Lezione R11

Real-time su multiprocessore

Sistemi embedded e real-time

18 dicembre 2012

Marco Cesati

Dipartimento di Ingegneria Civile e Ingegneria Informatica
Università degli Studi di Roma Tor Vergata

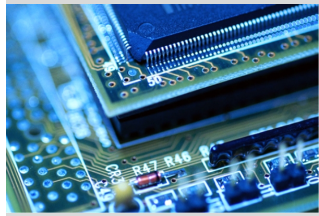

Di cosa parliamo in questa lezione?

In questa lezione si dà una visione introduttiva del problema della schedulazione real-time in sistemi multiprocessore

1. Sistemi multiprocessore
2. Effetto Dhall
3. Anomalie di schedulazione
4. Test e condizioni di schedulabilità
5. Schedulazione partizionata

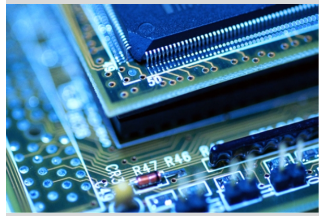

Sistemi multiprocessore

Un sistema real-time è detto multiprocessore quando è dotato di due o più processori, ciascuno in grado di eseguire job autonomamente

I processori possono essere dello stesso tipo o di tipo diverso

Ad esempio si consideri un sistema costituito da

- Diversi microprocessori multi-core
- Diverse schede di rete
- Diverse schede PCI con controllori DMA

In generale modellando il sistema è necessario specificare:

- il numero μ di tipi di processore
- il numero m_i di processori dell'i-esimo tipo ($1 \leq i \leq \mu$)
- su quali tipi di processore può eseguire ciascun job

In questa lezione tutti i processori sono dello stesso tipo

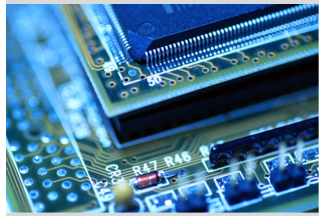

Real-time su sistemi multiprocessori

Few of the results obtained for a single processor generalize directly to the multiple processor case; bringing in additional processors adds a new dimension to the scheduling problem.

The simple fact that a task can use only one processor even when several processors are free at the same time adds a surprising amount of difficulty to the scheduling of multiple processors.

C. L. Liu, 1969

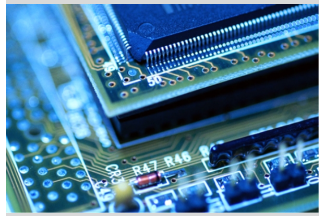

Sistemi statici

Un sistema real-time è detto *statico* quando ciascun job è assegnato ad uno specifico processore

Esistono due varianti di sistemi statici:

- L'insieme dei job (o task) nel sistema è predeterminato, e l'assegnazione di ciascun job ad uno specifico processore è effettuata una volta per tutte nella fase di progetto del sistema
- L'insieme dei task nel sistema non è predeterminato, e l'assegnazione del task ad uno specifico processore è effettuata dal sistema operativo durante la fase di creazione del task (*scheduler partizionati*)

In entrambi i casi lo scheduler **non** decide su quale processore sarà eseguito un job appena rilasciato (è già stabilito)

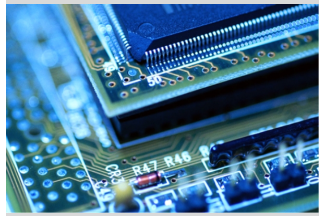

Sistemi dinamici

Un sistema real-time è detto *dinamico* quando lo scheduler può assegnare dinamicamente un job ad un qualunque processore disponibile

Esistono tre varianti di sistemi dinamici:

- Con job non interrompibili
- Con job interrompibili e non migrabili: anche se interrotto, il job deve riprendere l'esecuzione sullo stesso processore in cui era in esecuzione precedentemente
- Con job interrompibili e migrabili: una volta interrotto, il job può riprendere l'esecuzione su qualunque processore che possa eseguirlo

Un algoritmo di schedulazione per un sistema dinamico è detto ***globale*** perché stabilisce quale processore eseguirà ciascun job

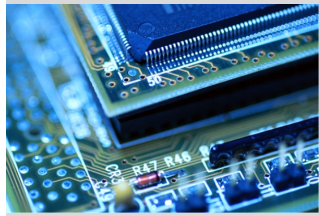

Esempio di schedulazione in sistema statico

In un sistema statico esiste per ogni processore una lista di task o job con le relative priorità

Lista processore P_1: J_1, J_2, J_3, J_4
Lista processore P_2: J_5, J_6, J_7, J_8

