

## Planificación de tareas

---

Juan Antonio de la Puente  
DIT/UPM

## Objetivos

---

- ◆ Veremos cómo **planificar** el uso de los recursos para poder **garantizar** los **requisitos temporales**
- ◆ Un **método de planificación** tiene dos aspectos importantes:
  - Un **algoritmo de planificación** que determina el orden de acceso de las tareas a los recursos del sistema (en particular al procesador)
  - Un **método de análisis** que permite calcular el **comportamiento temporal** del sistema
    - » Así se puede comprobar si los requisitos temporales están **garantizados** en todos los casos posibles
    - » En general se estudia el **peor comportamiento** posible

## Índice

---

- ◆ **Introducción**
- ◆ Planificación con ejecutivos cíclicos
- ◆ Planificación con prioridades
  - Tareas periódicas independientes
  - Tareas esporádicas y aperiódicas
  - Interacción entre tareas y bloqueos
  - Modelo de tareas generalizado
- ◆ Realización de sistemas con prioridades
- ◆ Otros métodos de planificación

## Planificación de tareas

---

- ◆ Un método de planificación puede ser
  - **estático**: el análisis se puede hacer antes de la ejecución
  - **dinámico**: el análisis se hace durante la ejecución
- ◆ Un método estático muy utilizado es el de **planificación con prioridades fijas y desalojo**
  - La prioridad es un parámetro relacionado con la *urgencia* o la *importancia* de la tarea
  - En cada momento se ejecuta la tarea con mayor prioridad de todas las ejecutables

## Modelo de tareas

---

Inicialmente consideraremos un **modelo simple**:

- El conjunto de tareas es **estático**
- Todas las tareas son **periódicas**
- Las tareas son **independientes** unas de otras
- Los **plazos** de respuesta de todas las tareas son **iguales** a los **períodos** respectivos
- El **tiempo de ejecución máximo** de cada tarea es conocido
- Las operaciones del núcleo de multiprogramación son **instantáneas**

## Parámetros de planificación

---

$N$	Número de tareas
$T$	Período de activación
$C$	Tiempo de ejecución máximo
$D$	Plazo de respuesta
$R$	Tiempo de respuesta máximo
$P$	Prioridad

En el modelo anterior, para todas las tareas  $\tau_i$ :

$$C_i \leq D_i = T_i$$

Se trata de asegurar que

$$R_i \leq D_i$$

## Hiperperíodo

---

- ◆ En el modelo de tareas simple, el valor

$$H = \text{mcm}(T_i)$$

se denomina **hiperperíodo** del sistema

- ◆ El comportamiento temporal se repite cada hiperperíodo

## Índice

---

- ◆ Introducción
- ◆ **Planificación con ejecutivos cíclicos**
- ◆ Planificación con prioridades
  - Tareas periódicas independientes
  - Tareas esporádicas y aperiódicas
  - Interacción entre tareas y bloqueos
  - Modelo de tareas generalizado
- ◆ Realización de sistemas con prioridades
- ◆ Otros métodos de planificación

## Planificación cíclica

- ◆ Si todas las tareas son periódicas, se puede confeccionar un plan de ejecución fijo
- ◆ Se trata de un esquema que se repite cada

$$T_M = \text{mcm}(T_i)$$

(**ciclo principal**)

- ◆ El ciclo principal se divide en **ciclos secundarios**, con período


$$T_s \quad (T_M = k \cdot T_s)$$

- ◆ En cada ciclo secundario se ejecutan las actividades correspondientes a determinadas tareas

## Ejemplo

Tarea	T	C
A	25	10
B	25	8
C	50	5
D	50	4
E	100	2

- El sistema es armónico
- El ciclo principal dura 100ms
- Se compone de 4 ciclos secundarios de 25ms cada uno



## Ejecutivo cíclico

```
procedure Cyclic_Executive is
  type Cycle is mod 4;
  Frame : Cycle := 0;
begin
  loop
    Wait_for_Interrupt;
    case Frame is
      when 0 => A; B; C;
      when 1 => A; B; D; E;
      when 2 => A; B; C;
      when 3 => A; B; D;
    end case;
    Frame := Frame + 1;
  end loop;
end Cyclic_Executive;
```

