



FONDAMENTI DI INFORMATICA

Lezione n. 14

- **GESTIONE DELLA GERARCHIA**
- **CONCETTO DI MEMORIA VIRTUALE**
- **RAGIONI PER L'USO DELLA MEMORIA VIRTUALE**
- **MECCANISMO DI GENERAZIONE DEGLI INDIRIZZI FISICI**
- **SEGMENTI, PAGINE**
- **ALGORITMI DI ALLOCAZIONE E POLITICHE DI SOSTITUZIONE**
- **ESEMPI DI MEMORIA VIRTUALE**
- **ORGANIZZAZIONE DI UNA MEMORIA CACHE**
- **MAPPING DEGLI INDIRIZZI**
- **AGGIORNAMENTO DELLA MEMORIA**



USO DELLA GERARCHIA

Per un uso efficiente della gerarchia è necessario stabilire:

- Quando effettuare la sostituzione dei blocchi.
- La dimensione del blocco da trasferire.
- Quale politica di allocazione utilizzare.

Queste caratteristiche devono essere specificate per ogni tipo di gerarchia.

Non esiste alcuna soluzione ottimale per qualunque classe di applicazioni o per qualunque programma.

Per valutare le alternative occorre fare riferimento a un insieme di applicazioni (*benchmarking*) che siano significative a rappresentare il maggior numero di applicazioni.



POLITICHE DI SOSTITUZIONE

La sostituzione può essere effettuata:

- **A RICHIESTA** - in caso di miss si richiamano nuovi dati dal secondo livello.
- **in modo PREVENTIVO** - (molto difficile) es. prefetching.

Il meccanismo di trasferimento a richiesta è l'unico utilizzato in questi tipi di gerarchia.

Un uso implicito del meccanismo di tipo preventivo consiste nel fatto che non si trasferisce mai un solo dato ma un intero blocco, e quindi si fa l'ipotesi (località spaziale) che tutti i dati così trasferiti saranno di utilità.



DIMENSIONE DEL BLOCCO

La dimensione del blocco da trasferire deve tenere conto:

- rapporto fra tempo di trasferimento effettivo e overhead.
- trasferimento di dati inutili.

E' necessario un compromesso fra la necessità di avere blocchi grandi per diminuire gli *overhead* sul tempo di trasferimento e quella di avere blocchi piccoli per ridurre la probabilità di trasferire dati che non verranno utilizzati.

Per dimensionare l'ottimo si ricorre alla sperimentazione. I valori attualmente in uso variano da 512 bytes a qualche Kbytes.



POLITICA DI ALLOCAZIONE

- **STATICA** - Ogni blocco è posto in posizione predeterminata.
- **DINAMICA** - Si assegna la quantità di memoria necessaria nella zona momentaneamente libera.
- **SOSTITUZIONE FORZATA** - Si espelle da M_1 una area scelta per ragioni opportune (preemption).
- **SENZA ALLOCAZIONE FORZATA** - Si alloca la nuova area solo se si individua uno spazio libero di dimensioni sufficienti.

Il meccanismo con sostituzione forzata è quello maggiormente impiegato.



THRASHING

Quando la politica di gestione della gerarchia non è efficiente si verificano troppi insuccessi (o miss), si ha il fenomeno di:

Thrashing

La CPU spende il proprio tempo ad allocare e disallocare aree di memoria senza più svolgere lavoro utile.

Questo fenomeno può inficiare le prestazioni di un sistema ed è dovuto a un cattivo dimensionamento della memoria rispetto ai dati utilizzati dal programma che opera sul sistema.



MEMORIA VIRTUALE

Il meccanismo di gestione della gerarchia formata da:

- Memoria principale
- Memoria secondaria

Prende il nome di **MEMORIA VIRTUALE**.

- Ogni attività o processo eseguito dal processore vede un proprio spazio di indirizzi virtuale o logico.
- La memoria è indirizzata tramite indirizzi fisici.
- Lo spazio degli indirizzi logici è maggiore dello spazio degli indirizzi fisici.



