Scheduling di processi "soft real-time"

Eugenio Faldella
Dipartimento di Informatica – Scienza e Ingegneria
Scuola di Ingegneria e Architettura, Università di Bologna

eugenio.faldella@unibo.it
http://www.ing.unibo.it

ALGORITMI PER LA SCHEDULAZIONE DI PROCESSI APERIODICI

- servizio in background
- servizio tramite server
  - a priorità statica
    - polling server
    - deferrable server
    - priority exchange server
    - sporadic server
    - ...
  - a priorità dinamica
    - constant utilization server
    - total bandwidth server
    - ...
- altri algoritmi
  - a priorità statica
    - slack stealer
    - ...
  - a priorità dinamica
    - ...

SERVIZIO IN BACKGROUND …

Le richieste aperiodiche, caratterizzate da vincoli temporali di tipo soft o non real-time, vengono servite solo se non vi sono processi hard real-time (periodici e/o sporadici) pronti per l'esecuzione.

La strategia di schedulazione dei processi aperiodici (tipicamente FCFS) è indipendente da quella selezionata per gli altri processi (tipicamente RMPO, DMPO o EDF).

La schedulabilità dei processi hard real-time non è influenzata dal servizio dei processi aperiodici.

… SERVIZIO IN BACKGROUND …

A_1	C [ms]	T [ms]
P_1	2	5
P_2	2	10
P_3	2	20

	a [ms]	s [ms]
R_{a1}	6	4
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	2

arrival time — service time

strategia di schedulazione: RMPO

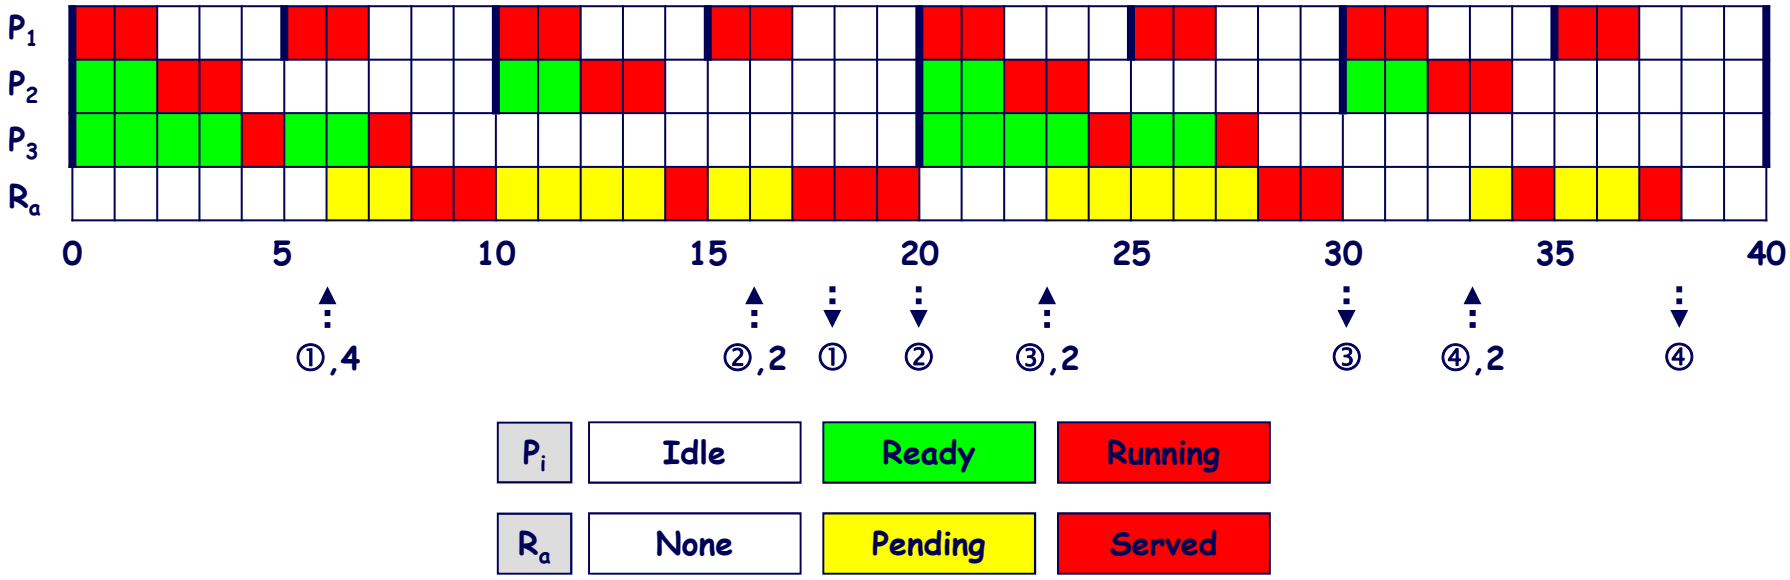

I tempi di risposta delle richieste aperiodiche possono risultare notevoli, soprattutto se il fattore di utilizzazione del processore da parte dei processi hard real-time è elevato.

… SERVIZIO IN BACKGROUND

A_2	C [ms]	T [ms]
P_1	2	8
P_2	2	10
P_3	2	20

strategia di schedulazione: RMPO

	a [ms]	s [ms]
R_{a1}	6	3
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	3

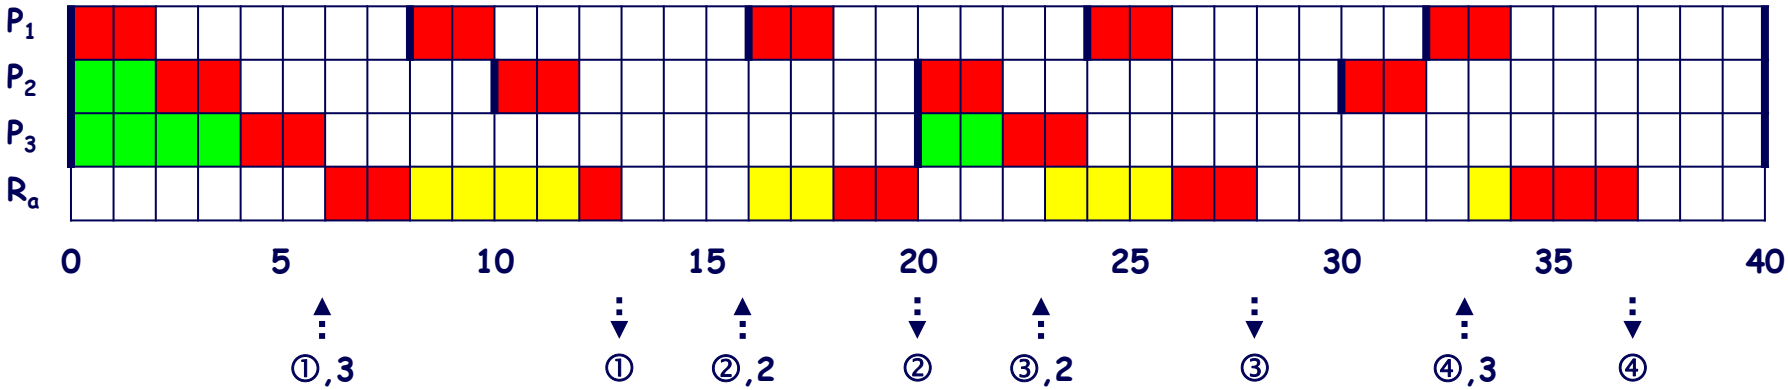

P_i	Idle	Ready	Running
R_a	None	Pending	Served

CONSIDERAZIONI REALIZZATIVE

Table	a [ms]	s [ms]
R_{a1}	a_1	s_1
...	...	...
R_{aM}	a_M	s_M

Un ambiente di simulazione:

i parametri temporali (tempo di arrivo e tempo di servizio) di un numero arbitrario M di richieste aperiodiche sono memorizzati in una tabella;

un processo **Pg** simula la generazione di ciascuna richiesta scrivendo in una FIFO, in corrispondenza dell'istante di arrivo specificato in tabella, il relativo tempo di servizio;

un processo **Pe** simula l'esecuzione del servizio di ciascuna richiesta impegnando la CPU per un tempo pari al valore corrispondentemente letto dalla FIFO.

Pg

```
Entry = TableFirstEntry;
LastEntryArrivalTime = 0;
while (Entry <= TableLastEntry)
{
   TaskDelay (Table[Entry]->ArrivalTime – LastEntryArrivalTime);
   put_fifo (Table[Entry]->ServiceTime);
   LastEntryArrivalTime = Table[Entry]->ArrivalTime;
   Entry++;
}
```

Pe

```
while (true)
{
   while (fifo_empty ( ));
   ServiceTime = get_fifo (  );
   BusyWait (ServiceTime);
}
```

RISULTATI SPERIMENTALI

A_3	C [ms]	T [ms]
P_1	2	6
P_2	9	30

strategia di schedulazione: RMPO

Table	a [ms]	s [ms]
R_{a1}	1	1.5

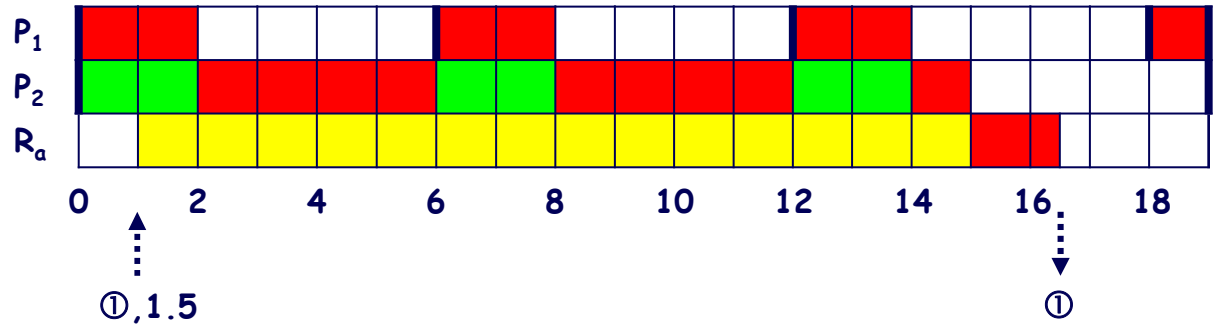

S.O.: RTAI Tool: Linux Trace Toolkit

Dopo 1 ms dall'inizio della simulazione, Pg genera la richiesta di servizio

Pe inizia il servizio della richiesta dopo 14 ms

Pe completa il servizio in 1.5 ms, ponendosi poi in attesa di nuove richieste

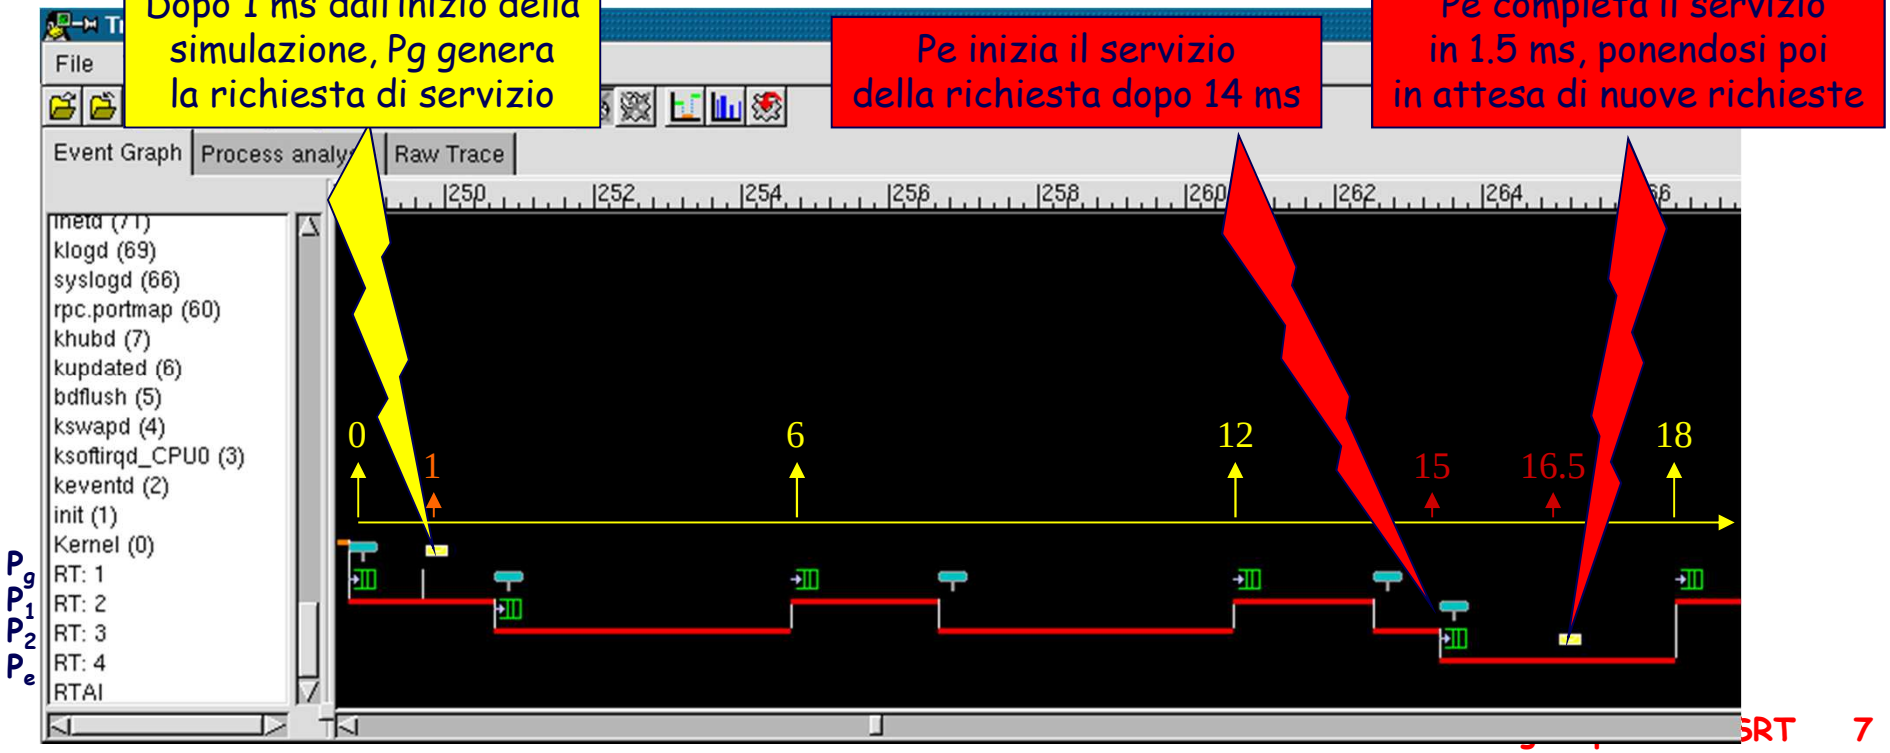

SERVIZIO TRAMITE SERVER A PRIORITÀ STATICA

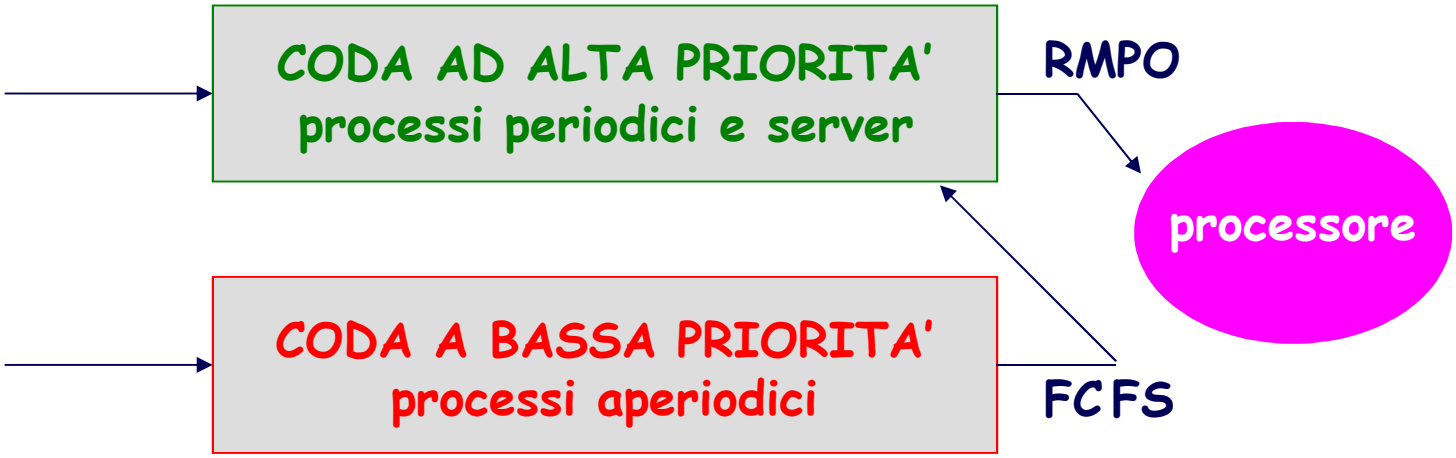

Il server è un processo periodico (P_S), con periodo T_S
e tempo massimo di esecuzione C_S (capacità massima del server) prefissati.

