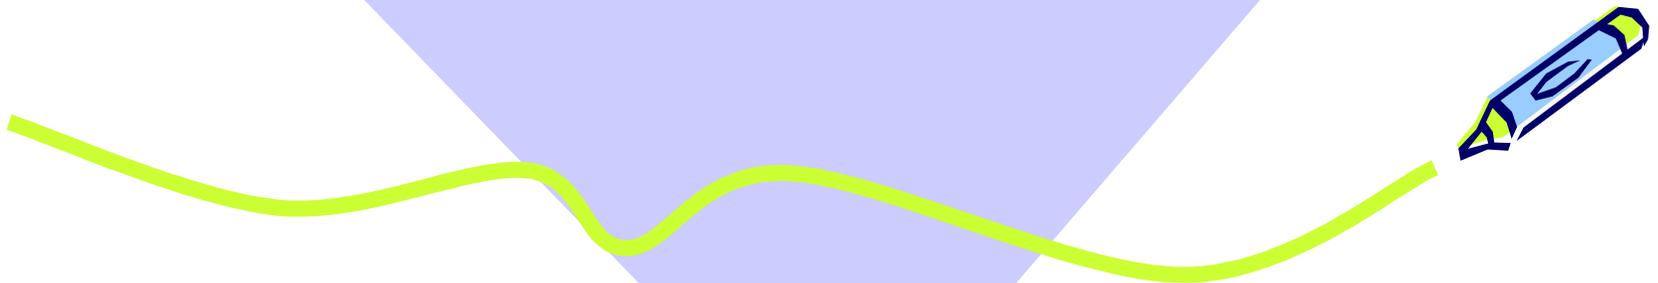
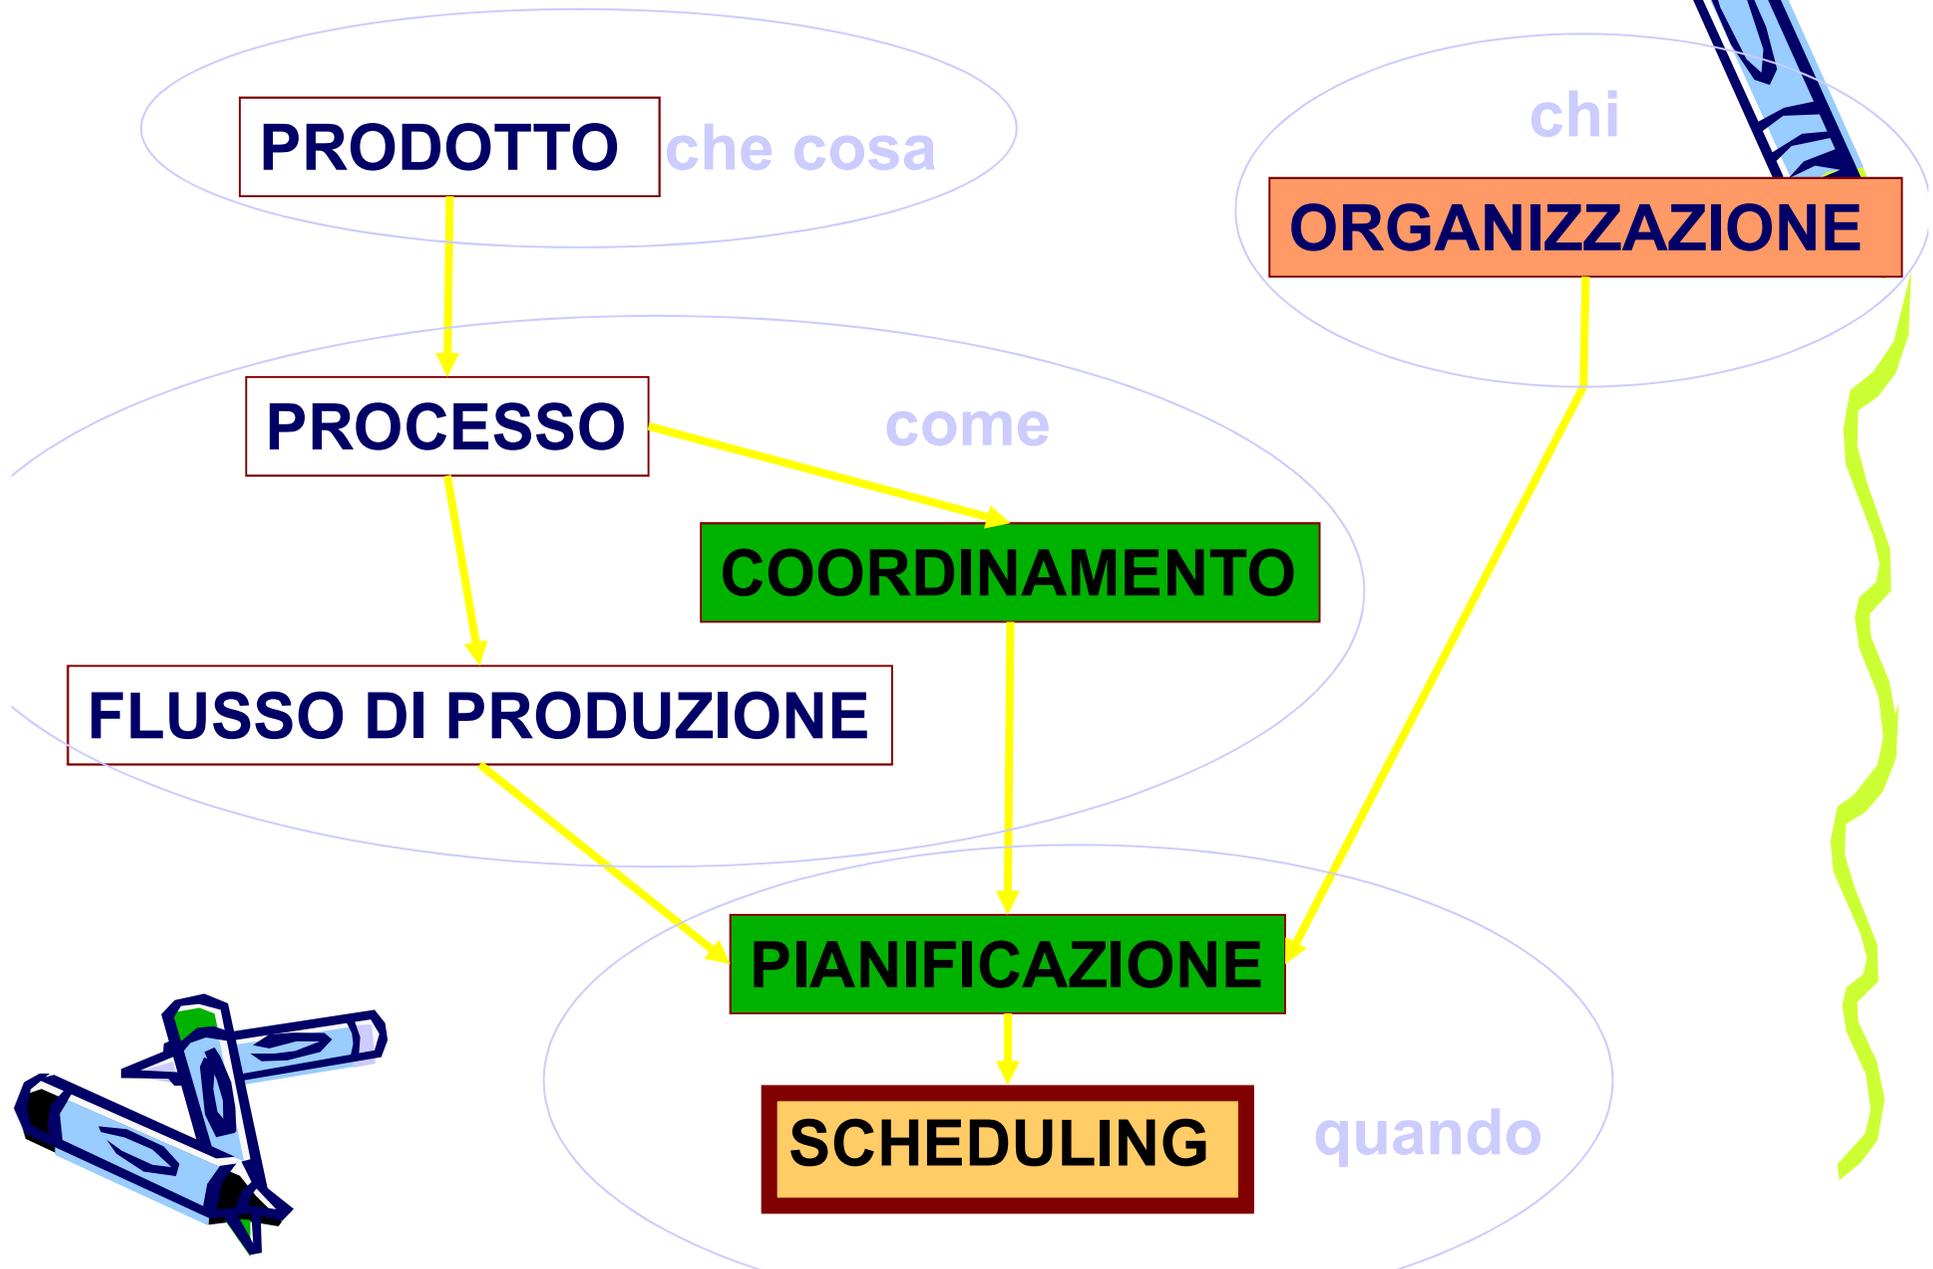


Scheduling



Organizzazione della produzione



Pianificazione della produzione: schedulazione di dettaglio



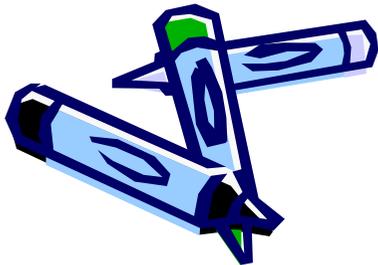
Sono dati:

- Un insieme di lavori (*job*): ognuno costituito da una o più operazioni
- Un insieme di risorse (*macchine*) che devono essere utilizzate per eseguire i lavori



Scheduling delle operazioni

Scelta dei tempi di inizio e fine di ogni operazione su ogni macchina



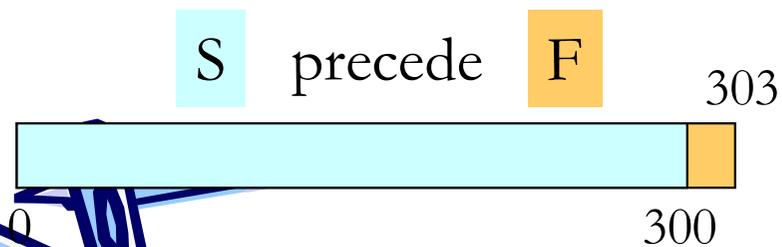
Esempio: fotocopie

Silvia (S) e Francesca (F) giungono nello stesso momento ad una macchina fotocopiatrice. F deve fare 1 fotocopia, S ne deve fare 100.

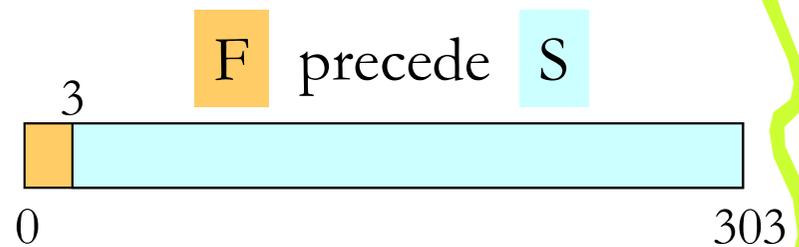
Il galateo imporrebbe a S di lasciar passare per prima F, che impegna la macchina per un tempo breve e poi la lascia libera.

È questa una buona idea?

Analisi. Supponiamo che l'esecuzione di una fotocopia richieda 3 secondi. Due casi:



Attesa totale = $300 + 303 = 603$

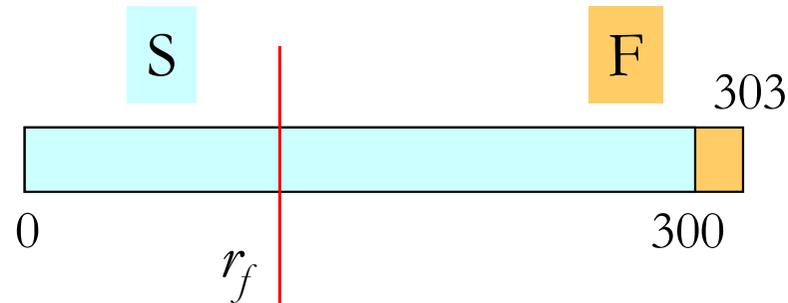


Attesa totale = $3 + 303 = 306$



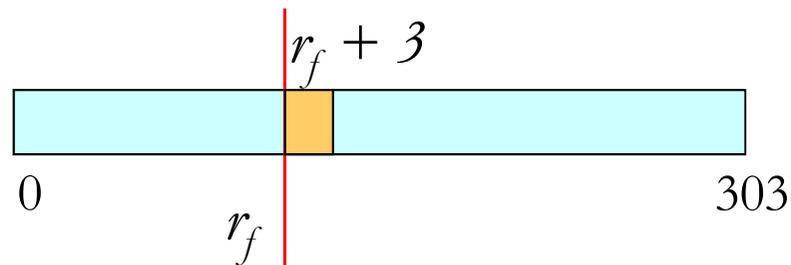
Esempio: fotocopie

E se Silvia (S) giungesse prima di Francesca (F) (che arriva all'istante r_f)?

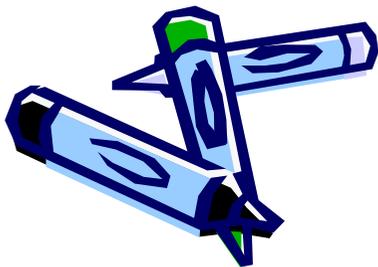


$$\text{Attesa totale} = 300 + 303 - r_f = 603 - r_f$$

Di nuovo, il galateo imporrebbe a Silvia di **interrompere** le proprie copie in favore di Francesca:

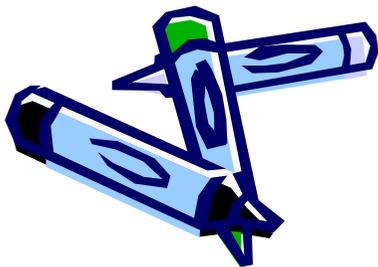
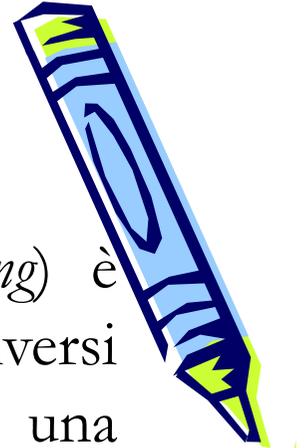


$$\text{Attesa totale} = 3 + 303 = 306$$



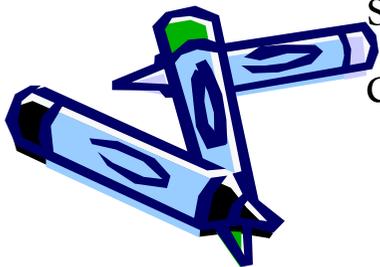
Esempio: CPU

- uno dei compiti del sistema operativo (*multitasking*) è quello di disciplinare l'accesso alla CPU dei diversi programmi di calcolo (eventualmente associati ad una priorità).
- il processamento di un programma può essere interrotto per consentire il completamento di altri. Ciò evita che un programma “lungo” ne blocchi altri molto brevi che hanno priorità più bassa.
- L'obiettivo tipico consiste nel minimizzare l'attesa complessiva dei programmi.

