



# SE206: Modélisation, génération de code et vérification

## *Analyse de temps de réponse*

Etienne Borde

[etienne.borde@telecom-paristech.fr](mailto:etienne.borde@telecom-paristech.fr)

# Objectifs du cours

- Comprendre les objectifs et hypothèses d'une analyse de temps de réponse, ainsi qu'un type de modèle associé
- Savoir calculer le temps de réponse d'une tâche selon la technique d'analyse dite « RTA », pour une classe d'algorithmes d'ordonnancement très classiques (FPS, RMS)
- Connaître les limitations de cette technique

# Remarques sur ce cours

- On ne verra qu'un petit sous-ensemble des techniques d'analyse temporelle des systèmes embarqué.
  - ⌘ Une seule classe d'algorithme d'ordonnancement
  - ⌘ Un seul test d'ordonnancement
  - ⌘ Une seule politique de protection des données
- Des UEs de 3<sup>ème</sup> année (notamment SE301) permettent d'aller plus loin.
- Le but est d'introduire UNE technique d'analyse avant de l'utiliser sur des modèles d'architecture...



## Plan du cours

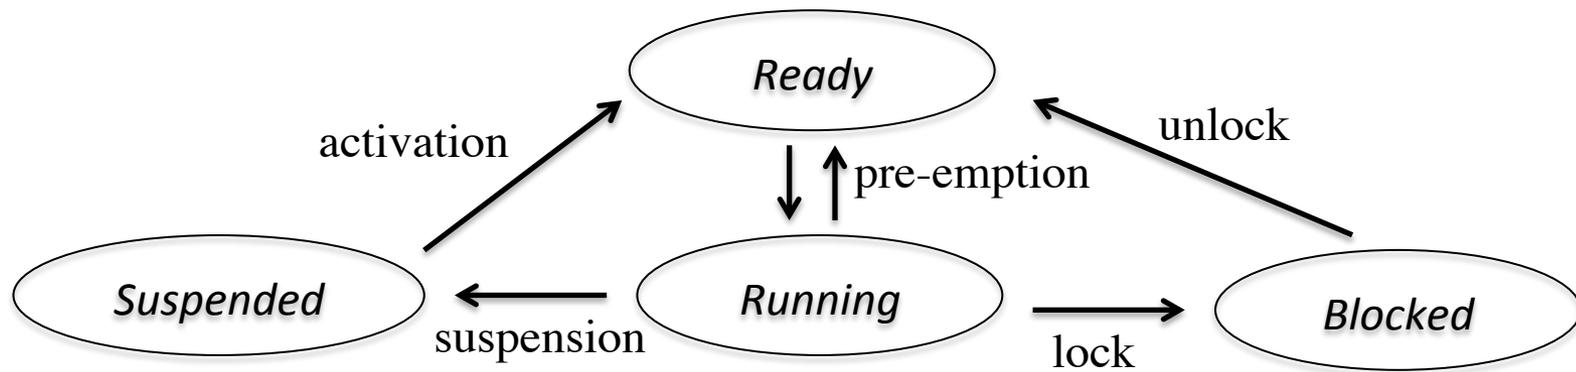
1. Présentation du modèle de tâches
2. Formule de calcul du pire temps de réponse
3. Prise en compte du temps de blocage (verrous pour données partagée)



## Modèle de tâche et d'ordonnancement

# Les états d'une tâche

- On considère un système dans lequel un seul processus est constitué de N tâches (ou *threads*)
- Une tâche a quatre états:



## Remarques:

- les état « Bloqué » et « Suspendue » sont très similaires, et auraient pu être confondus. On distingue cependant ces deux états pour identifier
  - ⌘ le cas où la tâche a fini son exécution et attend la prochaine activation (*suspended*)
  - ⌘ le cas où la tâche est bloquée sur une entrée/sortie (*blocked*) mais n'a pas fini son exécution.
- Le seul cas de blocage considéré dans ce cours correspond à l'usage de verrous
- Les tâches *ready* sont répertoriés dans une « *ready queue* »: une ou plusieurs files d'attente.