P_S è schedulato secondo la stessa strategia (tipicamente, e nel seguito, RMPO)
utilizzata per i processi periodici, in base alla priorità $p(P_S) \propto 1/T_S$,
di norma elevata, che gli compete.

I tempi di risposta dei processi aperiodici, mediamente sensibilmente inferiori
rispetto a quelli derivanti dal servizio in background,
dipendono dalle regole, peculiari di ciascuna tipologia di server,
secondo cui è operato il riempimento ed il consumo della capacità del server stesso.

SERVIZIO TRAMITE POLLING SERVER (PS)

Regole di riempimento e di consumo della capacità di P_S

La capacità è ripristinata al valore C_S all'inizio di ogni periodo T_S.
La capacità è progressivamente consumata durante il servizio di richieste aperiodiche.
In assenza di (ulteriori) richieste, la capacità (residua) disponibile è scartata.

A_1	C [ms]	T [ms]
P_1	2	5
P_2	2	10
P_3	2	20

P_S : T_S = 8 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	6	4
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	2

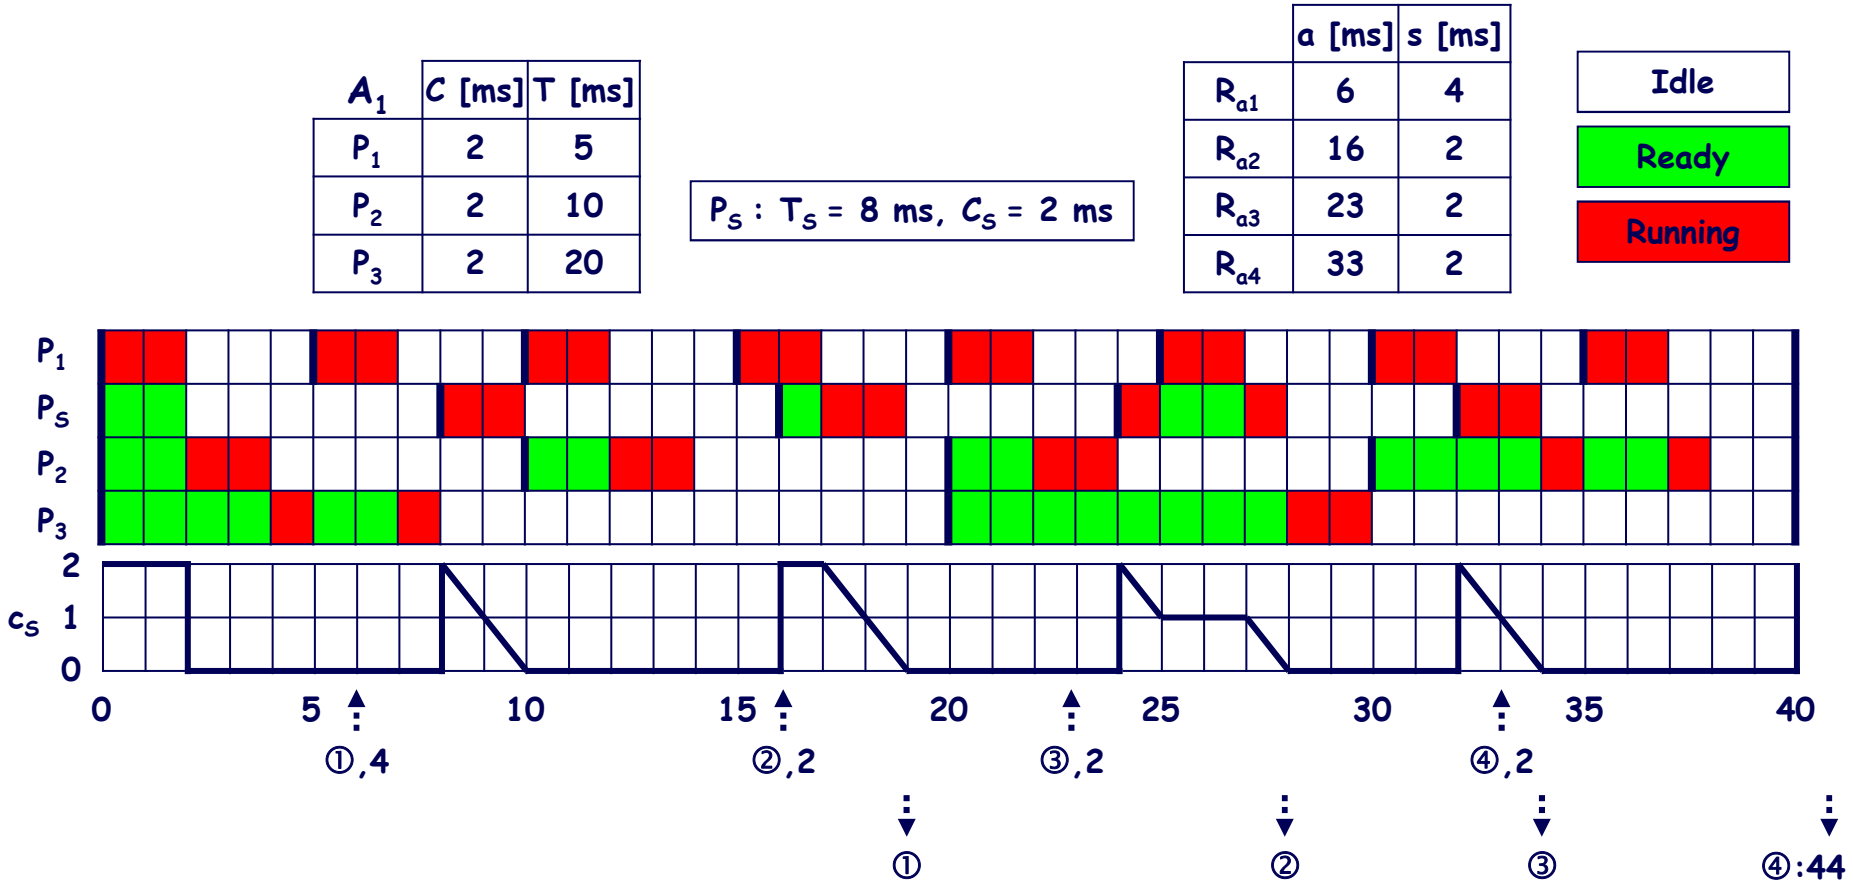

… SERVIZIO TRAMITE PS …

Server a massima priorità:

A_2	C [ms]	T [ms]
P_1	2	8
P_2	2	10
P_3	2	20

P_S : T_S = 5 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	6	3
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	3

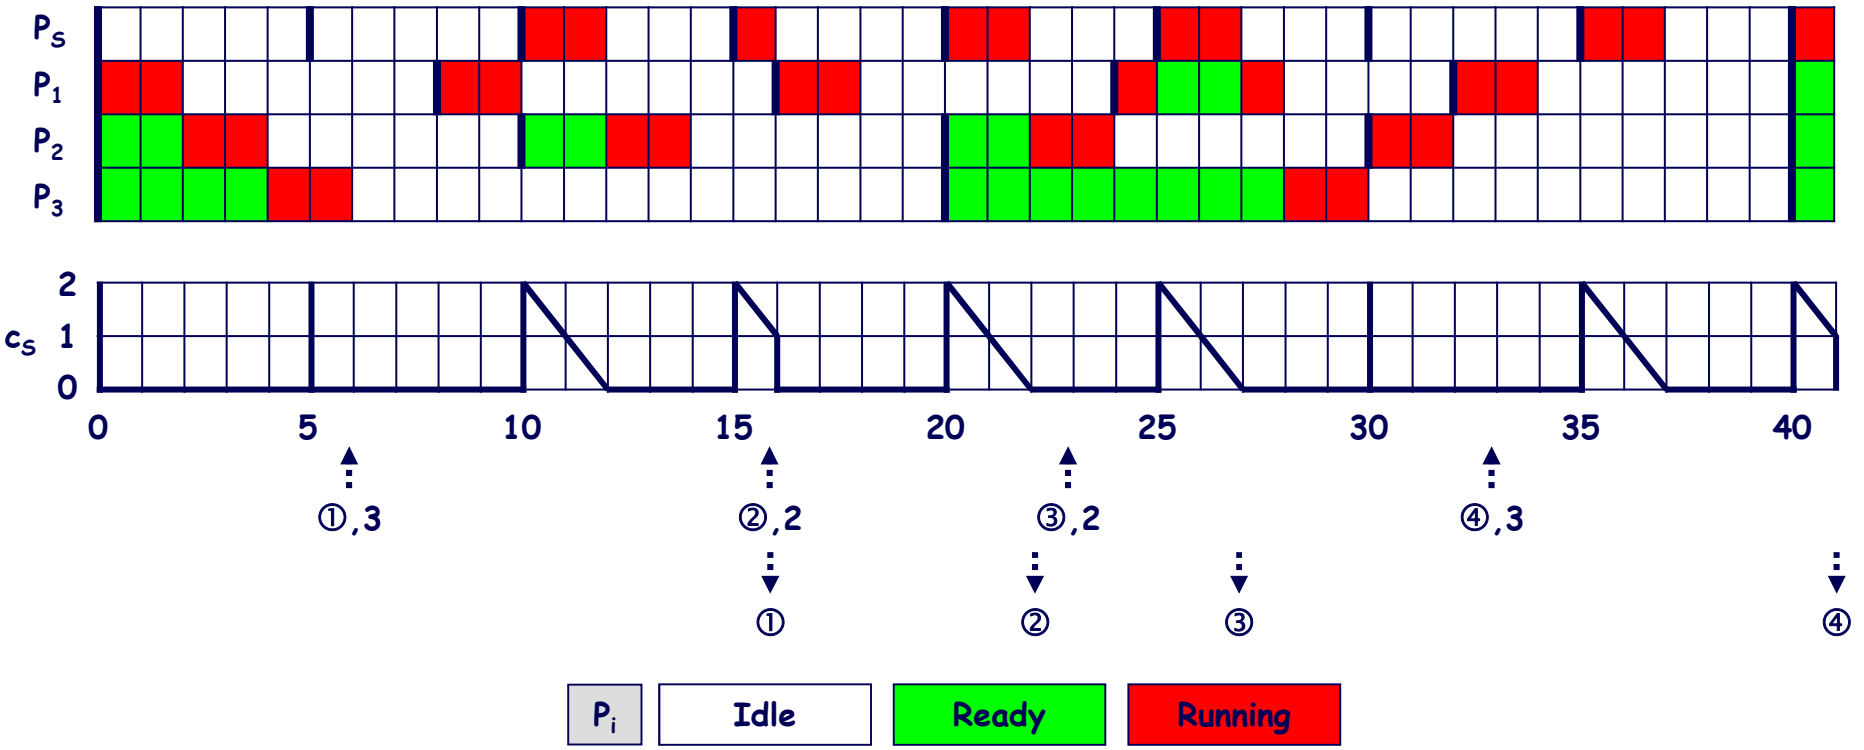

… SERVIZIO TRAMITE PS …

Garanzia di schedulabilità dei processi periodici:

La schedulabilità dei processi periodici è influenzata dal servizio delle richieste aperiodiche.

Il massimo carico computazionale indotto da PS è equivalente a quello derivante dall'esecuzione di un processo periodico con fattore di utilizzazione del processore $U_s = C_s/T_s$.

La schedulabilità di un insieme di N processi periodici contraddistinti da un fattore di utilizzazione del processore U_p è pertanto garantita (condizione sufficiente, ma non necessaria) se:

$$U_p + U_s \leq U_{RMPO}(N+1) = (N+1)\left(2^{1/(N+1)} - 1\right)$$

… SERVIZIO TRAMITE PS …

$$U_s \leq (N+1)\left(2^{1/(N+1)}-1\right) - U_p \underset{N\to\infty}{=} \ln 2 - U_p$$

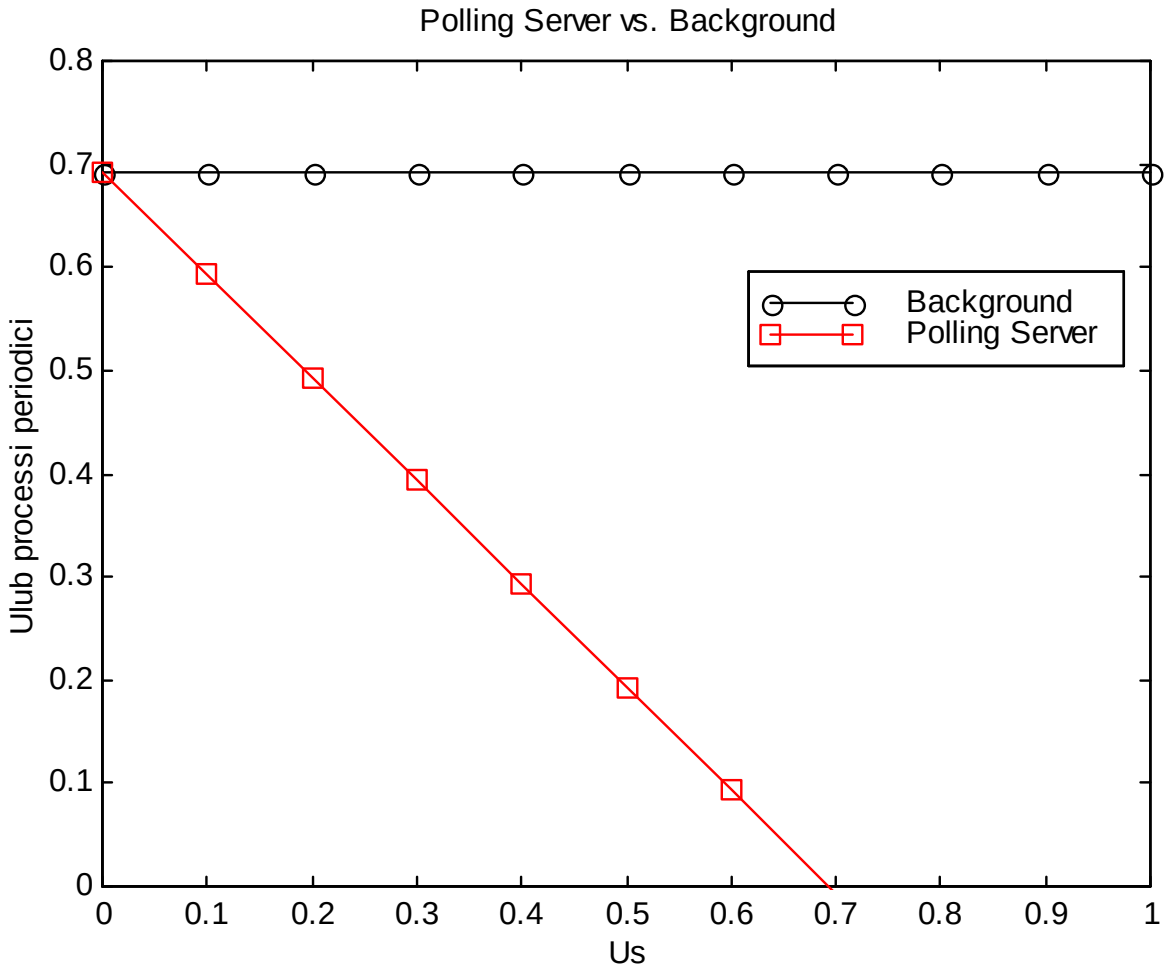

… SERVIZIO TRAMITE PS …

Garanzia di schedulabilità con server a massima priorità:

$$C_s = T_1 - T_s$$

$$C_1 = T_2 - T_1 \quad \cdots \quad C_{N-1} = T_N - T_{N-1}$$

$$C_N \le T_s - C_s - \sum_{j=1}^{N-1} C_j = 2T_s - T_N = C_{Nub}$$

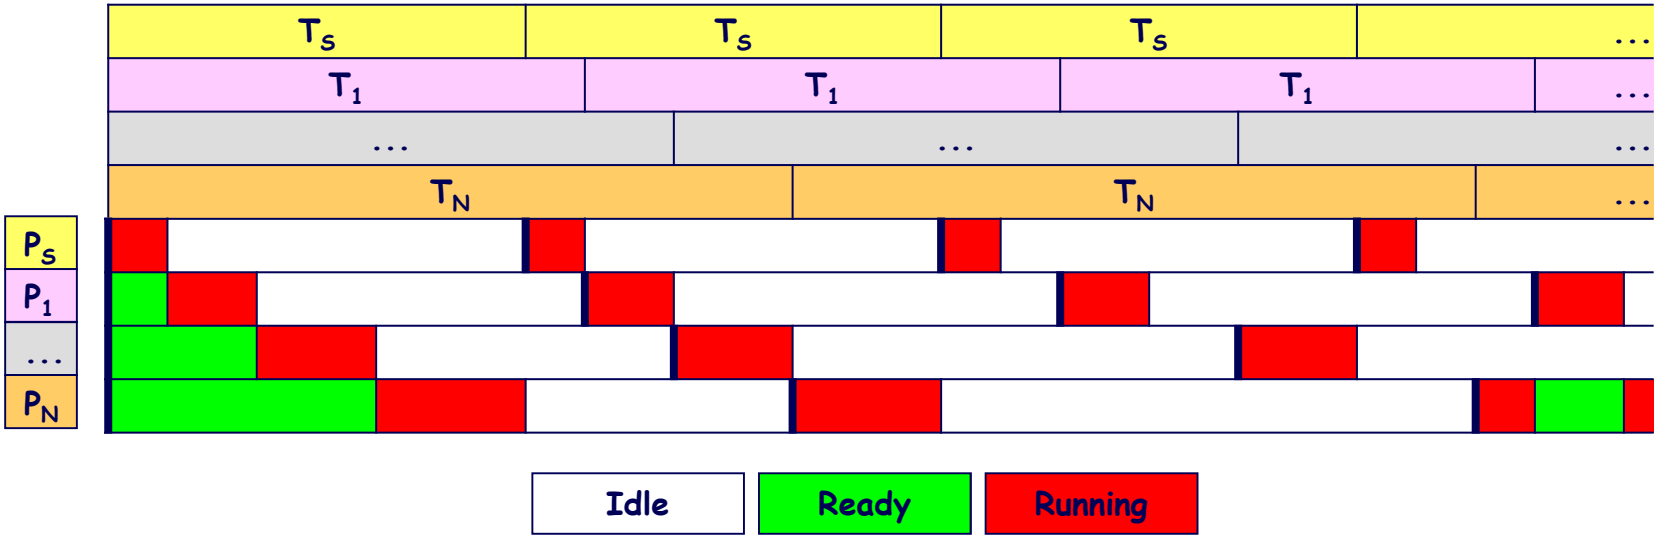

… SERVIZIO TRAMITE PS …

$$R_j = \frac{T_{j+1}}{T_j} \qquad j = 1, 2, \cdots, N-1$$

$$K = \frac{2\,T_s}{T_1} = \frac{2}{U_s + 1}$$

$$U_{p\,ub} = \sum_{j=1}^{N-1} R_j + \frac{K}{\prod_{j=1}^{N-1} R_j} - N$$

$$\frac{\partial\, U_{p\,ub}}{\partial\, R_j} = 0 \quad \forall\, j$$

$$R_j = K^{1/N} \quad \forall\, j$$

$$U_{p\,lub} = N\left(K^{1/N} - 1\right)$$

$$U_{p\,lub} = N\left(\left(\frac{2}{U_s + 1}\right)^{1/N} - 1\right) \underset{N\to\infty}{=} \ln\frac{2}{U_s + 1}$$

… SERVIZIO TRAMITE PS

$$U_s \leq \frac{2}{\left(1+U_p/N\right)^N} - 1 \underset{N\to\infty}{=} \frac{2}{e^{U_p}} - 1$$

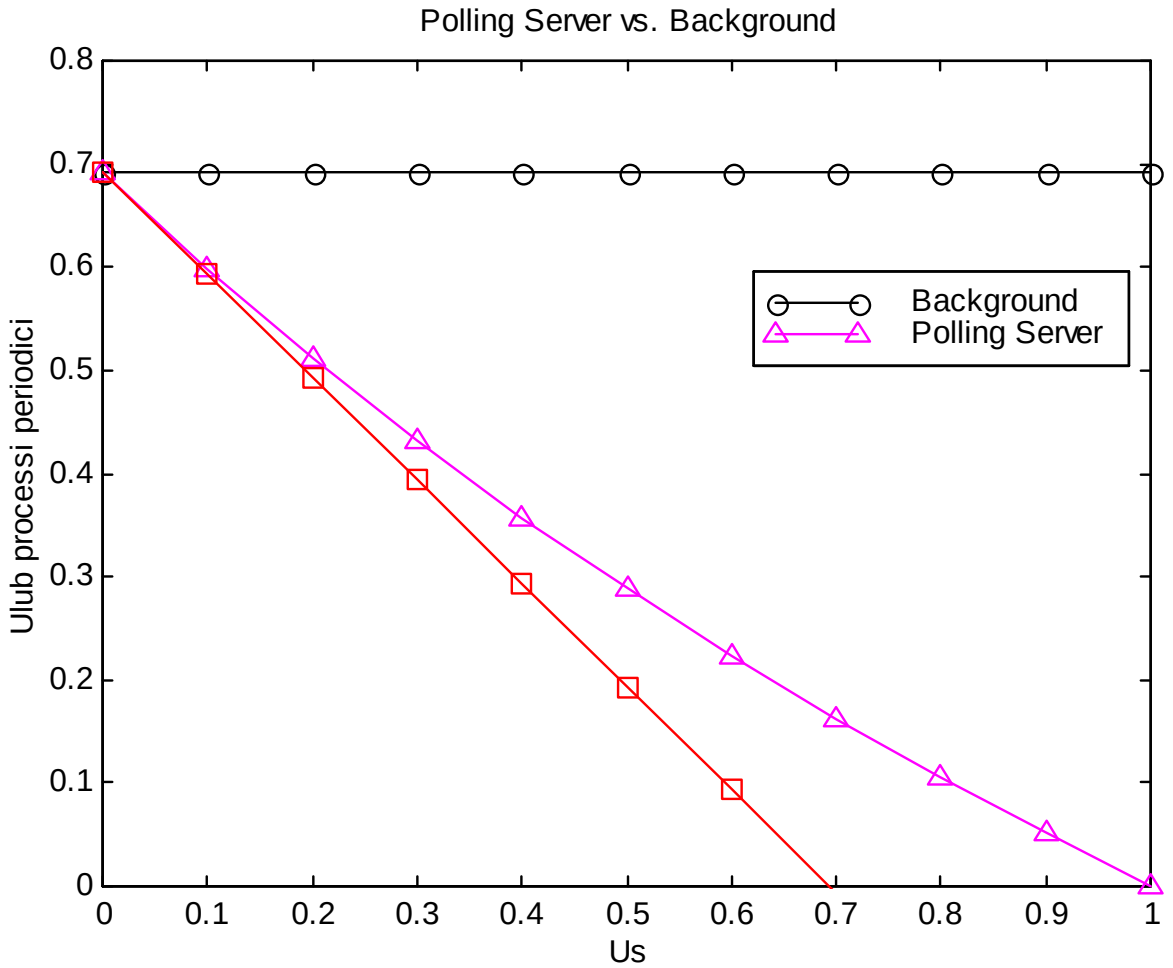

CONSIDERAZIONI REALIZZATIVE

Server a massima priorità

2 processi (Pc, Pe) che operano in sinergia:

Pc, periodico con periodo Ts, (ripristina la capacità al valore massimo Cs ed) attiva l'esecuzione di Pe

Pe serve le eventuali richieste pendenti e si sospende (scartando così la capacità residua)

Pc, se necessario, sospende Pe dopo un tempo pari a Cs

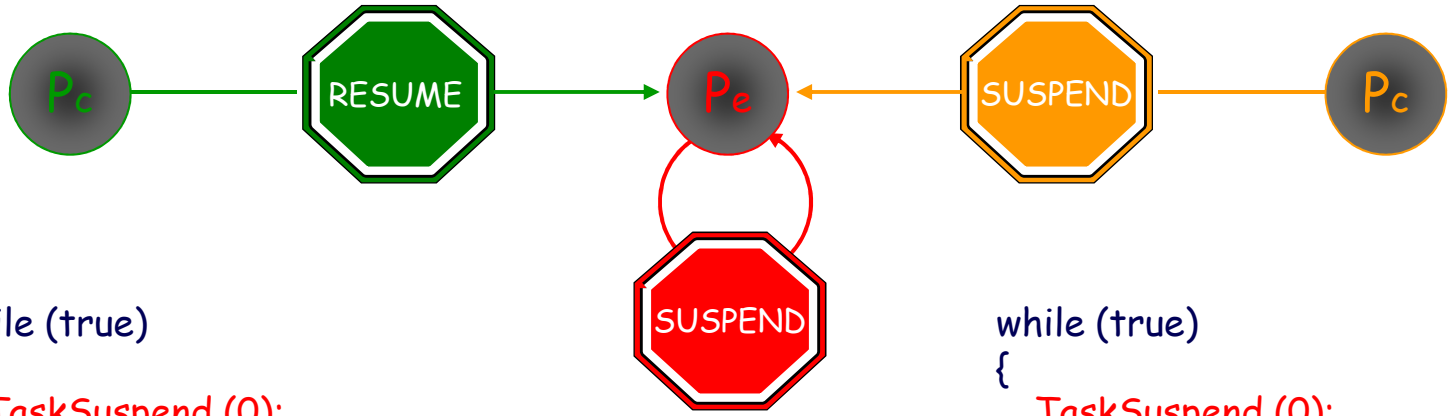

Pc

```
while (true)
{
   TaskSuspend (0);
   TaskResume (PeId);
   TaskDelay (Cs);
    if (!TaskIsSuspended (PeId))
        TaskSuspend (PeId);
}
```

Pe

```
while (true)
{
   TaskSuspend (0);
   while (!fifo_empty ( ))
   {
     ServiceTime = get_fifo (  );
     BusyWait (ServiceTime);
   }
}
```

RISULTATI SPERIMENTALI

A_3	C [ms]	T [ms]
P_1	2	6
P_2	9	30

P_S: T_S = 5 ms, C_S = 1 ms

strategia di schedulazione: RMPO

Table	a [ms]	s [ms]
R_{a1}	1	1.5

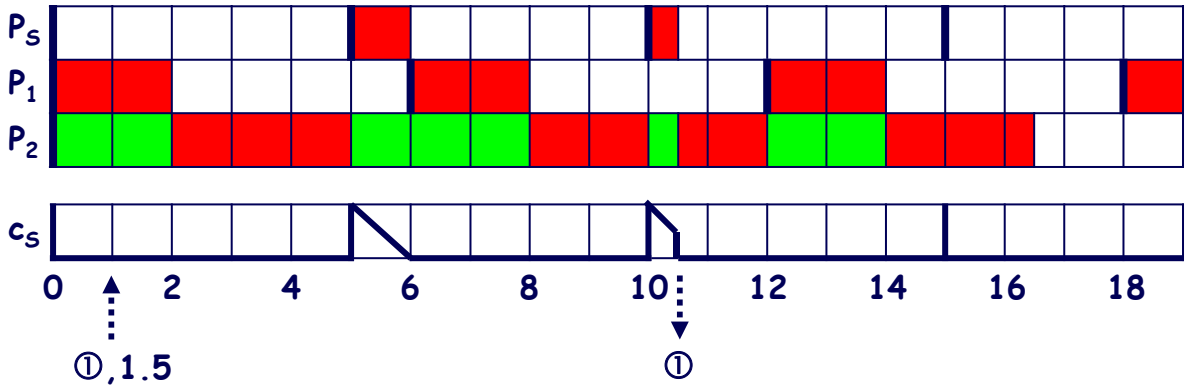

S.O.: RTAI Tool: Linux Trace Toolkit

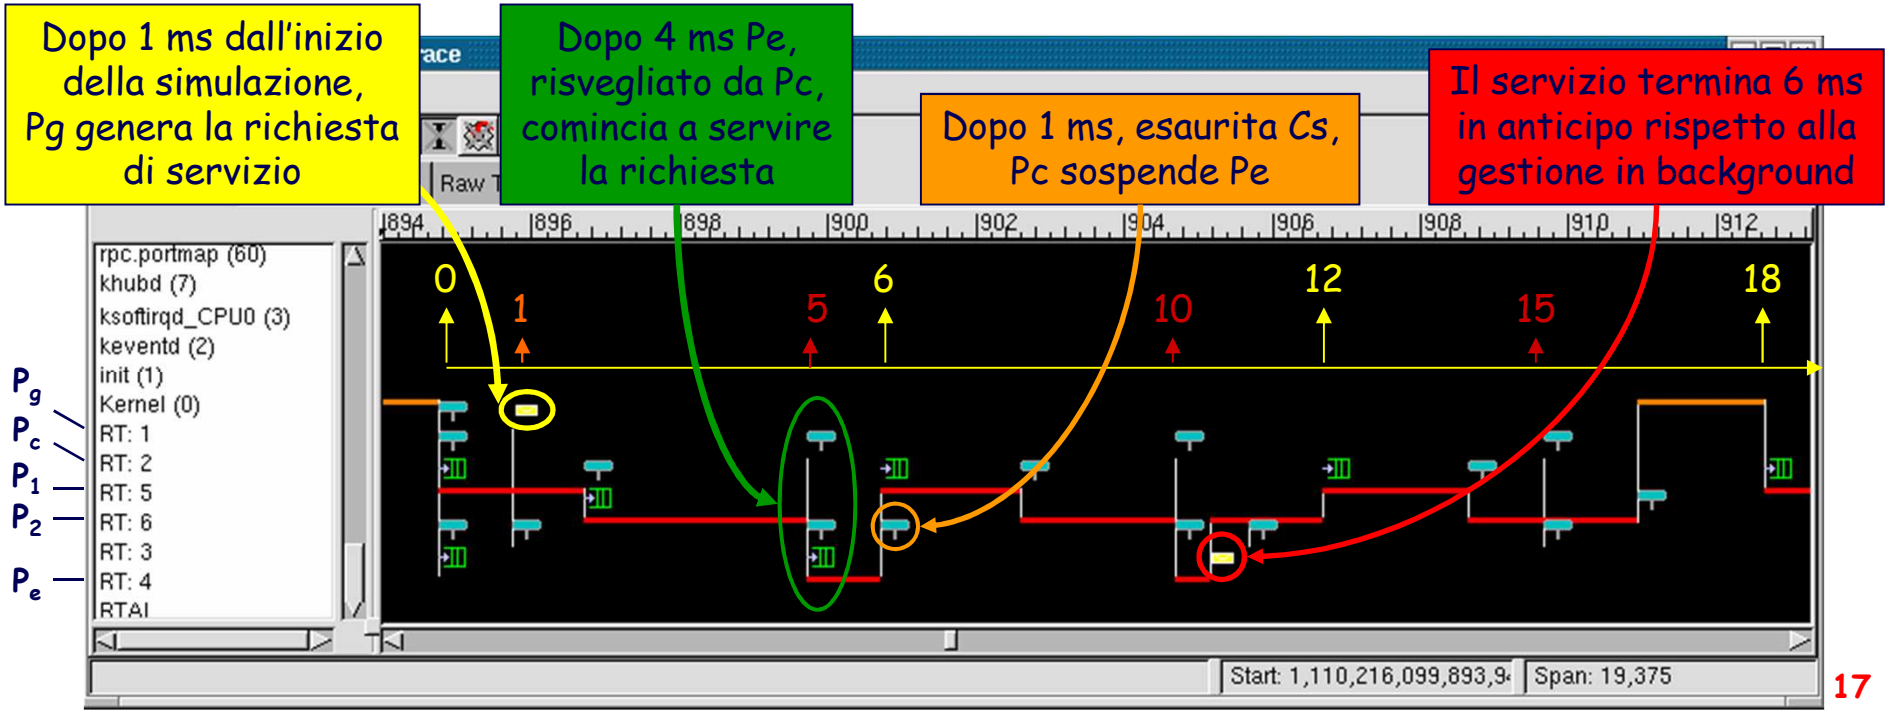

SERVIZIO TRAMITE DEFERRABLE SERVER (DS) [Lehoczky, Sha, Strosnider (87)] …

Regole di riempimento e di consumo della capacità di P_S

La capacità viene ripristinata al valore C_S all'inizio di ogni periodo T_S.

La capacità disponibile è conservata in assenza di richieste aperiodiche pendenti: il servizio può pertanto essere differito (bandwidth-preserving server).

La capacità è progressivamente consumata durante il servizio di richieste aperiodiche.