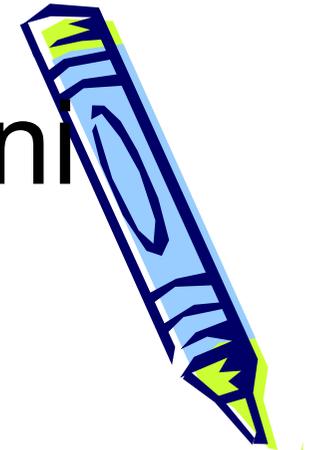


Esempio: voli in atterraggio

- L'area terminale di un aeroporto contiene l'insieme dei velivoli prossimi all'atterraggio.
- Il sistema di controllo dell'aeroporto permette di far atterrare al più un volo alla volta e la durata della manovra di atterraggio è nota per ogni velivolo.
- Ad ogni velivolo è inoltre associato un tempo previsto di atterraggio
- **Obiettivo** del controllore può essere quello di decidere la sequenza in modo da minimizzare la somma (pesata) dei ritardi.
- **Vincoli aggiuntivi:**
 - a causa della turbolenza, si deve garantire una certa separazione in atterraggio fra un aeromobile di grandi dimensioni ed di piccole dimensioni
 - precedenze fra voli



Scheduling delle operazioni



Consideriamo:

3 lavori e 3 macchine

Job	Sequenza delle operazioni operazione=(macchina, tempo)		
J ₁	(M ₁ ,10)	(M ₂ ,5)	(M ₃ ,6)
J ₂	(M ₂ ,5)	(M ₁ ,8)	-
J ₃	(M ₁ ,2)	(M ₃ ,10)	(M ₂ ,4)

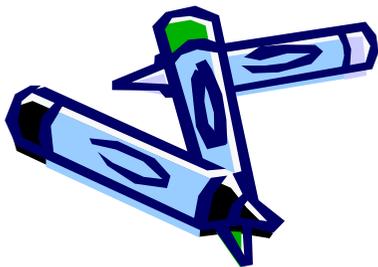
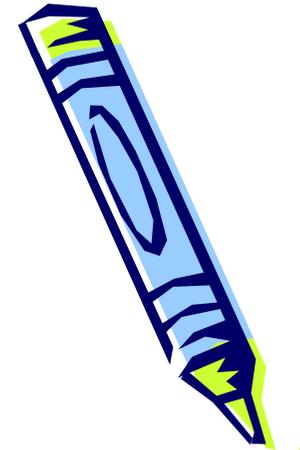


Diagramma di Gantt



Job	Sequenza Operazioni		
J ₁	(M ₁ ,10)	(M ₂ ,5)	(M ₃ ,6)
J ₂	(M ₂ ,5)	(M ₁ ,8)	-
J ₃	(M ₁ ,2)	(M ₃ ,10)	(M ₂ ,4)

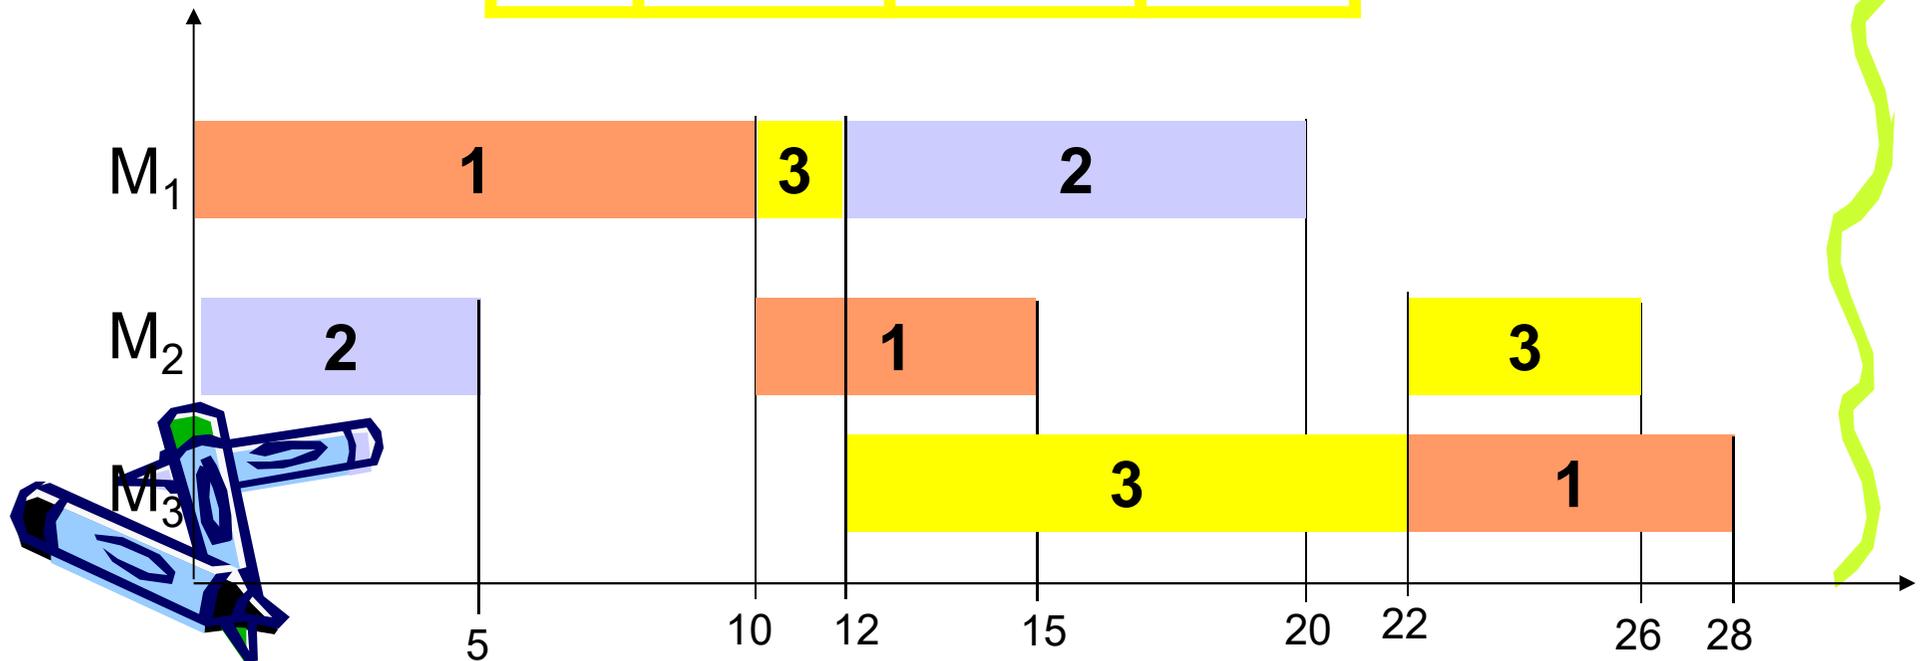
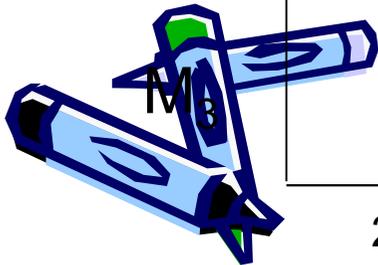
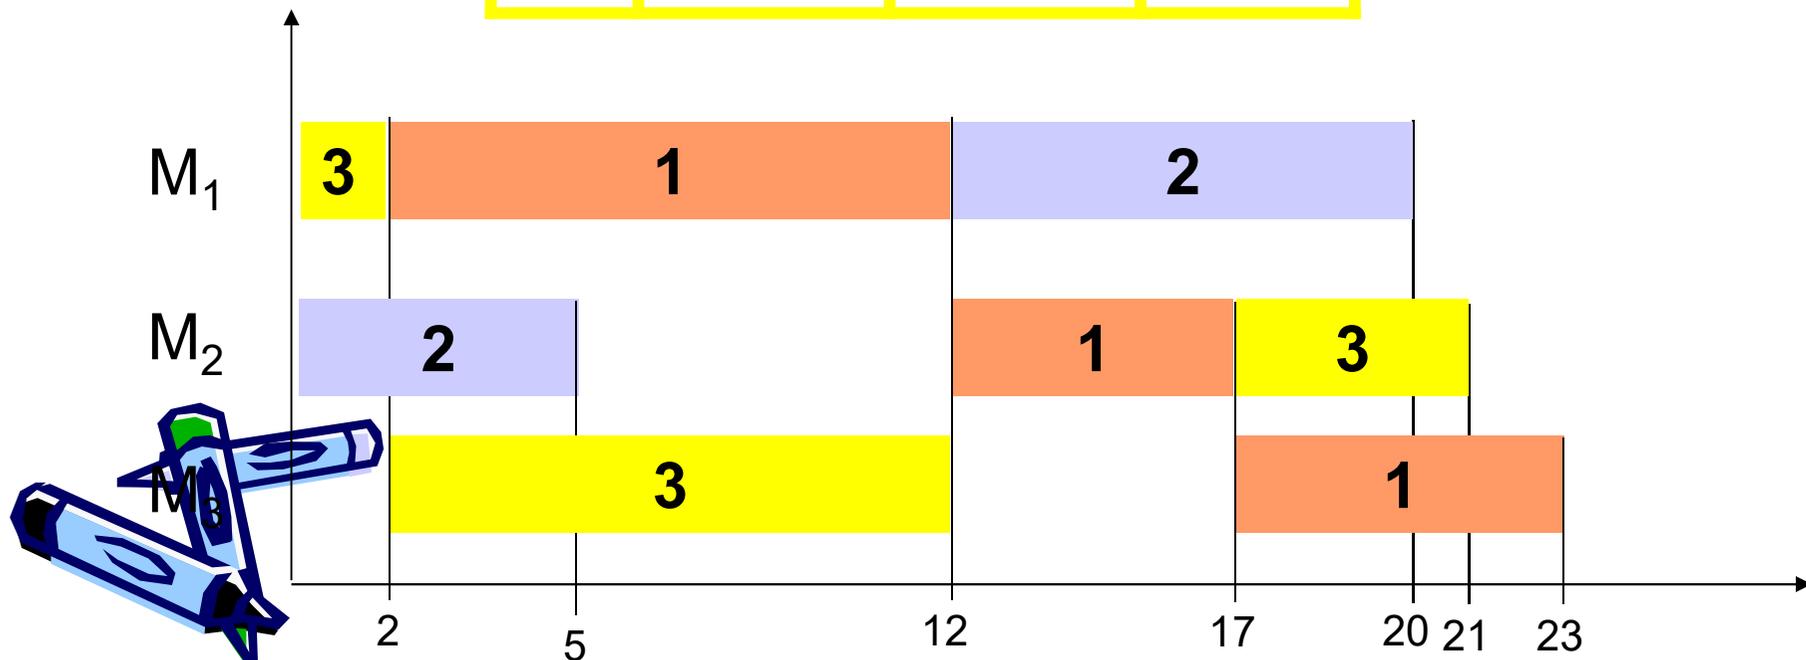
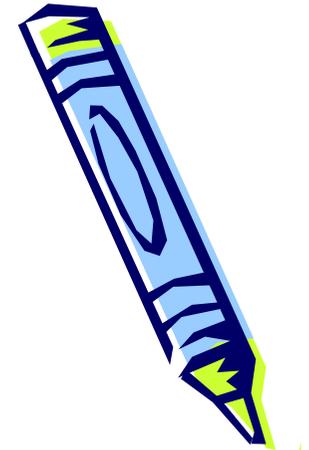


Diagramma di Gantt

Job	Sequenza Operazioni		
J ₁	(M ₁ ,10)	(M ₂ ,5)	(M ₃ ,6)
J ₂	(M ₂ ,5)	(M ₁ ,8)	-
J ₃	(M ₁ ,2)	(M ₃ ,10)	(M ₂ ,4)

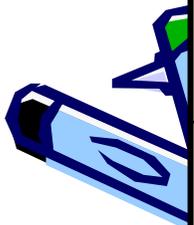


Esempio

Aldo (A), Bruno (B), Carlo (C), Duilio (D) condividono un appartamento. Ogni mattino ricevono 4 giornali: Financial Times (FT), Guardian (G), Daily Express (DE), Sun (S).

Ciascun lettore inizia la lettura ad una certa ora, ha la propria sequenza fissata di lettura dei giornali e legge ciascun giornale per un tempo prefissato:

lettore	Ora inizio	Sequenza lettura (tempo in min.)			
Aldo	8.30	FT(60)	G (30)	DE (2)	S(5)
Bruno	8.45	G(75)	DE(3)	FT(25)	S(10)
Carlo	8.45	DE(5)	G(15)	FT(10)	S(30)
Duilio	9.30	S(90)	FT(1)	G(1)	DE(1)



Esempio

- tutti i lettori preferiscono (eventualmente) aspettare che un giornale (il prossimo nella propria sequenza) sia disponibile anziché modificare la sequenza prefissata.
- nessun lettore rilascia un giornale prima di averlo letto completamente.
- ciascun lettore termina la lettura di tutti i giornali prima di uscire.
- i quattro lettori attendono che tutti abbiano terminato di leggere prima di uscire di casa

Problema:

Qual'è la minima ora in cui A, B, C, D possono uscire?

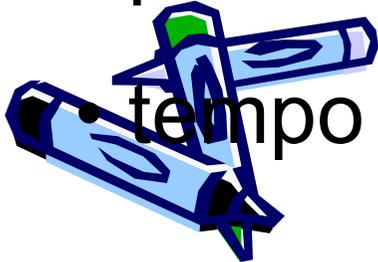


Classificazione dei problemi di *scheduling*

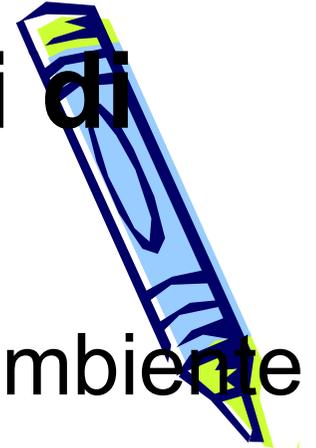


Caratterizzazione dei lavori:

- tempo di processamento p_j (p_{kj})
- data di consegna (*duedate* o *deadline*) d_j
- data di rilascio (*release date*) r_j
- peso del lavoro (priorità) w_j
- tempo di set-up tra due lavori s_{ij}

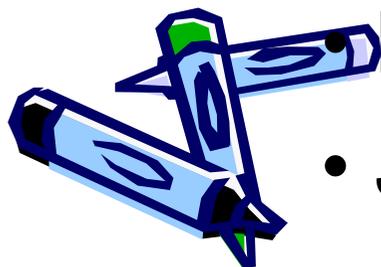


Classificazione dei problemi di *scheduling*



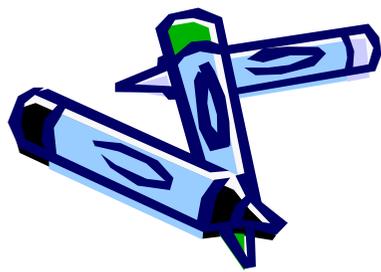
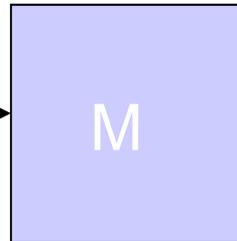
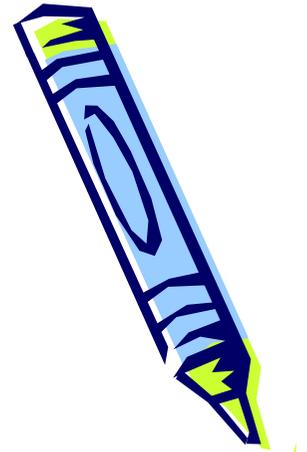
Caratterizzazione delle risorse e dell'ambiente produttivo:

- macchina singola
- macchine parallele
 - *identiche*
 - *scorrelate*
 - *uniformi*

