menos veces.
- Puede implementarse con un contador de accesos en cada ranura.

Algoritmo Aleatorio

- Se elige una ranura al azar
- Algunos estudios de simulación muestran que esta implementación es apenas menos performante que los anteriores

Políticas de escritura

Antes de que un bloque pueda ser reemplazado debe analizarse si fue modificado en caché pero no en memoria.

- $\times$ Si NO fue modificado $\rightarrow$ se pisa con el bloque nuevo
- $\surd$ Si fue modificado $\rightarrow$ La memoria debe ser actualizada.

Políticas de escritura

Las posibles políticas de escritura deben tener en cuenta lo siguiente:

- Más de un dispositivo puede tener acceso a la memoria principal (ej: modulo de entrada-salida) Si una palabra fue alterada en la caché es inválida en Memoria principal.
- Cuando varios procesadores comparten la memoria a través de distintas caché.

Write-through

- Es la política mas simple.
- Todas las escrituras de caché se replican a memoria principal en el acto.

Ventajas: Puede haber otros dispositivos cach-cpu que monitoreen las lineas de escritura a memoria.

Desventajas: Puede generarse un cuello de botella en memoria

Write-back

- Las actualizaciones a memoria se hacen sólo cuando un bloque es candidato a ser reemplazado.
- Se utiliza un bit *dirty* que se enciende cuando se hace una modificación en cache
- si *dirty*=1 cuando se reemplaza el bloque, se escribe en memoria

Ventaja: Las escrituras son mas eficientes

Desventaja: Algunas partes de la memoria son inválidas $\rightarrow$ los accesos de los módulos de entrada-salida deben pasar por caché (cuello de botella)

Write-back vs. Write-through

- La experiencia muestra que solo el 15 % son accesos de escritura, por lo que una simple política Write-through en mas comunmente usada que Write-back

Tamaño de bloque

¿Cuál es el tamaño de bloque óptimo?

Tamaño de bloque

¿Cuál es el tamaño de bloque óptimo?

Cuando se hace referencia a una palabra, se carga en la caché un número de palabras adyacentes.

Tamaño de bloque

¿Cuál es el tamaño de bloque óptimo?

Cuando se hace referencia a una palabra, se carga en la caché un número de palabras adyacentes.

- Si el bloque crece, la tasa de aciertos crece por el principio de localidad, hasta un cierto límite cuando se incluyen palabras demasiado distantes.
- Los bloques mas grandes reducen el número de bloques en caché $\rightarrow$ la información es reemplazada mas rápido

Tamaño de bloque

¿Cuál es el tamaño de bloque óptimo?

Cuando se hace referencia a una palabra, se carga en la caché un número de palabras adyacentes.

- Si el bloque crece, la tasa de aciertos crece por el principio de localidad, hasta un cierto límite cuando se incluyen palabras demasiado distantes.
- Los bloques mas grandes reducen el número de bloques en caché $\rightarrow$ la información es reemplazada mas rápido

La relación entre tamaño de bloque y tasa de aciertos es compleja y no hay un valor óptimo para el tamaño de bloque. Un valor razonable es entre 4 y 8 palabras.

Tasa de acierto y Tiempo efectivo de acceso

Dos indicadores de la performance de la memoria caché son:

- Si tenemos n accesos a memoria, y de esos k fueron hit, la tasa de aciertos se calcula como:

$$ta = \frac{\#k}{\#n}$$

- la tasa de fallos se calcula como:

$$tf = 1 - ta$$

Tiempo de acceso Total

Si tenemos n accesos, una tasa de aciertos Ta y conocemos el tiempo de cache tc y el tiempo de respuesta de la memoria tm:

- tp = n*Ta*tc + n*(1- Ta)*(tc+tm)

Ejemplo

- Memoria principal con
  a. bloques de 16 palabras
  b. tiempo de acceso de 2500ns
- Memoria caché con
  a. mapeo (correspondencia) directo
  b. 4 ranuras de 16 palabras
  c. tiempo de acceso de 80ns
  d. inicialmente vacía
- Programa: Ensamblado en las celdas 48 a 95

Ejemplo

Evento	Dirección	Bloque	Tiempo
1 fallo	48	3	2500ns + 80ns
15 aciertos	49-63	3	80*15ns=1200ns
1 fallo	64	4	2500ns + 80ns
15 aciertos	65-79	4	80*15ns=1200ns
1 fallo	80	5	2500ns + 80ns
15 aciertos	81-95	5	80*15ns=1200ns

Ejemplo

$$\#\text{aciertos: } 45$$

$$\#\text{fallos: } 3$$

$$\#\text{refs } 48$$

$$\text{tasa de aciertos } = 45/48 = 0{,}9375$$

$$\text{tiempo de acceso efectivo } = \frac{45*80ns+3*(2500ns+80ns)}{48} = \frac{3600+7740}{48} = \frac{11340ns}{48} = 236,25ns$$

Ejemplo

#aciertos: 45

#fallos: 3

#refs 48

$$\text{tasa de aciertos} = 45/48 = 0{,}9375$$

$$\text{tiempo de acceso efectivo} = \frac{45*80ns+3*(2500ns+80ns)}{48} = \frac{3600+7740}{48} = \frac{11340ns}{48} = 236,25ns$$

!! el TAE es mucho mayor al TAC, pero se debe al alto costo de un acceso a memoria.