A_1	C [ms]	T [ms]
P_1	2	5
P_2	2	10
P_3	2	20

P_S : T_S = 8 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	6	4
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	2

Idle
Ready
Running
Waiting

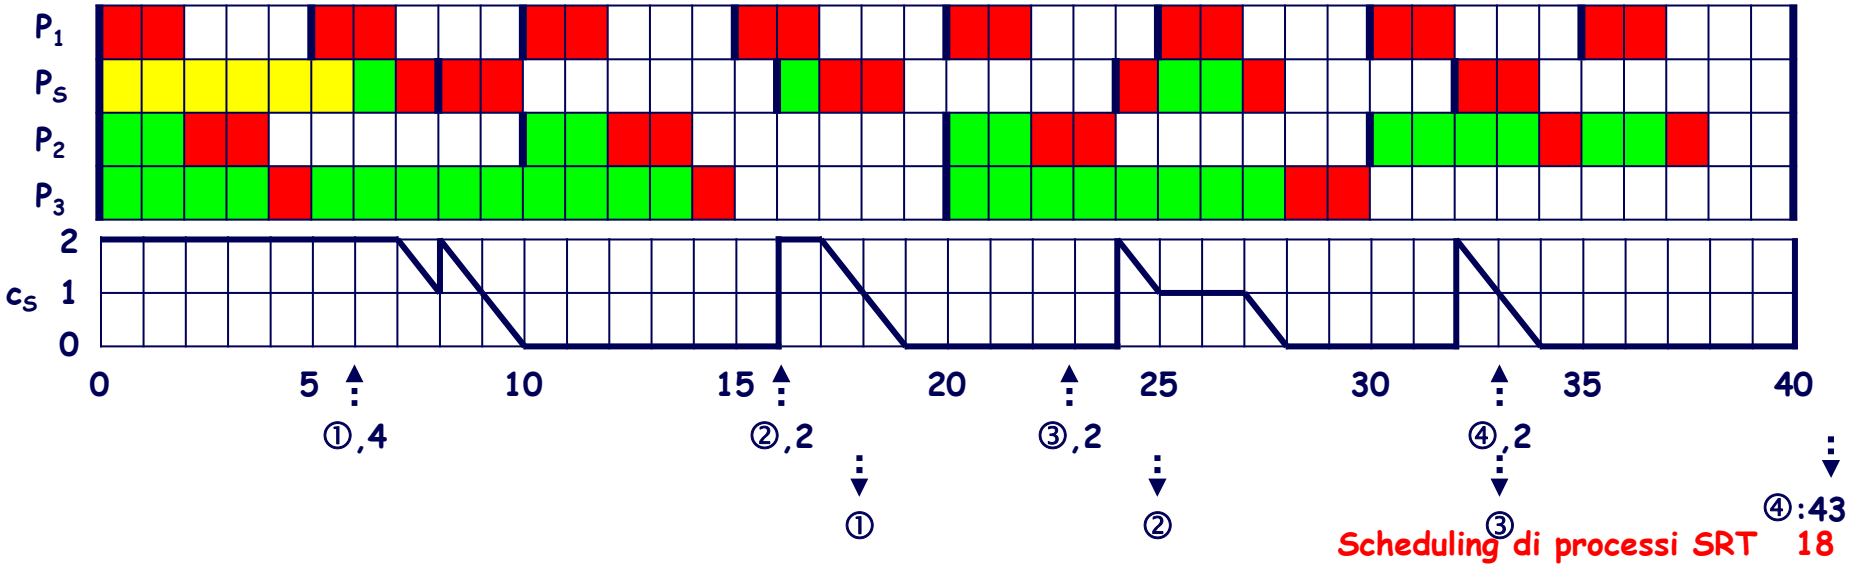

… SERVIZIO TRAMITE DS …

Server a massima priorità:

A_2	C [ms]	T [ms]
P_1	2	8
P_2	2	10
P_3	2	20

P_S : T_S = 5 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	6	3
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	3

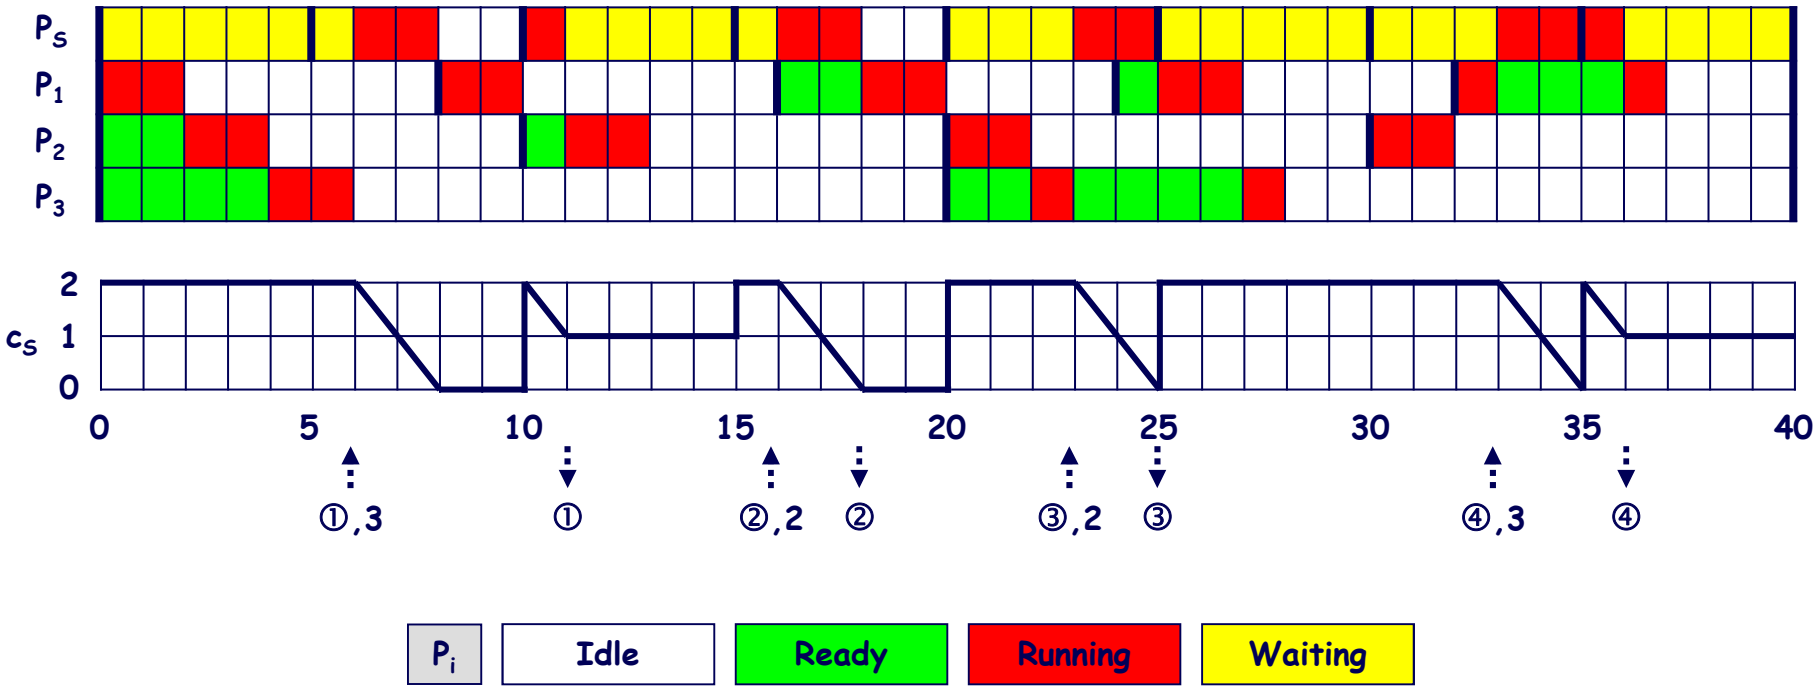

… SERVIZIO TRAMITE DS …

Garanzia di schedulabilità dei processi periodici:

Il contributo al fattore di utilizzazione del processore imputabile a DS è, in condizioni di massimo carico, maggiore di quello derivante dall'esecuzione di un processo periodico con periodo T_s e tempo di esecuzione C_s, ovvero $U_s > C_s/T_s$. Infatti:

A_4	C [ms]	T [ms]
P_1	2	4
P_2	2	5

A_4'	C [ms]	T [ms]
P_S	2	4
P_2	2	5

	a [ms]	s [ms]
R_{a1}	0	2
R_{a2}	3.5	2
R_{a3}	10	2
R_{a4}	11.2	2
R_{a5}	15.5	2

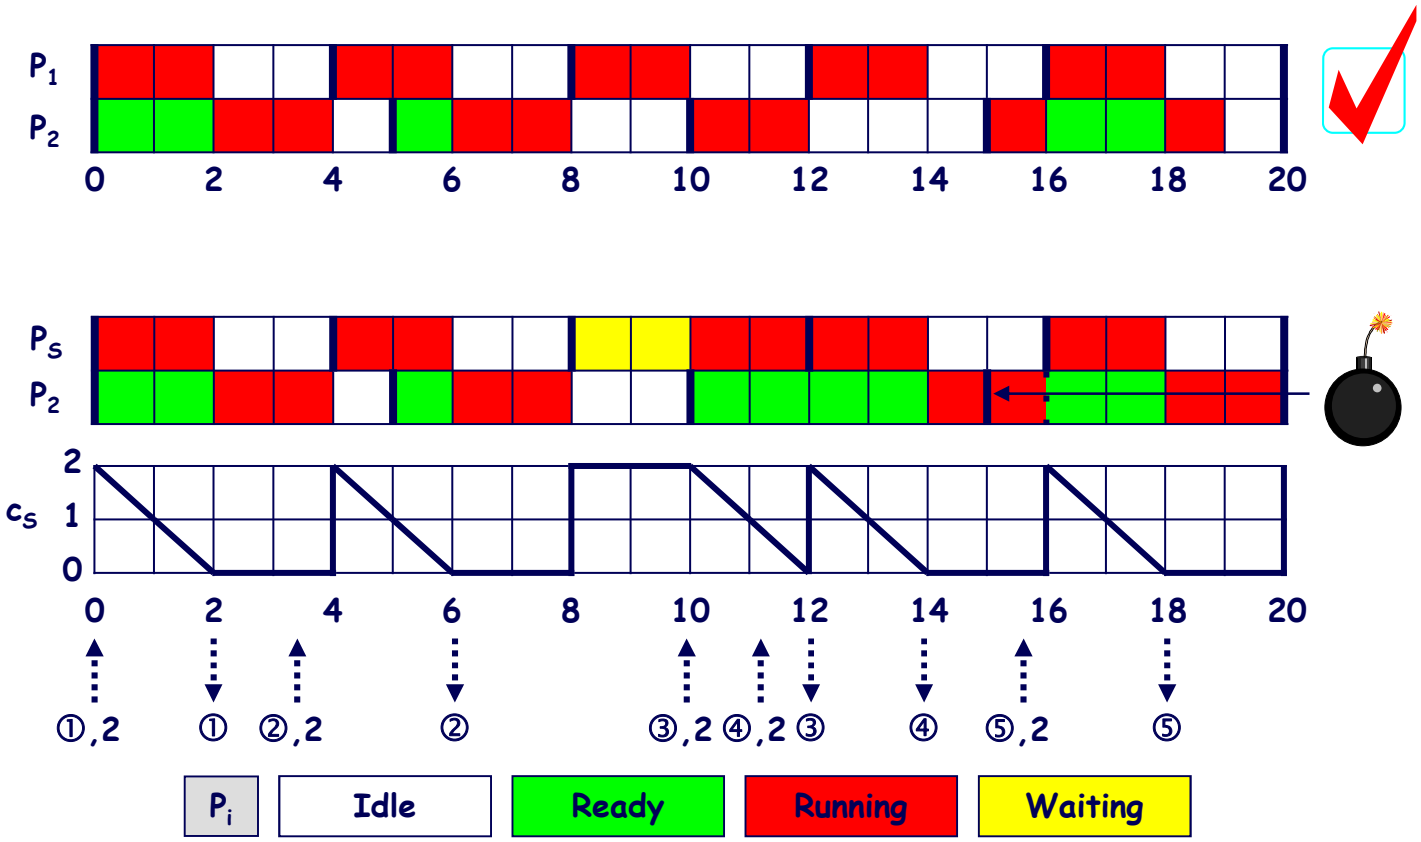

… SERVIZIO TRAMITE DS …

Garanzia di schedulabilità con server a massima priorità:

$$C_s = T_1 - (T_s + C_s) = \frac{T_1 - T_s}{2}$$

$$C_1 = T_2 - T_1 \quad \cdots \quad C_{N-1} = T_N - T_{N-1}$$

$$C_N \le T_s - C_s - \sum_{j=1}^{N-1} C_j = C_s + 2T_s - T_N = \frac{3T_s + T_1}{2} - T_N = C_{Nub}$$

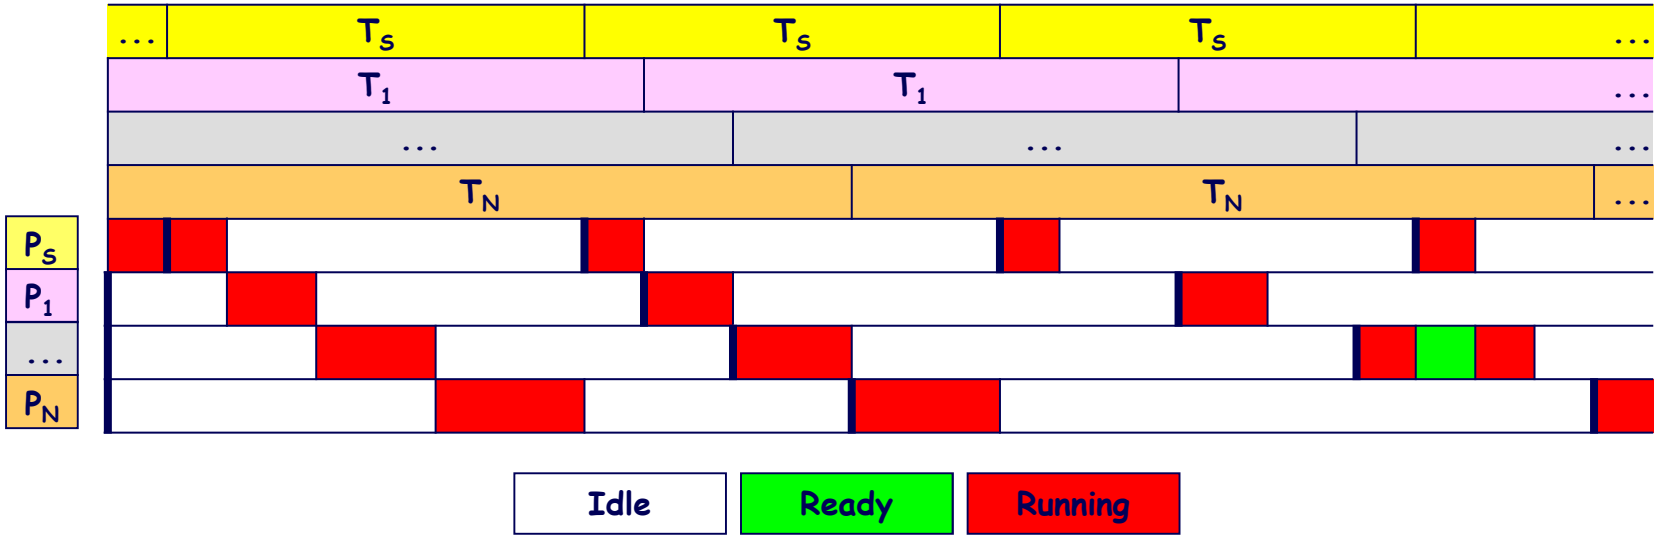

… SERVIZIO TRAMITE DS …

$$R_j = \frac{T_{j+1}}{T_j} \qquad j = 1, 2, \cdots, N-1$$

$$K = \frac{3\,T_s / T_1 + 1}{2} = \frac{U_s + 2}{2\,U_s + 1}$$

$$U_{p\,ub} = \sum_{j=1}^{N-1} R_j + \frac{K}{\prod_{j=1}^{N-1} R_j} - N$$

$$\frac{\partial\, U_{p\,ub}}{\partial\, R_j} = 0 \quad \forall\, j$$

$$R_j = K^{1/N} \quad \forall\, j$$

$$U_{p\,lub} = N\left(K^{1/N} - 1\right)$$

$$U_{p\,lub} = N\left(\left(\frac{U_s + 2}{2U_s + 1}\right)^{1/N} - 1\right) \underset{N \to \infty}{=} \ln \frac{U_s + 2}{2U_s + 1}$$