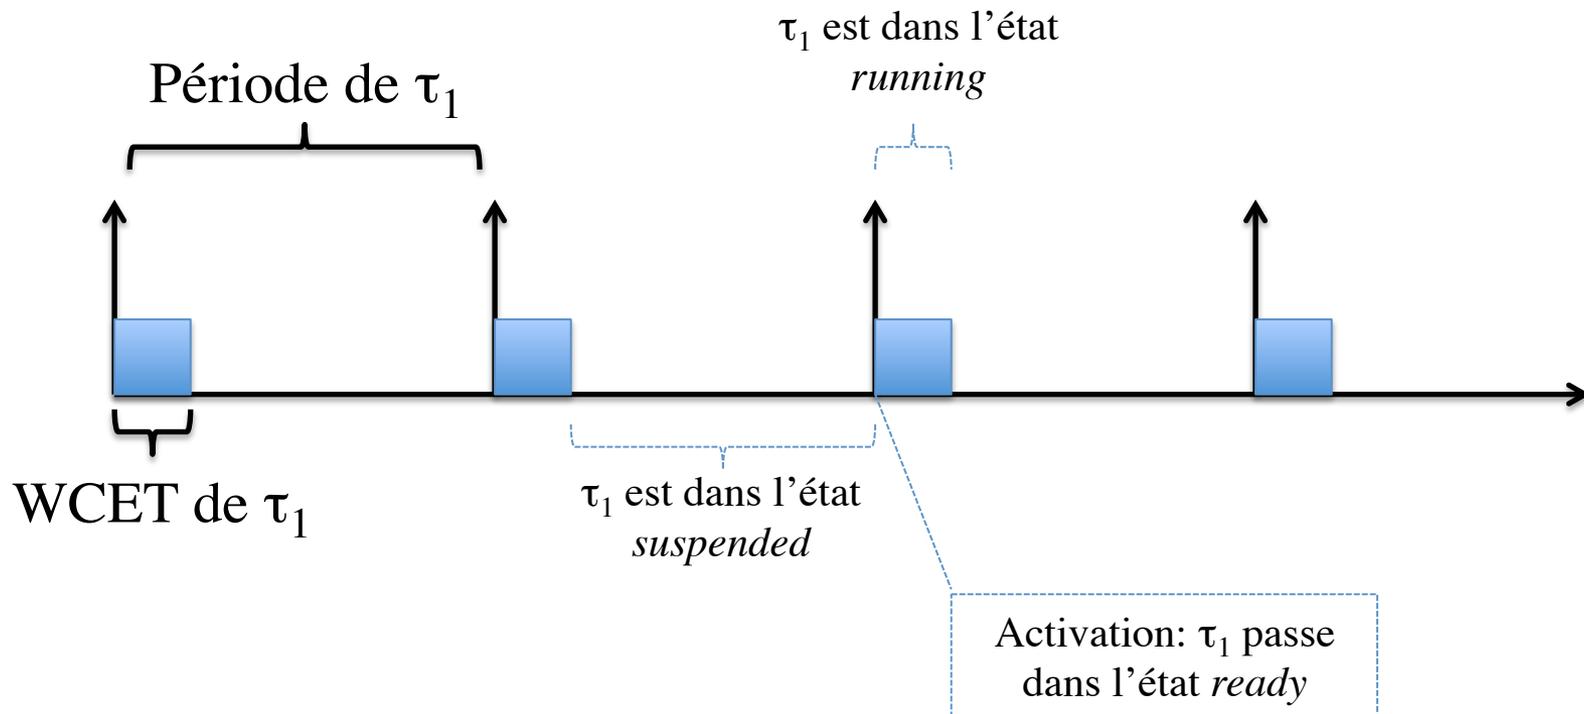


# Modèle de tâches

- Une tâche  $\tau$  est:
  - ⌘ Périodique:  $\tau$  est activée avec un délais constant entre deux activation. Cela permet de traiter l'activation de tâches récurrentes, comme les tâches de contrôle/commande (exemple du segway vu en introduction).
  - ⌘ Sporadique:  $\tau$  est activée avec un délais minimal entre deux activation. Cela permet de traiter des évènements rares tout en partageant l'accès à la ressource de calcul (exemple, détection d'obstacles).
- Un système temps réel est composé d'un ensemble de  $N$  tâches  $\{\tau_i\}_{0 < i \leq N}$ , caractérisés par:
  - ⌘  $T_i$  : période, ou intervalle de temps entre deux réveils de  $\tau_i$
  - ⌘  $C_i$  : pire temps d'exécution (WCET) de  $\tau_i$  isolée des autres tâche, et ininterrompue.
  - ⌘  $D_i$  : échéance de  $\tau_i$
- On suppose que toutes le tâches commencent leur exécution à la même date théorique  $t=0$  unité de temps
- On néglige le temps de changement de contexte

# Exemple (très simple!) de représentation classique d'un modèle de tâche

Tâche	Période	WCET	Deadline
$\tau_1$	10 ms	2 ms	6 ms



# Ordonnancement

- Ordonnanceur = composant logiciel qui choisit, à certains moments, quelle tâche est exécutée par le processeur
- Algorithme d'ordonnancement = algorithme qu'utilise l'ordonnanceur pour le choix.
- Test d'ordonnancement = formule qui, pour un algorithme d'ordonnancement et un ensemble de tâches, donne une condition nécessaire et/ou suffisante pour garantir que les contraintes temporelles seront satisfaites.