## Propiedades

- ◆ **No hay concurrencia** en la ejecución
  - Cada ciclo secundario es una secuencia de invocaciones de procedimientos
- ◆ Los procedimientos pueden **compartir datos**
  - No hace falta usar mecanismos de exclusión mutua
- ◆ Los períodos deben ser **armónicos**
  - Puede ser necesario utilizar períodos más cortos de lo necesario
- ◆ **No hace falta analizar** el comportamiento temporal
  - El sistema es correcto por construcción

## Problemas

---

- ◆ Las **tareas esporádicas** son difíciles de tratar
  - Se puede utilizar un *servidor de consulta*
- ◆ El plan cíclico es **difícil de construir**
  - Si los períodos son de diferentes órdenes de magnitud el número de ciclos secundarios se hace muy grande
  - Puede ser necesario partir una tarea en varios procedimientos
  - En el caso más general es NP-duro
- ◆ Es **poco flexible** y difícil de mantener
  - Cada vez que se cambia una tarea hay que rehacer toda la planificación


## Índice

---

- ◆ Introducción
- ◆ Planificación con ejecutivos cíclicos
- ◆ **Planificación con prioridades**
  - **Tareas periódicas independientes**
  - Tareas esporádicas y aperiódicas
  - Interacción entre tareas y bloqueos
  - Modelo de tareas generalizado
- ◆ Realización de sistemas con prioridades
- ◆ Otros métodos de planificación

## Planificación con prioridades fijas

- ◆ Las tareas se realizan como **procesos concurrentes**
- ◆ Una tarea puede estar en varios **estados**
- ◆ Las tareas ejecutables se **despachan** para su ejecución en orden de **prioridad**
- ◆ El despacho puede hacerse
  - **con desalajo**
  - **sin desalajo**
- ◆ En general supondremos **prioridades fijas con desalajo**



## Prioridades monótonas en frecuencia

- ◆ La asignación de mayor prioridad a las tareas de menor período (*rate monotonic scheduling*) es **óptima** para el modelo de tareas simple (tareas periódicas, independientes, con plazos iguales a los períodos)

*Si se pueden garantizar los plazos de un sistema de tareas con otra asignación de prioridades, se pueden garantizar con la asignación monótona en frecuencia*

## Factor de utilización

- ◆ La cantidad

$$U = \sum_{i=1}^N \frac{C_i}{T_i}$$

es el *factor de utilización del procesador*

- ◆ Es una medida de la carga del procesador para un conjunto de tareas
- ◆ En un sistema monoprocesador debe ser

$$U \leq 1$$

## Condición de garantía de los plazos basada en la utilización

- ◆ Para el modelo simple, con prioridades monótonas en frecuencia, los plazos están garantizados si

$$U = \sum_{i=1}^N \frac{C_i}{T_i} \leq N \cdot (2^{1/N} - 1)$$

- ◆ La cantidad

$$U_0(N) = N \cdot (2^{1/N} - 1)$$

es la **utilización mínima garantizada** para N tareas

## Utilización mínima garantizada

N	U0
1	1,000
2	0,828
3	0,779
4	0,756
5	0,743


$$\lim_{n \rightarrow \infty} U_0(N) = \log 2 \approx 0,693$$

## Ejemplo 1

Tarea	T	C	P	U
$\tau_1$	30	10	3	0,333
$\tau_2$	40	10	2	0,250
$\tau_3$	50	12	1	0,240
				<b>0,823</b>

El sistema no cumple la prueba de utilización  
( $U > 0,779$ )

La tarea 3 falla en  $t = 50$




## Instante crítico

- ◆ El cronograma se puede utilizar para comprobar si se cumplen los plazos
  - Hay que trazar el cronograma durante un hiperperíodo completo
  - En el caso más desfavorable,  $H = O(N^M)$
- ◆ El tiempo de respuesta es máximo cuando todas las tareas se activan a la vez  
Se denomina **instante crítico**
- ◆ Si el instante inicial es crítico basta comprobar el **primer ciclo** de cada tarea

## Ejemplo 2

Tarea	T	C	P	U
$\tau_1$	16	4	3	0,250
$\tau_2$	40	5	2	0,125
$\tau_3$	80	32	1	0,400
				<b>0,775</b>


Este sistema está garantizado  
( $U < 0,779$ )



## Ejemplo 3

Tarea	T	C	P	U
$\tau_1$	20	5	3	0,250
$\tau_2$	40	10	2	0,250
$\tau_3$	80	40	1	0,500
				<b>1,000</b>