… SERVIZIO TRAMITE DS

$$U_s \leq \frac{2-\left(1+U_p/N\right)^N}{2\left(1+U_p/N\right)^N-1} \underset{N\to\infty}{=} \frac{2-e^{U_p}}{2e^{U_p}-1}$$

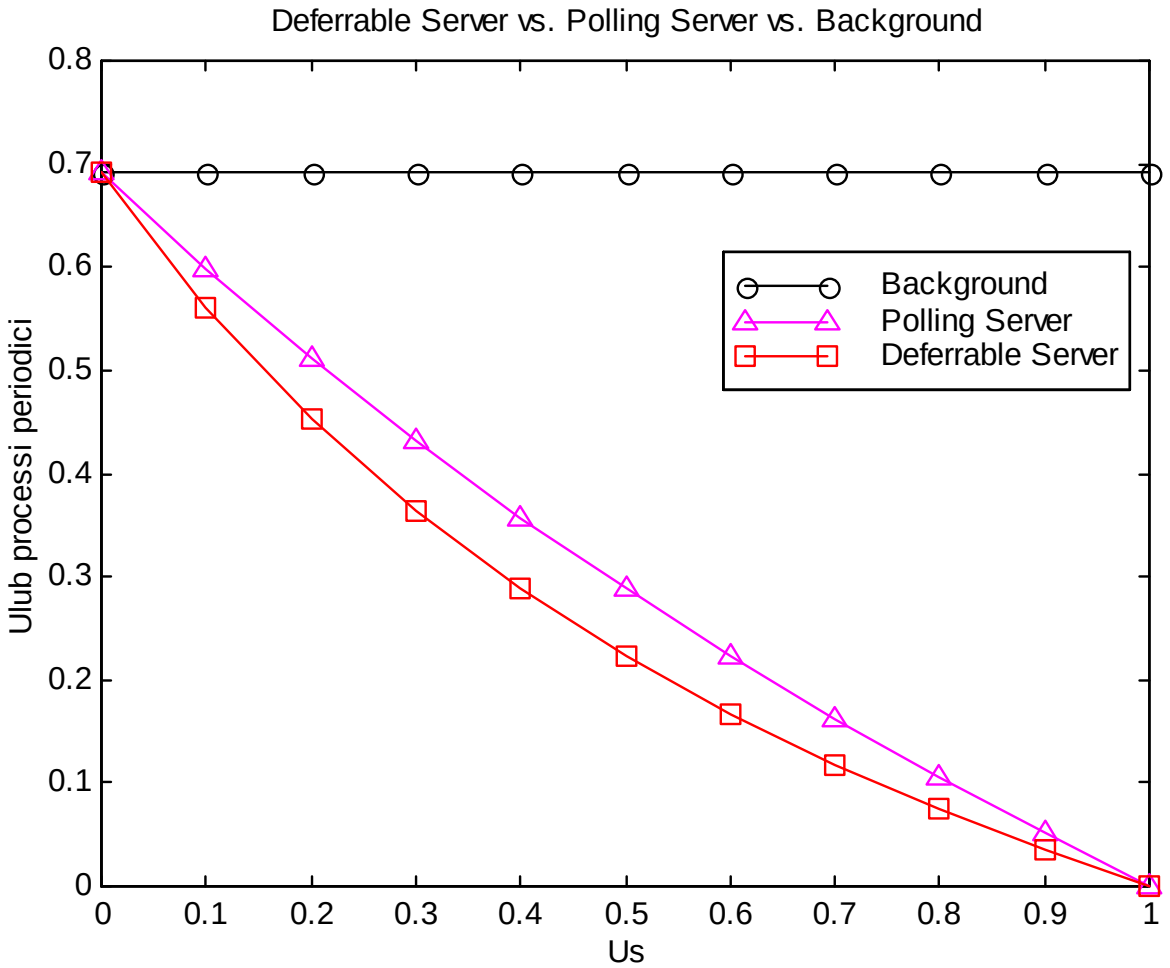

SERVIZIO TRAMITE PRIORITY EXCHANGE SERVER (PES) [Lehoczky, Sha, Strosnider (87)] ...

Regole di riempimento e di consumo della capacità di P_S

La capacità può essere accumulata, oltre che al livello di priorità $p(P_S)$ proprio di P_S, al livello di priorità che compete a ciascun processo periodico P_j di priorità $p(P_j) < p(P_S)$.

La capacità al livello di priorità $p(P_S)$ è ripristinata al valore C_S all'inizio di ogni periodo T_S.

La capacità disponibile ad un qualunque livello di priorità è conservata durante l'esecuzione di un processo periodico di priorità non inferiore.

La capacità disponibile al massimo livello di priorità è progressivamente consumata sia durante il servizio di richieste aperiodiche, sia in assenza di richieste aperiodiche qualora non vi siano processi periodici di priorità inferiore pronti per l'esecuzione.

La capacità disponibile al massimo livello di priorità, in assenza di richieste aperiodiche ed in presenza di uno o più processi periodici di priorità inferiore pronti per l'esecuzione, è progressivamente trasferita durante l'esecuzione di ciascun processo al corrispondente livello di priorità.

In presenza di richieste aperiodiche, P_S, se dispone di capacità ad un qualche livello di priorità, ha la precedenza rispetto ad un processo periodico di pari priorità.

Da tali regole discende che il servizio delle richieste aperiodiche, ancorché talora con priorità $< p(P_S)$, può essere differito (bandwidth-preserving server).

… SERVIZIO TRAMITE PES …

A_1	C [ms]	T [ms]
P_1	2	5
P_2	2	10
P_3	2	20

P_S : T_S = 8 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	6	4
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	2

Idle
Ready
Running
Waiting

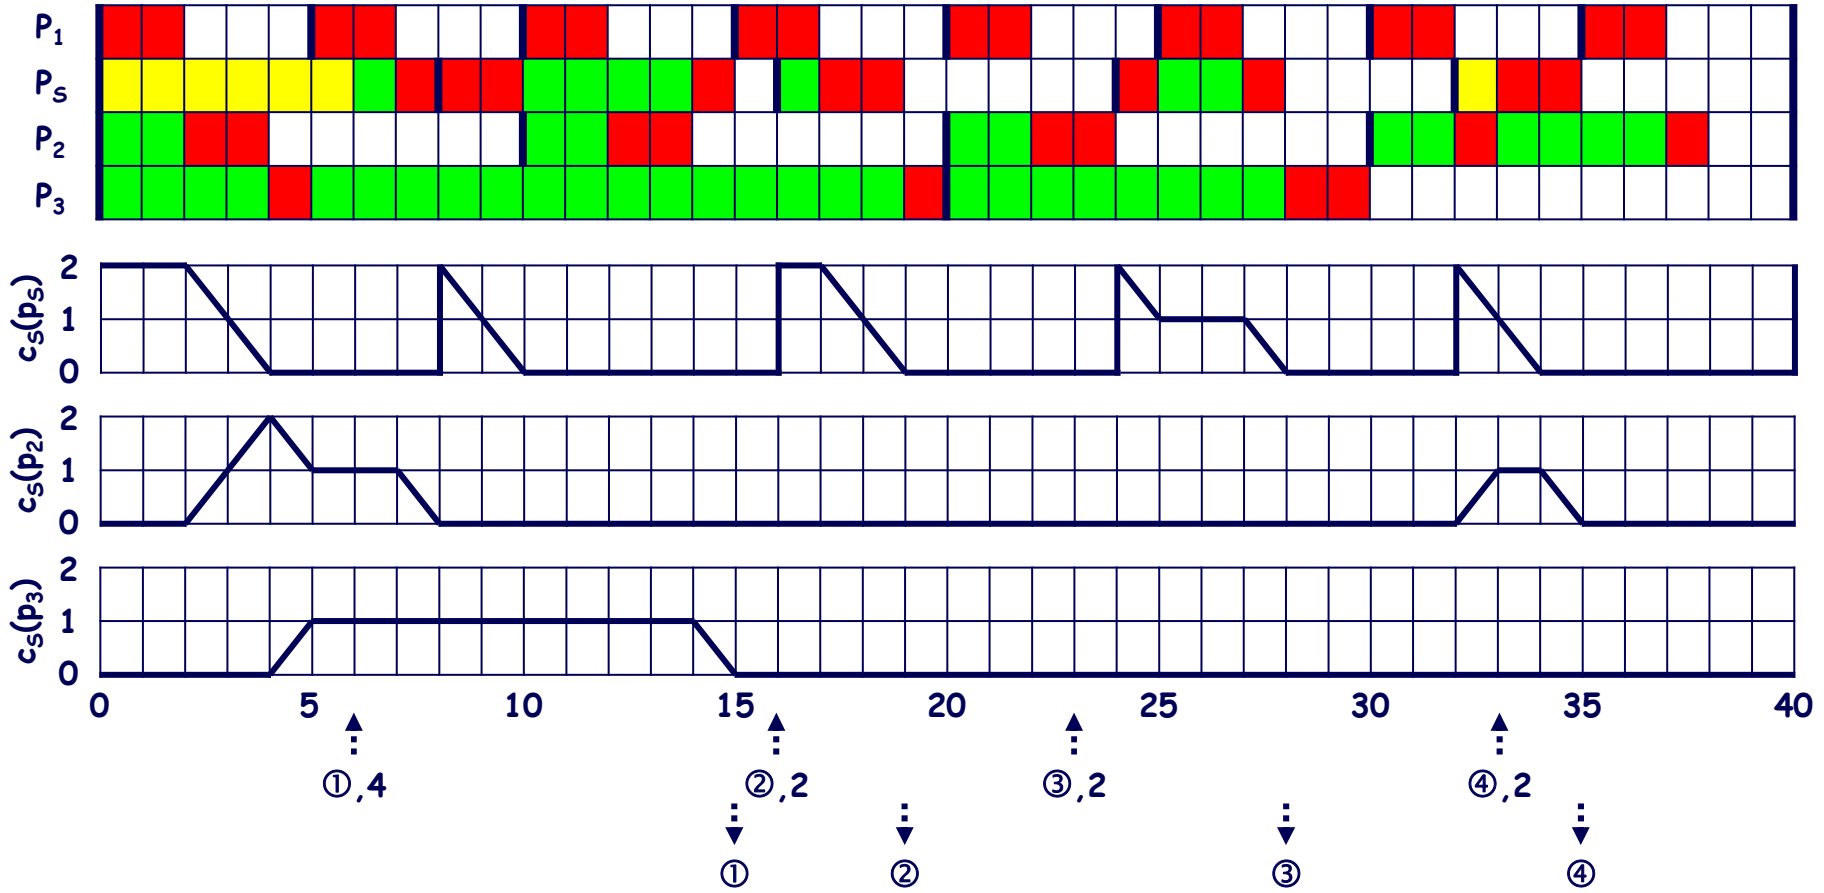

… SERVIZIO TRAMITE PES …

Server a massima priorità:

A_2	C [ms]	T [ms]
P_1	2	8
P_2	2	10
P_3	2	20

P_S : T_S = 5 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	6	3
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	3

Idle
Ready
Running
Waiting

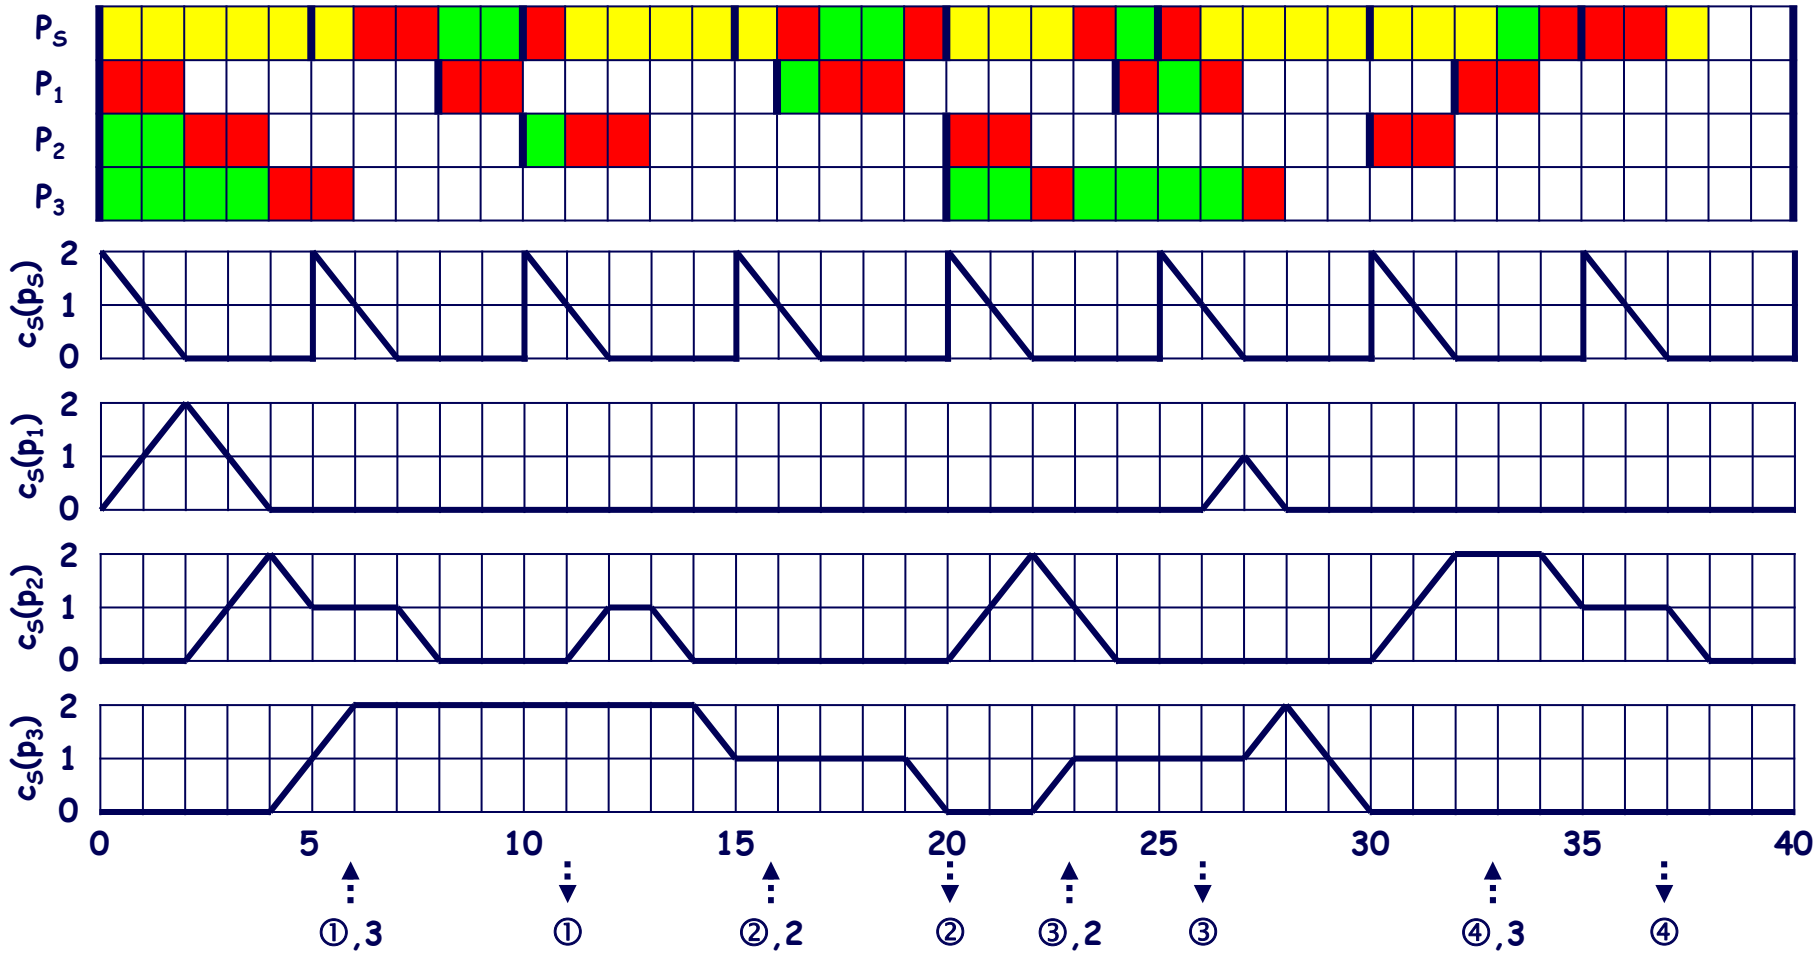

… SERVIZIO TRAMITE PES

Il massimo carico computazionale indotto da PES
è equivalente a quello derivante dall'esecuzione di un processo periodico
con fattore di utilizzazione del processore $U_s = C_s/T_s$.