i	1	2	3	4	5	6	7	8
r_i	0	0	0	0	4	0	0	0
e_i	3	1	2	2	2	4	4	1

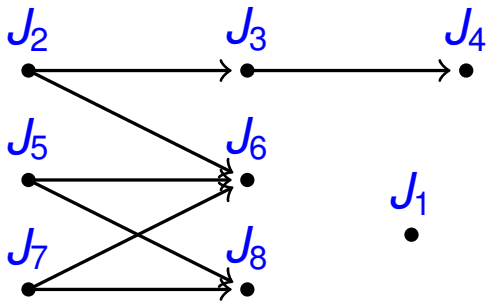

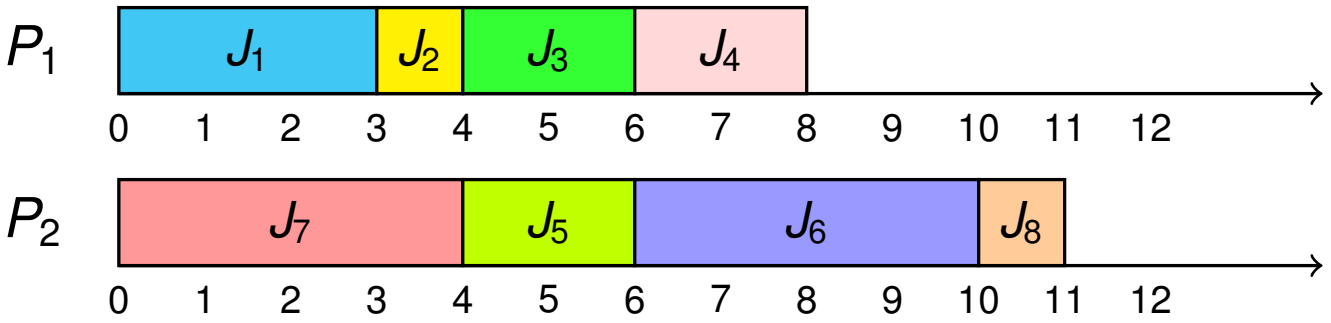

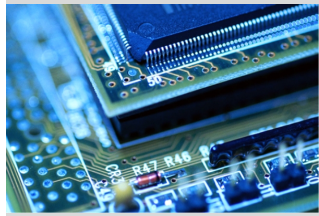

Esempio di schedulazione in sistema dinamico

Lista: $J_1, J_2, \ldots, J_8$

i	1	2	3	4	5	6	7	8
r_i	0	0	0	0	4	0	0	0
e_i	3	1	2	2	2	4	4	1

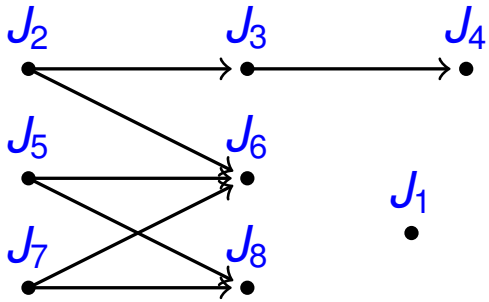

Job interrompibili e migrabili:

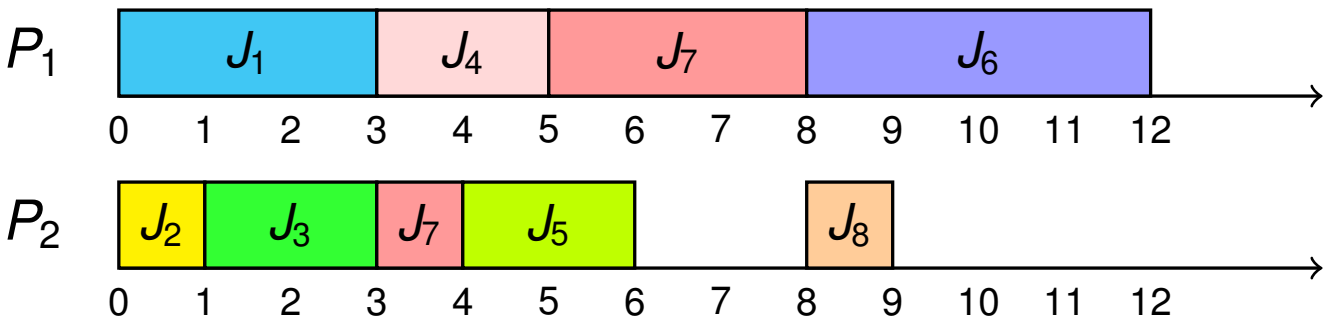

Job non interrompibili:

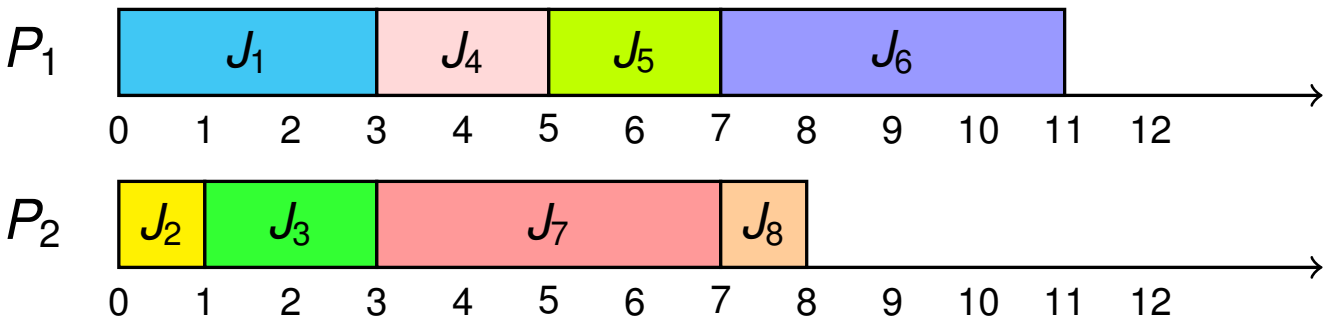

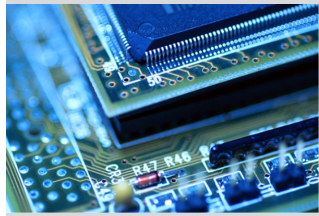

Vantaggi dei sistemi statici

Quali sono i vantaggi dei sistemi statici?

- Si può analizzare la schedulabilità su ciascun processore utilizzando i risultati teorici validi per il caso uniprocessore (fondamentale per i sistemi hard real-time!)
- Un job che impiega più tempo di quanto previsto dal suo WCET (*overrun*) può ritardare l'esecuzione dei soli task associati al suo processore
- Poiché i job interrotti riprendono sempre l'esecuzione sullo stesso processore si evitano i costi dovuti alla migrazione del contesto ad un altro processore
- La coda di esecuzione (in cui i job rilasciati aspettano di essere attivati) è relativa al singolo processore ed è quindi più piccola

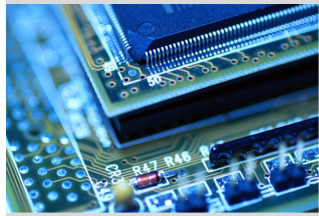

Vantaggi dei sistemi dinamici

Quali sono i vantaggi dei sistemi dinamici?