# Algorithmes d'ordonnement

- Dans ce cours, nous nous limitons à deux algorithmes d'ordonnement, préemptifs, à priorité fixe:

- ⌘ FPS (*Fixed Priority Scheduling*): en plus des caractéristiques mentionnées ci-dessus, une tâche  $\tau_i$  se voit attribué un niveau de priorité  $P_i$  (représenté par un entier en général).
- ⌘ RMS (*Rate Monotonic Scheduling*): dérivé de FPS, les priorités sont fixées en fonction de la période des tâches. Plus la période est petite, plus la priorité est élevée. Plus formellement,  $T_i < T_j \Leftrightarrow P_i > P_j$

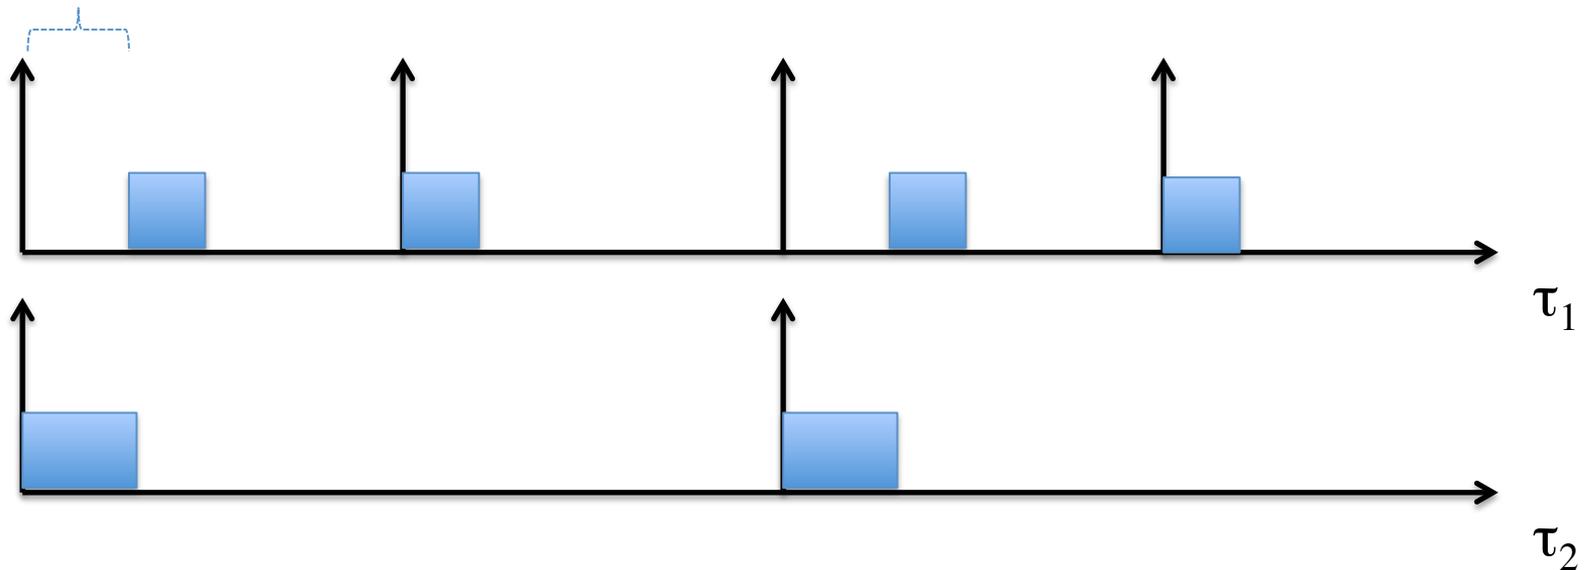
- Effet de la pré-emption:

- ⌘ lorsqu'une tâche passe de l'état *blocked/suspended* à *ready*, si cette tâche est la plus prioritaire elle passe dans l'état *running*. Si cela se produit alors qu'une autre tâche s'exécutait, cette dernière passe dans l'état *ready* et attend d'être choisie par l'ordonnanceur.
- ⌘ Lorsqu'une tâche passe de l'état *running* à *blocked/suspended*, l'ordonnanceur consulte la ready queue, et si elle n'est pas vide il choisit la tâche la plus prioritaire. Cette dernière passe dans l'état *running* et s'exécute.