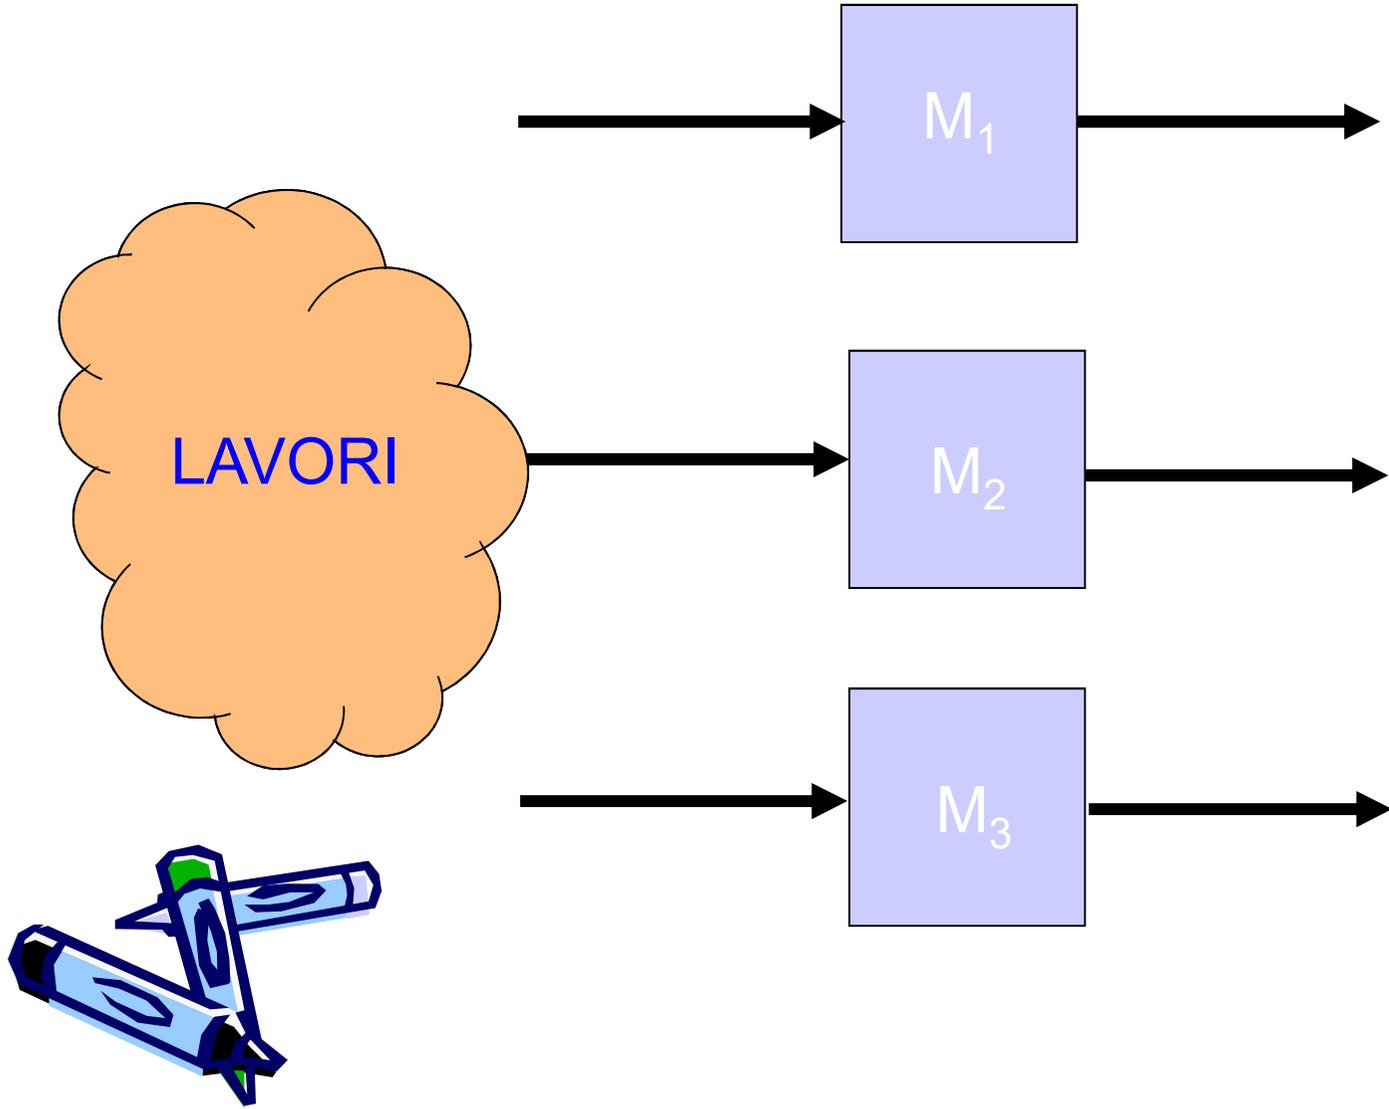
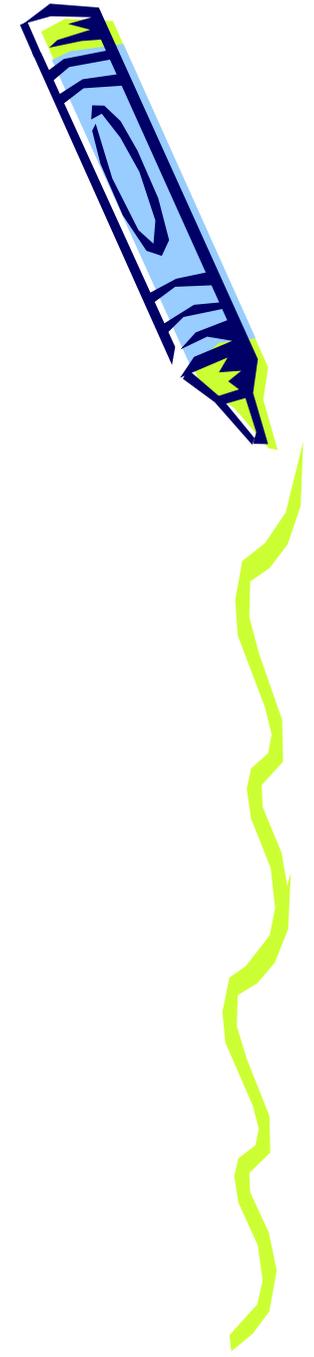