Este sistema no pasa la prueba ( $U > 0,779$ ), pero se cumplen los plazos



©1997-2000 Juan Antonio de la Puente

22


## Análisis del tiempo de respuesta

- ◆ La prueba del factor de utilización no es exacta, ni se puede generalizar a modelos de tareas más complejos
- ◆ La construcción de un cronograma es compleja, incluso considerando que el instante inicial es crítico
- ◆ Veremos una prueba basada en el cálculo del tiempo de respuesta de cada tarea

©1997-2000 Juan Antonio de la Puente

23


## Ecuación del tiempo de respuesta



$$R_i = C_i + I_i$$

El tiempo de respuesta de una tarea es la suma de su tiempo de cómputo más la interferencia que sufre por la ejecución de tareas más prioritarias

## Cálculo de la interferencia máxima



Para una tarea de prioridad superior

$$I_i^j = \left\lceil \frac{R_i}{T_j} \right\rceil \cdot C_j$$

Para todas las tareas de prioridad superior

$$I_i = \sum_{j \in hp(i)} \left\lceil \frac{R_i}{T_j} \right\rceil \cdot C_j$$

## Cálculo del tiempo de respuesta

La ecuación del tiempo de respuesta queda así:

$$R_i = C_i + \sum_{j \in hp(i)} \left\lceil \frac{R_j}{T_j} \right\rceil \cdot C_j$$

$R_i$  es la solución mínima de la ecuación

$$w = C_i + \sum_{j \in hp(i)} \left\lceil \frac{w}{T_j} \right\rceil \cdot C_j$$

- ◆ La ecuación no es continua ni lineal
- ◆ No se puede resolver analíticamente

## Iteración lineal

La ecuación del tiempo de respuesta se puede resolver mediante la relación de recurrencia

$$w_i^{n+1} = C_i + \sum_{j \in hp(i)} \left\lceil \frac{w_j^n}{T_j} \right\rceil \cdot C_j$$

Un valor inicial aceptable es

$$w_i^0 = C_i + \sum_{j \in hp(i)} C_j$$

Se termina cuando

- $w_i^{n+1} = w_i^n$ , o bien
- $w_i^{n+1} > T_i$  (no se cumple el plazo)

## Ejemplo 4

Tarea	T	C	P	R
$\tau_1$	7	3	3	3
$\tau_2$	12	3	2	6
$\tau_3$	20	5	1	20

$$\begin{aligned}\tau_1: w_1^0 &= 3; \\ \tau_2: w_2^0 &= 3 + 3 = 6; \\ w_2^1 &= 3 + \left\lceil \frac{6}{7} \right\rceil \cdot 3 = 6\end{aligned}$$

$$\tau_3: w_3^0 = 5 + 3 + 3 = 11;$$

$$w_3^1 = 5 + \left\lceil \frac{11}{7} \right\rceil \cdot 3 + \left\lceil \frac{11}{12} \right\rceil \cdot 3 = 14;$$

$$w_3^2 = 5 + \left\lceil \frac{14}{7} \right\rceil \cdot 3 + \left\lceil \frac{14}{12} \right\rceil \cdot 3 = 17;$$

$$w_3^3 = 5 + \left\lceil \frac{17}{7} \right\rceil \cdot 3 + \left\lceil \frac{17}{12} \right\rceil \cdot 3 = 20;$$

$$w_3^4 = 5 + \left\lceil \frac{20}{7} \right\rceil \cdot 3 + \left\lceil \frac{20}{12} \right\rceil \cdot 3 = 20$$

Todas las tareas tienen sus plazos garantizados  
Tenemos una condición **suficiente** y **necesaria**

## Tiempo de cómputo

Hay dos formas de obtener el valor de C para una tarea:

◆ **Medida del tiempo de ejecución**

- no es fácil saber cuándo se mide el tiempo máximo

◆ **Análisis del código ejecutable**

- » se descompone el código en un grafo de bloques secuenciales
- » se calcula el tiempo de ejecución de cada bloque
- » se busca el camino más largo
- la estimación de C puede ser muy pesimista
- es difícil tener en cuenta los efectos de los dispositivos de hardware (*caches*, *pipelines*, etc..)
- se puede mejorar con análisis estático