# Exemple FPS

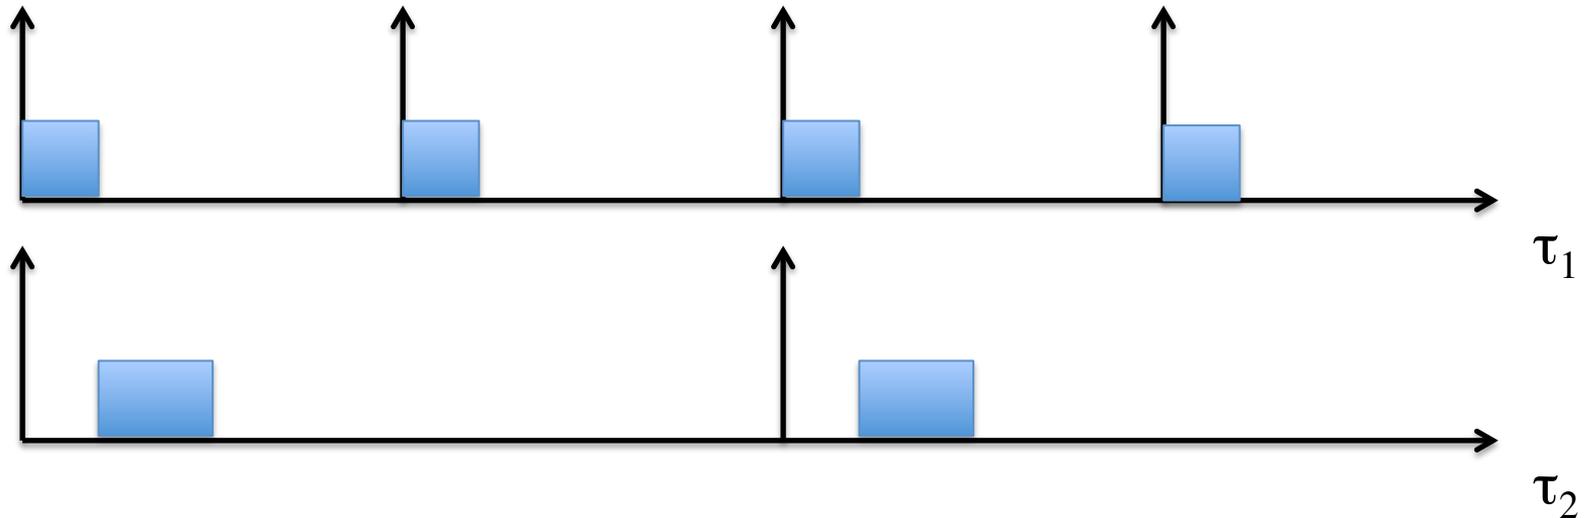
Tâche	Période	WCET	Deadline	Priorité
$\tau_1$	10 ms	2 ms	6 ms	5
$\tau_2$	20 ms	3 ms	10 ms	10

$\tau_1$  est dans l'état  
*ready*



# Exemple RMS

Tâche	Période	WCET	Deadline
$\tau_1$	10 ms	2 ms	6 ms
$\tau_2$	20 ms	3 ms	10 ms





## Formule du calcul de temps de réponse (tâches indépendentes)

# Temps de réponse avec FPS

- Le temps de réponse  $R_i$  d'une tâche  $\tau_i$ , se calcule en considérant:
  - ⌘  $C_i$ , le pire temps d'exécution de  $\tau_i$
  - ⌘  $I_i$ , le temps correspondant aux interférences des tâches de plus forte priorité

$$R_i = C_i + I_i$$

- Il suffit alors de vérifier que  $R_i \leq D_i$  pour toutes les tâches: toutes les tâches finissent leur exécution avant leur échéance.
- Toute la difficulté est de calculer  $I_i$  bien sûr...

# Interférences: nombre de pré-emption

- Pour prendre en compte les interférences, on doit calculer combien de fois tâche  $\tau_j$  (plus prioritaire que  $\tau_i$ ) préempte  $\tau_i$ .
- En supposant que toutes les tâche démarrent en même temps, à l'instant  $t=0$ , le nombre maximum de préemption de  $\tau_i$  par  $\tau_j$  est:

$$\left\lfloor \frac{R_i}{T_j} \right\rfloor$$

- Cela revient à compter le nombre de fois que  $\tau_j$  est activée dans l'intervalle  $[0, R_i]$ .

# Interférences: temps associé

- Pour chaque préemption, le pire temps d'interférence est  $C_j$
- Par conséquent, le temps pendant lequel  $\tau_i$  subit les interférences de  $\tau_j$  est:

$$\left[ \frac{R_i}{T_j} \right] C_j$$

# Temps de réponse

- Considérons une tâche  $\tau_i$ , et  $hp_i$  l'ensemble des tâches ayant une priorité supérieure à celle de  $\tau_i$
- Nous pouvons alors calculer le pire temps de réponse de  $\tau_i$  comme suit:

$$R_i = C_i + \sum_{j \in hp_i} \left\lceil \frac{R_i}{T_j} \right\rceil C_j$$

- Calcul par récurrence, initialisé avec  $R_i^0 = C_i$ , qui s'arrête lorsque
  - ⌘  $R_i^N > D_i$  : le test d'ordonnancement échoue (*i.e.* le système peut ne pas respecter ses contraintes temporelles).
  - ⌘  $R_i^{N+1} = R_i^N$  : le test d'ordonnancement réussi et on a obtenu le pire temps de réponse de  $\tau_i$ .

# Exemple (énoncé)

- En considérant le lot de tâches suivant, ordonnancé avec RMS:

Tâche	Période	WCET	Deadline
$\tau_1$	8 ms	4 ms	6 ms
$\tau_2$	16 ms	3 ms	16 ms
$\tau_3$	4 ms	1 ms	2 ms

- Calculez le pire temps de réponse de  $\tau_3$ ,  $\tau_2$ , et  $\tau_1$
- Le système est-il ordonnançable?

