

Sistemi Operativi

AAF - Secondo anno - 3CFU

A.A. 2024/2025

Corso di Laurea in Matematica

Architettura di un elaboratore

Annalisa Massini

Dipartimento di Informatica
Sapienza Università di Roma

Argomenti della lezione

1 Architettura di un elaboratore

- Descrizione generale
- I registri
- Le istruzioni
- Le interruzioni
- La memoria
- Input/Output


Architettura di un elaboratore

Descrizione generale

Definizione di elaboratore

- Un elaboratore è un sistema complesso che contiene milioni di componenti elettronici di base
- Le funzioni base di un elaboratore sono:
 - Elaborazione di dati (o informazioni) - **Data processing**
 - le informazioni possono avere una grande varietà di formati
 - Memorizzazione di dati (o informazioni) - **Data storage**
 - in particolare occorre memorizzare almeno le informazioni che vengono elaborate in un dato momento
 - Spostamento di dati (o informazioni) - **Data movement**
 - informazioni (dati) devono poter essere trasferite sia all'interno dell'elaboratore che verso il mondo esterno
 - Attività di controllo - **Control**
 - per supervisionare (**controllare**) l'esecuzione delle tre funzioni precedenti


Architettura di Von Neumann




Nozioni di Base: Parti Principali

- Processore
 - il cervello del computer: si occupa di tutte le computazioni
- Memoria Principale
 - volatile: se si spegne il computer, se ne perde il contenuto
 - talvolta chiamata memoria reale o primaria
- Moduli di input/output
 - dispositivi di memoria secondaria (dischi...), non volatile
 - dispositivi per la comunicazione (schede di rete...)
 - altri dispositivi: tastiera, monitor, stampante, mouse, ...
- Bus di sistema
 - mezzo per far comunicare tra loro le parti interne del computer: processori, memoria principale, e moduli di input/output


Struttura ad alto livello




Struttura ad alto livello



Struttura ad alto livello



Componenti di un Computer




PC = Program counter
 IR = Instruction register
 MAR = Memory address register
 MBR = Memory buffer register
 I/O AR = Input/output address register
 I/O BR = Input/output buffer register

Architettura di un elaboratore

I registri


Registri del Processore

- Registri di controllo e di stato
 - usati dal processore per controllare l'uso del processore stesso
 - usati da funzioni privilegiate del SO per controllare l'esecuzione dei programmi
- Registri *interni*
 - usati dal processore per l'esecuzione delle istruzioni
- Registri visibili dall'utente
 - piccolo insieme di registri (veloci e costosi) usati per evitare l'accesso alla memoria principale
 - usati da chi programma in assembler o dai compilatori di linguaggi *non* interpretati




Registri di Controllo e Stato

- Program Counter o PC
 - contiene l'indirizzo di un'istruzione da prelevare dalla memoria
- Instruction Register o IR
 - contiene l'istruzione prelevata più di recente
- Program Status Word, o PSW
 - contiene le informazioni di stato, ad es: interrupt disabilitati
- Condition code o flag
 - singoli bit settati dal processore come risultato di operazioni
 - esempi: risultato positivo, negativo, zero, overflow, ...



Registri Interni

- Registro dell'indirizzo di memoria - MAR (Memory Address Register)
 - contiene l'indirizzo della prossima operazione di lettura/scrittura
- Registro di memoria temporanea - MBR (Memory Buffer Register)
 - contiene i dati da scrivere in memoria, o fornisce lo spazio dove scrivere i dati letti dalla memoria
- Registro dell'indirizzo di input/output - I/O address register
- Registro di memoria temporanea per l'input/output - I/O buffer register