MEMORIA VIRTUALE

- Esiste una corrispondenza (se necessaria) tra indirizzo logico e indirizzo fisico.
- La corrispondenza prende il nome di allocazione.
- L'allocazione è una funzione f che:


$$\text{indir. fisico} = f(\text{indir. logico})$$

- Libera il programmatore dalla necessità di occuparsi direttamente dello spazio in memoria fisica.
- Facilita la gestione comune della memoria tra più utenti.



MEMORIA VIRTUALE

- Rende il programma indipendente dalle dimensioni di memoria della singola macchina.
- Sfrutta efficacemente la gerarchia.



ALLOCAZIONE

Chi effettua la traduzione da ind. logico a ind. fisico ?

- Il programmatore.
- Il compilatore in fase di compilazione.
- Il loader in fase di caricamento.
- Il sistema operativo in esecuzione.


In un sistema monoutente o monoapplicazione:

- Il programmatore (o il loader) specifica in modo diretto gli indirizzi fisici.
- Se la memoria necessaria all'applicazione supera la memoria fisica si ricorre all'OVERLAY.



OVERLAY

Gestione diretta del programma dello spostamento dei dati dalla memoria secondaria alla memoria principale.




ALLOCAZIONE

In un sistema multiutente o multiapplicazione:

- Il programmatore o il compilatore specificano gli indirizzi relativi all'interno di singoli blocchi di programma.
- Il sistema operativo (S.O.), definisce, in fase di esecuzione, le locazioni fisiche nelle quali il singolo blocco viene posto.

ALLOCAZIONE DINAMICA

- In ambiente di multiprogrammazione la collocazione fisica dello stesso codice varia.
- I blocchi sono rilocati in memoria alterando l'indirizzo di base.



ALLOCAZIONE DINAMICA

- Il S.O. ha il controllo sulla allocazione.
- Una tabella in memoria *Memory address table* o *Memory map* o un insieme di registri di base o di rilocazione contengono le informazioni necessarie.


INDIRIZZO VIRTUALE

- Indirizzo di blocco virtuale - da cui si estrae l'indirizzo fisico di blocco.
- Spiazzamento (offset) - usato direttamente come offset all'interno del blocco fisico.

INDIRIZZO Fisico (o virtuale)

$$\begin{array}{l}
 \text{Indirizzo di blocco} \\
 \text{spiazzamento} \\
 \text{indirizzo fisico (o} \\
 \text{virtuale)}
 \end{array}
 =
 \begin{array}{|c|c|c|c|c|}
 \hline
 E & 2 & C & 0 & 0 \\
 \hline
 \end{array}
 +
 \begin{array}{|c|c|c|}
 \hline
 1 & 8 & 3 \\
 \hline
 \end{array}
 =
 \begin{array}{|c|c|c|c|c|}
 \hline
 E & 2 & D & 8 & 3 \\
 \hline
 \end{array}$$

MEMORIA VIRTUALE




Il TLB è una memoria temporanea che consente di effettuare velocemente la localizzazione nella memoria fisica dei dati individuati dall'indirizzo virtuale.

STRUTTURA

- Parte della mappa di memoria è riportata nel TLB o Translation Lookaside Buffer.
- Il TLB viene gestito dinamicamente.
- La traduzione degli indirizzi nel TLB può avvenire con tecniche associative.

MEMORIA ASSOCIATIVA



- **Memoria tradizionale:** (in lettura) restituisce un dato conoscendone la posizione (indirizzo).
- **Memoria associativa:** restituisce una informazione fornendo un dato.

La memoria associativa consente di verificare la presenza di un dato al suo interno e di inviare all'esterno o la posizione del dato o una parte del dato stesso.

Il dato presente nella memoria è formato dall'indirizzo virtuale cui è associato l'indirizzo fisico. Quando la memoria associativa individua al suo interno il dato (indirizzo virtuale) in ingresso, invia in uscita l'indirizzo fisico associato.



SEGMENTI

- I programmi ad alto livello sono organizzati a moduli o blocchi.
- I moduli sono trasformati dal compilatore in segmenti.
- **SEGMENTO**: insieme di bytes (dati o programmi) contigui e posti in relazione logica.
- Il segmento è il blocco elementare che viene trasferito fra le gerarchie.
- I segmenti hanno dimensioni diverse.
- La CPU ha accesso a una tabella di descrittori di segmenti.
- Se il programma fa riferimento ad un segmento che non è presente in memoria viene generata una procedura di caricamento.