# Exemple (corrigé)

- $R_3^0 = C_3 = 1$ ;  $\tau_3$  est la tâche la plus prioritaire, donc pas d'interférences

$$R_3 = 1$$

- $R_2^0 = C_2 = 3$ ;  $\tau_2$  peut subir des interférences de  $\tau_3$  et  $\tau_1$
- $R_2^1 = \text{ceil}(R_2^0/T_3) * C_3 + \text{ceil}(R_2^0/T_1) * C_1 + C_2 = \text{ceil}(3/4) * 1 + \text{ceil}(3/8) * 4 + 3 = 8 \text{ ms}$
- $R_2^2 = \text{ceil}(R_2^1/T_3) * C_3 + \text{ceil}(R_2^1/T_1) * C_1 + C_2 = \text{ceil}(8/4) * 1 + \text{ceil}(8/8) * 4 + 3 = 9 \text{ ms}$
- $R_2^3 = \text{ceil}(R_2^2/T_3) * C_3 + \text{ceil}(R_2^2/T_1) * C_1 + C_2 = \text{ceil}(9/4) * 1 + \text{ceil}(9/8) * 4 + 3 = 14 \text{ ms}$
- $R_2^4 = \text{ceil}(R_2^3/T_3) * C_3 + \text{ceil}(R_2^3/T_1) * C_1 + C_2 = \text{ceil}(14/4) * 1 + \text{ceil}(14/8) * 4 + 3 = 15 \text{ ms}$
- $R_2^5 = \text{ceil}(R_2^4/T_3) * C_3 + \text{ceil}(R_2^4/T_1) * C_1 + C_2 = \text{ceil}(15/4) * 1 + \text{ceil}(15/8) * 4 + 3 = 15 \text{ ms}$

$$R_2 = 15 \text{ ms}$$

# Exemple (corrigé)

- $R_1^0 = C_1 = 4$ ;  $\tau_1$  peut subir des interférences de  $\tau_3$
- $R_1^1 = \text{ceil}(R_1^0/T_3) * C_3 + C_1 = \text{ceil}(4/4) * 1 + 4 = 5$  ms
- $R_1^2 = \text{ceil}(R_1^1/T_3) * C_3 + C_1 = \text{ceil}(5/4) * 1 + 4 = 6$  ms
- $R_1^3 = \text{ceil}(R_1^2/T_3) * C_3 + C_1 = \text{ceil}(6/4) * 1 + 4 = 6$  ms

$$R_1 = 6 \text{ ms}$$

- Le lot de tâches est-il ordonnançable?



## Formule du calcul de temps de réponse (tâches avec variables partagées)

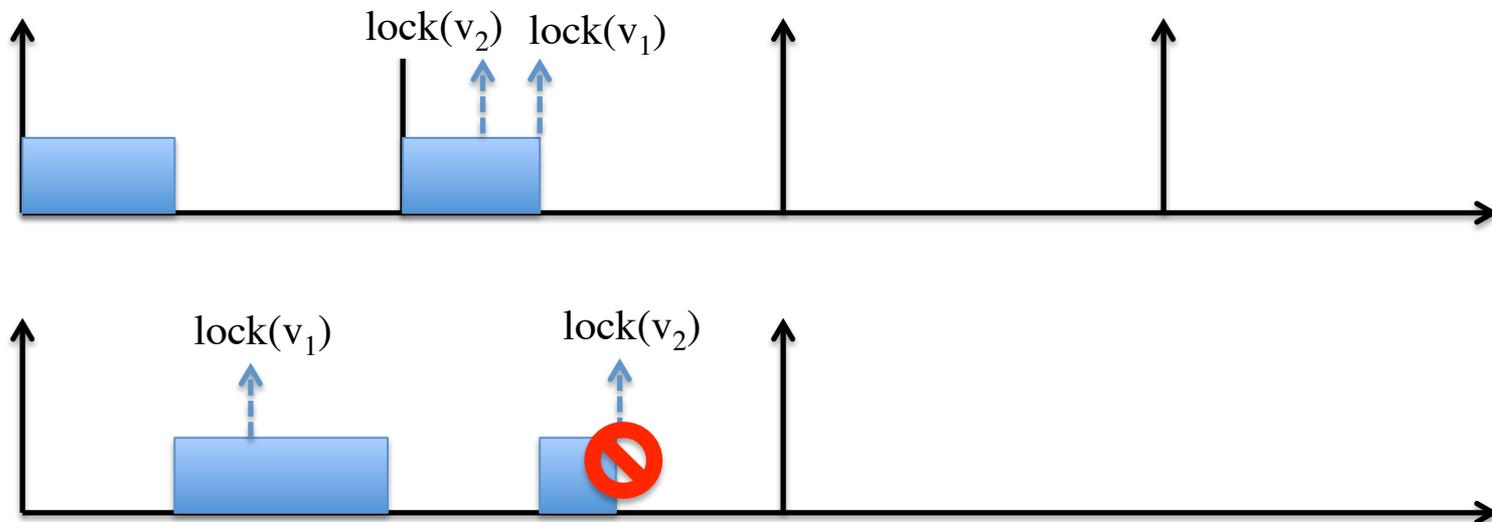
# Problèmes posés par les variables partagées

- Pour garantir leur cohérence, il faut (parfois) utiliser des verrous.
  - ⌘ Risques de deadlock.
  - ⌘ Risques d'inversion de priorité.
- Rappel: un verrou permet d'accéder à une variable partagée, dans une section critique, en **exclusion mutuelle**:
  - ⌘ Fonction lock : entrer dans la section critique en exclusion mutuelle.
  - ⌘ Fonction unlock : sortir de la section critique.