Registri Visibili dall'Utente


- Gli unici che possono essere usati *direttamente* (con il loro nome) quando si programma in linguaggio macchina (o assembler), ad es.:
 - `mov $5, %eax` (Pentium con sintassi AT&T)
 - `li $t1, 5` (MIPS, ad es. R3000A nella PlayStation)
- Possono contenere dati o indirizzi
- Nel caso contengano indirizzi, possono essere
 - puntatori diretti
 - registri-indice: per ottenere l'indirizzo effettivo, occorre aggiungere il loro contenuto ad un indirizzo base
 - puntatori a segmento: se la memoria è divisa in segmenti, contengono l'indirizzo di inizio di un segmento

Architettura di un elaboratore

Le istruzioni


Esecuzione di un'istruzione

- Due passi ripetuti iterativamente:
 - **Fetch stage** - Il processore legge un'istruzione dalla memoria
 - **Execute stage** - Il processore esegue l'istruzione



Prelievo ed Esecuzione di un'istruzione

- Il processore preleva l'istruzione dalla memoria principale
- Dopo ogni prelievo il PC è incrementato
- Il PC mantiene l'indirizzo della successiva istruzione da prelevare
- Se l'istruzione è una jump, il PC verrà ulteriormente modificato dall'istruzione stessa caricando l'indirizzo di destinazione del salto




Registro Istruzione

- L'istruzione prelevata viene caricata nell'IR
- Categorie di istruzioni
 - Scambio dati tra processore e memoria
 - Scambio dati tra processore e input/output
 - Manipolazione di dati
 - include operazioni aritmetiche
 - solitamente solo con registri, ma in alcuni processori anche direttamente in RAM
 - Controllo
 - modifica del PC tramite salti condizionati o non
 - Operazioni riservate
 - disabilitazione interrupt
 - disabilitazione cache

Esempio su una macchina ipotetica



(a) Instruction format



(b) Integer format


Program counter (PC) = Address of instruction
Instruction register (IR) = Instruction being executed
Accumulator (AC) = Temporary storage

(c) Internal CPU registers

0001 = Load AC from memory
0010 = Store AC to memory
0101 = Add to AC from memory

(d) Partial list of opcodes

Esempio di esecuzione di un programma



Architettura di un elaboratore

Le interruzioni

Interruzioni

- Le **interruzioni** interrompono la normale esecuzione sequenziale del processore
 - come conseguenza, viene eseguito del **software di sistema**, che tipicamente non è stato scritto dall'utente che sta eseguendo un certo programma
- Le **cause di un'interruzione** sono molteplici e danno luogo a diverse **classi** di interruzioni:
 - da I/O
 - da fallimento hardware
 - da programma
 - da timer

Classi di Interruzioni *Asincrone*

● Interruzioni da input/output

- generate dal controllore di un dispositivo di input/output
- per la maggior parte, i dispositivi di input/output sono più lenti del processore
- quindi, il processore deve mettersi in pausa per aspettare che il dispositivo completi l'operazione corrente
- segnalano il completamento o l'errore di un'operazione di I/O

● Interruzioni da fallimento HW

- Improvvisa mancanza di potenza (power failure)
- errore di parità nella memoria

Classi di Interruzioni *Asincrone*

- **Interruzioni da comunicazione tra CPU**
 - per sistemi dove ce n'è più d'una
- **Interruzioni da timer**
 - generate da un timer interno al processore
 - permettono al sistema operativo di eseguire alcune operazioni ad intervalli regolari

Classi di Interruzioni *Sincrone*

- **Interruzioni di programma** - causate principalmente da:
 - overflow
 - divisione per 0
 - debugging: single step o breakpoint
 - tentativo di esecuzione di un'istruzione macchina errata
 - opcode illegale, oppure operando non allineato
 - chiamata a *system call* (molto spesso)
 - riferimento ad indirizzo di memoria fuori dallo spazio disponibile al programma
 - riferimento ad indirizzo di memoria momentaneamente non disponibile (**memoria virtuale**, come vedremo)