- Flow shop
- Job shop

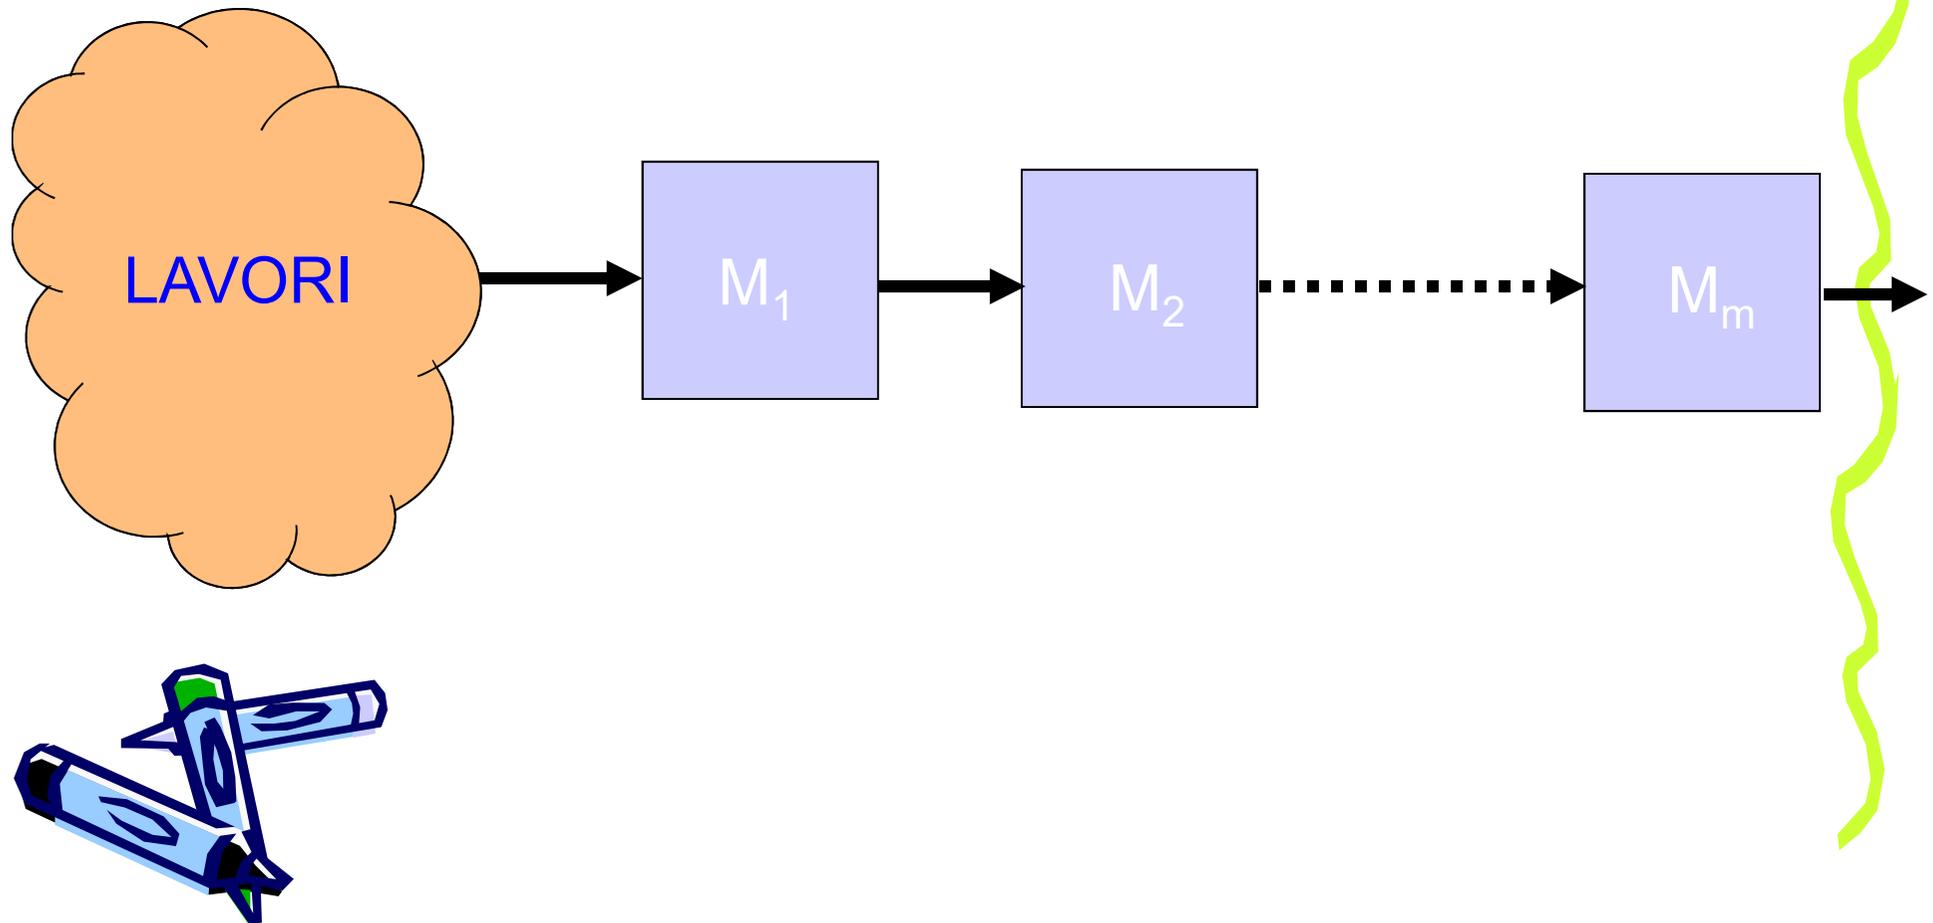
Macchina singola



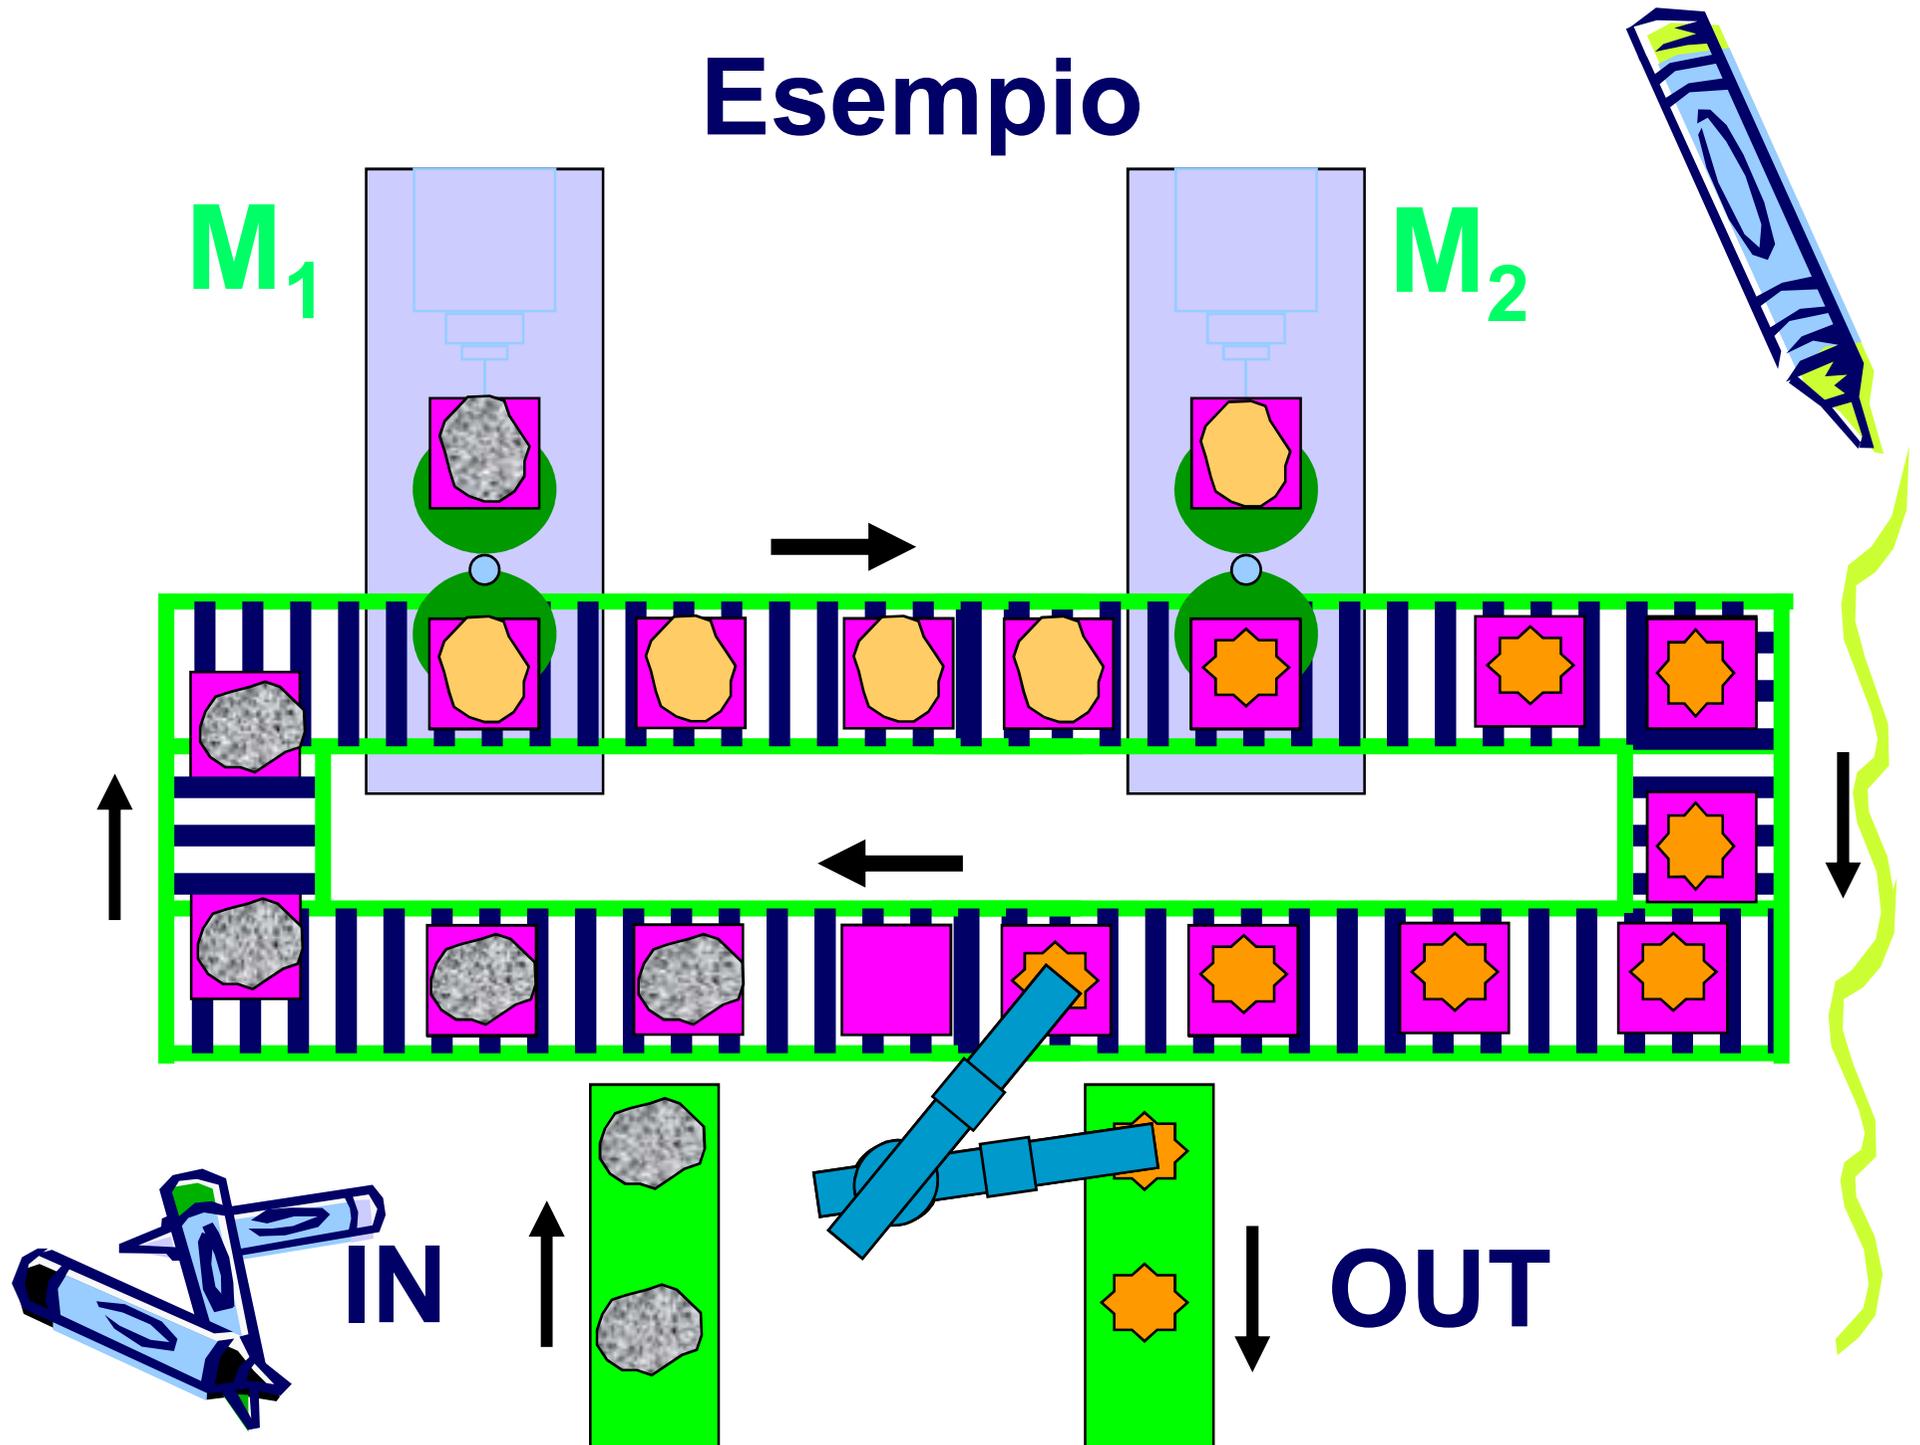
Macchine parallele



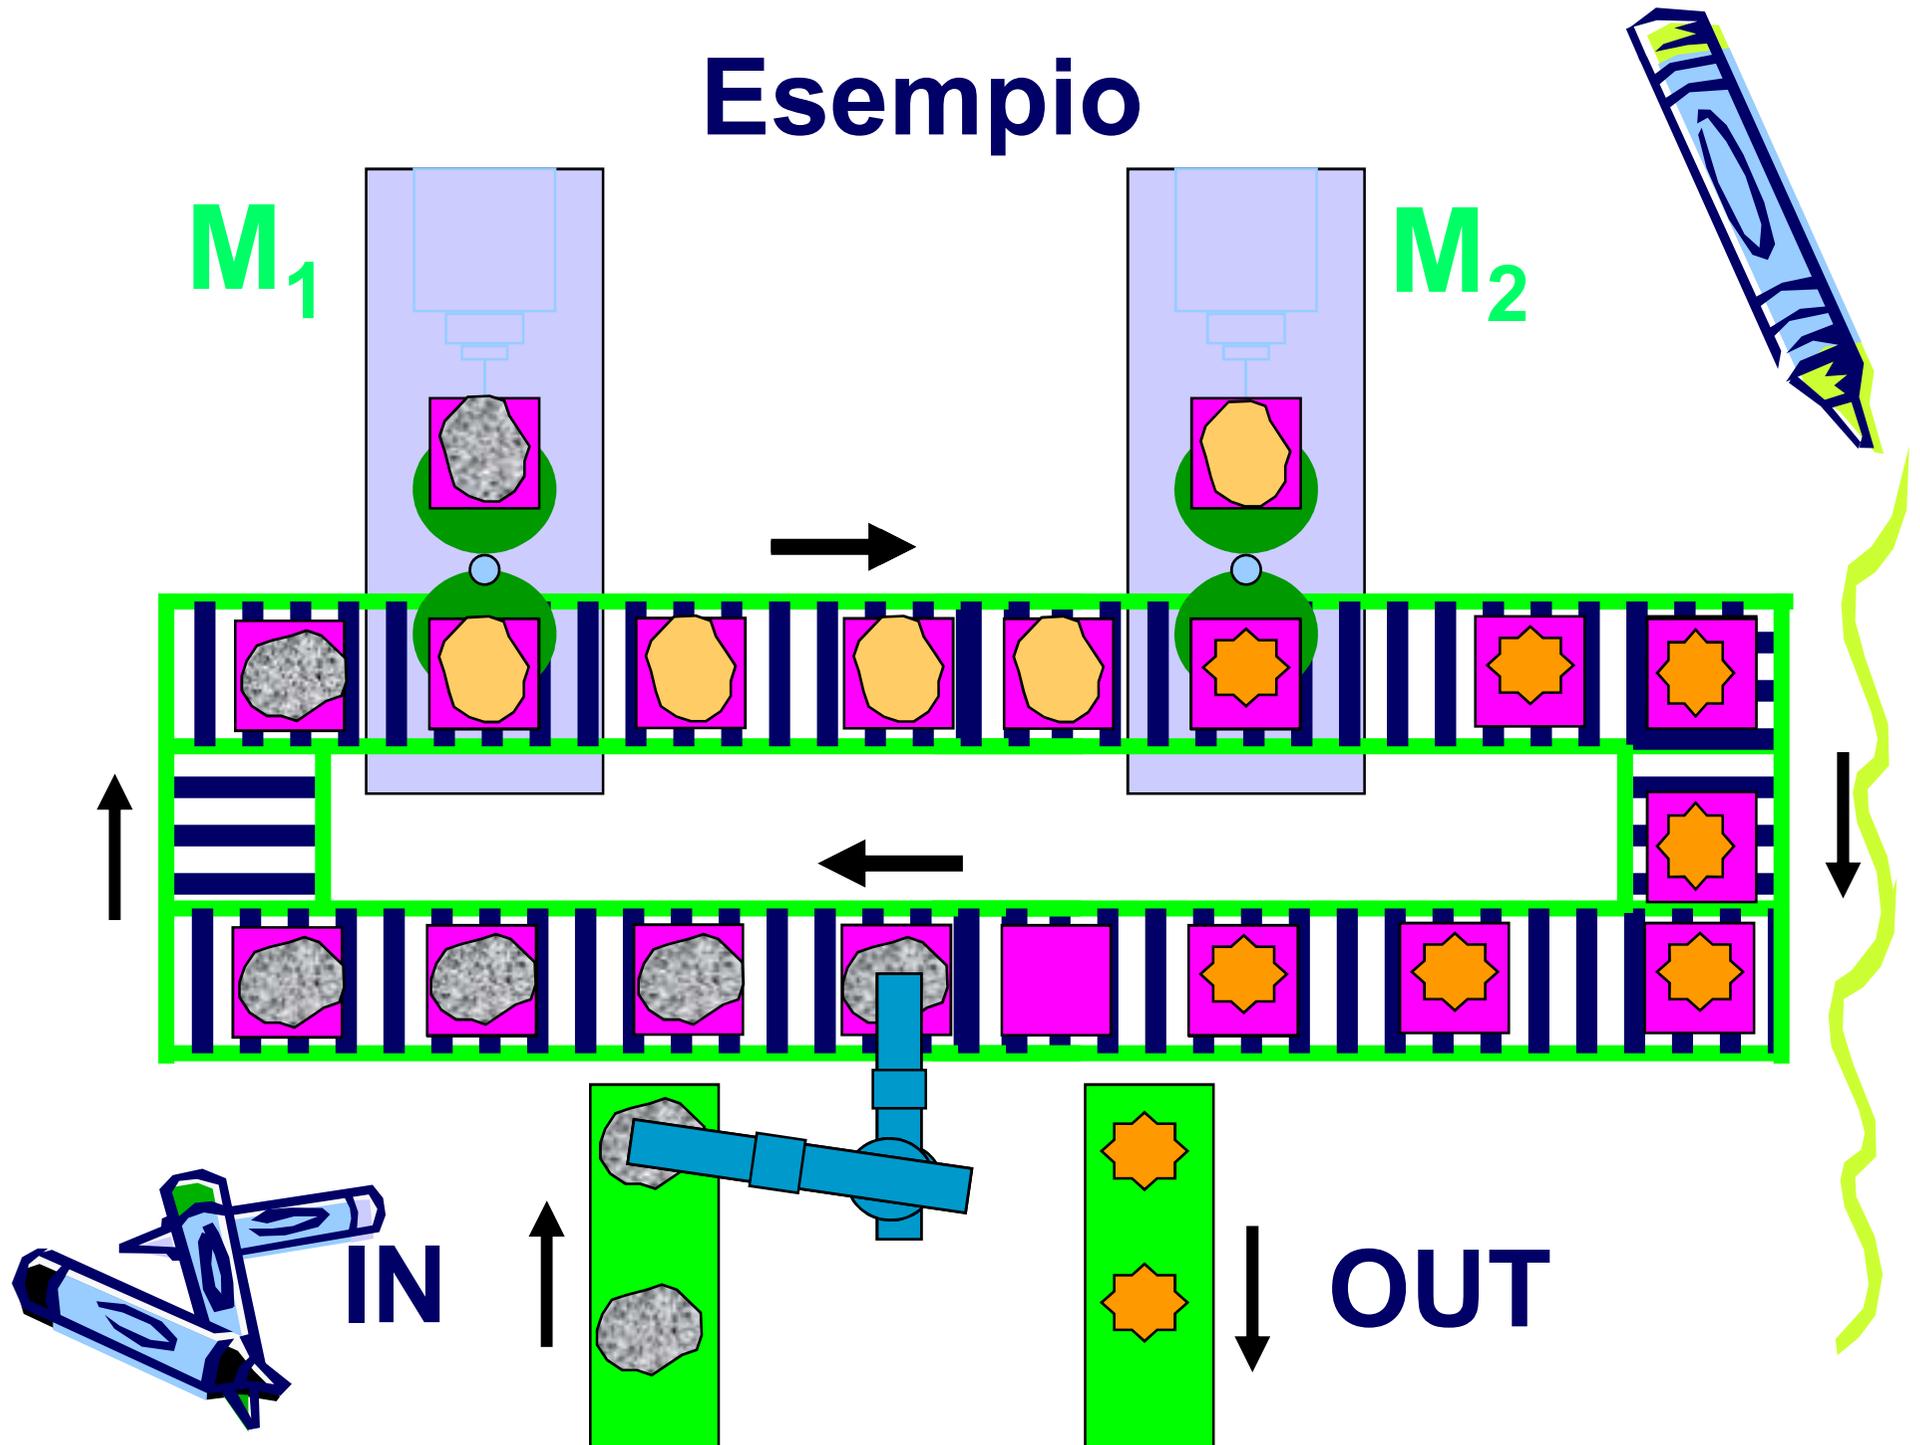
Macchine in linea (Flow shop)