- Hanno tipicamente meno cambi di contesto e interruzioni dei job, poiché un job è interrotto solo quando nessun processore è idle
- Se un job esegue per meno tempo di quanto previsto dal suo WCET, il tempo liberato sul processore può essere utilizzato potenzialmente da tutti i task nel sistema
- Se un job impiega più tempo di quanto previsto dal suo WCET (*overrun*), la probabilità che ciò comporti il mancato rispetto di una o più scadenze è minore
- Per ogni task del sistema che è creato a run-time, assegnazione e bilanciamento del carico sono “automatici” e determinati dall’algoritmo di schedulazione globale
- In confronto ai sistemi statici, sono in grado di schedulare meglio i task con fattore di utilizzazione “grande”

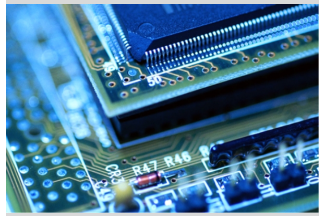

Algoritmi di schedulazione multiprocessore

Gli algoritmi di schedulazione clock-driven sono in generale utilizzabili senza problemi con i sistemi multiprocessore

Infatti la schedulazione effettiva è generata “off-line” e validata una volta per tutte

Al contrario, non è immediato applicare gli algoritmi priority-driven ai sistemi multiprocessore

Diverse problematiche:

- Efficienza degli algoritmi (effetto Dhall)
- Predicibilità del sistema (anomalie di schedulazione)
- Test di schedulabilità (teoremi non più validi)

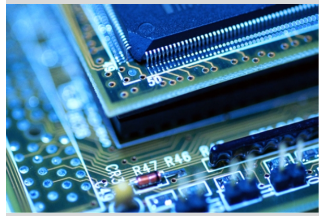

Effetto Dhall

Teorema (Dhall & Liu, 1978)

Per ogni numero di processori $m \geq 2$, esistono insiemi di task con utilizzazione bassa che non sono schedulabili con RM, DM o EDF

Consideriamo $T_1 = (1, 2\varepsilon)$, $T_2 = (1, 2\varepsilon)$, $\ldots$, $T_m = (1, 2\varepsilon)$, $T_{m+1} = (1 + \varepsilon, 1)$

Utilizzazione globale: $U_g = 2\varepsilon \cdot m + 1/(1 + \varepsilon) \rightarrow 1$ se $\varepsilon \rightarrow 0$

Schedulazione fattibile, $m = 2$:

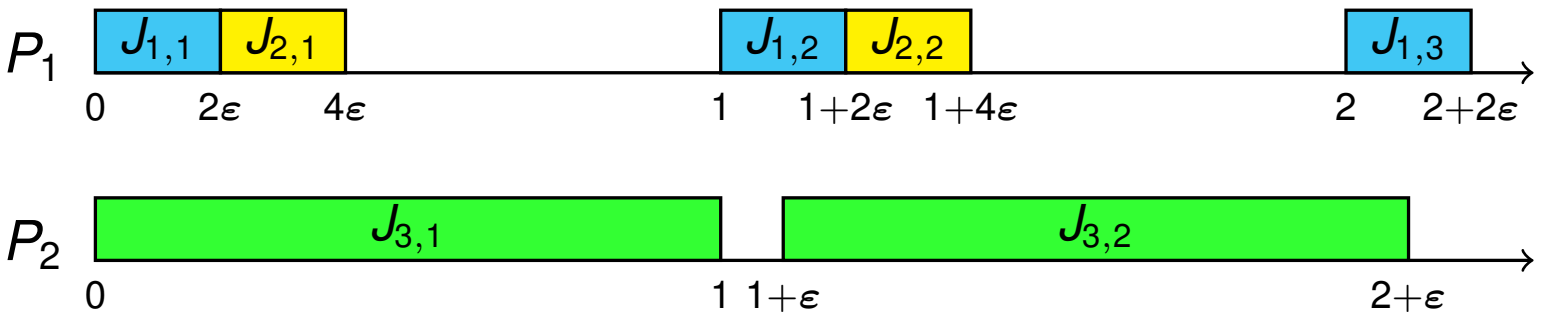

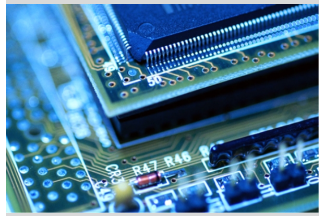

Effetto Dhall (2)

Schedulazione con EDF, $m = 2$:

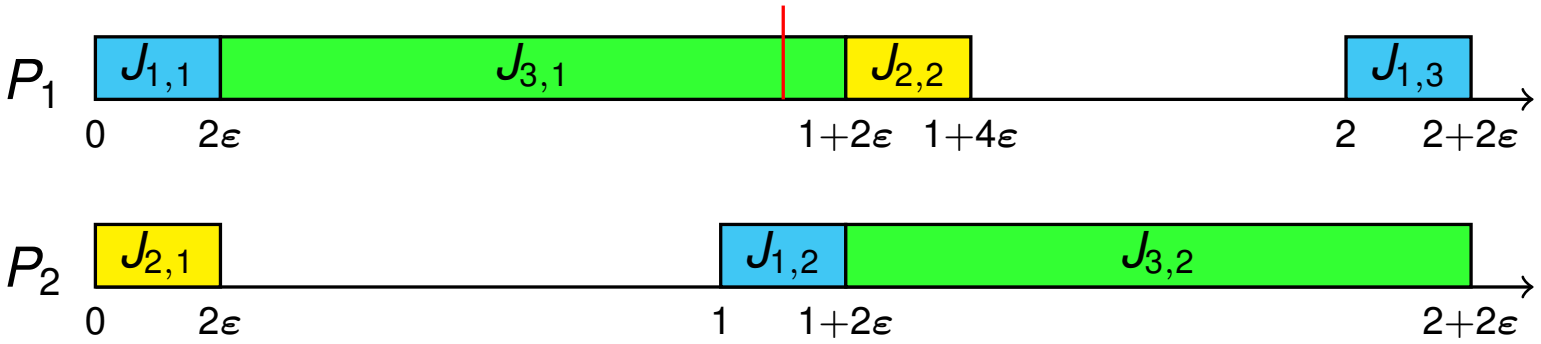

Schedulazione con RM, $m = 2$:

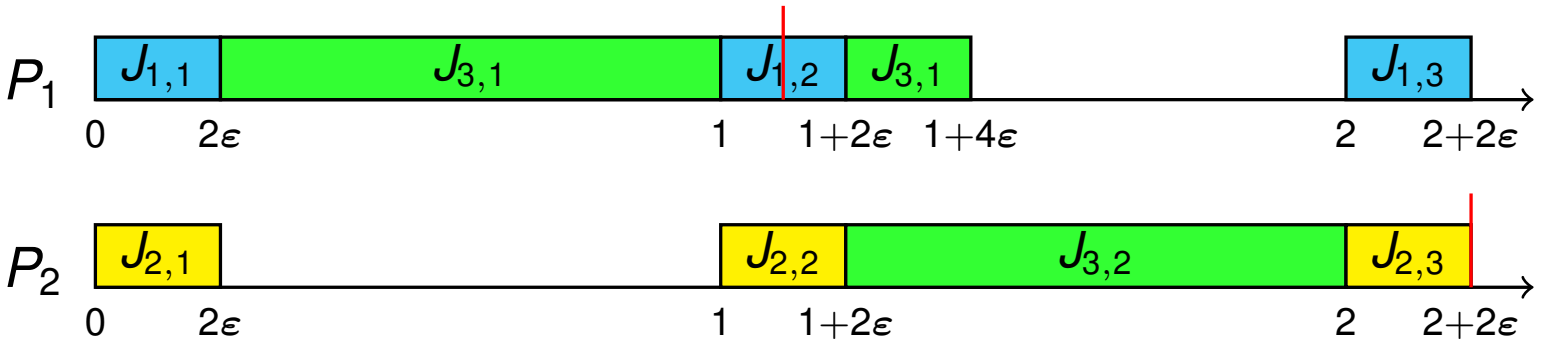

Comportamenti analoghi all'effetto Dhall si verificano solo se almeno uno dei task ha una utilizzazione molto alta (Funk, Goossens & Baruah, 2001)

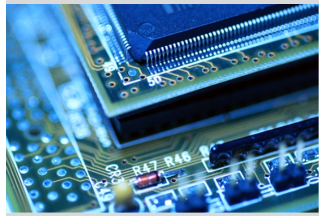

Anomalie di schedulazione

Si definisce *anomalia di schedulazione* il comportamento di un algoritmo di schedulazione per cui, in presenza di variazioni apparentemente vantaggiose del carico del sistema, si ottiene un peggioramento delle prestazioni

Esempi di variazioni “vantaggiose”:

- Aumento del periodo di un task
- Diminuzione del tempo di esecuzione di un task
- Rimozione di vincoli di precedenza tra i job
- Aumento del numero di processori

Nei sistemi uniprocessore le anomalie di schedulazione possono verificarsi solo nel caso in cui job sono **non interrompibili** e/o **non indipendenti** (Mok, 2000)

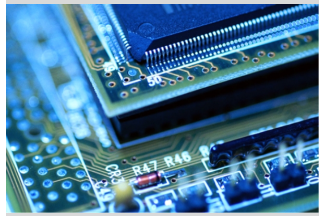

Anomalie di schedulazione in sistemi multiprocessore

Assumiamo che tutti i job siano indipendenti:

Tipo di sistema	Anomalie ?
Statico, job non interrompibili	Sì (1)
Statico, job interrompibili	No
Dinamico, job non interrompibili	Sì (2)
Dinamico, job interrompibili ma non migrabili	Sì (3)
Dinamico, job interrompibili e migrabili	Sì (4)

(1) Mok, 2000 (cfr. esempi in Lezione R5)
(2) Graham, 1969
(3) Ha & Liu, 1994
(4) Andersson & Jonsson, 2000

Perché le anomalie complicano il problema della validazione?

Se i parametri dei job possono variare, non si può validare il sistema esaminando solo il “caso peggiore”, ma è necessario esaminare tutte le combinazioni di parametri