# Risque de deadlock (interblocage)

- Un deadlock peut se produire lorsqu'un ensemble de tâche attendent **cycliquement** que la tâche qui les précèdent (dans le cycle) libère une ressource (un verrou dans notre cas).
- Exemple simple: ordo RMS, 2 tâches ( $\tau_1$  et  $\tau_2$ ) et deux verrous ( $v_1$  et  $v_2$ ).

Tâche	Période	WCET	Deadline
$\tau_1$	10 ms	4 ms	10 ms
$\tau_2$	20 ms	7 ms	20 ms

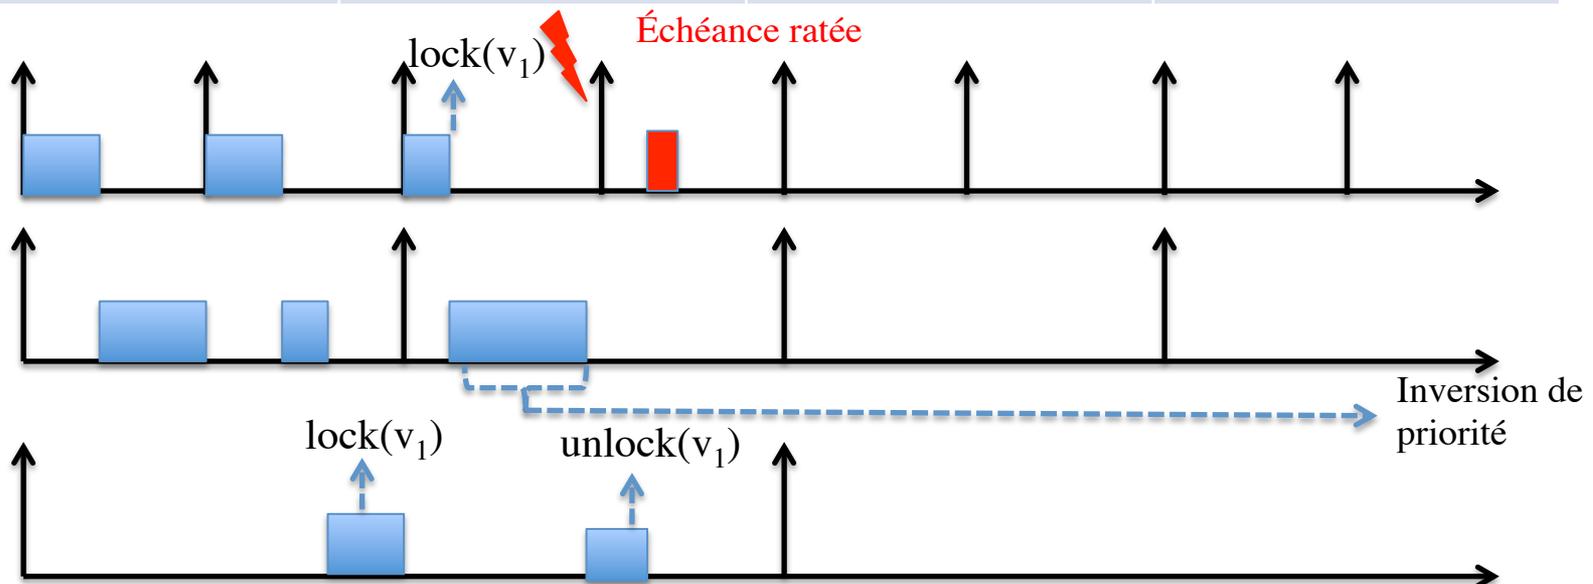


**Deadlock!**

# Risque d'inversion de priorité

- Une inversion de priorité peut se produire lorsqu'une tâche de faible priorité s'exécute avant une tâche de plus forte priorité car celle-ci est bloquée par un verrou.
- Exemple simple: ordo RMS, 3 tâches ( $\tau_1$ ,  $\tau_2$ , et  $\tau_3$ ) et un verrou ( $v_1$ ).

Tâche	Période	WCET	Deadline
$\tau_1$	5 ms	2 ms	5 ms
$\tau_2$	10 ms	4 ms	10 ms
$\tau_3$	20 ms	7 ms	20 ms