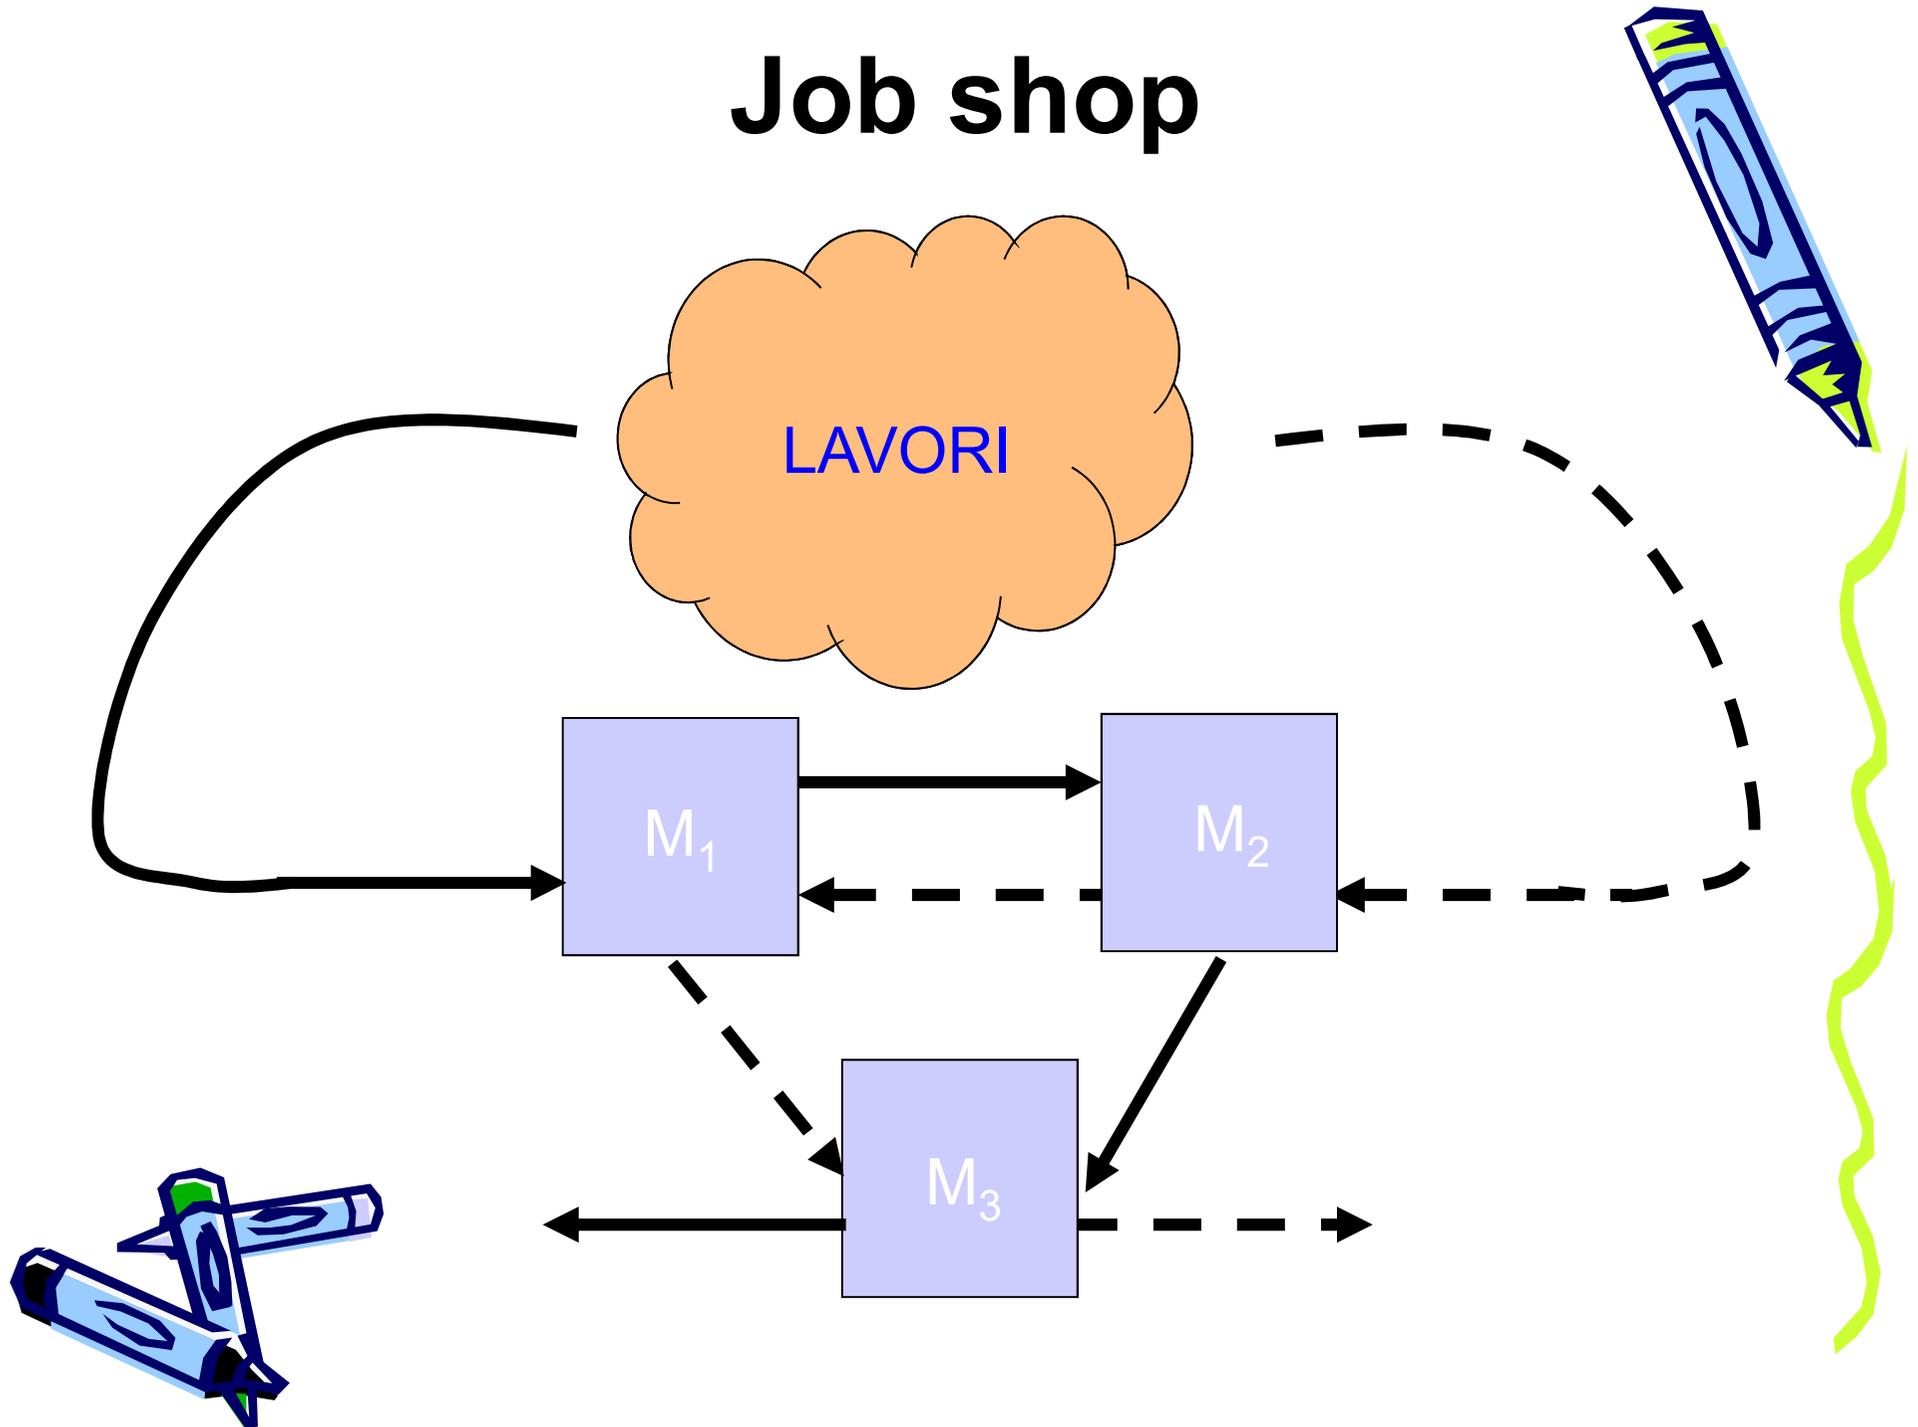
Esempio



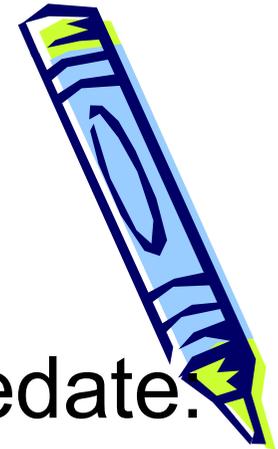
Esempio



Job shop



Misure di prestazione (lavori)

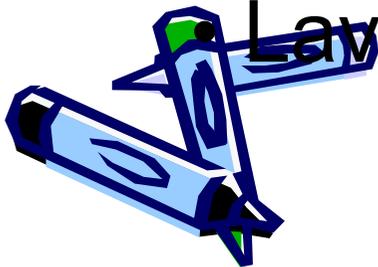


Dato il lavoro i con release date e due date.

- tempo di completamento C_i
- tempo di attraversamento $F_i = C_i - r_i$
- *Lateness* $L_i = C_i - d_i$
- *Tardiness* $T_i = \max\{0, C_i - d_i\}$
- *Earliness* $E_i = \max\{0, d_i - C_i\}$

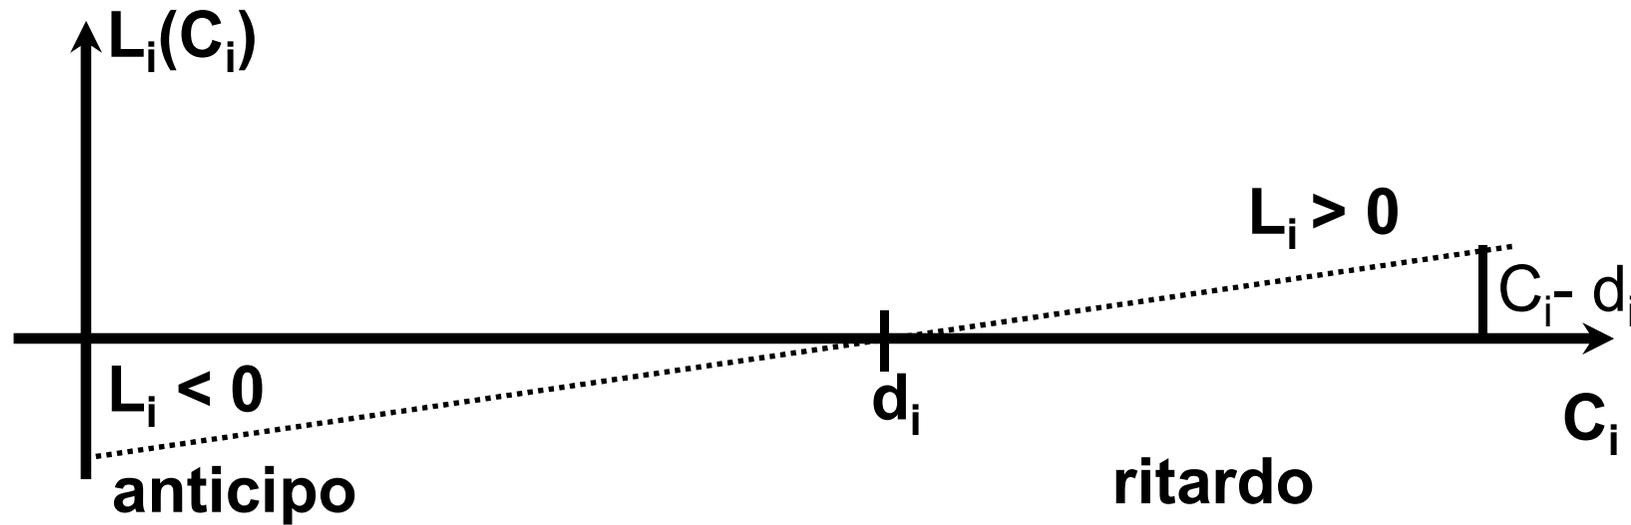
• Lavori in ritardo $U_i = 1$ se $C_i > d_i$

$U_i = 0$ se $C_i \leq d_i$

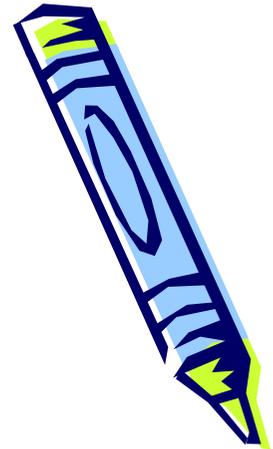


Lateness (Ritardo)

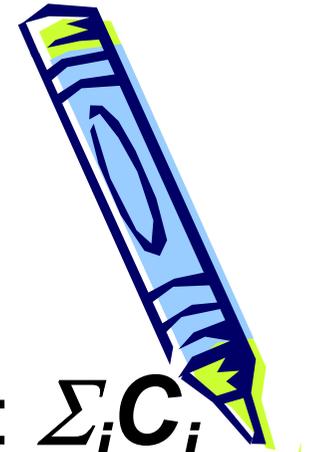
Ritardo del lavoro i : $L_i = C_i - d_i$



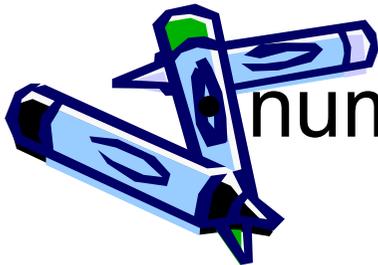
d_i : tempo di consegna (duedate) per il lavoro i



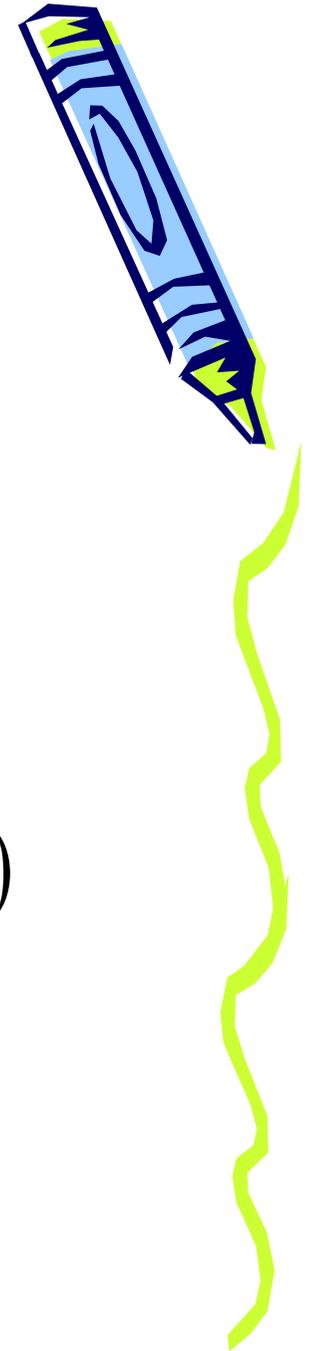
Misure di prestazione (sistema)



- somma dei tempi di completamento: $\sum_i C_i$
- *flow time* totale: $\sum_i F_i$
- massima *Lateness*: $L_{max} = \max_i L_i$
- massima *Tardiness*: $T_{max} = \max_i T_i$
- *Tardiness* totale pesata $\sum_i w_i T_i$
- makespan $C_{max} = \max_i C_i$
- numero di lavori in ritardo $\sum_i U_i$

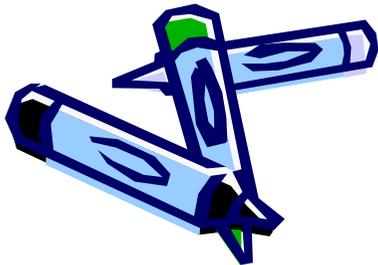


Misure di prestazione

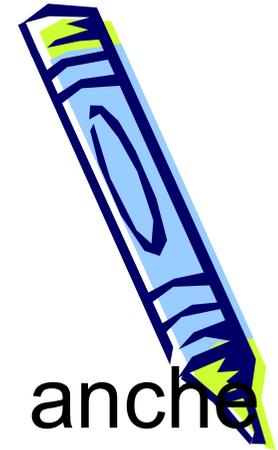


Equivalenza tra misure

$$\sum_{i=1}^n L_i = \sum_{i=1}^n C_i - \sum_{i=1}^n d_i = \sum_{i=1}^n F_i + \sum_{i=1}^n (r_i - d_i)$$

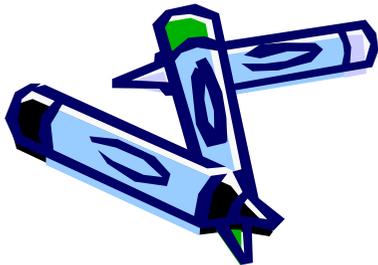


Misure di prestazione



Una sol. che minimizza L_{\max} minimizza anche T_{\max} (ma, in generale, non è vero il viceversa):

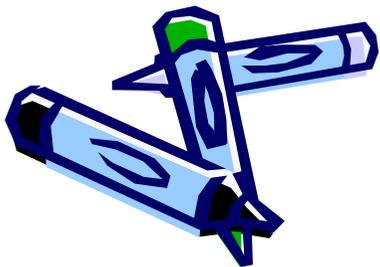
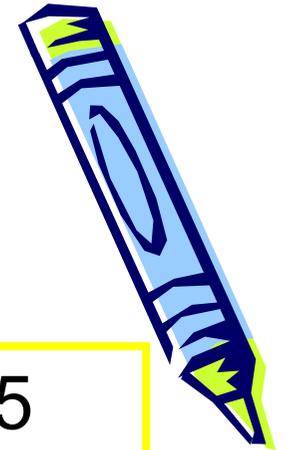
$$\begin{aligned} T_{\max} &= \max \{T_1, \dots, T_n, 0\} = \\ &= \max \{ \max \{L_1, 0\}, \dots, \max \{L_n, 0\} \} = \\ &= \max \{L_1, \dots, L_n, 0\} = \max \{L_{\max}, 0\} \end{aligned}$$



Esempio

Lavori	1	2	3	4	5
p_i	8	16	10	7	2

Sequenza ottima (5, 4, 1, 3, 2)

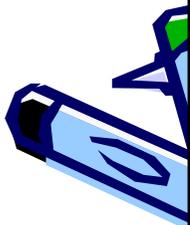


Esempio

Aldo (A), Bruno (B), Carlo (C), Duilio (D) condividono un appartamento. Ogni mattino ricevono 4 giornali: Financial Times (FT), Guardian (G), Daily Express (DE), Sun (S).

Ciascun lettore inizia la lettura ad una certa ora, ha la propria sequenza fissata di lettura dei giornali e legge ciascun giornale per un tempo prefissato:

lettore	Ora inizio	Sequenza lettura (tempo in min.)			
Aldo	8.30	FT(60)	G (30)	DE (2)	S(5)
Bruno	8.45	G(75)	DE(3)	FT(25)	S(10)
Carlo	8.45	DE(5)	G(15)	FT(10)	S(30)
Duilio	9.30	S(90)	FT(1)	G(1)	DE(1)



Esempio

- tutti i lettori preferiscono (eventualmente) aspettare che un giornale (il prossimo nella propria sequenza) sia disponibile anziché modificare la sequenza prefissata.
- nessun lettore rilascia un giornale prima di averlo letto completamente.
- ciascun lettore termina la lettura di tutti i giornali prima di uscire.
- i quattro lettori attendono che tutti abbiano terminato di leggere prima di uscire di casa

Problema:

Qual'è la minima ora in cui A, B, C, D possono uscire?