Interruzioni ed istruzione di ritorno

- Per le interruzioni asincrone, una volta che l'**handler** è terminato, si riprende dall'istruzione subito successiva a quella dove si è verificata l'interruzione
- In realtà, potrebbe succedere che ci sia un *process switch*, ma di questo parleremo più avanti
- Comunque, quando la computazione ritornerà al processo interrotto, si ricomincia dall'istruzione successiva

Interruzioni ed istruzione di ritorno

- Con le interruzioni sincrone, non è detto che si riprenda con l'istruzione successiva
 - **faults**: errore correggibile, viene *rieseguita la stessa istruzione*
 - es.: page fault
 - **aborts**: errore non correggibile, computazione terminata
 - es.: segmentation fault
 - **traps** e **system calls**: si continua dall'istruzione successiva
 - es. per traps: debugging

Fase di interruzione

- Ad ogni ciclo fetch-execute, viene anche controllato se c'è stata un'interruzione (o una exception)
- Se è così il programma viene *sospeso* e viene eseguita una funzione che gestisce l'interruzione (interrupt-handler routine)





Figure 1.7 Instruction Cycle with Interrupts


Interruzioni: trasferimento del controllo

- L'**interrupt handler** è una funzione particolare: nel programma utente non era prevista
- Sistema operativo e hardware collaborano per salvare le informazioni (almeno registro di stato e Program Counter) e settare il Program Counter al nuovo valore
 - normalmente, questo lo fa il *programmatore* (se scrive direttamente in assembler) o il *compilatore*
 - corrisponde a una chiamata a funzione, ma non è stata scritta dal programmatore (niente di strano, esistono le librerie...)
 - Infatti nel punto in cui avviene questa *chiamata*, il programma utente non prevedeva affatto di effettuare la chiamata all'interrupt handler!
 - ma comunque si sa che le *interruzioni vere* - **eccezioni** - possono essere sollevate

Interruzioni: trasferimento del controllo




Interruzioni: trasferimento del controllo



Interruzioni: modifiche a memoria e registri


Il processore sta eseguendo l'istruzione all'indirizzo N quando arriva un'interruzione, da gestire con l'handler all'indirizzo Y



(a) Interrupt occurs after instruction at location N


Interruzioni: modifiche a memoria e registri

Quando l'handler è completato, si va all'indirizzo $N + 1$, **ma** se l'interruzione era una *fault* correggibile (es. un page fault), si va all'indirizzo N




(b) Return from interrupt

Interruzioni: sequenziali ed annidate




(a) Sequential interrupt processing




(b) Nested interrupt processing

Multiprogrammazione



- Un processore deve eseguire più programmi contemporaneamente
- La sequenza con cui i programmi sono eseguiti dipende dalla loro priorità e dal fatto che siano o meno in attesa di input/output
- Alla fine della gestione di un'interruzione, il controllo potrebbe non tornare al programma che era in esecuzione al momento dell'interruzione


Gerarchia di memoria



Dall'alto verso il basso

- Diminuisce la velocità di accesso
- Diminuisce il costo al bit
- Aumenta la capacità
- Diminuisce la frequenza di accesso alla memoria da parte del processore


Gerarchia della memoria




La **memoria principale** (o *inboard*) ha le seguenti caratteristiche:

- è volatile: se si spegne il computer, il contenuto si perde
- contiene i programmi in esecuzione e parte dei dati
- la velocità del processore è maggiore della velocità di accesso alla memoria principale
- per ridurre i tempi di attesa, si usa la *memoria cache*, memoria piccola e veloce, che sfrutta il principio di località

Cache e Memoria Principale



(a) Single cache



(b) Three-level cache organization

Cache: Nozioni di Base

- Contiene copie di porzioni della memoria principale
- Il processore prima controlla se un dato è nella cache
- Se non c'è, il corrispondente blocco di memoria principale viene caricato nella cache
- Siccome vale la *località dei riferimenti*, è probabile che il dato appena caricato serva ancora nell'immediato futuro
 - in generale, i futuri riferimenti in memoria ricadranno probabilmente nel blocco appena caricato
- Gestione totalmente demandata all'hardware
 - il programmatore non “vede” la cache, neanche se usa l'assembler
 - quindi, non la “vede” neanche un compilatore
 - e neanche il sistema operativo, che però la “imita” spesso