# Solution: politique d'accès dédiée

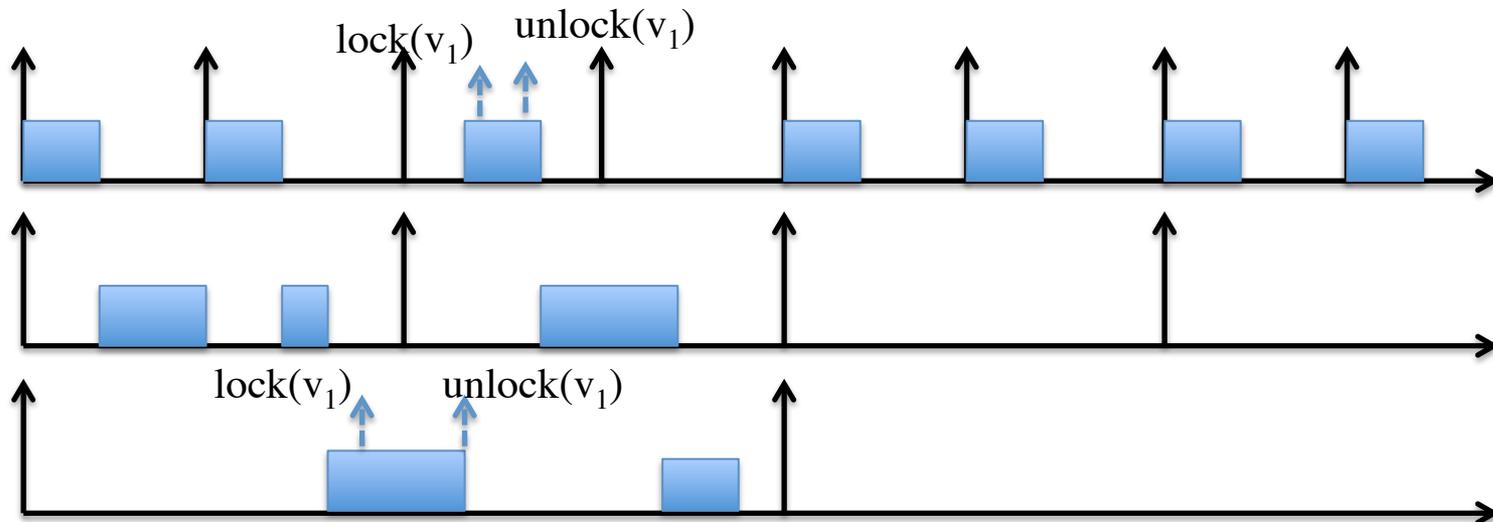
- Différentes politiques ont été proposées pour remédier à ce problème, nous n'en présentons qu'une: *ICPP*, *Immediate Ceiling Priority Protocol*.
  - ⌘ Lorsqu'une tâche entre dans la section critique, elle prend **immédiatement une priorité supérieur** à la plus forte priorité de l'ensemble des tâches susceptible d'entrer dans la section critique.
- Illustration (page suivante)

# ICPP, illustration

- Exemple simple: ordo RMS, 3 tâches ( $\tau_1$ ,  $\tau_2$ , et  $\tau_3$ ) et un verrou ( $v_1$ ).

Tâche	Période	WCET	Deadline	Priorité
$\tau_1$	5 ms	2 ms	5 ms	3
$\tau_2$	10 ms	4 ms	10 ms	2
$\tau_3$	20 ms	7 ms	20 ms	1

- $\tau_1$  et  $\tau_3$  utilise  $v_1$ . En utilisant la politique ICPP, la priorité de ces tâches dans la section critique est supérieure à 3.



# Impact sur le temps de réponse

- L'utilisation de verrous a chamboulé l'ordonnancement: une tâche moins prioritaire peut bloquer une tâche plus prioritaire.

⌘ Il faut donc mettre à jour la formule du temps de réponse pour une tâche  $\tau_i$ :

$$R_i = C_i + I_i + B_i$$

- On considère un nombre  $V$  de verrous pour l'ensemble des tâches.

⌘ Pour un verrou  $v$  et une tâche  $\tau_i$ , on définit la fonction  $usage(v,i)$  qui revoie:

- 1 si  $v$  est utilisé par au moins une tâche de priorité strictement inférieure à  $\tau_i$ , et par au moins une tâche de priorité supérieure ou égale à  $\tau_i$ .
- 0 sinon.

⌘ Pour un verrou  $v$  et une tâche  $\tau_i$ , le pire temps passé dans la section critique est donné par  $C_{v,i}$

- On a alors:

$$B_i = \max_{v=0}^V (usage(v,i) \cdot C_{v,i})$$

# Pire temps de réponse avec temps de blocage

- Le calcul du temps de réponse revient à résoudre, par récurrence, l'équation suivante:

$$R_i = C_i + \sum_{j \in hp_i} \left\lfloor \frac{R_i}{T_j} \right\rfloor C_j + \max_{v=0}^V (usage(v,i) \cdot C_{v,i})$$

$$C_{v,i} = \max_{\tau_j \in Ts.t. P_j < P_i} (t_{unlock}^{\tau_j} - t_{lock}^{\tau_j})$$

- A propos d'ICPP
  - ⌘ Ce protocole résout les problèmes d'interblocage et d'inversion de priorité. Par ailleurs, il:
    - minimise le temps de blocage (voir définition plus loin)
    - introduit des perturbations pour les tâches de niveau de priorité intermédiaire

# Exercice (énoncé)

- En considérant le lot de tâches suivant, ordonnancé avec RMS, ainsi qu'une ressource R partagée par  $\tau_1$  and  $\tau_2$  :

Tâche	Période	WCET	Deadline	Resource usage
$\tau_1$	8 ms	4 ms	6 ms	Uses R for 1 ms
$\tau_2$	16 ms	3 ms	16 ms	Uses R for 2 ms
$\tau_3$	4 ms	1 ms	2 ms	Does not use R

- R est protégée en utilisant la politique ICPP
- Calculez le pire temps de réponse de  $\tau_3$ ,  $\tau_2$ , et  $\tau_1$
- Le lot de tâches est-il ordonnançable?