¿QUE HAY DE NUEVO VIEJO?

Read Only Memory (ROM)

ROM: Memoria de sólo lectura

Cuando un programa se carga en memoria permanece ahí hasta que

a. La memoria es sobreescrita
b. La computadora se apaga

ROM: Memoria de sólo lectura

1. Para algunas aplicaciones, el programa no necesita ser cambiado y entonces puede ser 'hardwired' en una memoria de sólo lectura
2. Las ROMs se utilizan para almacenar programas en videojuegos, calculadoras, hornos de microondas, computadoras de vehículos, etc.

ROM: Memoria de sólo lectura

1. Para algunas aplicaciones, el programa no necesita ser cambiado y entonces puede ser 'hardwired' en una memoria de sólo lectura
2. Las ROMs se utilizan para almacenar programas en videojuegos, calculadoras, hornos de microondas, computadoras de vehículos, etc.

¿Algún otro ejemplo?

PROM

1. Para grandes producciones, la ROM se programa en fábrica, pero también existen las ROM Programables (PROM) que son escritas por el usuario usando un dispositivo para tal fin.
2. Las PROM pueden utilizarse para implementar Unidades de control o ALUs

EPROM y EEPROM

Si es necesario escribirla mas de una vez:

1. Las EPROM pueden ser borradas con luz ultravioleta,
2. Las EEPROM que pueden borrarse eléctricamente.

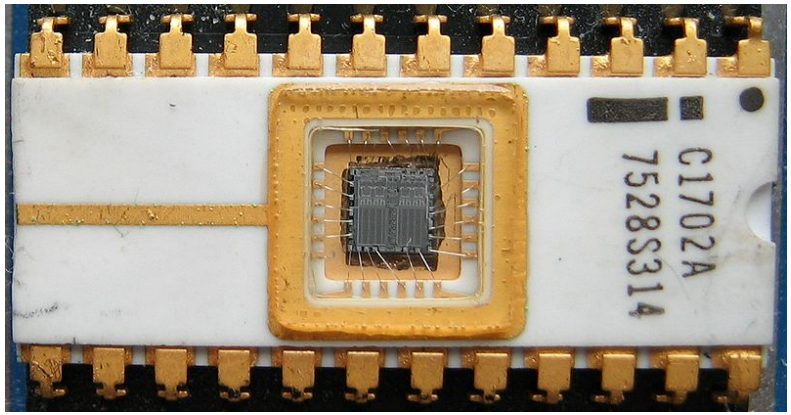

Memoria EPROM

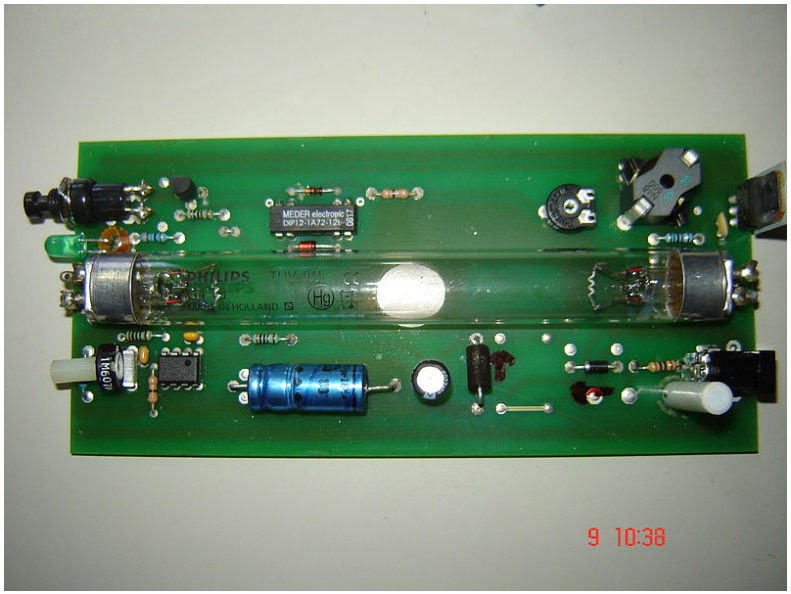

Borrador de EPROM