## Restricciones en el código

---

- ◆ Para poder calcular el tiempo de cómputo hay que evitar utilizar estructuras con tiempo de cómputo no acotado, como:
  - bucles no acotados
  - recursión no acotada
  - objetos dinámicos
  - tareas dinámicas

## Índice

---

- ◆ Introducción
- ◆ Planificación con ejecutivos cíclicos
- ◆ **Planificación con prioridades**
  - Modelo de tareas básico
  - **Tareas esporádicas y aperiódicas**
  - Interacción entre tareas y bloqueos
  - Modelo de tareas generalizado
- ◆ Realización de sistemas con prioridades
- ◆ Otros métodos de planificación

## Tareas aperiódicas

---

- ◆ Las tareas aperiódicas pueden ser
  - **críticas (*hard*)** o **esporádicas**
    - » tienen un plazo de respuesta crítico (no puede fallar)
    - » se caracterizan por una separación mínima entre dos sucesos de activación consecutivos
  - **acríticas (*soft*)**
    - » pueden responder tarde ocasionalmente
    - » se caracterizan por un esquema de activación estocástico (por ejemplo, Poisson)
- ◆ Deben garantizarse
  - los plazos de todas las tareas en condiciones “normales”
  - los plazos de las tareas críticas en las peores condiciones

## Tareas esporádicas

---

- ◆ Para incluir tareas esporádicas hace falta modificar el modelo simple de tareas:
  - El parámetro ***T*** representa la **separación** mínima entre dos sucesos de activación consecutivos
  - Suponemos que en el peor caso la activación es pseudoperiódica (con período *T*)
  - El plazo de respuesta puede ser menor que el período ( $D \leq T$ )
- ◆ El análisis de tiempo de respuesta sigue siendo válido
- ◆ Funciona bien con cualquier orden de prioridad

## Prioridades monótonas en plazos

Cuando los plazos son menores o iguales que los períodos, la asignación de mayor prioridad a las tareas de menor plazo de respuesta (*deadline monotonic scheduling*) es **óptima**

- ◆ El tiempo de respuesta se calcula de la misma forma que con la asignación monótona en frecuencia
  - se termina cuando  $w_i^{n+1} = w_i^n$ ,
  - o cuando  $w_i^{n+1} > D_i$

## Ejemplo 5

Tarea	T	D	C	P	R
$\tau_1$	20	5	3	4	3
$\tau_2$	15	7	3	3	6
$\tau_3$	10	10	4	2	10
$\tau_4$	20	20	3	1	20

Con prioridades monótonas en frecuencia los plazos no están garantizados:

Tarea	T	D	C	P	R
$\tau_3$	10	10	4	4	4
$\tau_2$	15	7	3	3	7
$\tau_1$	20	5	3	2	10
$\tau_4$	20	20	3	1	20

## Índice

---


- ◆ Introducción
- ◆ Planificación con ejecutivos cíclicos
- ◆ **Planificación con prioridades**
  - Modelo de tareas básico
  - Tareas esporádicas y aperiódicas
  - **Interacción entre tareas y bloqueos**
  - Modelo de tareas generalizado
- ◆ Realización de sistemas con prioridades
- ◆ Otros métodos de planificación

## Interacción entre tareas

---

- ◆ En la mayoría de los sistemas de interés práctico las tareas interaccionan mediante
  - datos comunes (protegidos)
  - citas o mensajes
- ◆ En todos estos casos puede ocurrir que una tarea tenga que esperar un suceso de otra menos prioritaria
- ◆ Esta situación se denomina **bloqueo**, y produce una **inversión de prioridad** indeseable
- ◆ La inversión de prioridad no se puede eliminar completamente, pero es posible limitar su duración


## Ejemplo 6



Tarea	P	ta	Acciones
$\tau_1$	4	4	a1; ax; ay; a2
$\tau_2$	3	2	b1; by; b2
$\tau_3$	2	2	c1
$\tau_4$	1	0	d1; dx; d2

Acción	P	C	usa
a1	4	2	
ax	4	1	X
ay	4	1	Y
a2	4	1	
b1	3	1	
by	3	2	Y
b2	3	1	
c1	2	2	
d1	1	1	
dx	1	4	X
d2	1	1	