La schedulabilità di un insieme di N processi periodici
contraddistinti da un fattore di utilizzazione del processore U_p
è pertanto garantita (condizione sufficiente, ma non necessaria) se:

$$U_s \leq (N+1)\left(2^{1/(N+1)}-1\right) - U_p \underset{N\to\infty}{=} \ln 2 - U_p$$

o, nel caso PES abbia massima priorità, se:

$$U_s \leq \frac{2}{\left(1+U_p/N\right)^N} - 1 \underset{N\to\infty}{=} \frac{2}{e^{U_p}} - 1$$

SERVIZIO TRAMITE SPORADIC SERVER (SS) [Sprunt, Sha, Lehoczky (89)] …

Regole di riempimento e di consumo della capacità di P_s

La capacità disponibile è conservata in assenza di richieste aperiodiche pendenti: il servizio può pertanto essere differito (bandwidth-preserving server).

La capacità è progressivamente consumata soltanto durante il servizio di richieste aperiodiche.

La capacità viene reintegrata solo dopo essere stata consumata e nella misura in cui è stata effettivamente utilizzata.

Indicando con t_A l'istante in cui si verifica la condizione $c_S > 0$ e P_S attivo (P_S si dice attivo all'istante t se il processo in esecuzione ha priorità $\geq p(P_S)$), e con t_D il successivo istante in cui si verifica la condizione $c_S = 0$ o P_S non attivo, l'entità RA (replenishment amount) e l'istante RT (replenishment time) del successivo reintegro sono stabiliti come segue:

RA = capacità consumata in $[t_A, t_D]$,

$RT = \max \{t_A + T_S, t_D\}$.

Il comportamento di P_s è (!?) equivalente a quello di una molteplicità di processi periodici aventi tutti lo stesso periodo T_s e tempo di esecuzione uguale complessivamente a C_s.

… SERVIZIO TRAMITE SS …

A_1	C [ms]	T [ms]
P_1	2	5
P_2	2	10
P_3	2	20

P_S : T_S = 8 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	6	4
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	2

Idle

Ready

Running

Waiting

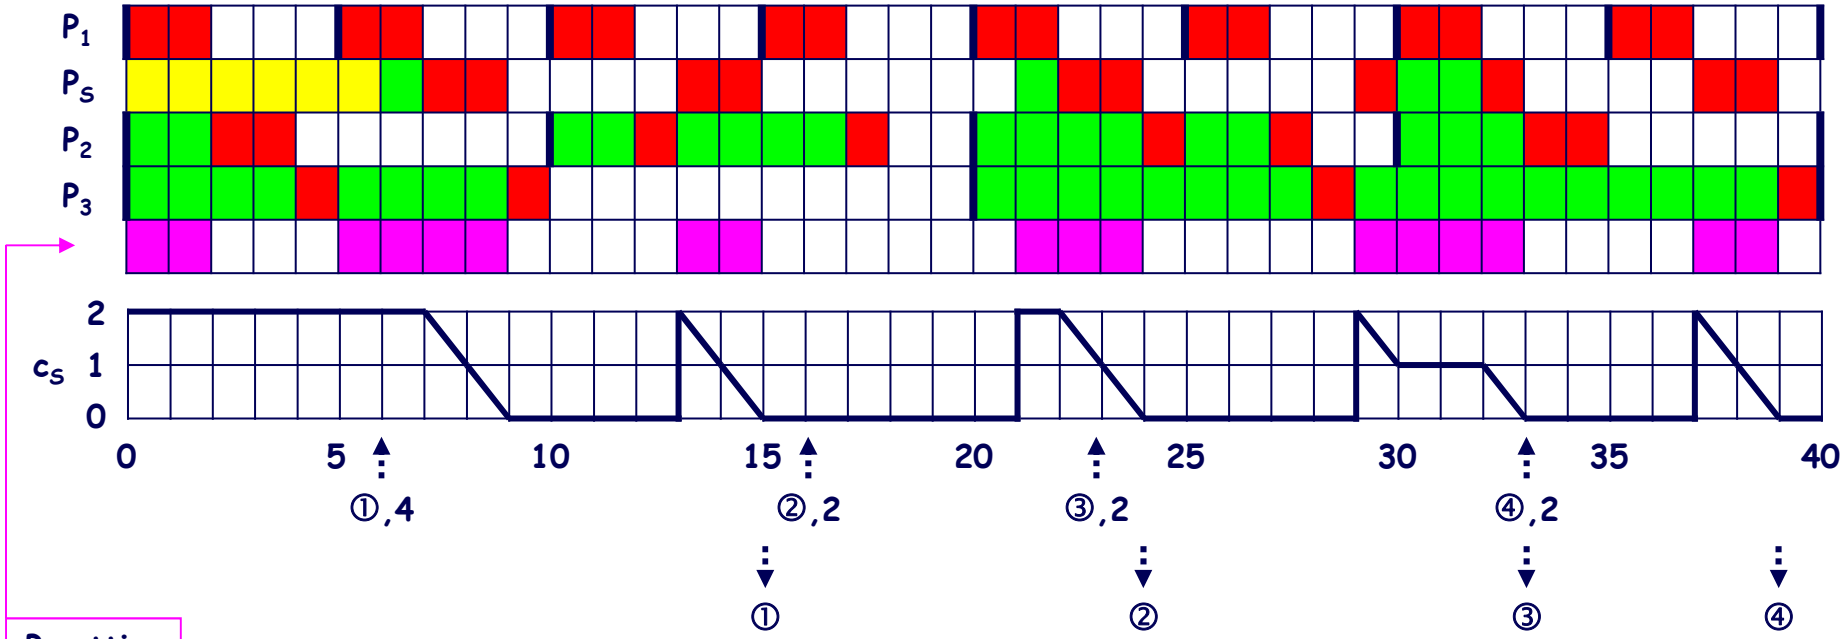

P_S attivo & c_S > 0

t_A	0	5	13	21	29	37
t_D	2	9	15	24	33	39
RA	0	2	2	2	2	2
RT	-	13	21	29	37	45

… SERVIZIO TRAMITE SS …

Server a massima priorità:

A_2	C [ms]	T [ms]
P_1	2	8
P_2	2	10
P_3	2	20

P_S : T_S = 5 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	6	3
R_{a2}	16	2
R_{a3}	23	2
R_{a4}	33	3

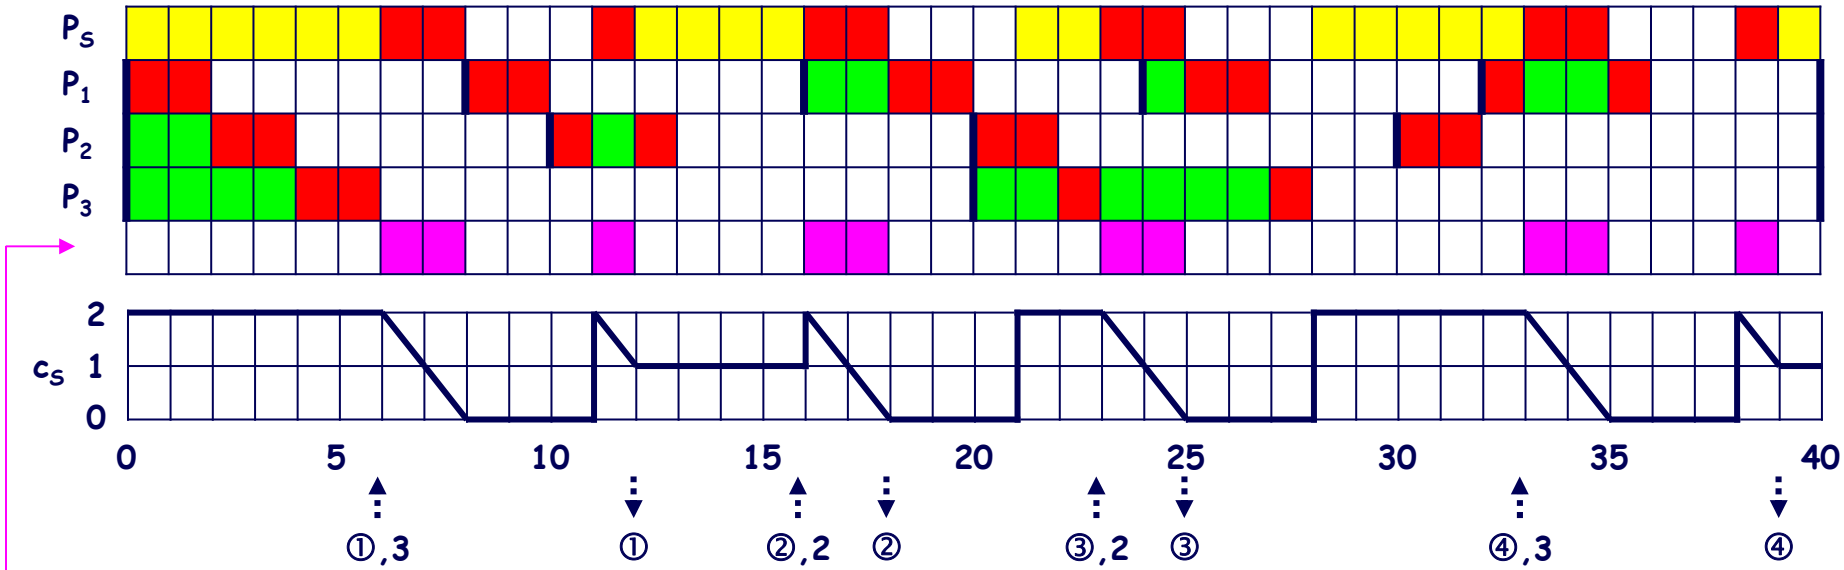

P_S attivo & c_S > 0

t_A	6	11	16	23	33	38
t_D	8	12	18	25	35	39
RA	2	1	2	2	2	1
RT	11	16	21	28	38	43

Idle

Ready

Running

Waiting

… SERVIZIO TRAMITE SS …

A_5	C [ms]	T [ms]
P_1	2	6
P_2	6	16

P_S : T_S = 8 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	0	1
R_{a2}	8	4

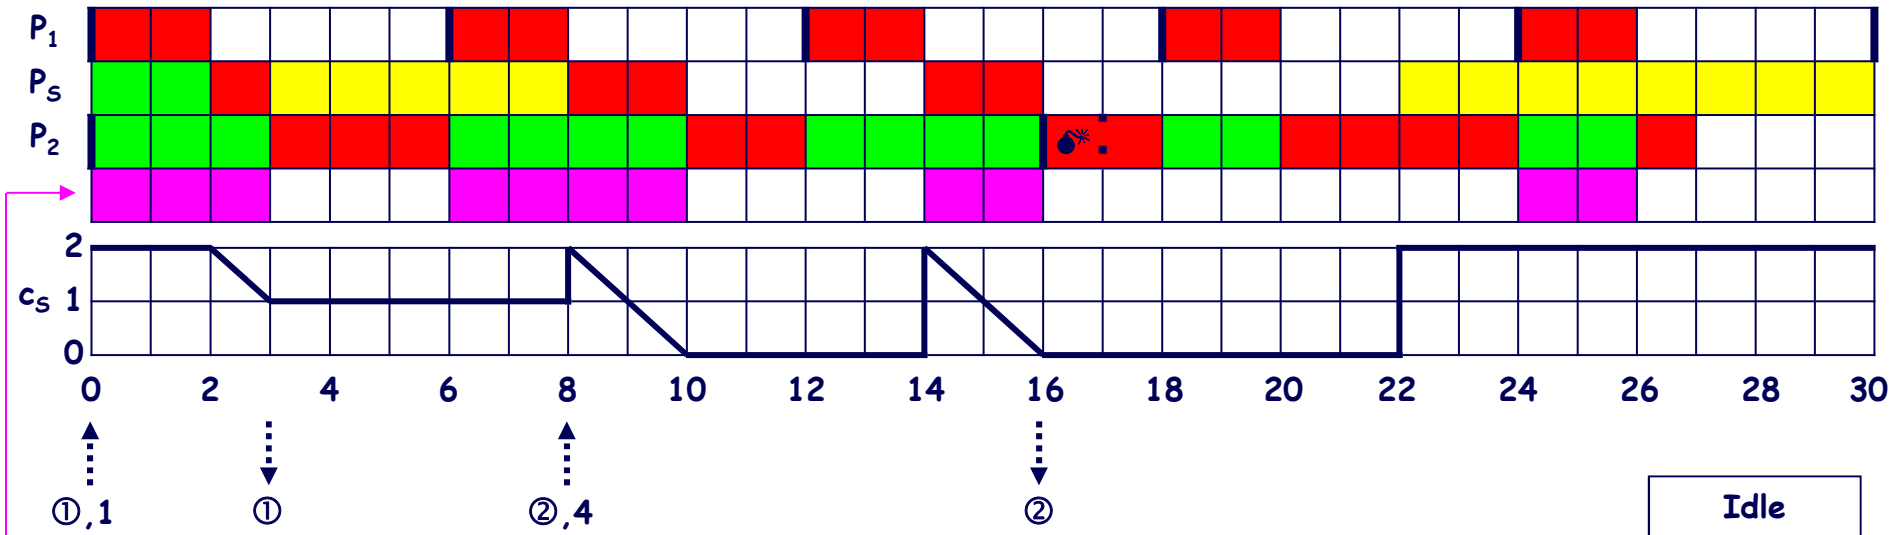

P_S attivo & $c_S > 0$

t_A	0	6	14	24
t_D	3	10	16	26
RA	1	2	2	0
RT	8	14	22	-

Idle

Ready

Running

Waiting

Eppure, se P_s fosse un normale processo periodico, l'insieme dei 3 processi P_1, P_S, P_2 risulterebbe schedulabile.

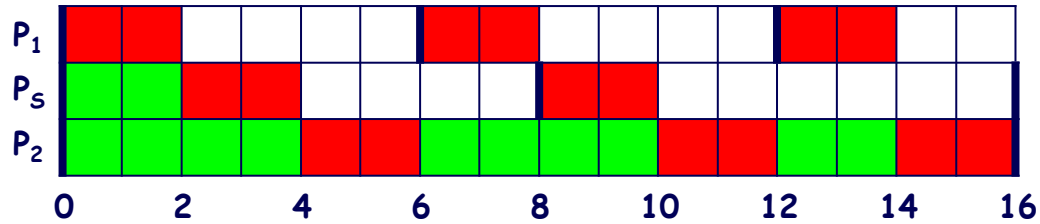

… SERVIZIO TRAMITE SPORADIC SERVER …

… Regole di riempimento e di consumo della capacità di P_s

Quando il carico derivante da richieste aperiodiche è tale da non comportare il totale consumo della capacità disponibile, le distinte porzioni (chunks) di capacità che ne derivano, quella residua non utilizzata e quella consumata ed in seguito reintegrata, devono essere gestite separatamente, tenendo traccia per ciascuna di esse del corrispondente tempo di reintegro RT.

Le regole di reintegro dei singoli chunks, di volta in volta utilizzati per il servizio delle richieste aperiodiche in ordine di RT crescente, sono pertanto generalizzate come segue:

t_E (effective replenishment time) = max {RT, t_A},

RA = capacità consumata in [t_E, t_D],

RT = max {t_E + T_S, t_D}.

Due o più chunks sono consolidati in un unico chunk quando il loro tempo efficace di reintegro t_E coincide.