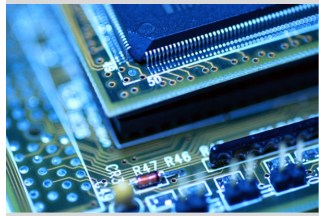

Anomalie di schedulazione con job non migrabili

Job interrompibili ma non migrabili

Indice minore $\equiv$ priorità maggiore

e_2 varia da 2 a 6

i	1	2	3	4
r_i	0	0	4	0
d_i	10	10	15	20
e_i	5	$[2,6]$	8	10

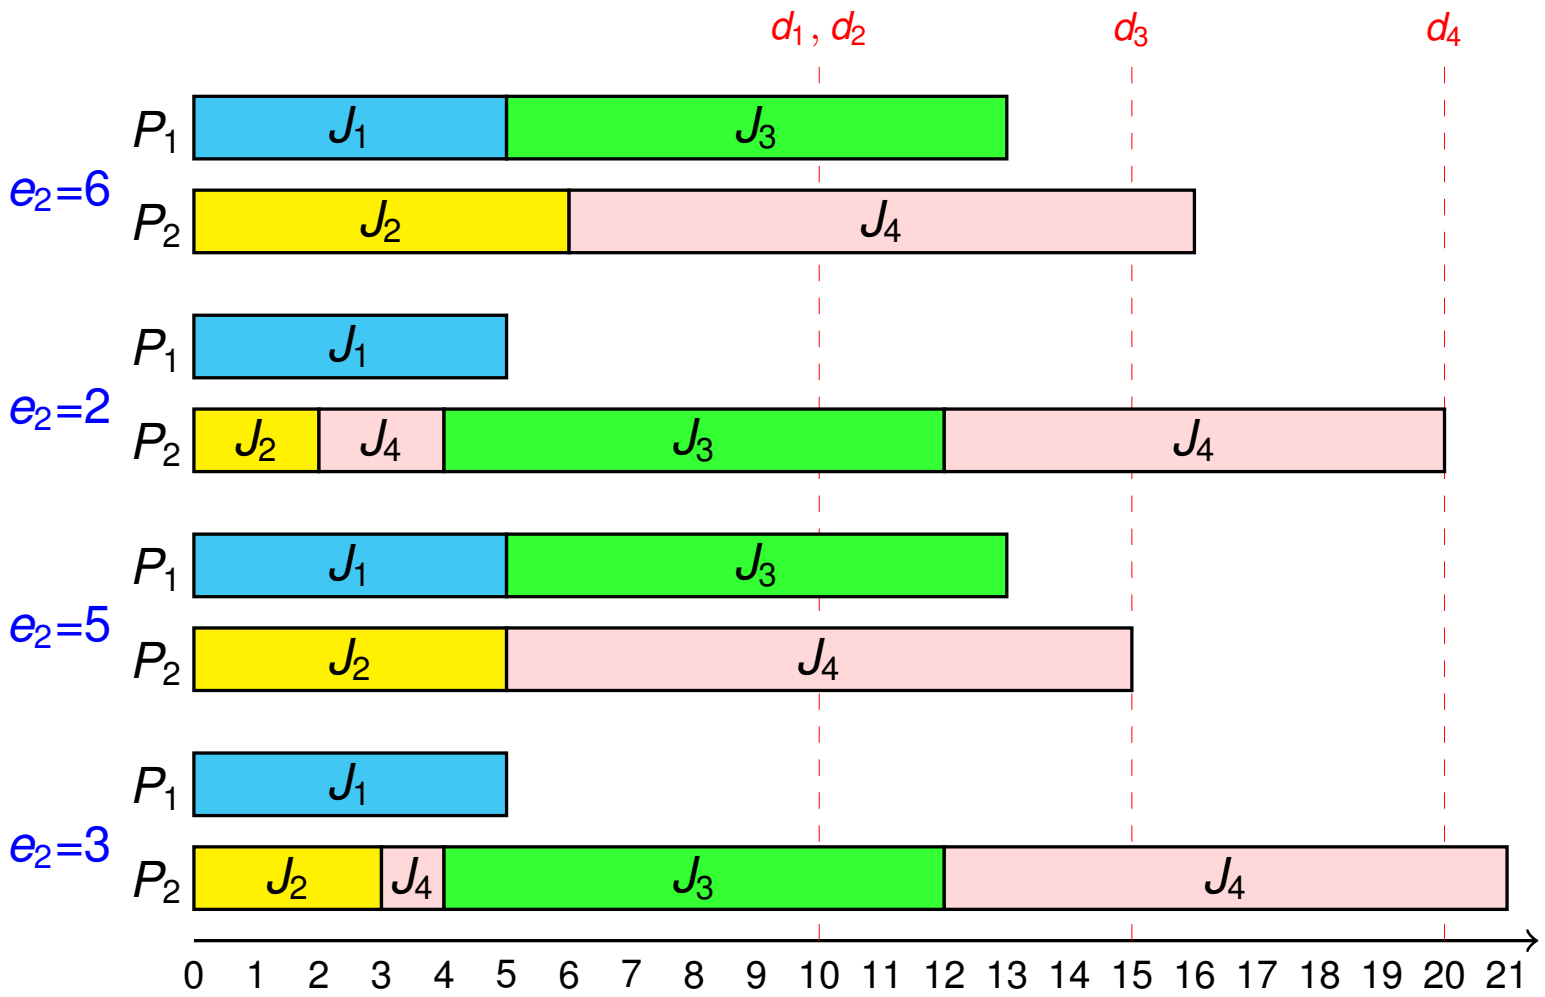

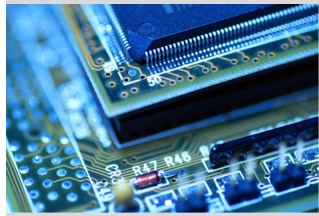

Anomalie di schedulazione con job migrabili

Aumento del periodo di un task di priorità alta:

$T_1 = (3, 2),\ T_2 = (4, 2),\ T_3 = (12, 8)$

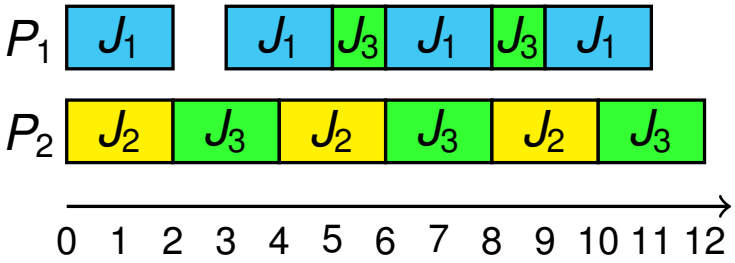

$T_1 = (4, 2),\ T_2 = (4, 2),\ T_3 = (12, 8)$

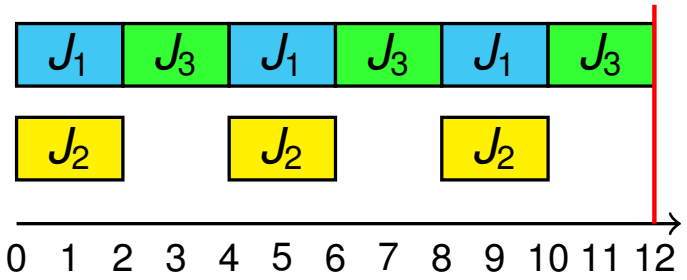

Aumento del periodo di un task di priorità bassa:

$T_1 = (4, 2),\ T_2 = (5, 3),\ T_3 = (10, 7)$

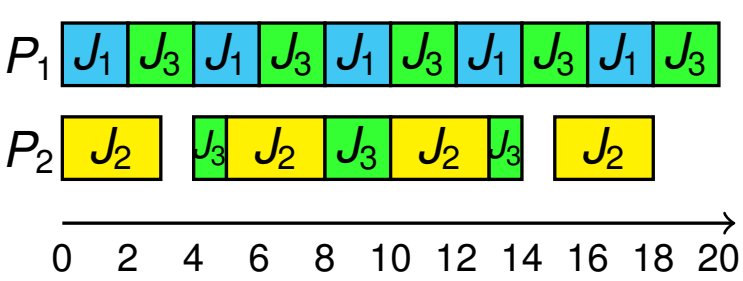

$T_1 = (4, 2),\ T_2 = (5, 3),\ T_3 = (11, 7)$

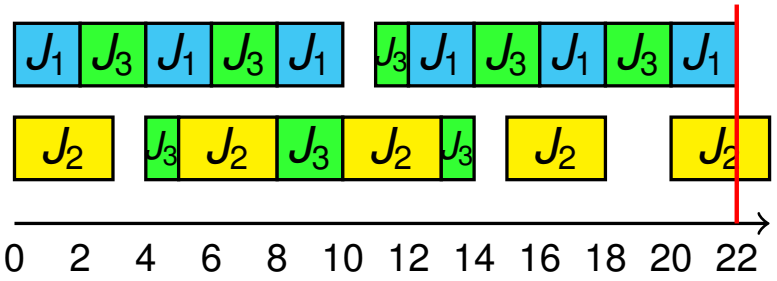

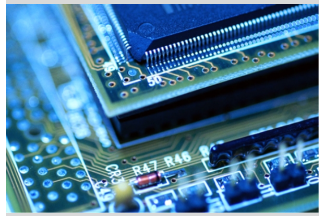

Istanti critici in schedulazioni globali

Teorema (Lauzac, Melhem & Mosse, 1998)

Utilizzando uno scheduler globale a priorità fissa a livello di task (es., DM), l'istante in cui un job di un task T_i è rilasciato contemporaneamente ai job di tutti i task di priorità superiore $T_1, \ldots T_{i-1}$ **non** è necessariamente un istante critico di T_i

T_1=(8, 2, 2), T_2=(10, 2, 2), T_3=(8, 4, 6), T_4=(8, 4, 7), m=2

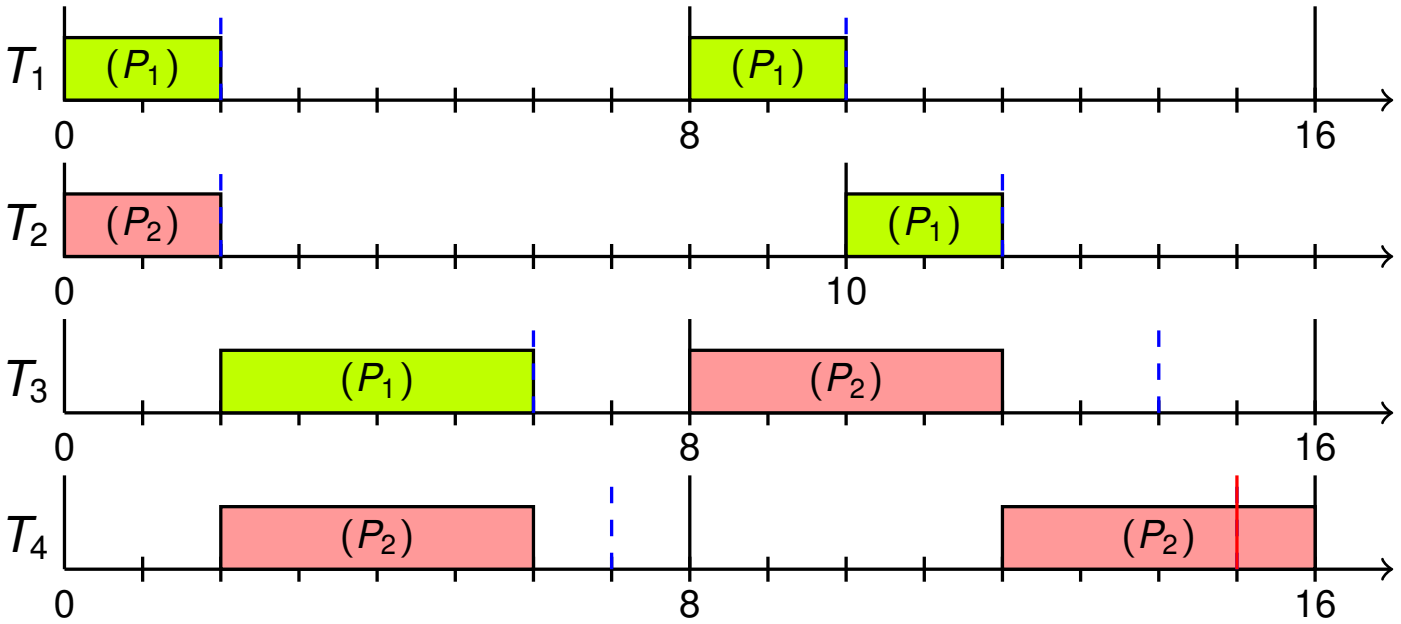

Il test di schedulabilità non funziona!