## Ejemplo 6 : inversión de prioridad



## Herencia de prioridad

- ◆ Una forma de reducir la duración de los bloqueos es variar dinámicamente la prioridad de las tareas
- ◆ Cuando una tarea está bloqueando a otra más prioritaria, **hereda** la prioridad de ésta
- ◆ La prioridad dinámica de una tarea es el máximo de
  - su prioridad básica
  - las prioridades de todas las tareas bloqueadas por ella
- ◆ La herencia de prioridad es **transitiva**

## Ejemplo 6 : herencia de prioridad



## Duración máxima del bloqueo

- ◆ Con el protocolo de herencia de prioridad, una tarea se puede bloquear como máximo
  - una vez por cada recurso
  - una vez por cada tarea de prioridad inferior
- ◆ La duración total máxima de los bloqueos es

$$B_i = \sum_{j \in p(i), k} C_{j,k}$$

donde

- $K$  es el número de recursos compartidos
- $C_{j,k}$  es el tiempo durante el cual la tarea  $j$  accede al recurso  $k$  ( $= 0$  si no usa el recurso)

## Ejemplo 6 : cálculo del bloqueo

$$B_1 = C_{2,Y} + C_{4,X} = 2 + 4 = 6$$

$$B_2 = C_{4,X} = 4$$

$$B_3 = C_{4,X} = 4$$

$$B_4 = 0$$

- Una tarea puede bloquearse por recursos a los que no accede (por ejemplo,  $\tau_2$ )
- Una tarea puede sufrir bloqueo aunque no acceda a recursos compartidos (por ejemplo,  $\tau_3$ )
- La tarea de menor prioridad ( $\tau_4$ ) no sufre bloqueo

## Tiempo de respuesta con bloqueos

- ◆ Cuando hay bloqueos, la ecuación del tiempo de respuesta queda así:

$$R_i = C_i + B_i + \sum_{j \in hp(i)} \left\lceil \frac{R_j}{T_j} \right\rceil \cdot C_j$$


La solución se obtiene mediante la relación de recurrencia

$$w_i^{n+1} = C_i + B_i + \sum_{j \in hp(i)} \left\lceil \frac{w_j^n}{T_j} \right\rceil \cdot C_j$$

## Protocolos de techo de prioridad

- ◆ El **techo de prioridad** de un recurso es la máxima prioridad de las tareas que lo usan
- ◆ El **protocolo del techo de prioridad** consiste en :
  - la prioridad dinámica de una tarea es el máximo de su prioridad básica y las prioridades de las tareas a las que bloquea
  - una tarea sólo puede usar un recurso si su prioridad dinámica es mayor que el techo de todos los recursos en uso por otras tareas

## Ejemplo 6 : techo de prioridad



## Propiedades

- ◆ Cuando se usa el protocolo del techo de prioridad en un sistema monoprocesador,
  - Cada tarea se puede bloquear una vez, como máximo, en cada ciclo
  - No puede haber interbloqueos
  - No puede haber bloqueos encadenados
  - Se consigue la exclusión mutua sin mecanismos de protección adicionales
- ◆ La duración máxima del bloqueo es ahora


$$B_i = \max_{j \in lp(i), k \in lc(i)} C_{j,k}$$

$lc(i)$  es el conjunto de recursos que pueden bloquear  $i$

## Protocolo del techo de prioridad inmediato

- ◆ Con este protocolo, una tarea que accede a un recurso hereda inmediatamente el techo de prioridad del recurso
  - la prioridad dinámica de una tarea es el máximo de su prioridad básica y los techos de prioridad de los recursos que usa
- ◆ Las propiedades son las mismas que las del protocolo del techo de prioridad, y además,
  - si una tarea se bloquea, lo hace al principio del ciclo
- ◆ Es más fácil de implementar que el protocolo básico
- ◆ Es más eficiente (menos cambios de contexto)

## Ejemplo 6 : techo de prioridad inmediato



## Índice

---

- ◆ Introducción
- ◆ Planificación con ejecutivos cíclicos
- ◆ **Planificación con prioridades**
  - Modelo de tareas básico
  - Tareas esporádicas y aperiódicas
  - Interacción entre tareas y bloqueos
  - **Modelo de tareas generalizado**
- ◆ Realización de sistemas con prioridades
- ◆ Otros métodos de planificación

## Modelo de tareas generalizado

---

- ◆ El modelo de tareas básico que hemos visto incluye
  - tareas periódicas y esporádicas
  - plazos menores o iguales que los períodos
  - interacción mediante secciones críticas
- ◆ El análisis del tiempo de respuesta se puede extender con
  - planificación cooperativa
  - variación (*jitter*) en el esquema de activación
  - plazos arbitrarios (también mayores que los períodos)