Cache vs. Memoria Principale

$$\frac{2^n}{K} \gg C; |Tag| = \log_2 \frac{2^n}{K}; \text{tipicamente, } K = 4$$




Figure 1.17 Cache/Main-Memory Structure


Cache: Nozioni di Base

- Capacità della cache
 - cache anche piccole hanno un grande impatto sulle performance
- Dimensione dei blocchi
 - i dati scambiati tra memoria e cache sono in quantità multiple di un blocco
 - incrementare la misura del blocco aumenta il numero di accessi riusciti
 - ma incrementarla troppo è controproducente: saranno di più anche i dati che vengono rimossi e più bassa la probabilità di accesso riuscito

Cache: Nozioni di Base

- Funzione di mappatura (mapping)
 - determina la locazione della cache nella quale andrà messo il blocco proveniente dalla memoria
- Algoritmo di rimpiazzamento
 - sceglie il blocco da rimpiazzare
 - algoritmo Least-Recently-Used (LRU): si rimpiazza il blocco usato meno di recente
- Politica di scrittura
 - determina quando occorre scrivere in memoria
 - può accadere ogni volta che un blocco viene modificato (*write-through*)
 - può accadere quando il blocco è rimpiazzato (*write-back*)
 - occorre minimizzare le operazioni di scrittura
 - questo vuol dire che la memoria può trovarsi in uno stato “obsoleto”, ovvero non in linea con il contenuto della cache

Gerarchia della memoria



La memoria secondaria:

- corrisponde alla memoria esterna (o *outboard*) e all'*offline storage*
- è considerata una memoria *ausiliaria*
- è non volatile: se si spegne il computer, il contenuto rimane
- è usata per memorizzare i file contenenti programmi o dati


Architettura di un elaboratore

Input/Output

Generalità sui meccanismi di I/O

- Grande varietà di dispositivi per I/O (periferiche)
 - gestiscono diverse quantità di dati
 - lavorano a diverse velocità
 - gestiscono dati in formati diversi
- I dispositivi di I/O sono più lenti della CPU e della RAM
- Necessità di **moduli di I/O** per liberare la CPU delegando al modulo di I/O il controllo del trasferimento dei dati tra memoria e periferiche


Moduli di I/O



Moduli di I/O

- Un modulo di Input/Output fornisce:
 - un'interfaccia tra CPU e memoria
 - un'interfaccia con una o più periferiche
- Azioni del modulo di I/O
 - il CPU controlla lo stato del modulo di I/O
 - il modulo di I/O restituisce il suo stato
 - se il modulo di I/O è pronto, la CPU richiede il trasferimento di dati
 - il modulo richiede i dati alla periferica
 - il modulo trasferisce i dati alla CPU

Moduli di I/O



Moduli di I/O

- Nel tempo sono state adottate soluzioni sempre più efficienti per eseguire il trasferimento di dati tra memoria e periferiche
 - Lo scopo principale è liberare la CPU dal compito di eseguire il trasferimento dati
 - Il motivo è la grande differenza di velocità della CPU rispetto alle periferiche
- Tipi di realizzazione di I/O
 - I/O programmato - metodo più vecchio e più lento perchè gestito dalla CPU che lavora secondo i tempi delle periferiche
 - I/O da interruzioni - metodo più efficiente del precedente il cui la CPU è coinvolta quando porzioni di dati sono pronti per il trasferimento ed è richiesta tramite interruzione
 - Accesso diretto alla memoria - Direct Memory Access (DMA) - metodo più efficiente in cui la CPU demanda la gestione del trasferimento dati ad un modulo dedicato, cioè il controllore di DMA