SEGMENTI

VANTAGGI

- La struttura del segmento corrisponde alla naturale suddivisione dei dati e dei programmi.
- E' agevole gestire meccanismi di separazione e di protezione per i dati dei singoli utenti.


SVANTAGGI

I segmenti hanno dimensioni fisiche diverse, quindi:

- allocazione complessa
- frammentazione (esterna)
- necessità di ricompattazione della memoria.



FRAMMENTAZIONE ESTERNA




La frammentazione esterna riduce l'utilizzazione della memoria quando risulta necessario disporre i dati dei segmenti in celle di memoria contigue. Lo stesso problema si verificava sui sistemi di memoria secondaria (dischi) quando i ogni file doveva essere memorizzato in segmenti adiacenti.



RICOMPATTAZIONE

- La memoria non può essere sfruttata completamente.
- Tra le aree occupate rimangono zone di piccola dimensione nelle quali non possono essere allocati segmenti.
- Per migliorare l'utilizzazione della memoria: ricompattazione.



ALLOCAZIONE

Il processo di allocazione gestisce la disponibilità della memoria fisica e cerca di ottimizzare:

- tasso di successo (H_A),
- tempo di accesso (T_A),
- utilizzo dello spazio (u).

MANCATO UTILIZZO

- Regioni vuote. Frammenti di memoria non utilizzati.
- Regioni occupate dal sistema di gestione.
- Regioni occupate da informazioni che non vengono utilizzate.



ALLOCAZIONE DEI SEGMENTI

- Senza **PREEMPTION** : se non vi è spazio non si alloca.
- Con **PREEMPTION** : se non vi è spazio si ricoprono zone di memoria già occupate.

In questo ultimo caso occorre scegliere quale zona di memoria utilizzare: *Politica di sostituzione*



ALLOCAZIONE SENZA PREEMPTION

Per allocare un blocco di dimensioni L:

- **FIRST-FIT** - Si scandisce la memoria e lo si pone nel primo posto libero che lo contiene.
- **BEST-FIT** - Si esaminano tutti gli spazi liberi (lunghezza n_i) e si sceglie l'area libera per la quale $n_i - L$ è minimo.

L'allocazione non forzata presenta notevoli inconvenienti quando il sistema di elaborazione deve operare in un ambiente nel quale più utilizzatori condividono la stessa risorsa di calcolo.

In tal caso infatti occorre che le attività che utilizzano la memoria giungano a termine prima di poter iniziare nuove attività.



PAGINAZIONE

Per trasferire dati tra memoria principale e secondaria non si usano blocchi logici (segmenti) ma blocchi di dimensione fissa o **PAGINE**.

La Tabella Pagine contiene informazioni relative a:

- Indirizzo fisico.
- Presenza in memoria.
- Se modificato da quando in memoria.
- Diritti di accesso.

L'uso delle pagine al posto dei segmenti come blocco elementare per il trasferimento dei dati nella gerarchia di memoria formata dalle memorie primaria e secondaria consente di semplificare le procedure di trasferimento.



VANTAGGI E SVANTAGGI

VANTAGGI


- **Allocazione più semplice (dimensione fissa del blocco).**
- **Assenza di frammentazione esterna.**

SVANTAGGI

- **Maggiore difficoltà di gestione delle proprietà.**
- **Frammentazione interna - La dimensione dei dati da trasferire non è un multiplo intero delle pagine.**



FRAMMENTAZIONE INTERNA



SEGMENTI PAGINATI

Per cercare di ottenere i vantaggi di entrambe le soluzioni:

- Ogni segmento è suddiviso in pagine.
- I segmenti mantengono le loro proprietà.
- Non è più necessario allocare i segmenti in modo contiguo in memoria.
- Tabella segmento + Tabella pagine per ogni segmento.



SEGMENTI PAGINATI

Problema: dimensione ottima della pagina per utilizzare al meglio la memoria.

- S_p dimensione pagina.
- S_s dimensione segmento.