## Planificación cooperativa

---

- ◆ Es un método de despacho más eficiente que el desalojo inmediato
  - Las tareas se pueden bloquear por acceso al núcleo
  - Con el protocolo del techo de prioridad inmediato los bloqueos no se acumulan
  - Si  $B_{MAX}$  es el bloqueo máximo por recursos, se divide el código de las tareas en **bloques no desalojables** de duración  $B_{MAX}$
  - Al final de cada bloque se ofrece un cambio de contexto (si hay alguna tarea más prioritaria)
  - Las secciones críticas se meten dentro de un solo bloque

## Ventajas

---

- ◆ Ventajas
  - Mejora la planificabilidad
  - Se pueden reducir los tiempos de cómputo
  - Los tiempos de cómputo de los bloques son más fáciles de calcular
- ◆ Problemas
  - el coste de ofrecer un cambio de contexto puede ser alto (e innecesario)

## Análisis del tiempo de respuesta


- ◆ El último bloque de una tarea no puede sufrir interferencia
- ◆ La ecuación queda así:

$$w_i^{n+1} = B_{MAX} + C_i - F_i + \sum_{j \in hp(i)} \left\lceil \frac{w_i^n}{T_j} \right\rceil \cdot C_j$$
$$R_i = w_i^n + F_i, \text{ para } w_i^{n+1} = w_i^n$$

donde  $F_i$  es el tiempo de cómputo del último bloque

## Activación irregular

- ◆ Puede haber variaciones en los esquemas de activación periódicos y esporádicos
- ◆ Por ejemplo, sea una tarea esporádica activada por un suceso producido por una tarea periódica situada en otro procesador



## Tareas esporádicas con jitter

- ◆ La variación en los instantes de activación con respecto al esquema ideal se denomina *jitter*
- ◆ El tiempo de respuesta de la tarea  $i$  se obtiene con

$$w_i^{n+1} = C_i + B_i + \sum_{j \in hp(i)} \left\lceil \frac{w_i^n + J_j}{T_j} \right\rceil \cdot C_j$$
$$R_i = w_i^n, \text{ para } w_i^{n+1} = w_i^n$$

donde  $J_j$  es el *jitter* máximo de la tarea  $j$

## Tareas periódicas con jitter

- ◆ Las tareas periódicas no suelen tener *jitter*
- ◆ Puede haberlo si la planificación se hace con una granularidad apreciable
- ◆ El tiempo de respuesta se calcula con

$$w_i^{n+1} = C_i + B_i + \sum_{j \in hp(i)} \left\lceil \frac{w_i^n + J_j}{T_j} \right\rceil \cdot C_j$$
$$R_i = w_i^n + J_i, \text{ para } w_i^{n+1} = w_i^n$$

## Plazos arbitrarios

- ◆ Si el plazo es mayor que el período, puede haber varias activaciones pendientes en un ciclo
- ◆ Para analizar esta situación construimos una sucesión de **ventanas**  $w_i(q)$ , donde  $q + 1$  es el número de activaciones de  $\tau_i$ .
- ◆ Para cada ventana se obtiene un valor de  $R_i$  con

$$w_i^{n+1}(q) = (q + 1) \cdot C_i + B_i + \sum_{j \in hp(i)} \left\lceil \frac{w_i^n(q)}{T_j} \right\rceil \cdot C_j$$
$$R_i(q) = w_i^n(q) - q \cdot T_i$$

## Tiempo de respuesta máximo

- ◆ Se calcula  $R_i(q)$  para  $q = 0, 1, \dots, q_{max}$ , donde  $q_{max}$  es el menor valor que cumple

$$R_i(q_{max}) \leq T_i$$

En esta situación ya no hay solape con la siguiente activación

- ◆ El tiempo de respuesta en el peor caso es

$$R_i = \max_{q=0 \dots q_{max}} R_i(q)$$

## Caso general

- ◆ Si consideramos plazos arbitrarios y *jitter*, el tiempo de respuesta se obtiene con

$$w_i^{n+1}(q) = (q + 1) \cdot C_i + B_i + \sum_{j \in hp(i)} \left\lceil \frac{w_j^n(q) + J_j}{T_j} \right\rceil \cdot C_j$$
$$R_i(q) = w_i^n(q) - q \cdot T_i + J_i$$