Soluzioni

- Il problema equivale a: determinare in quale ordine ciascun giornale deve esser letto dai quattro lettori in modo da minimizzare il tempo di lettura totale.

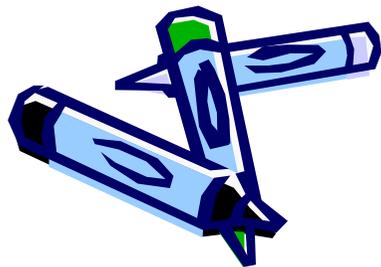
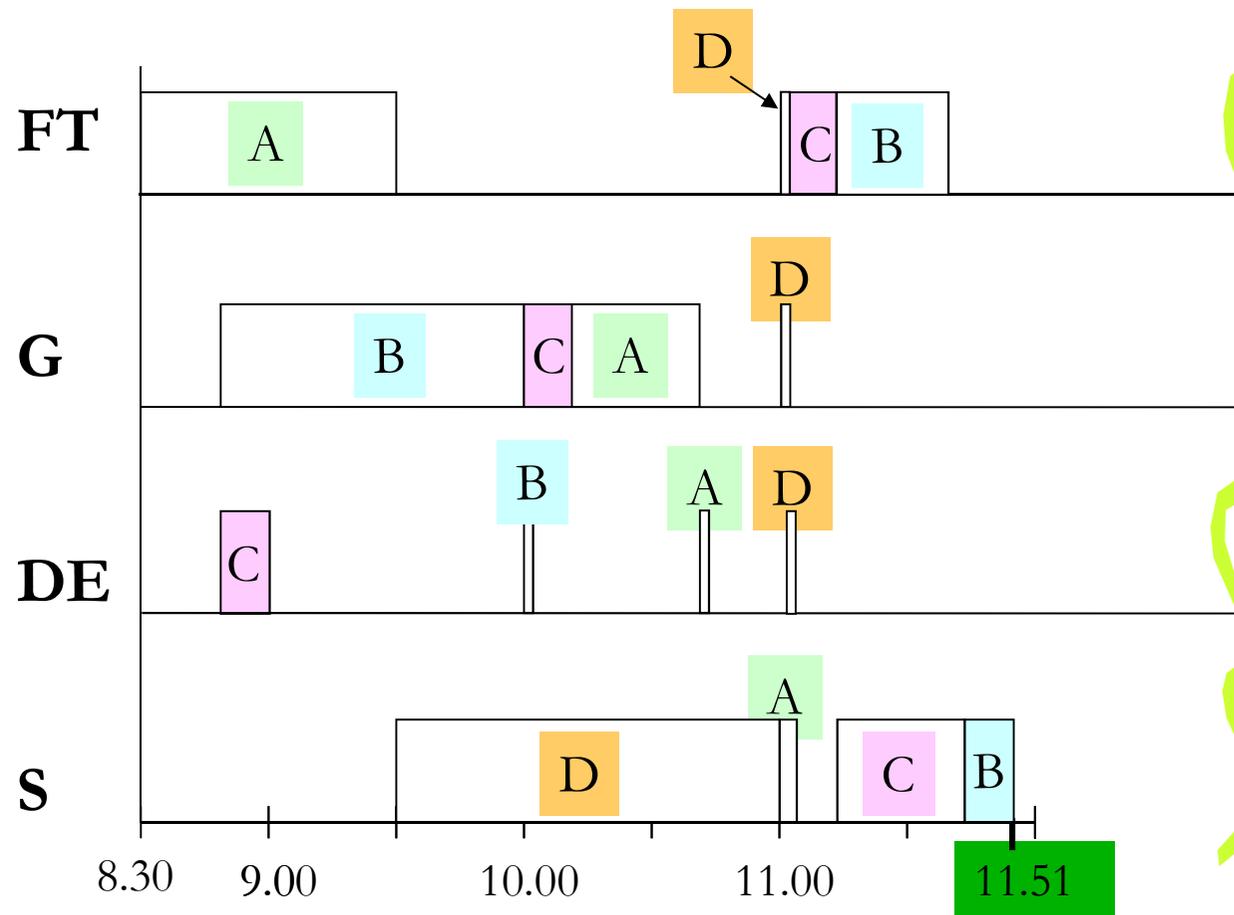
una possibile soluzione:

giornale	Lett. 1	Lett. 2	Lett. 3	Lett. 4
FT	A	D	C	B
G	B	C	A	D
DE	C	B	A	D
S	D	A	C	B



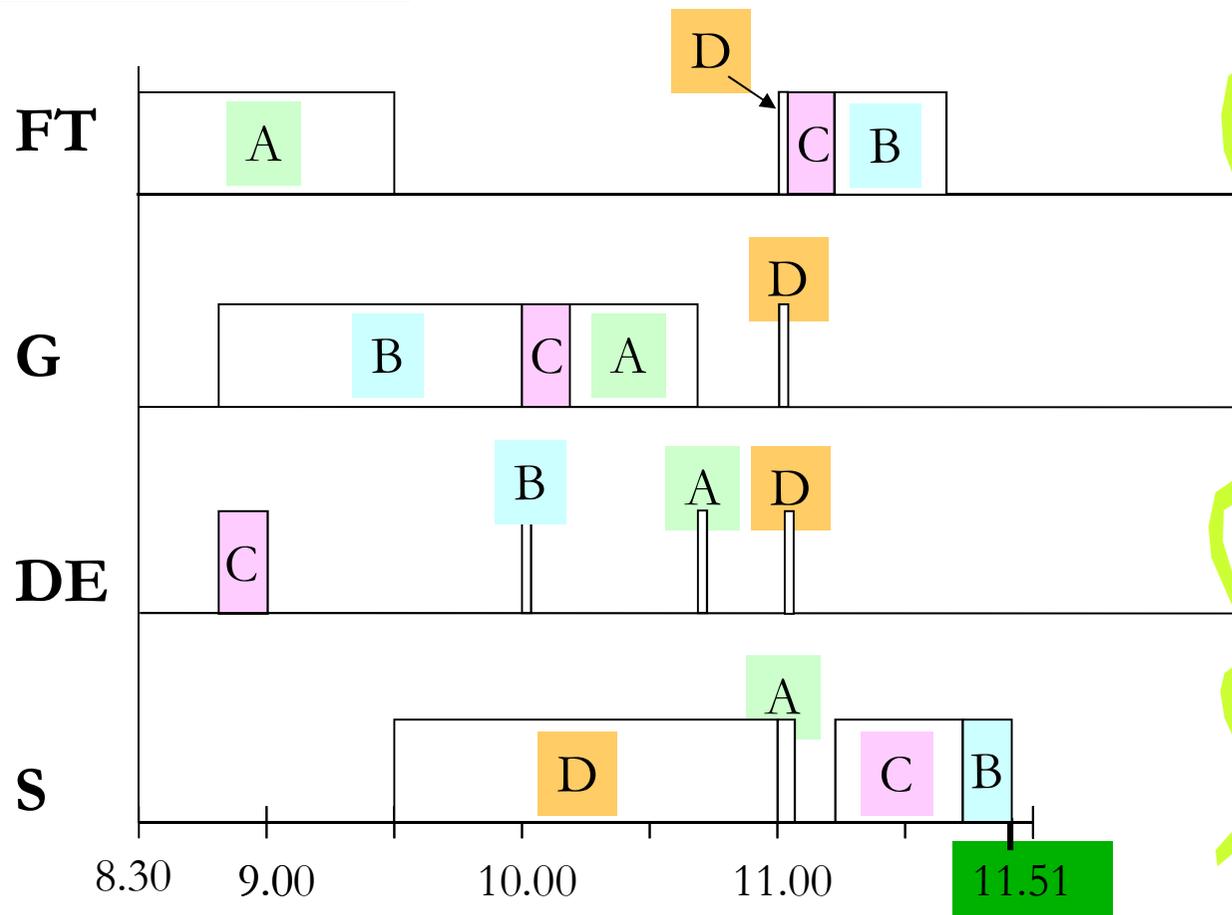
Giorn.	L1	L2	L3	L4
FT	A	D	C	B
G	B	C	A	D
DE	C	B	A	D
S	D	A	C	B

Diagramma
di Gantt

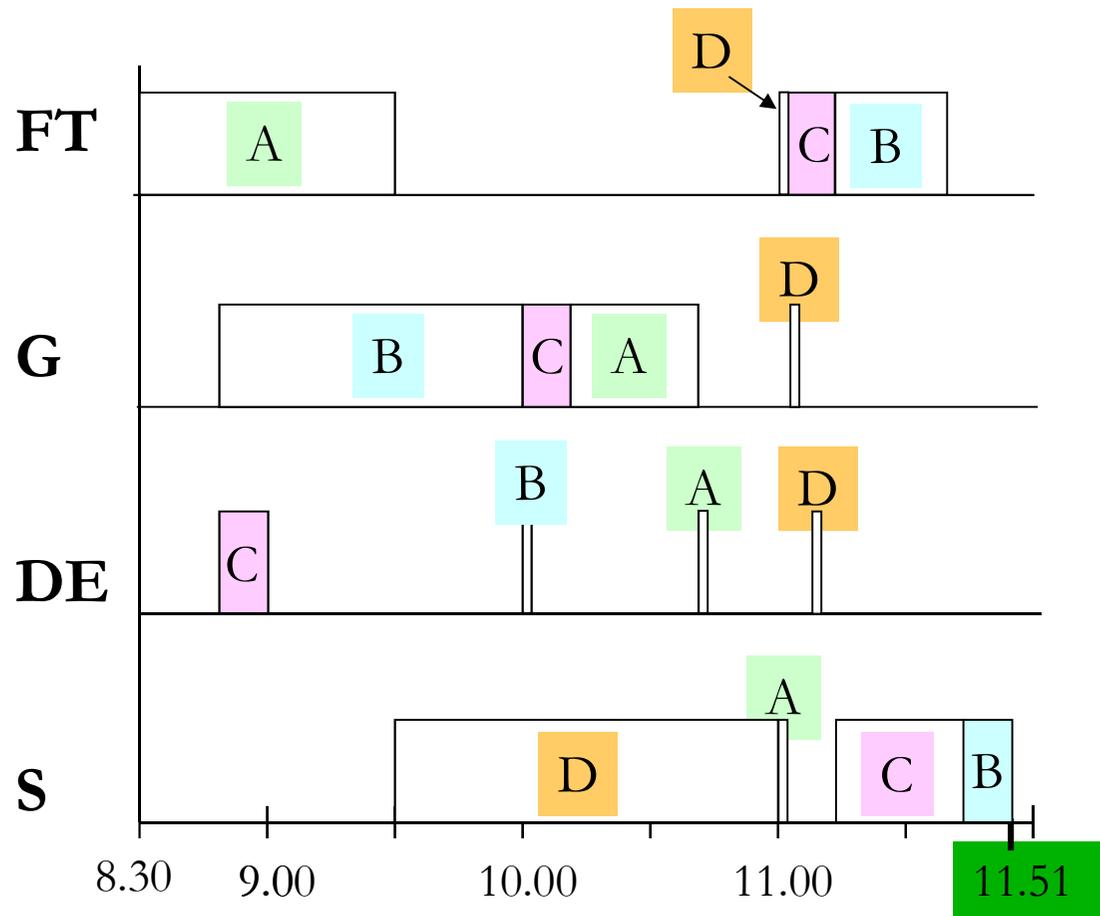


lettore	inizio	Sequenza lettura			
Aldo	8.30	FT	G	DE	S
Bruno	8.45	G	DE	FT	S
Carlo	8.45	DE	G	FT	S
Duilio	9.30	S	FT	G	DE

Vincini
tecnologici

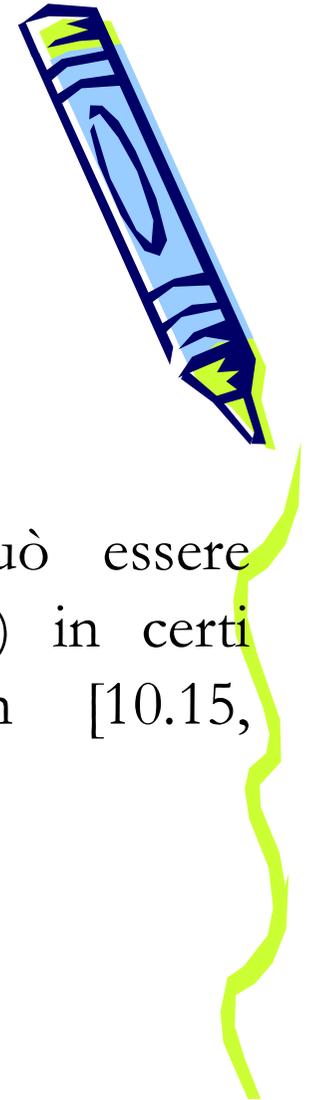


Commenti



- un lettore può essere inattivo (in *idle*) in certi periodi (C in [10.15, 11.01])

• ci può essere un giornale “fermo” anche se c’è un lettore disponibile che deve ancora leggerlo: B potrebbe avere S 11.05, ma questo violerebbe la sua sequenza; FT potrebbe avere C alle 9.30 ma viola la soluzione

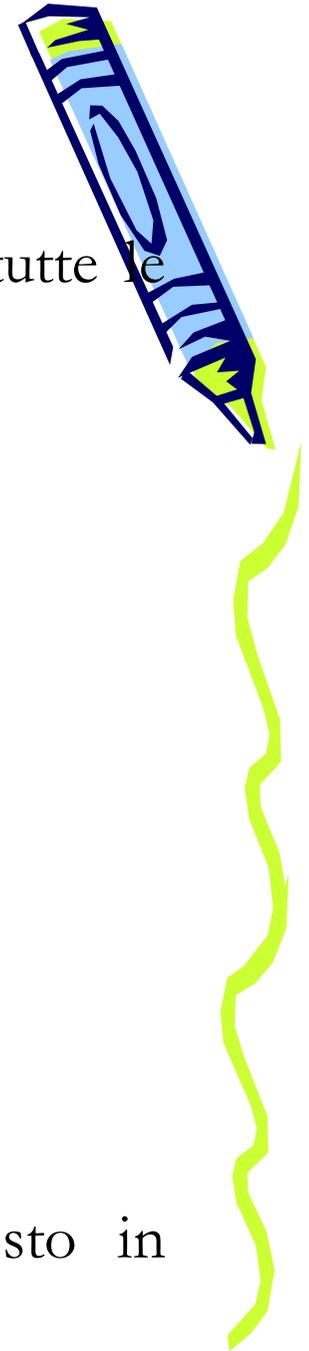


Esercizi

- Determinare il valore del tempo di completamento di tutte le letture per la seguente soluzione:

giornale	Lett. 1	Lett. 2	Lett. 3	Lett. 4
FT	D	B	A	C
G	D	C	B	A
DE	D	B	C	A
S	A	D	C	B

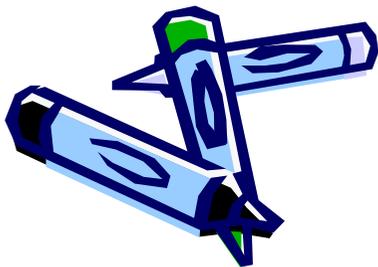
- Determinare una schedule migliore di quello proposto in precedenza



Enumerazione totale

- Il numero di soluzioni è $(4!)^4 = 331.776$
- per un problema con n lettori e m giornali diventa $(n!)^m$.
- esaminando 10.000 soluzioni al secondo (4 giornali e n lettori):

n	tempo
5	354 min
10	$2 \cdot 10^{17}$ giorni



Elementi di un problema di scheduling

- **job**: attività da svolgere

Fotocopia, esecuzione di un programma di calcolo, lettura di un giornale

Un job può rappresentare una singola attività o un insieme di attività (*task*) tecnologicamente legate

- **macchine**: risorse che eseguono le attività

Fotocopiatrice, CPU, giornali

L'esecuzione di un'attività su una macchina è detta **operazione**.