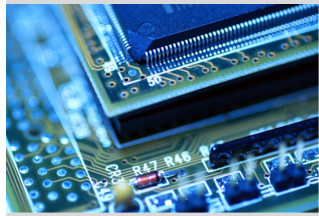

Fattore di utilizzazione per multiprocessore

Teorema (Oh & Baker, 1998)

Dato un sistema di task periodici con scadenze uguali ai periodi e m processori, se X è un qualsiasi algoritmo di schedulazione partizionato con priorità fissa a livello di task:

$$U_X \leq \frac{m+1}{1+2^{1/(m+1)}}$$

Teorema (Andersson, Baruah & Jonsson, 2001)

Dato un sistema di task periodici con scadenze uguali ai periodi e m processori, sia X

- un qualsiasi algoritmo di schedulazione partizionato, o
- un qualsiasi algoritmo di schedulazione globale con priorità fissa a livello di job;

allora per il fattore di utilizzazione di X si ha: $U_X \leq \frac{m+1}{2}$

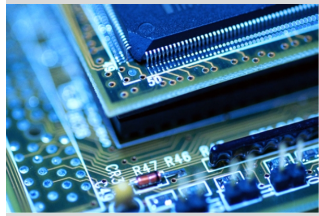

Schedulazione a priorità fissa su multiprocessore

Corollario (Andersson, Baruah & Jonsson, 2001)

Nessun algoritmo di schedulazione globale con priorità fissa a livello di job è ottimale su multiprocessore

Schedul. EDF di $T_1 = (1, 1)$, $T_2 = (2, 1)$, $T_3 = (5, 5)$, $m = 2$:

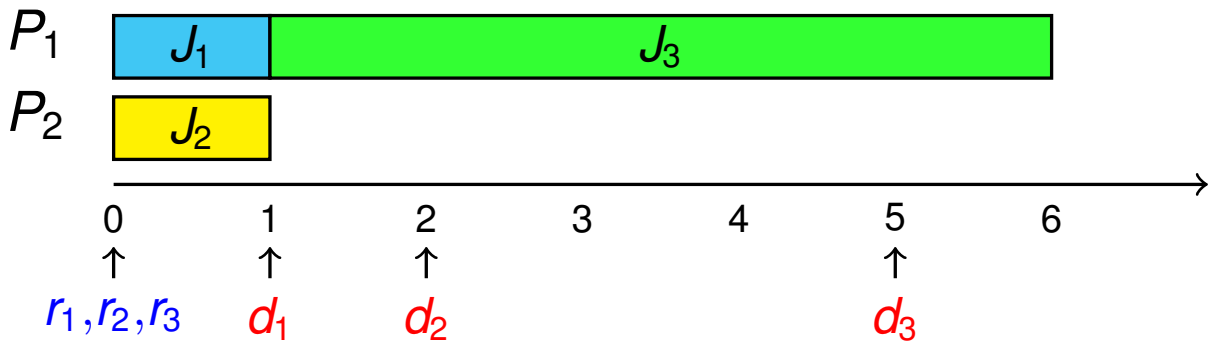

Eppure una schedulazione fattibile non EDF esiste:

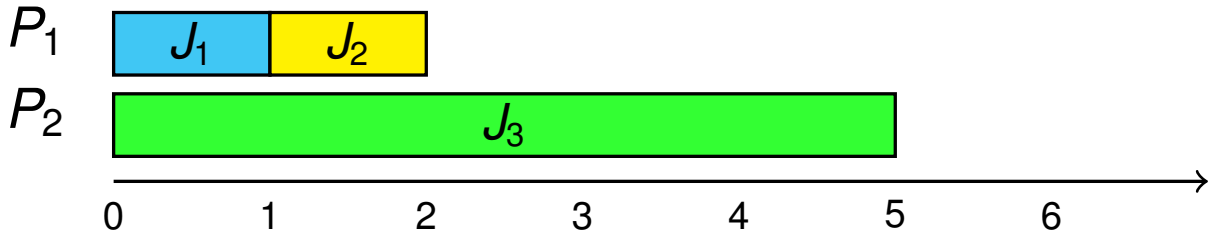

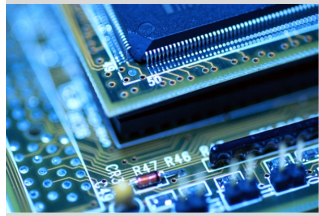

Algoritmi ottimali per multiprocessore

Possono esistere algoritmi ottimali per multiprocessore? **Sì!**

- Alcuni algoritmi di schedulazione dinamica a livello di job hanno fattore di utilizzazione pari a m
- Tuttavia, nessun algoritmo on-line (non "chiaroveggente") è ottimale se gli istanti di rilascio dei job non sono esattamente prefissati (Fisher, 2007)

Una classe di algoritmi ottimali su multiprocessore sono derivati dall'algoritmo Pfair (Baruah & al., 1996):

- basato sull'idea di schedulazione *fluida*: ogni task progredisce in modo proporzionale alla sua utilizzazione
- tempo diviso in *quanti*: allo scadere di ogni quanto, lo scheduler assegna i task ai processori in modo che per ogni task T_i il lavoro compiuto sia $\lceil t \cdot e_i/p_i \rceil$ o $\lfloor t \cdot e_i/p_i \rfloor$

Gli algoritmi dinamici a livello di job sono molto costosi in termini di overhead dello scheduler, quindi non sono adottati

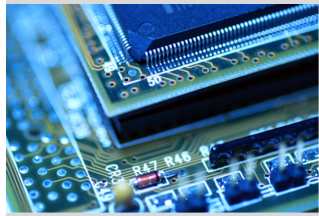

Schedulazione partizionata

Nei sistemi real-time multiprocessore statici l'algoritmo di schedulazione è detto *partizionato*

Consiste di due componenti:

- *Allocazione dei task*: assegnazione di ciascun task ad uno specifico processore
  - questo problema è analogo a *bin packing* ed è NP hard (Garey & Johnson, 1979)
- *Problema di priorità*: schedulazione dei task su ciascun processore
  - questo è il problema della schedulazione su sistemi con un singolo processore

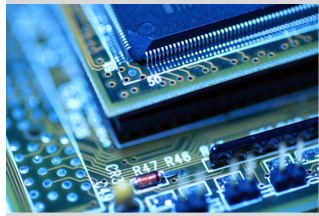

Allocazione dei task

Formulazione del problema

Dato un sistema di task periodici, partizionare i task in sottoinsiemi tali che ciascun sottoinsieme può essere schedulato in modo fattibile su un singolo processore utilizzando un determinato algoritmo di schedulazione

Un sistema di n task indipendenti è schedulabile con n processori (purché ciascun task abbia densità inferiore a uno)

Non è noto alcun algoritmo polinomiale che sia in grado di determinare, dato un sistema di n task indipendenti, il minimo numero m_0 di processori che permetta di schedularlo

Gli algoritmi di allocazione dei task utilizzabili in pratica trovano soluzioni non ottimali:

- Non riescono ad associare i task ai processori in modo da sfruttarli nel miglior modo possibile
- Non riescono a determinare schedulazioni fattibili per ogni possibile insieme di task schedulabile

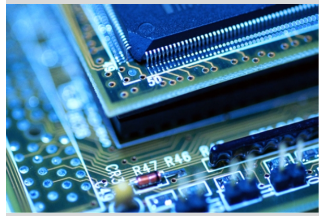

Allocazione dei task (2)

Come misurare la "bontà" di un algoritmo di allocazione?