… SERVIZIO TRAMITE SS …

A_5	C [ms]	T [ms]
P_1	2	6
P_2	6	16

P_S : T_S = 8 ms, C_S = 2 ms

	a [ms]	s [ms]
R_{a1}	0	1
R_{a2}	8	4

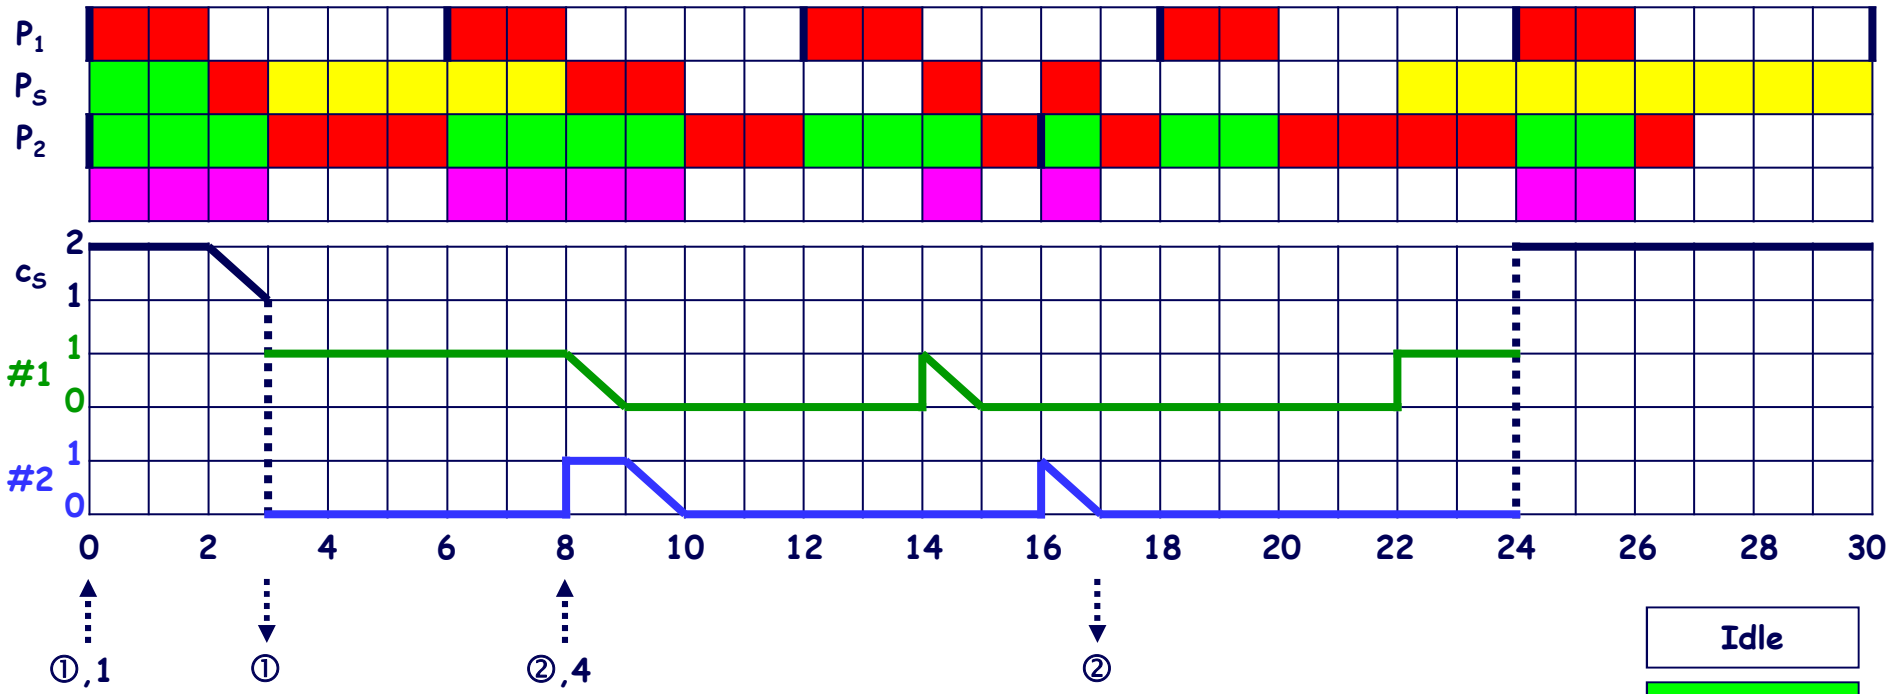

		#1	#2	#1	#2	
t_A	0	6		14	16	24
t_E	0	6	8	14	16	24
t_D	3	10		15	17	26
RA	1	1	1	1	1	0
RT	8	14	16	22	24	-

… SERVIZIO TRAMITE SS

Il massimo carico computazionale indotto da SS
è equivalente a quello derivante da una molteplicità di processi periodici aventi tutti lo stesso periodo T_s e tempo massimo di esecuzione uguale complessivamente a C_s.
Ne deriva che il fattore di utilizzazione del processore da parte di SS è $U_s = C_s/T_s$.

La schedulabilità di un insieme di N processi periodici
contraddistinti da un fattore di utilizzazione del processore U_p
è pertanto garantita (condizione sufficiente, ma non necessaria) se:

$$U_s \le (N+1)\left(2^{1/(N+1)}-1\right) - U_p \underset{N\to\infty}{=} \ln 2 - U_p$$

o, nel caso SS abbia massima priorità, se:

$$U_s \le \frac{2}{\left(1+U_p/N\right)^N} - 1 \underset{N\to\infty}{=} \frac{2}{e^{U_p}} - 1$$

Confronto delle prestazioni: risultati di una simulazione disponibili in rete

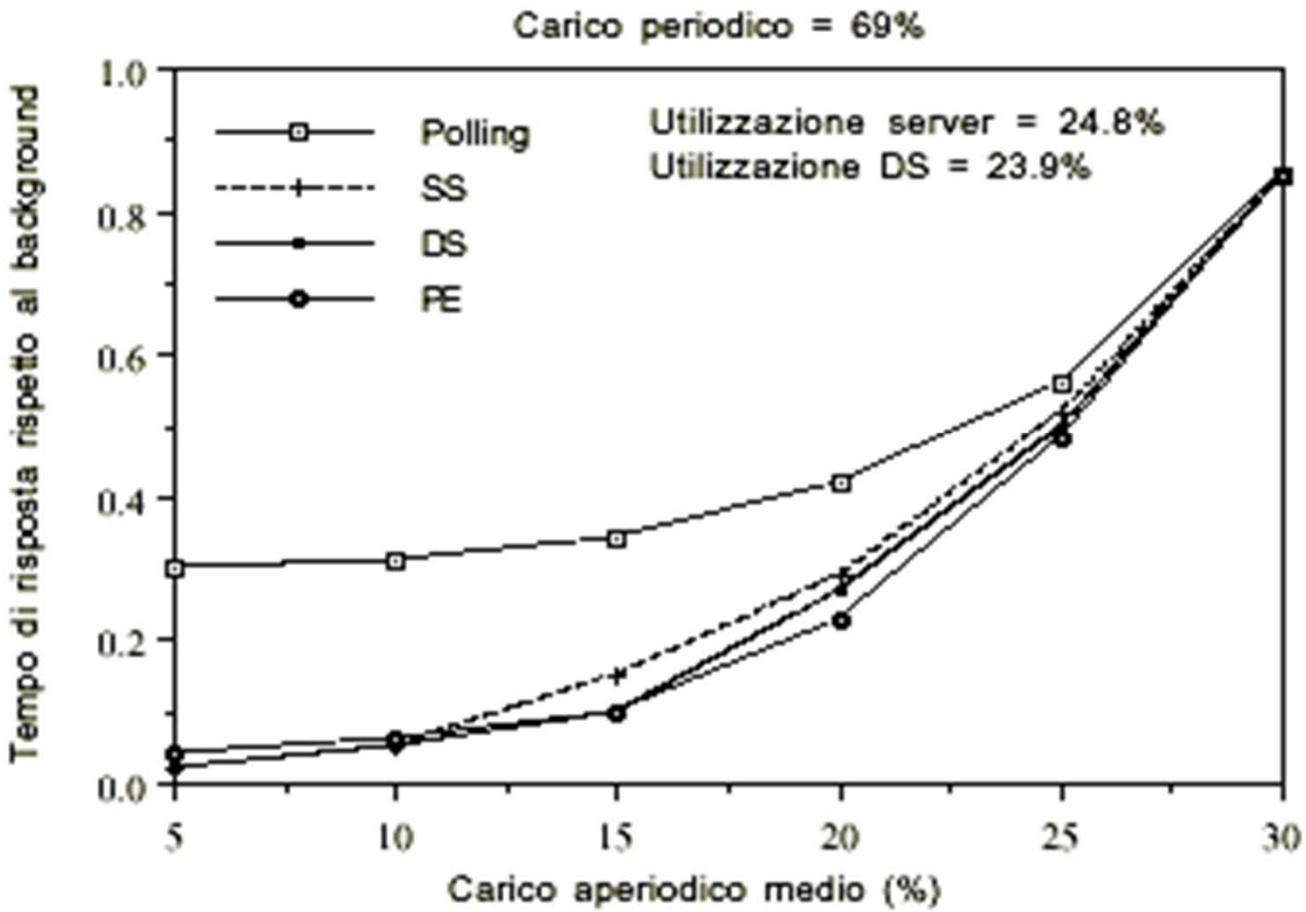

Un confronto delle prestazioni

algoritmo	complessità	prestazioni (tempi di risposta)	schedulabilità processi hard RT
background service			
polling server			
deferrable server			
priority exchange server			
sporadic server			

Lo sporadic server fornisce un buon compromesso
tra prestazioni, schedulabilità e complessità realizzativa.

SERVIZIO TRAMITE SERVER A PRIORITÀ DINAMICA

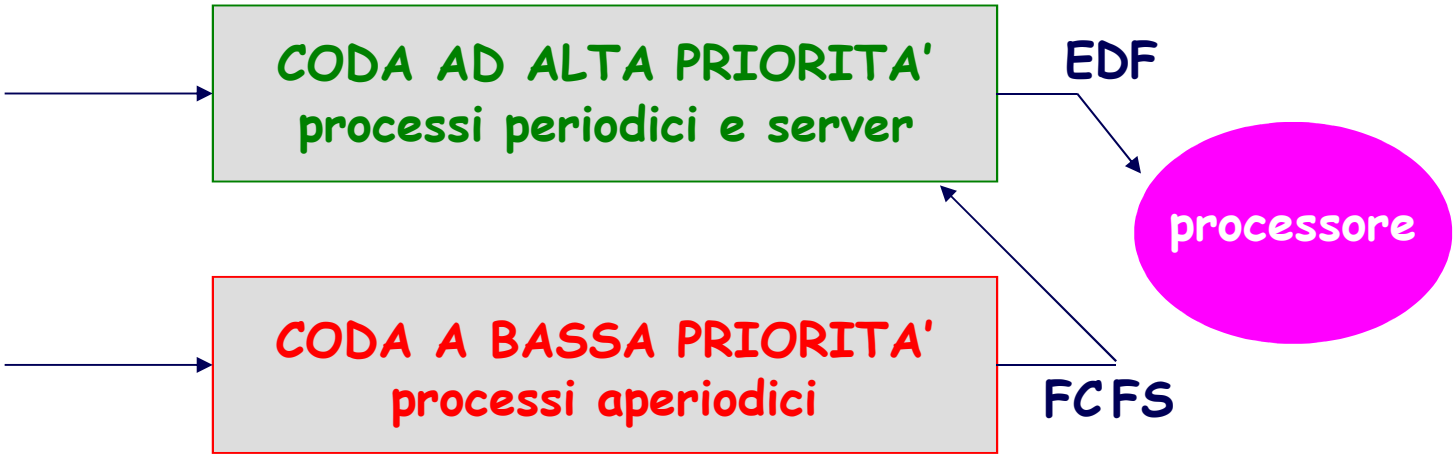

Il server (P_S) viene schedulato secondo la stessa strategia (tipicamente, e nel seguito, EDF) utilizzata per gli altri processi, in accordo alla sua priorità dinamica correlata alla deadline assoluta d_S.

P_S emula un processo sporadico con fattore di utilizzazione scelto in modo tale da non compromettere la schedulabilità dei processi periodici: $U_S \leq 1 - U_p$.

I tempi di risposta dei processi aperiodici, mediamente inferiori rispetto a quelli derivanti dal servizio con server a priorità statica in conseguenza del più elevato valore di U_S selezionabile, dipendono dalle regole, peculiari di ciascuna tipologia di server, secondo cui è operato il riempimento ed il consumo della capacità del server stesso.

SERVIZIO TRAMITE CONSTANT UTILIZATION SERVER (CUS) [Deng, Liu, Sun (97)] ...

Regole di riempimento e di consumo della capacità di P_S

P_S, inizialmente posto nello stato di attesa di richieste aperiodiche,
diviene pronto per l'esecuzione non appena si presenta all'istante t_{Ra} una richiesta.
Inserita la richiesta in testa alla coda, c_S e d_S vengono calcolati come segue:

$$c_S = C_{Ra},\ d_S = t_{Ra} + c_S / U_S,$$

essendo C_{Ra} il tempo di servizio della richiesta.
P_S viene eseguito in accordo alla priorità dinamica correlata alla deadline d_S,
e c_S progressivamente consumata durante l'espletamento del servizio.

Eventuali richieste che si presentano prima di d_S vengono accodate.

Completato il servizio, la richiesta viene rimossa dalla coda
e P_S posto nello stato idle fino all'istante d_S.

All'istante d_S se una o più richieste sono già pendenti,
oppure all'istante di arrivo $t_{Ra} > d_S$ di una nuova richiesta,
viene identificato il tempo di servizio C_{Ra} della richiesta in testa alla coda e, posto

$$c_S = C_{Ra},\ d_S = \max(d_S, t_{Ra}) + c_S / U_S,$$

P_S nuovamente dichiarato pronto per l'esecuzione.

… SERVIZIO TRAMITE CUS

A_6	C [ms]	T [ms]	C/T
P_1	3	6	0.50
P_2	2	8	0.25

P_S : $U_S = 1 - U_p = 0.25$

	a [ms]	s [ms]
R_{a1}	3	1
R_{a2}	9	2
R_{a3}	14	1

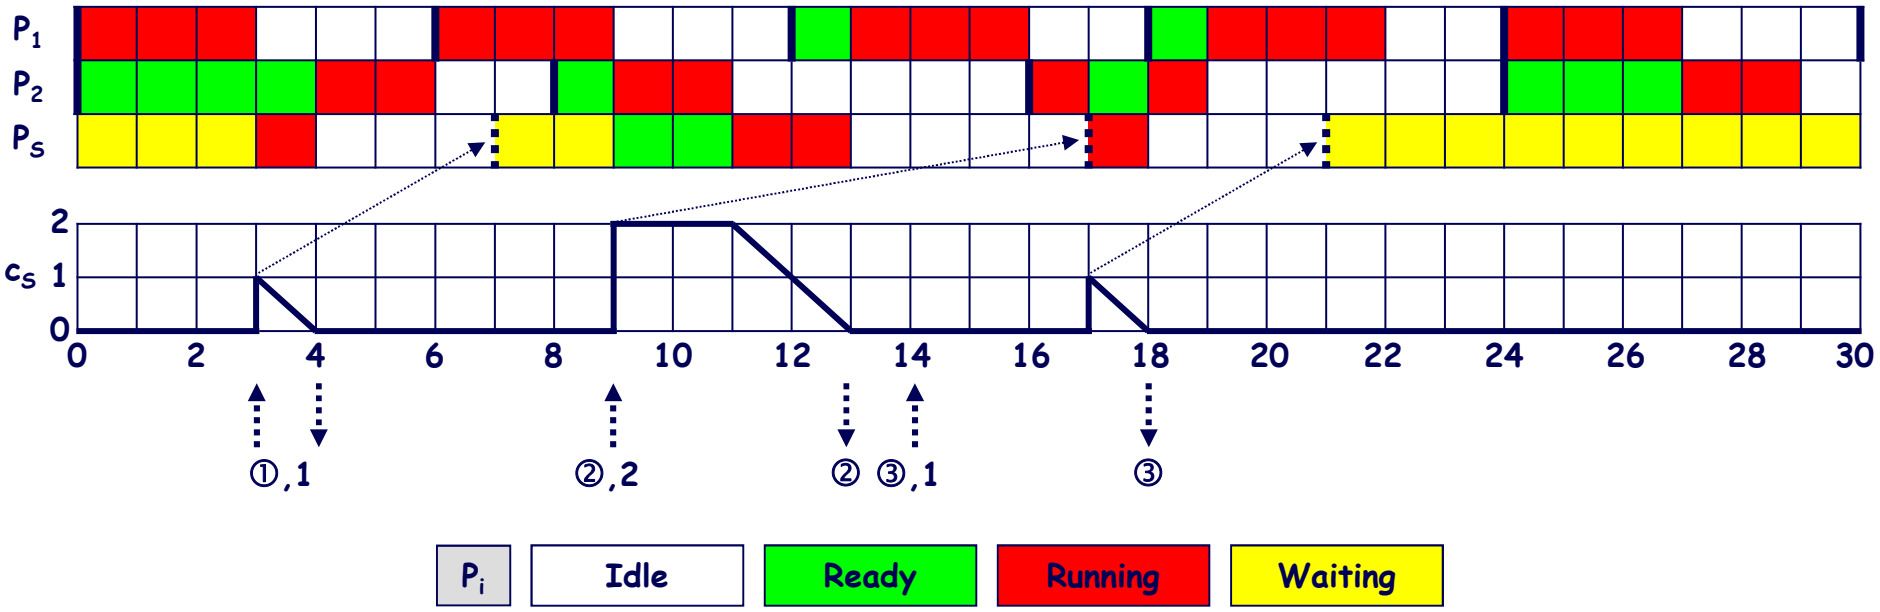

SERVIZIO TRAMITE TOTAL BANDWIDTH SERVER (TBS) [Spuri, Buttazzo (96)] …

Regole di riempimento e di consumo della capacità di P_S

P_S, inizialmente posto nello stato di attesa di richieste aperiodiche, diviene pronto per l'esecuzione non appena si presenta all'istante t_{Ra} una richiesta. Inserita la richiesta in testa alla coda, c_S e d_S vengono calcolati come segue:

$$c_S = C_{Ra},\ d_S = t_{Ra} + c_S / U_S,$$

essendo C_{Ra} il tempo di servizio della richiesta.
P_S viene eseguito in accordo alla priorità dinamica correlata alla deadline d_S, e c_S progressivamente consumata durante l'espletamento del servizio.