I problemi di scheduling si classificano in base alle caratteristiche dei *task* e all'architettura delle macchine



Attributi dei job

- **tempo di processamento** p_{ij} : durata del processamento del job j sulla macchina i
- **release date** r_j : tempo in cui j arriva nel sistema, rendendosi disponibile al processamento
- **due date** d_j : tempo entro il quale si desidera che il job j sia completato (data di consegna)
- **peso** w_j : indica l'importanza del job j

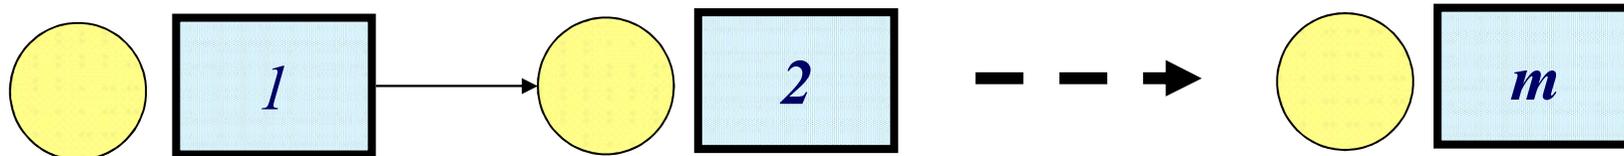
Notazione a tre campi: $\alpha/\beta/\gamma$:

- α descrive il sistema di macchine
- β rappresenta vincoli e modalità di processamento (0, 1 o più componenti)
- γ indica l'obiettivo



Campo α

- *Macchina singola (1)* : ciascun job richiede una singola operazione da eseguirsi sull'unica macchina disponibile
- *Macchine identiche parallele (P_m)* : ciascun job richiede una singola operazione da eseguirsi su una qualunque delle m macchine identiche.
- *Flow shop (F_m)* : m macchine in serie. Ciascun job deve essere processato su ciascuna di esse (m task). Tutti i job hanno lo stesso *routing*. Una volta terminata un'operazione il job viene posto nel buffer della macchina successiva



• *Job shop (J_m)* : ciascun job deve essere processato da un sottoinsieme di un insieme di m macchine, secondo un proprio *routing*.



Campo β

- *Release dates (r_j)* : il job j non può iniziare il processamento prima dell'istante r_j
- *Tempi di set-up (s_{jk})* : tempo richiesto per il riattrezzaggio delle macchine fra i job j e k . Se dipende dalla macchina i , si esprime con s_{jk}^i
- *Preemption (prmp)* : è ammesso interrompere un'operazione su una macchina prima del suo completamento per iniziare una nuova operazione. Il processamento eseguito prima dell'interruzione non va perso: quando l'operazione viene ripresa, essa richiede solo il tempo *rimanente* di processamento
- *vincoli di precedenza (prec)* : un job può essere processato solo se tutti i job di un certo insieme sono stati completati. Grafo delle precedenze. Se ciascun job ha al più un predecessore e un successore $\beta = chain$.
- *breakdown (brkdwn)* : le macchine non sono sempre disponibili, ma hanno periodi fissati di interruzione del servizio



Campo γ

Definizioni.

C_j tempo di completamento del job j

$L_j = C_j - d_j$ *lateness* del job j

$T_j = \max(L_j, 0)$ *tardiness* del job j

$U_j = 1$ se $C_j > d_j$ (*tardy job*) e 0 altrimenti

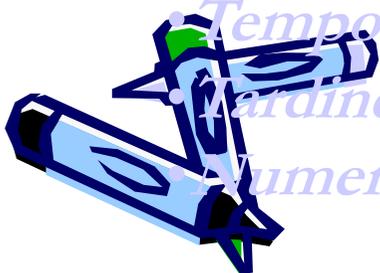
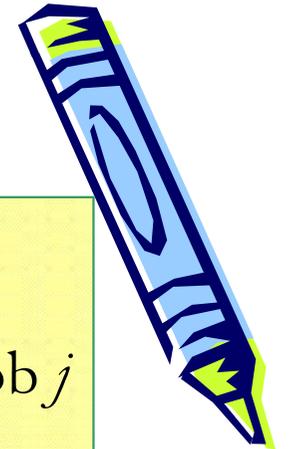
- *Makespan* (C_{\max}): $\max(C_1, \dots, C_n)$ tempo di completamento dell'ultimo job

- *Massima Lateness* (L_{\max})

- *Tempo totale pesato di completamento* ($\sum w_j C_j$)

- *Tardiness totale pesata* ($\sum w_j T_j$)

- *Numero di tardy job* ($\sum U_j$)



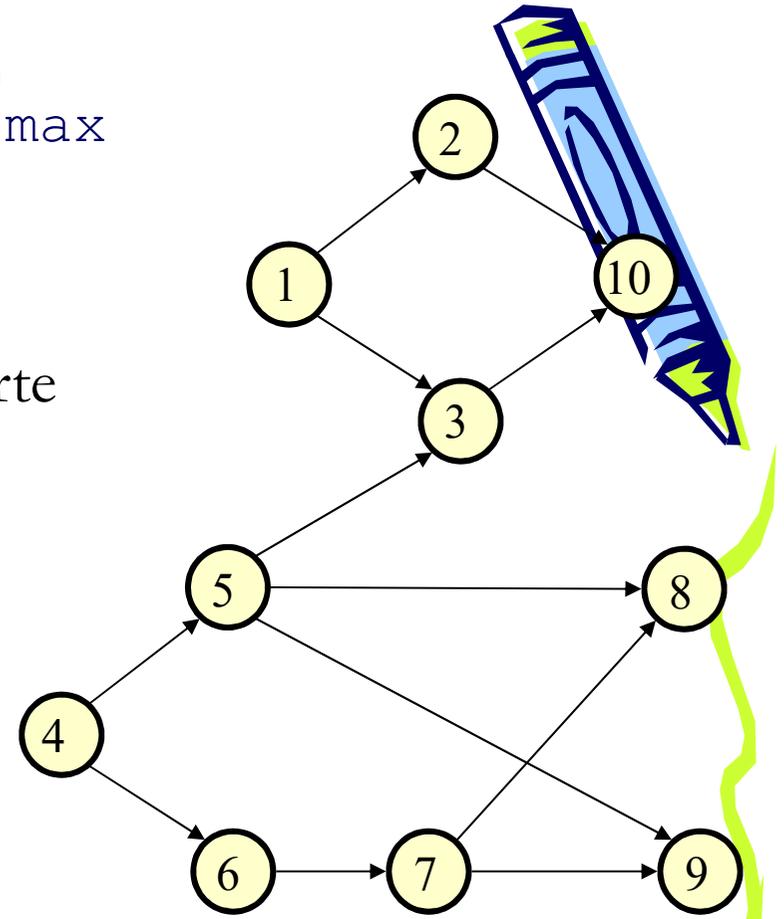
Definizioni di base

- Una funzione obiettivo si dice **regolare** se è non-decrescente in C_1, \dots, C_n
- Una permutazione dei job che definisce l'ordine con cui i job sono processati su una certa macchina si dice **sequenza**
- Una soluzione di un problema di scheduling si dice **schedule**. Consiste nell'assegnamento di un istante di inizio a ciascuno dei task di ogni job (se *prmp*, istanti di inizio di ciascuna delle parti in cui viene suddiviso un task)
- uno schedule ammissibile è detto **nondelay** se nessuna macchina è ferma quando esiste un'operazione disponibile al processamento

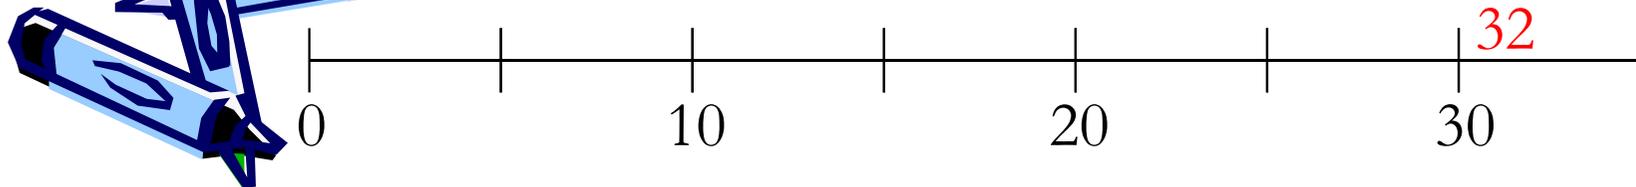
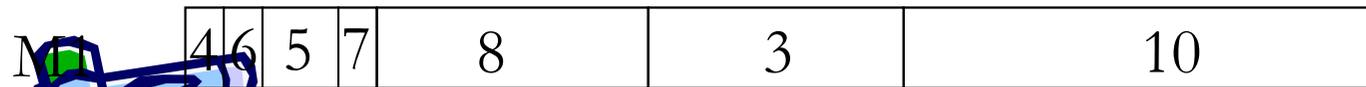
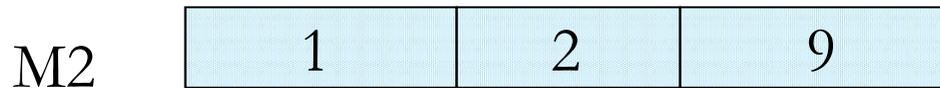


$P_2/\text{prec}/C_{\max}$

Regola di buon senso: mandare una parte processabile sulla prima macchina libera.

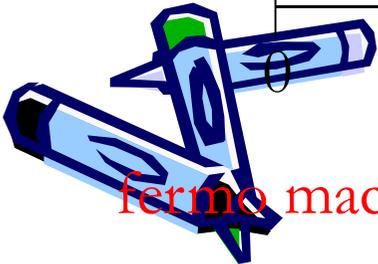
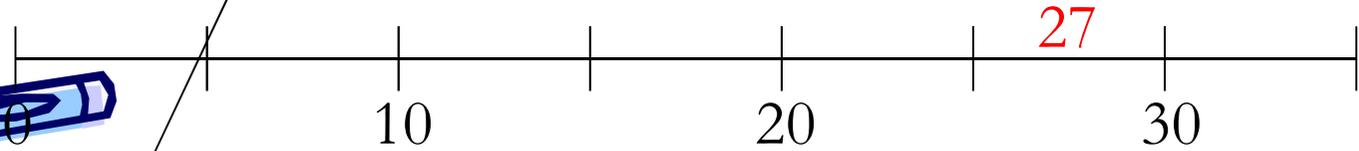
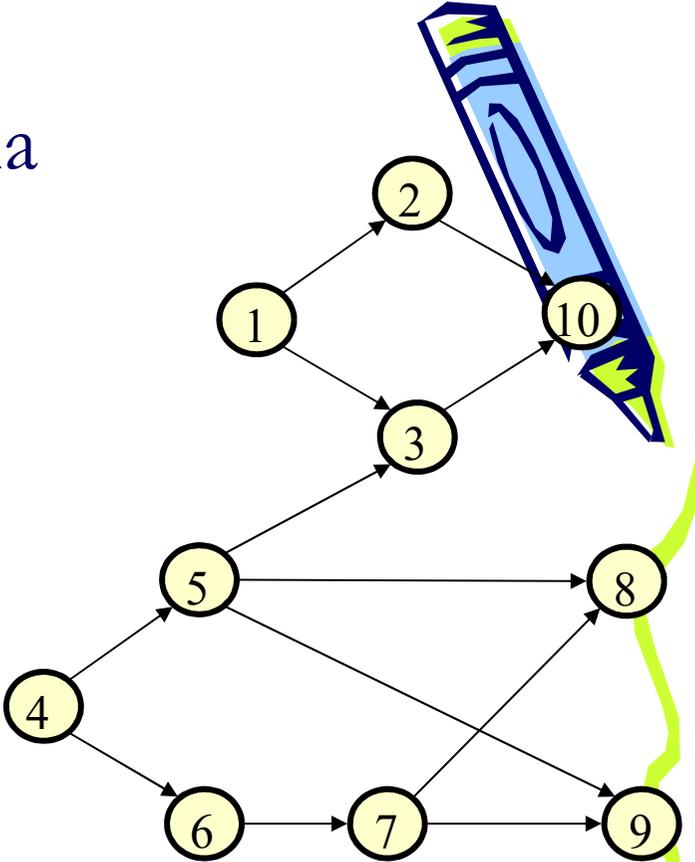


Soluzione:



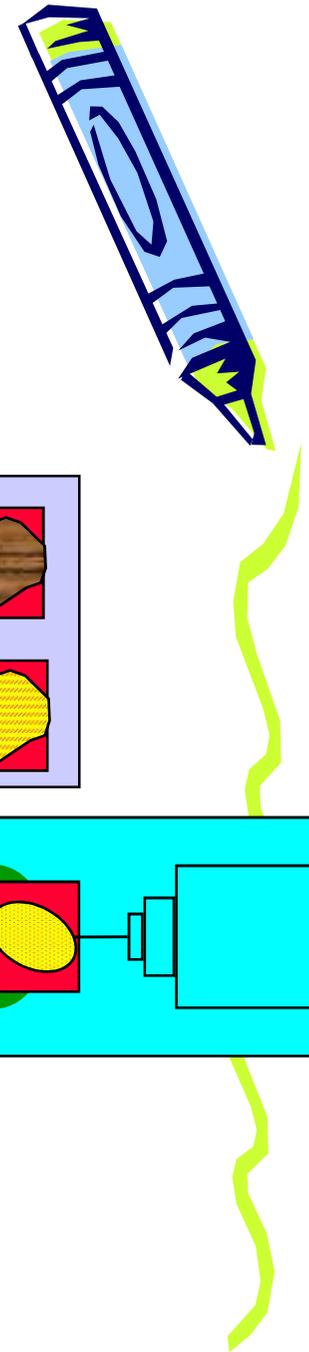
Soluzione ottima

- Nonostante l'idea di non fermare le macchine se non necessario sia ragionevole, la seguente soluzione migliora quella ottenuta dalla regola precedente:



fermo macchina "forzato"

Scheduling su singola macchina



Descrizione del problema

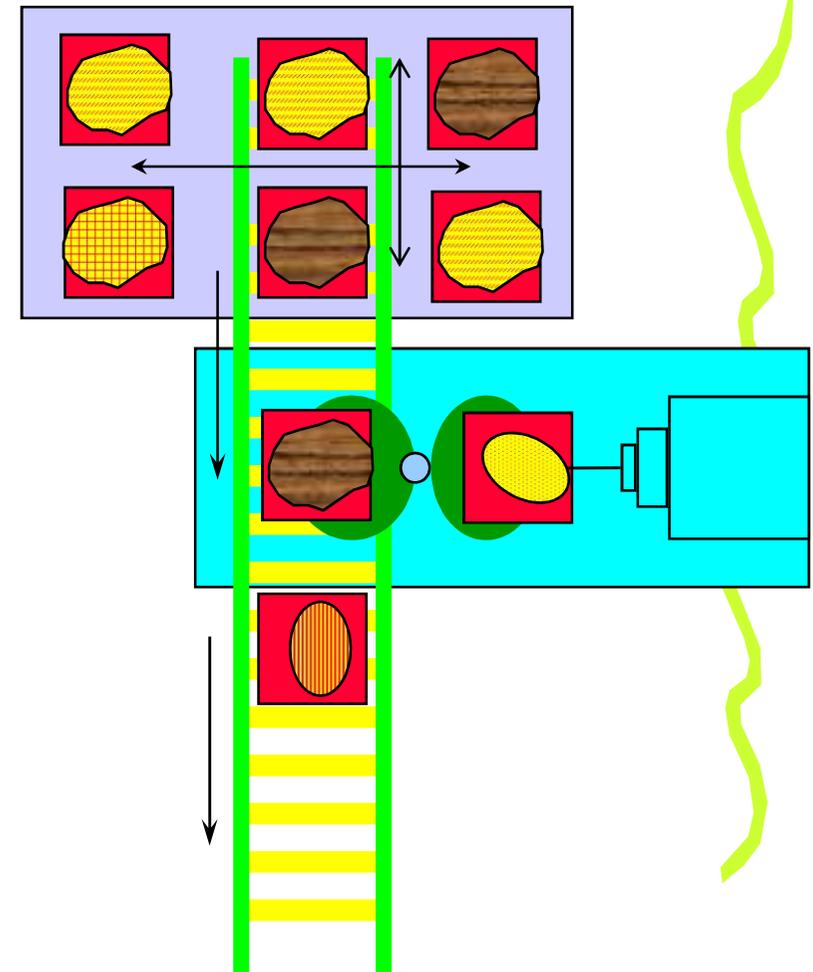
Un insieme di n operazioni deve essere eseguito su una macchina

Dati

I tempi di *processamento* p_i , $i=1, \dots, n$, del lavoro i sulla macchina sono noti.