Overhead per segmento:

$S = \text{mezza pag.} + 1 \text{ parola per pag.} =$

$$S = \frac{S_p}{2} + \frac{S_s}{S_p}$$

UNIVERSITA' DEGLI STUDI DI PARMA
Dipartimento di Ingegneria dell'Informazione

COMPUTER ENGINEERING

POLITICA FIFO

t	1	2	3	4	5	6	7	8	9	10	11	12
P	2	3	2	1	5	2	4	5	3	2	5	2

Fondamenti di Informatica/14 Gianni CONTE 37 / 58

UNIVERSITA' DEGLI STUDI DI PARMA
Dipartimento di Ingegneria dell'Informazione

COMPUTER ENGINEERING

POLITICA LRU

t	1	2	3	4	5	6	7	8	9	10	11	12
P	2	3	2	1	5	2	4	5	3	2	5	2

Fondamenti di Informatica/14 Gianni CONTE 38 / 58

UNIVERSITA' DEGLI STUDI DI PARMA
Dipartimento di Ingegneria dell'Informazione

COMPUTER ENGINEERING

ESEMPIO: VAX11/780

- L'architettura VAX11 venne progettata per operare in ambiente di multiprogrammazione.
- Numerosi processi operano contendendosi le risorse: CPU, I/O, Memoria.
- Spazio di memoria virtuale 2^{32} bytes suddivisi in pagine di 512 bytes.
- Ogni processo dispone del diritto ad operare su una quantità di memoria fisica definita (working set).
- Quando un processo è attivo risiede completamente in memoria virtuale.

Fondamenti di Informatica/14 Gianni CONTE 39 / 58

UNIVERSITA' DEGLI STUDI DI PARMA
Dipartimento di Ingegneria dell'Informazione

COMPUTER ENGINEERING

ESEMPIO: VAX11/780

- Nella memoria fisica risiedono solo le pagine in uso.
- La memoria è suddivisa in Memoria di sistema (SM) e Memoria dei Processi (PM).

Fondamenti di Informatica/14 Gianni CONTE 40 / 58

UNIVERSITA' DEGLI STUDI DI PARMA
Dipartimento di Ingegneria dell'Informazione

COMPUTER ENGINEERING

ESEMPIO: VAX11/780

Fondamenti di Informatica/14 Gianni CONTE 41 / 58

UNIVERSITA' DEGLI STUDI DI PARMA
Dipartimento di Ingegneria dell'Informazione

COMPUTER ENGINEERING

MEMORIA CACHE

- La cache è una memoria veloce e di piccole dimensioni posta fra la CPU e la memoria principale.
- La cache e la memoria principale formano una gerarchia di memoria.

I tre livelli di memoria: Cache - Mem. principale - Mem. secondaria sono gestiti come due gerarchie a due livelli:

- Mem. principale - Mem. secondaria.
- Cache - Memoria principale.

Fondamenti di Informatica/14 Gianni CONTE 42 / 58



MEMORIA CACHE

Le prestazioni della memoria cache dipendono anche dalla sua posizione rispetto alla CPU:

- Cache su scheda.
- Cache su chip.

La presenza di una memoria cache sullo stesso chip del processore rappresenta la soluzione che garantisce la maggiore efficienza.

Nei sistemi più recenti sono presenti entrambe le soluzioni.

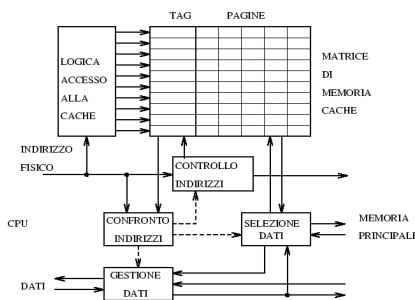


CONFRONTO

Gerarchia	Cache - M.Pr.	M.Pr. - M.Se.
Rapporto tempi di accesso	5/1	1000/1
Gestione	Hardware	Software
Dim. pagina	4 - 128 bytes	64 - 4096 bytes
Accesso CPU	Diretto	Sempre tramite il primo
2° livello		




MEMORIA CACHE



DATI NELLA CACHE

I dati vengono memorizzati in pagine di cache (o linee) caratterizzate da una parte dell'indirizzo o tag.



CICLO OPERAZIONI

Un indirizzo fisico viene inviato dalla CPU.

La cache confronta la parte rilevante dell'indirizzo. Se vi è **{hit}** viene completato il ciclo.