Tre metriche principali:

- Rapporto di approssimazione: è il massimo valore m/m_0, ove m è il numero di processori utilizzato dall'algoritmo di allocazione e m_0 è il minimo numero teoricamente necessario, considerando ogni possibile sistema di task
- Fattore di accelerazione: quanto è necessario aumentare la velocità di esecuzione degli m_0 processori per schedulare fattibilmente ogni possibile sistema di task con le assegnazioni determinate dall'algoritmo di allocazione
- Fattore di utilizzazione: il valore di soglia per cui tutti i sistemi di task con fattore di utilizzazione totale inferiore o uguale sono sempre schedulabili utilizzando l'algoritmo di allocazione dei task

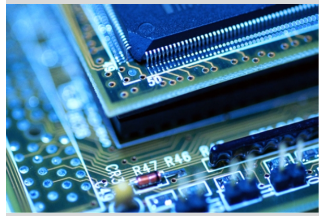

Algoritmo RMFF

Il più semplice algoritmo per l'allocazione dei task è RMFF (Rate Monotonic First Fit, Dhall & Liu, 1978):

1. ordina i task per periodi non decrescenti: $T_1, T_2, \ldots$
2. ordina arbitrariamente i processori: $P_1, P_2, \ldots$
3. cominciando da T_1, assegna ciascun task T_i al primo processore P_j tale che l'insieme dei task già assegnati a P_j insieme a T_i risulta ancora schedulabile tramite RM

- $U_{\text{RMFF}} = m \cdot \left(\sqrt{2} - 1\right)$ (Oh & Baker, 1998)
- Fattore di approssimazione: 2.23 (Oh & Son, 1993)

RMFF può essere usato come un algoritmo on-line?

L'ordinamento dei job richiede la conoscenza di tutti i periodi dei task da schedulare $\Rightarrow$ usare RMFF on-line richiede di riallocare tutti i task quando ne viene creato uno nuovo

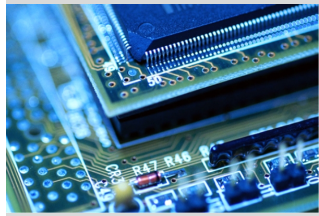

Algoritmo FFDU

Un altro algoritmo per l'allocazione dei task è FFDU (First Fit Decreasing Utilization, Davari & Dhall, 1986):

1. ordina i task per fattori di utilizzazione decrescenti: $T_1, T_2, \ldots$
2. ordina arbitrariamente i processori: $P_1, P_2, \ldots$
3. cominciando da T_1, assegna ciascun task T_i al primo processore P_j tale che l'insieme dei task già assegnati a P_j insieme a T_i risulta ancora schedulabile tramite RM

- $U_{\text{FFDU}} = m \cdot \left(\sqrt{2} - 1\right)$ (Lopez & al., 2003)
- Fattore di approssimazione: 1.67 (Oh & Son, 1995)

Poiché richiede l'ordinamento dei task, FFDU è tipicamente utilizzato come algoritmo off-line

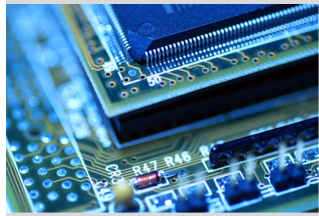

Algoritmo RM-FF

Una variante di RMFF è l'algoritmo RM-FF (Oh & Son, 1994) che sostanzialmente non effettua l'ordinamento dei task prima della allocazione:

1. ordina arbitrariamente i processori: $P_1, P_2, \ldots$
2. assegna ciascun task T_i al primo processore P_j tale che l'insieme dei task già assegnati a P_j insieme a T_i risulta ancora schedulabile tramite RM

- $U_{\text{RM-FF}} = m \cdot \left(\sqrt{2} - 1\right)$ (Oh & Baker, 1998)
- Fattore di approssimazione: 2.33 (Oh & Son, 1994)

A differenza di RMFF, RM-FF è facilmente utilizzabile come algoritmo on-line

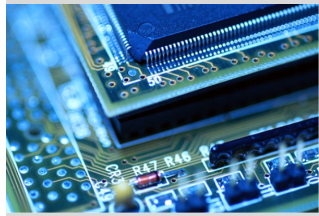

Algoritmo EDF-FF

L'euristica "first fit" accoppiata all'algoritmo di schedulazione EDF dà luogo all'algoritmo di allocazione "on-line" EDF-FF:

1. ordina arbitrariamente i processori: $P_1, P_2, \ldots$
2. assegna ciascun task T_i al primo processore P_j tale che l'insieme dei task già assegnati a P_j insieme a T_i risulta ancora schedulabile tramite EDF

- $U_{\text{EDF-FF}} = \dfrac{\beta \cdot m + 1}{\beta + 1}, \quad \beta = \left\lfloor 1 / \max_k \dfrac{e_k}{p_k} \right\rfloor$ (Lopez & al., 2000)
- Fattore di approssimazione: 1.7 (Garey & Johnson, 1979)

EDF-FF è ottimale tra tutti gli algoritmi partizionati:

$$\beta = 1 \quad \Longrightarrow \quad U_{\text{EDF-FF}} = (m+1)/2$$