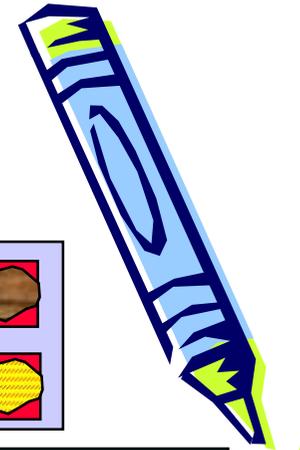
Obiettivo

Sequenziare le operazioni sulla macchina in modo da minimizzare la somma dei tempi di completamento.

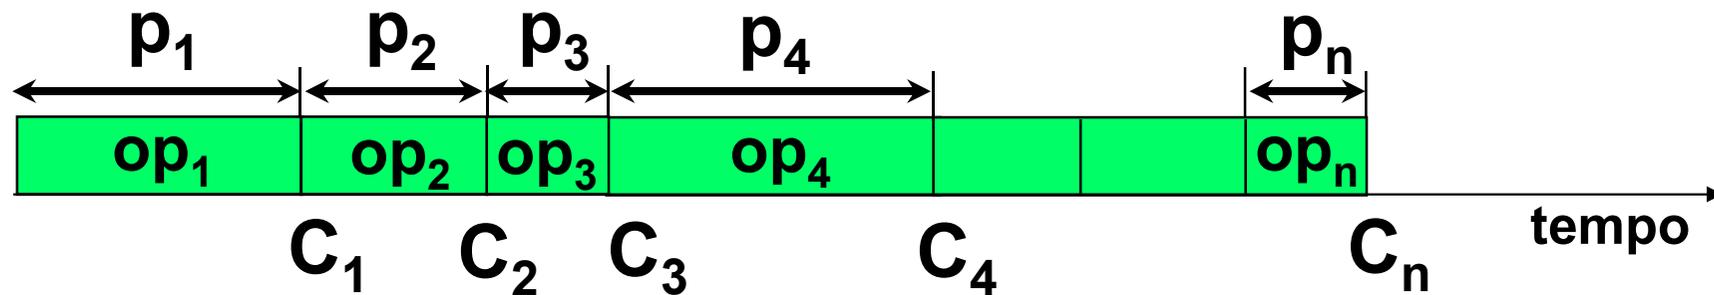


$$\min \sum_i C_i$$

Gantt del Sequenziamento



Sequenza S



$C_n = \sum_i p_i$: tempo di completamento totale
(*makespan*)

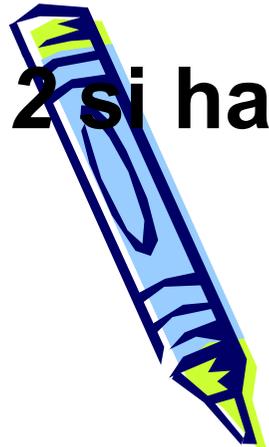
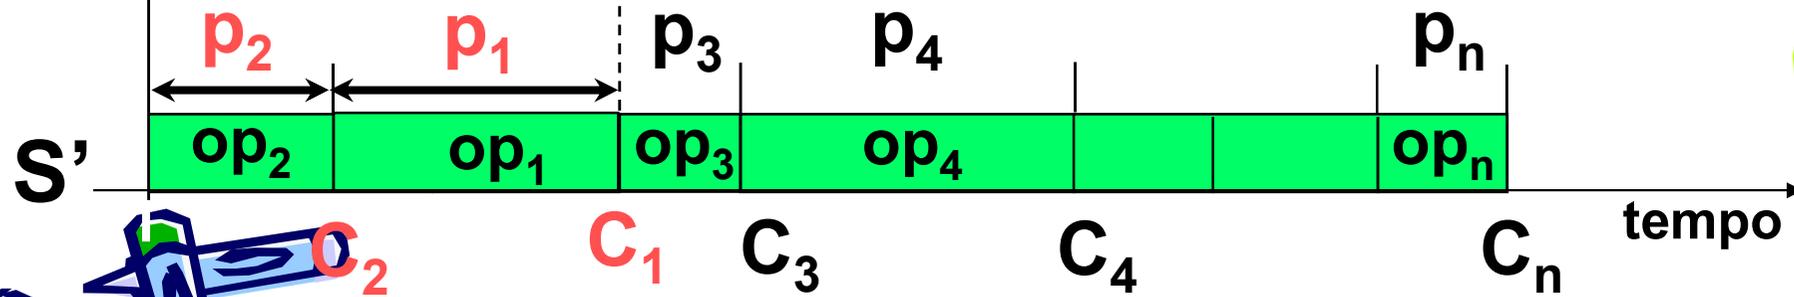
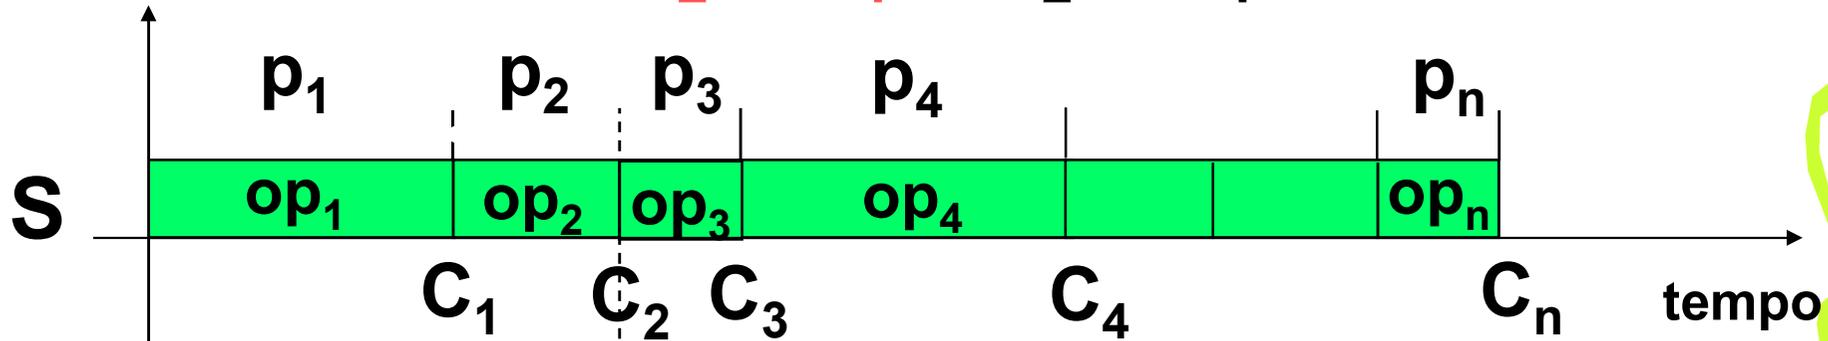


Obiettivo: $\min \sum_i C_i$

se $p_2 < p_1$ allora scambiando le op. 1 e 2 si ha

$$C_2 < C_1$$

$$C_2 + C_1 < C_2 + C_1$$



Regola *SPT* (shortest processing time first)



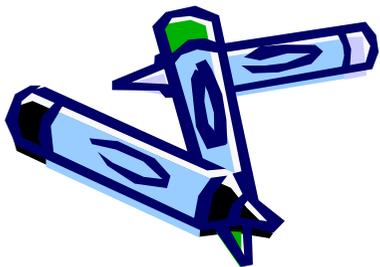
SPT: sequenzia prima le operazioni che hanno tempo di esecuzione più piccolo

Consente di minimizzare la somma dei tempi di completamento $\sum_i C_i$ di n operazioni (lavori) su una macchina



1.1 Tempo totale pesato di completamento

$$\sum w_j C_j$$



Tempo totale pesato di completamento

$$1 // \sum w_j C_j$$

Definiamo WSPT una regola che ordina i job per valori non crescenti del rapporto w_j/p_j

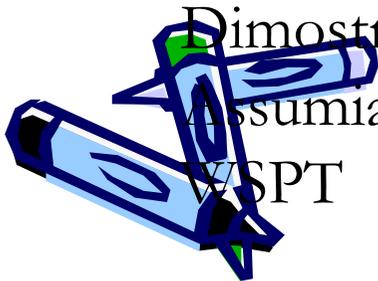
Sussiste il seguente

Teorema 1.1 La regola WSPT calcola una soluzione ottima del problema $1 // \sum w_j C_j$

Dimostrazione. (Per contraddizione)

Assumiamo che S sia uno schedule ottimo e che non rispetti

WSPT



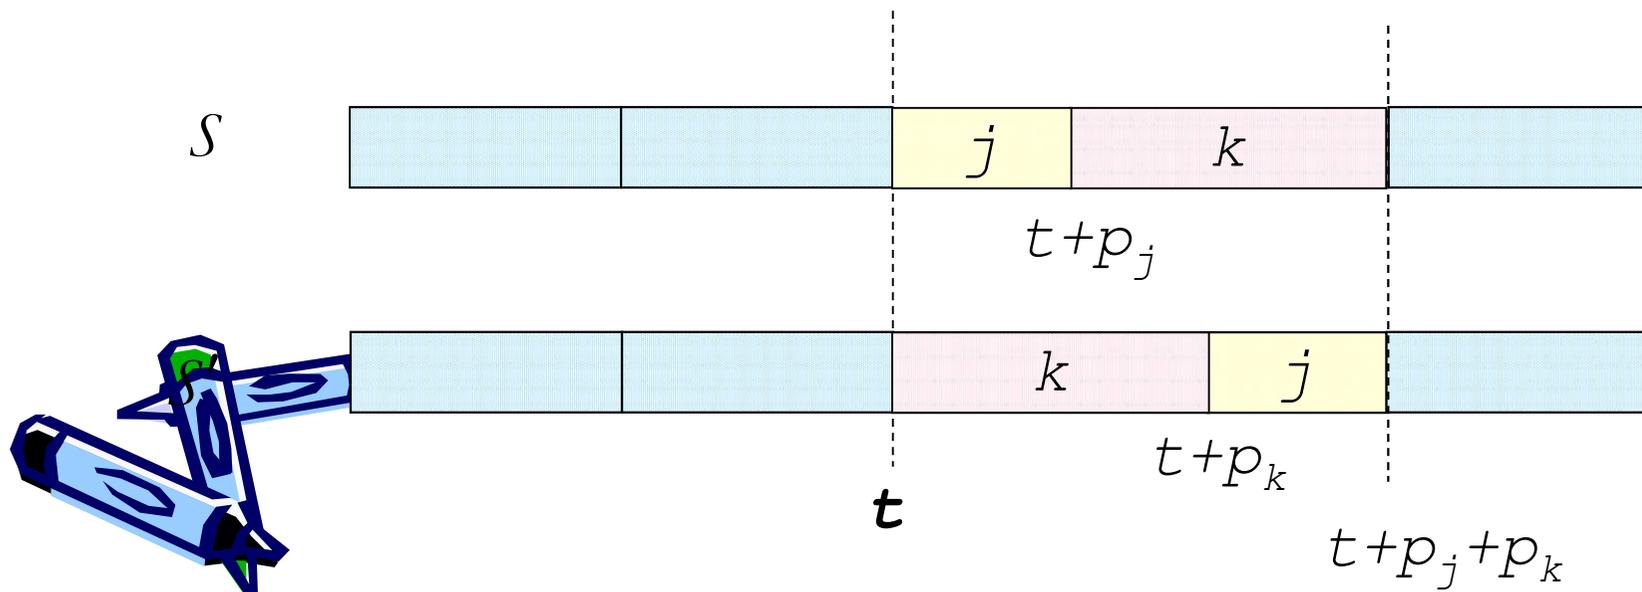
Dimostrazione

Allora devono esserci in S due job adiacenti, diciamo j seguito da k tali che

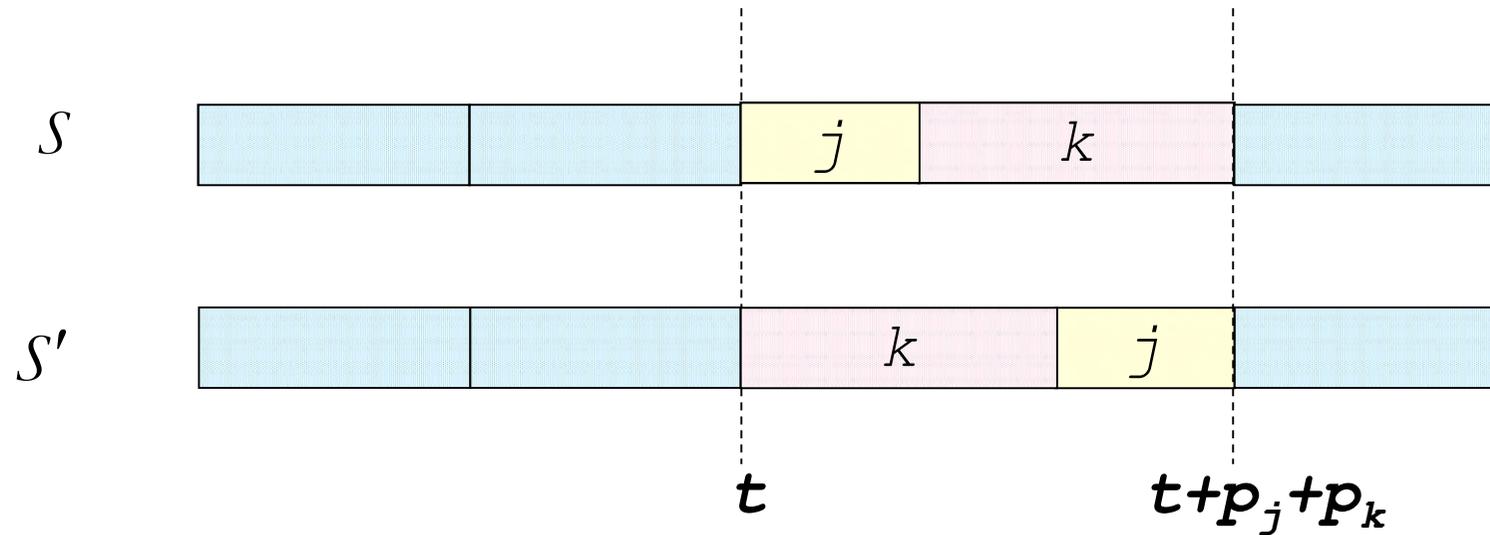
$$w_j/p_j < w_k/p_k$$

Assumiamo che il job j inizi all'istante t .

Eseguiamo uno scambio dei job j e k ottenendo un nuovo schedule S'



Dimostrazione

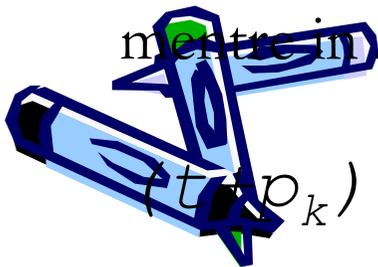


Il tempo totale (pesato) di completamento dei job che precedono e seguono la coppia (j, k) non è modificato dallo scambio. Il contributo dei job j e k in S è:

$$(t+p_j)w_j + (t+p_j+p_k)w_k$$

mentre in S' è:

$$(t+p_k)w_k + (t+p_k+p_j)w_j$$



Dimostrazione

$$\text{in } S] \quad (t+p_j) w_j + (t+p_j+p_k) w_k$$

$$\text{in } S'] \quad (t+p_k) w_k + (t+p_k+p_j) w_j$$

Eliminando i termini uguali:

$$\text{in } S] \quad p_j w_k$$

$$\text{in } S'] \quad p_k w_j$$

Quindi, se $w_j/p_j < w_k/p_k$, risulta $p_k w_j < p_j w_k$,
cioè il tempo totale pesato in S' è strettamente inferiore a
quello in S , contraddizione

□