Eventuali richieste che si presentano prima del completamento del servizio vengono accodate.

Terminato il servizio, la richiesta viene rimossa dalla coda. Immediatamente se una o più richieste sono già pendenti, oppure all'istante di arrivo t_{Ra} di una nuova richiesta, viene identificato il tempo di servizio C_{Ra} della richiesta in testa alla coda e, posto

$$c_S = C_{Ra},\ d_S = \max(d_S, t_{Ra}) + c_S / U_S,$$

P_S nuovamente dichiarato pronto per l'esecuzione.

… SERVIZIO TRAMITE TBS

A_6	C [ms]	T [ms]	C/T
P_1	3	6	0.50
P_2	2	8	0.25

P_S : $U_S = 1 - U_p = 0.25$

	a [ms]	s [ms]
R_{a1}	3	1
R_{a2}	9	2
R_{a3}	14	1

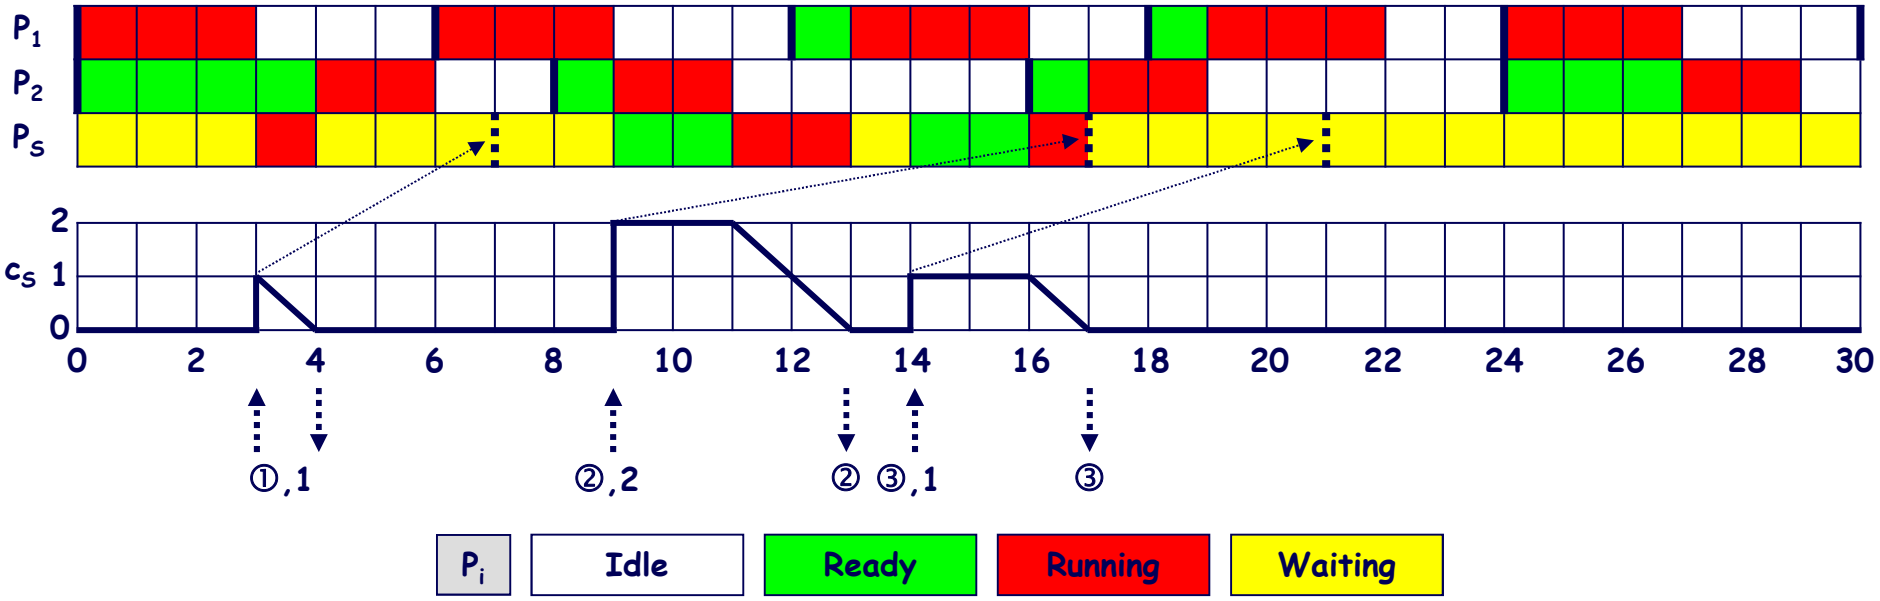

CUS vs. TBS …

A_7	C [ms]	T [ms]
P_1	1	5
P_2	2	10
P_3	8	40

$U_p = 0.6 \rightarrow U_S = 0.4$

	a [ms]	s [ms]
R_{a1}	2	4
R_{a2}	15	2
R_{a3}	22	4
R_{a4}	30	2

d [ms]
2 + 4 / 0.4 = 12
15 + 2 / 0.4 = 20
22 + 4 / 0.4 = 32
32 + 2 / 0.4 = 37

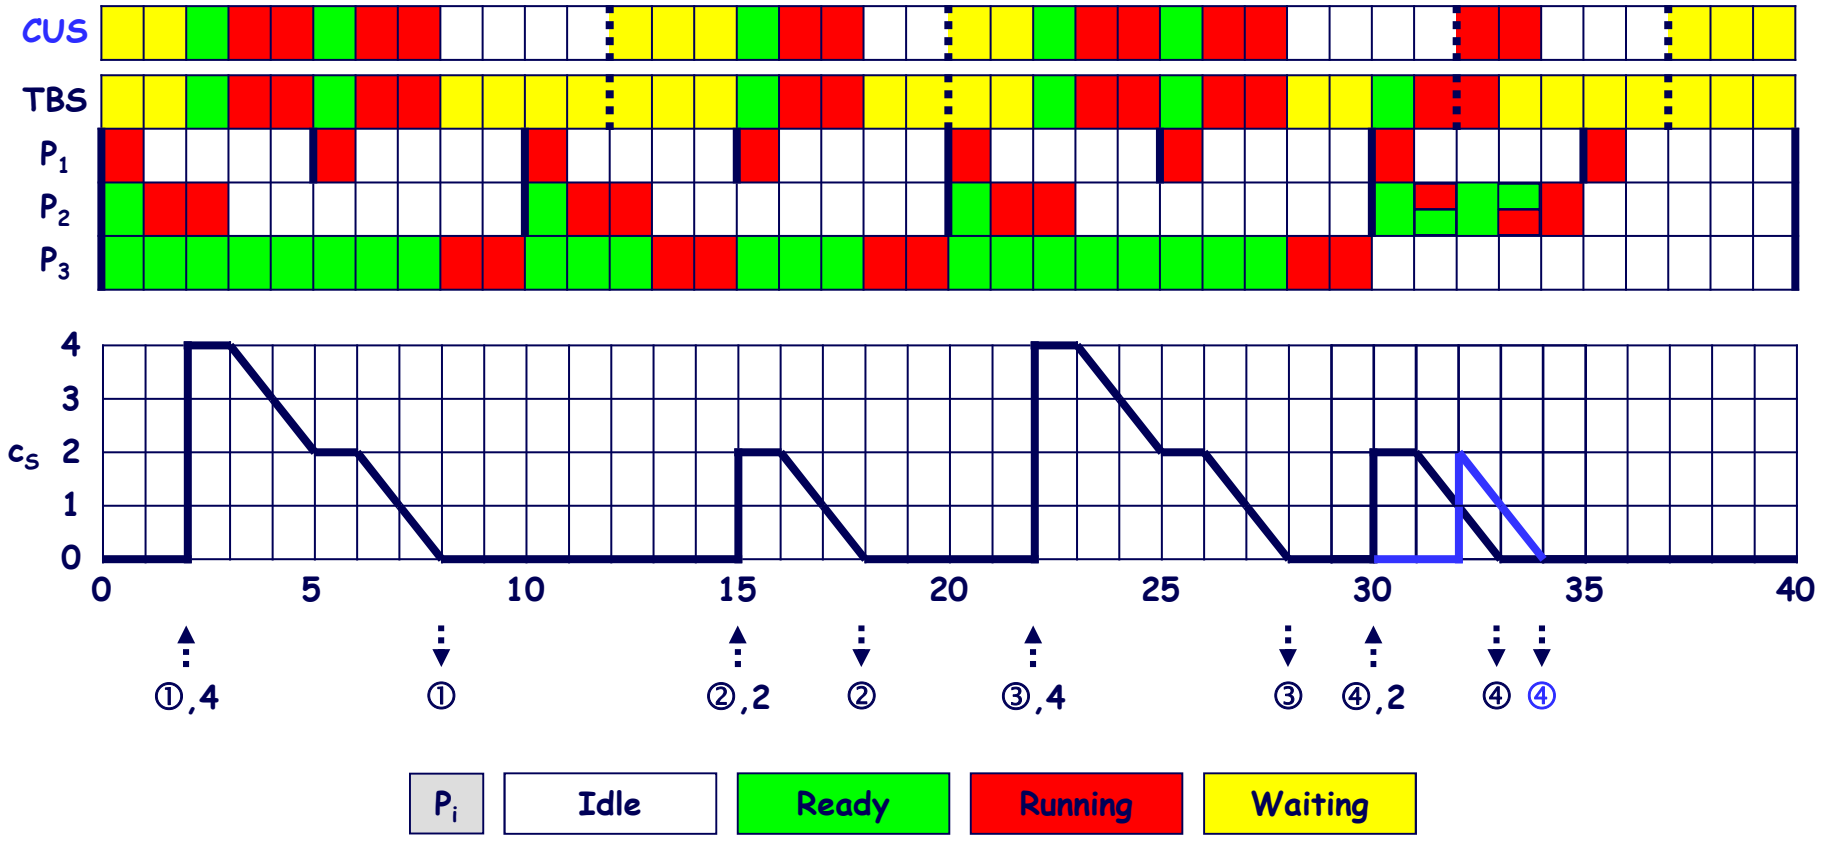

… CUS vs. TBS

A_7	C [ms]	T [ms]
P_1	2	5
P_2	1	10
P_3	4	40

$U_p = 0.6 \rightarrow U_S = 0.4$

	a [ms]	s [ms]
R_{a1}	2	4
R_{a2}	15	2
R_{a3}	22	4
R_{a4}	30	2

d [ms]
2 + 4 / 0.4 = 12
15 + 2 / 0.4 = 20
22 + 4 / 0.4 = 32
32 + 2 / 0.4 = 37

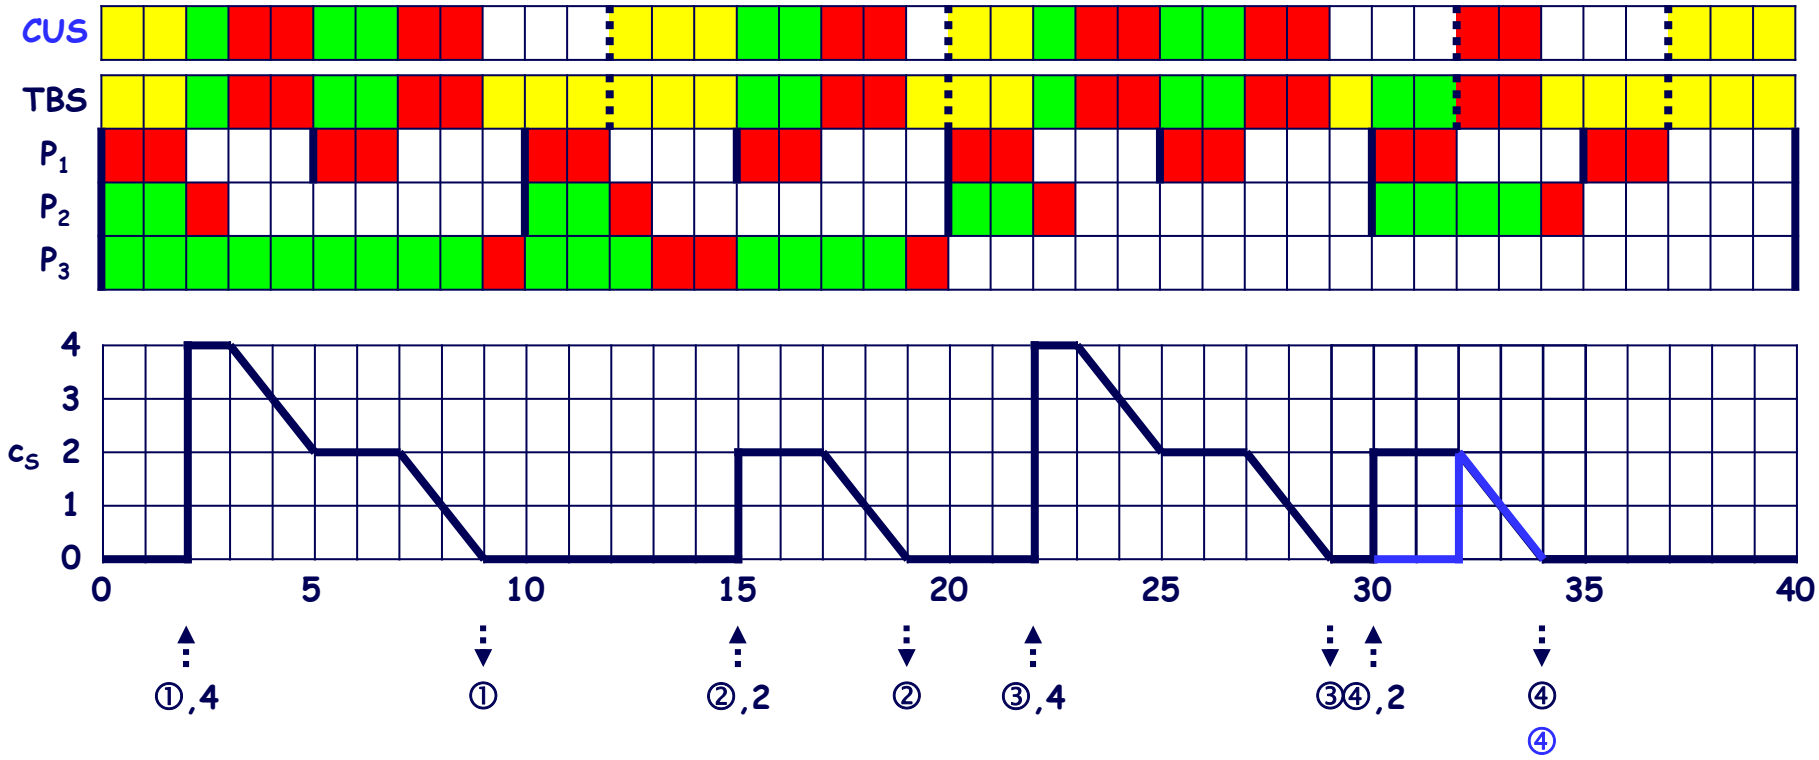

… SERVIZIO TRAMITE CUS O TBS

Se il tempo di servizio C_{Ra} di una richiesta aperiodica non è noto all'istante di arrivo t_{Ra}, si può porre:

$$c_s = C_s,\ d_s = \max(d_s, t_{Ra}) + c_s / U_s,$$

essendo C_s un valore di default per la capacità del server.

Se il servizio non è completato all'istante d_s preventivato, ovvero se $C_{Ra} > C_s$, si ripete contestualmente il riempimento di c_s e si ricalcola d_s come segue:

$$c_s = C_s,\ d_s = d_s + c_s / U_s.$$

In caso contrario, ovvero se $C_{Ra} < C_s$ o, più in generale, se $C_{Ra} < n\ C_s$ ($n = 1, 2, \ldots$), si procede al completamento del servizio a ridimensionare, in base alla capacità residua del server c_s, l'ultimo valore di d_s preventivato, di fatto eccessivo, ponendo:

$$d_s = d_s - c_s / U_s,\ c_s = 0.$$