## Asignación de prioridades

- ◆ Con el modelo general que hemos, la ordenación de prioridades monótona en frecuencia (RMS) o en plazos **no es óptima**
- ◆ Se aplica el siguiente **teorema**:

*Si una tarea  $\tau$  cumple su plazo con la prioridad más baja del sistema, y existe un orden de prioridades admisible para todo el sistema, entonces hay un orden de prioridades que garantiza todas las tareas en el cual  $\tau$  tiene la prioridad más baja*

## Algoritmo

```
procedure Assign_Priority (System: in out Task_Set;
                          N      :      Natural;
                          OK     :      out Boolean) is
begin
  for k in 1 .. N loop
    for next in k ..N loop
      Swap (System, k, next);
      Test (System, k, OK);
      exit when OK;
    end loop;
    exit when not OK; -- no hay ninguna tarea garantizada
  end loop;
end Assign_Priority;
```

System(1) tiene la prioridad mínima y System(N) la máxima

Test comprueba el plazo de la tarea System (k)

## Índice

- ◆ Introducción
- ◆ Planificación con ejecutivos cíclicos
- ◆ Planificación con prioridades
  - Modelo de tareas básico
  - Tareas esporádicas y aperiódicas
  - Interacción entre tareas y bloqueos
  - Modelo de tareas generalizado
- ◆ **Realización de sistemas con prioridades**
- ◆ Otros métodos de planificación

## Planificación de tareas en Ada

- ◆ En el anexo de tiempo real se define un modelo de planificación con prioridades y desalojo
- ◆ La prioridad de una tarea es de un subtipo definido en el paquete *System*

```
subtype Any_Priority is Integer range intervalo;  
subtype Priority is Any_Priority  
  range Any_Priority'First .. valor;  
subtype Interrupt_Priority is Any_Priority  
  range Priority'Last + 1 .. Any_Priority'Last;
```

- ◆ Los valores mayores denotan prioridades más altas

## Prioridad básica

- ◆ La prioridad básica de una tarea o un tipo tarea se especifica con un pragma *Priority*

```
task Controller is  
  pragma Priority (10);  
end Controller;
```

```
task type Server (Task_Priority : System.Priority) is  
  entry Service_1 (...);  
  ...  
  pragma Priority (Task_Priority);  
end Server;
```

## Techo de prioridad inmediato

- ◆ Se puede usar el protocolo del techo de prioridad inmediato para acceder a los objetos protegidos
- ◆ Hay que poner un pragma

```
pragma Locking_Policy (Ceiling_Locking);
```

- ◆ El techo de prioridad de un objeto o un tipo protegido se especifica mediante un pragma *Priority*

```
protected type Resource(Ceiling : System.Priority) is
  ...
  pragma Priority (Ceiling);
end Resource;
```

## Prioridad activa

- ◆ La prioridad activa de una tarea es el máximo de su prioridad básica y la prioridad heredada de otras
- ◆ Una tarea puede heredar prioridad de varias formas :
  - cuando ejecuta una operación protegida hereda el techo de prioridad del objeto
  - cuando ejecuta una instrucción *accept* hereda la prioridad de la tarea que llama al punto de entrada
  - durante su activación hereda la prioridad de su progenitor

## Protocolo de despacho

- ◆ Se puede especificar un protocolo de despacho mediante un pragma:

```
pragma Task_Dispatching_Policy (FIFO_within_Priority);
```

- ◆ Hay una cola conceptual por cada nivel de prioridad
- ◆ El núcleo de ejecución despacha la primera tarea de la cola de mayor prioridad que no esté vacía
- ◆ Cuando una tarea se activa se coloca al final de la cola correspondiente a su prioridad activa
- ◆ Las tareas desalojadas se colocan al principio de su cola

## Otros mecanismos de planificación

- ◆ Prioridades dinámicas (que se pueden cambiar por el programa)
- ◆ Colas ordenadas por prioridades en puntos de entrada

```
pragma Queuing_Policy (Priority_Queueing);
```

- ◆ Identificadores y atributos de tareas
- ◆ Control síncrono y asíncrono de tareas
- ◆ Aborto inmediato
- ◆ Restricciones para facilitar el análisis de tiempos
- ◆ Requisitos sobre documentación de tiempos