In caso di **{miss}**:

- La cache inizia la lettura da memoria principale di dati che comprendono quello richiesto.
- La politica di sostituzione ha gli stessi problemi di quella preemptive della memoria virtuale.



PROBLEMI SPECIFICI

- Come sono organizzati nella memoria cache i dati provenienti dalla memoria principale ?
- Quando la CPU modifica un dato nella cache, come viene aggiornata la memoria principale ?

ORGANIZZAZIONE CACHE

Il dato richiesto deve essere trovato rapidamente nella memoria cache.

- Tecniche associative.
- Accesso diretto.
- Tecniche miste.



TECNICHE ASSOCIATIVE

- La cache è organizzata come una memoria associativa.
- Il tag viene utilizzato come chiave di lettura.

Come si è già visto in precedenza la tecnica associativa è molto costosa quando le dimensioni della memoria crescono.



ACCESSO DIRETTO

La memoria cache M_1 è suddivisa in $S_1 = 2^k$ pagine (o linee).


Ogni pagina immagazzina n parole consecutive. La memoria principale M_2 è suddivisa in S_2 regioni di eguale dimensione.

$M1(1), \dots, M1(i), \dots, M1(S_1)$: pagine in cache.
 $M2(1), \dots, M2(j), \dots, M2(S_2)$: pagine in mem. principale.

$M2(j)$ va in $M1(i)$ con $i = j \pmod{S_1}$




ACCESSO DIRETTO



TECNICA MISTA O SET ASSOCIATIVE

- Le linee nella cache sono suddivise in gruppi.
- Ogni gruppo può ospitare linee della memoria principale individuate secondo la tecnica di accesso diretto.
- All'interno di ogni gruppo la linea viene individuata in modo associativo.

- L'accesso diretto avviene rapidamente.
- Sono necessarie più memorie associative ma di dimensioni ridotte.



AGGIORNAMENTO MEMORIA PRINCIPALE

Quando la CPU scrive sulla memoria cache si genera una discrepanza fra il valore del dato nella memoria principale e nella cache.

- **Write-back o Copy-back.**
 - Quando viene modificato un dato nella cache la linea corrispondente viene marcata.
 - Quando una linea è scaricata viene ricopiata nella memoria principale solo se marcata
- **Write-through o Copy-through.**
 - In un programma il rapporto fra le operazioni di lettura e di scrittura è dell'ordine di 10.
 - Quando viene modificato un dato nella cache, lo stesso viene modificato anche nella memoria principale.



AGGIORNAMENTO MEMORIA PRINCIPALE

La connessione tra la memoria principale e la memoria cache è fondamentale per le prestazioni del sistema.


Le tecniche che consentono di migliorare le prestazioni della connessione sono:

- L'uso di parallelismo nel collegamento (più byte trasferiti in parallelo).
- L'uso di buffer per la memorizzazione temporanea dei dati. Quando una linea è scaricata dalla cache viene dapprima memorizzata in una memoria temporanea con tempo di accesso ridotto e trasferito solo successivamente nella memoria principale.



CACHE VAX11/780


- Memoria cache con capacità 8K bytes.
- Ogni linea contiene 8 bytes.
- Tecnica *set associative* con 512 gruppi di 2 linee.



Interpretazione dell'indirizzo fisico da parte della cache.



CACHE VAX11/780



CACHE VAX11/780

Come si vede nella figura precedente:

- i tre bit (A0-A2) meno significativi dell'indirizzo vengono utilizzati per individuare il byte all'interno della linea,
- i nove bit (A3-A11) immediatamente precedenti sono utilizzati per individuare il gruppo nel quale la linea può essere immagazzinata.

Per riconoscere la presenza del dato nella memoria cache si procede quindi alla ricerca associativa nel gruppo (composto da due elementi).



ALCUNI PROBLEMI

- La memoria cache può fare riferimento all'indirizzo virtuale invece che all'indirizzo fisico.
- La traduzione dell'indirizzo e la ricerca nella cache possono essere parzialmente sovrapposte.
- La gestione è molto più complessa.

ALCUNE ALTERNATIVE

- Cache separate per i dati e le istruzioni.
- Livelli di cache multipli.

La utilizzazione di memorie cache separate e di livelli di cache diversi si va affermando nelle unità di elaborazione più moderne.