## Planificación en POSIX

- ◆ POSIX.1b define un modelo de planificación con prioridades y desalojo
- ◆ Se puede especificar el protocolo de despacho *FIFO* (como en Ada)
- ◆ Se puede especificar que todos los *threads* de un sistema se planifiquen globalmente (*system contention*)
- ◆ La prioridad básica de una tarea se puede cambiar dinámicamente

## Ámbito de planificación

- ◆ El ámbito de la planificación se define con

```
#include <pthread.h>
int pthread_attr_setscope (pthread_attr_t *attr,
                          int contentionscope);
```

- ◆ También hay que especificar si los atributos de planificación son específicos de cada *thread*:

```
int pthread_attr_setinheritsched (
    pthread_attr_t *attr,
    int inheritsched);
```

- ◆ Normalmente se pone
  - PTHREAD\_SCOPE\_SYSTEM para *contentionscope*
  - PTHREAD\_EXPLICIT\_SCHED para *inheritsched*

## Política de planificación

- ◆ La política de planificación dentro del mismo nivel de prioridad se define con

```
int pthread_attr_setschedpolicy (  
    pthread_attr_t *attr,  
    int policy);
```

- ◆ El parámetro *policy* puede ser
  - SCHED\_FIFO (orden de llegada)
  - SCHED\_RR (turno circular con rodajas de tiempo)
  - SCHED\_OTHER (dependiente de la implementación)

En general, hay que poner SCHED\_FIFO

## Prioridades

- ◆ La prioridad de un *thread* es un parámetro de planificación:

```
#include <sched.h>  
  
struct sched_param {  
    int sched_priority;  
    ...  
}
```

y se especifica con

```
int pthread_attr_setschedparam (  
    const pthread_attr_t *attr,  
    const struct sched_param *param);
```

Los atributos se usan para crear el *thread*

## Protocolo de acceso a *mutex*

---

- ◆ Se puede especificar un protocolo de acceso con

```
#include <pthread.h>

int pthread_mutexattr_setprotocol (
    pthread_mutexattr_t *attr,
    int *protocol);
```

El protocolo puede ser

- PTHREAD\_PRIO\_INHERIT (herencia de prioridad)
- PTHREAD\_PRIO\_PROTECT (techo de prioridad inmediato)
- PTHREAD\_PRIO\_NONE (no hay herencia de prioridad)

## Techo de prioridad

---

- ◆ Se especifica con

```
int pthread_mutexattr_setprioceiling (
    pthread_mutexattr_t *attr,
    int prioceiling);
```

Los atributos se usan para iniciar el *mutex*

## Índice

---

- ◆ Introducción
- ◆ Planificación con ejecutivos cíclicos
- ◆ Planificación con prioridades
  - Modelo de tareas básico
  - Tareas esporádicas y aperiódicas
  - Interacción entre tareas y bloqueos
  - Modelo de tareas generalizado
- ◆ Realización de sistemas con prioridades
- ◆ **Otros métodos de planificación**

## Otros métodos de planificación

---

- ◆ Se pueden conseguir mejores resultados realizando la planificación **dinámicamente** en función de los requisitos temporales y de los recursos disponibles
- ◆ Dos métodos dinámicos interesantes son:
  - **Primero el más urgente** (*earliest deadline first, EDS*)
  - **Primero el menos holgado** (*least slack first, LSF*)
- ◆ Ambos son óptimos para tareas independientes
  - se garantizan los plazos hasta el 100% de utilización
  - se comportan bien cuando hay muchas tareas esporádicas
- ◆ Problemas:
  - el comportamiento en caso de sobrecarga es imprevisible
  - no está bien resuelta la interacción entre tareas

## Resumen

---

- ◆ Un método de planificación tiene dos partes:
  - un **algoritmo de reparto** de recursos
  - un **método de análisis** del comportamiento temporal
- ◆ El método clásico se basa en un **ejecutivo cíclico**
  - el análisis es inmediato (por construcción)
  - es poco flexible y de bajo nivel
- ◆ Un método mejor se basa en el uso de **prioridades fijas**
  - las prioridades se asignan por orden de períodos, plazos o de forma arbitraria
  - se puede analizar el tiempo de respuesta de las tareas
  - se pueden analizar tareas con interacción si se usa un protocolo de herencia o techo de prioridad