# Exercice (corrigé)

- $R_3^0 = C_3 = 1$ ;  $\tau_3$  est la tâche la plus prioritaire, donc pas d'interférences

$$R_3 = 1$$

- $R_2^0 = C_2 = 3$ ;  $\tau_2$  peut subir des interférences de  $\tau_3$  et  $\tau_1$ ;  $\text{usage}(R, 2) = 0$ ; donc  $R_2$  n'est pas impacté par l'usage de la ressource  $R$ .

- $R_2^1 = \text{ceil}(R_2^0/T_3) * C_3 + \text{ceil}(R_2^0/T_1) * C_1 + C_2 = \text{ceil}(3/4) * 1 + \text{ceil}(3/8) * 4 + 3 = 8 \text{ ms}$
- $R_2^2 = \text{ceil}(R_2^1/T_3) * C_3 + \text{ceil}(R_2^1/T_1) * C_1 + C_2 = \text{ceil}(8/4) * 1 + \text{ceil}(8/8) * 4 + 3 = 9 \text{ ms}$
- $R_2^3 = \text{ceil}(R_2^2/T_3) * C_3 + \text{ceil}(R_2^2/T_1) * C_1 + C_2 = \text{ceil}(9/4) * 1 + \text{ceil}(9/8) * 4 + 3 = 14 \text{ ms}$
- $R_2^4 = \text{ceil}(R_2^3/T_3) * C_3 + \text{ceil}(R_2^3/T_1) * C_1 + C_2 = \text{ceil}(14/4) * 1 + \text{ceil}(14/8) * 4 + 3 = 15 \text{ ms}$
- $R_2^5 = \text{ceil}(R_2^4/T_3) * C_3 + \text{ceil}(R_2^4/T_1) * C_1 + C_2 = \text{ceil}(15/4) * 1 + \text{ceil}(15/8) * 4 + 3 = 15 \text{ ms}$

$$R_2 = 15 \text{ ms}$$

# Exemple (corrigé)

- $R_1^0 = C_1 = 4$ ;  $\tau_1$  peut subir des interférences de  $\tau_3$ ;  $\tau_1$  peut être bloquée par  $\tau_2$ .  $B_1(R) = 2 \text{ ms}$
- $R_1^1 = \text{ceil}(R_1^0/T_3) * C_3 + C_1 + B_1(R) = \text{ceil}(4/4) * 1 + 4 + 2 = 7 \text{ ms}$
- $R_1^2 = \text{ceil}(R_1^1/T_3) * C_3 + C_1 = \text{ceil}(7/4) * 1 + 4 + 2 = 8 \text{ ms}$
- $R_1^3 = \text{ceil}(R_1^2/T_3) * C_3 + C_1 = \text{ceil}(8/4) * 1 + 4 + 2 = 8 \text{ ms}$

$$R_1 = 8 \text{ ms}$$

- Le lot de tâches considéré n'est pas ordonnançable



## A propos des analyses d'architectures de systèmes temps-réel



# Analyse structurelle d'un modèle

- Nous avons vu dans ce cours que pour appliquer une analyse de temps de réponse, il faut respecter certaines contraintes « structurelle »:
  - ⌘ Tâches périodiques ou sporadiques seulement
  - ⌘ Toutes les tâches ont une période et un WCET
  - ⌘ L'algorithme d'ordonnancement est FPS ou RMS
  - ⌘ Si l'algorithme d'ordonnancement est RMS, la priorité des tâches doit être conforme à cet algorithme
  - ⌘ Le seul mécanisme de protection des ressources est le mécanisme de verrou, configuré avec ICPP
- La vérification de ces contraintes peut se faire sur
  - ⌘ Du code (profile Ada Ravenscar)
  - ⌘ Des modèles d'architecture

# Limitations de l'analyse de temps de réponse

## Concernant l'analyse présentée dans ce cours

- Suppose le WCET connu, ce qui n'est pas si facile (analyse statique de code, tests exhaustif!)
  - ⌘ Plus d'infos dans SE301
- Très pessimiste, donc mauvaise utilisation des ressources de calcul
  - ⌘ Toutes les tâches s'exécutent selon leur WCET.
  - ⌘ Toutes les sections critiques s'exécutent selon leur WCET.
- Très pessimiste, mais nécessaire à la certification et au dimensionnement de certains systèmes (dits temps-réel critiques).
- Considère une architecture **mono-cœur**! Se complexifie fortement sur multi-cœur (placement, interconnexion...)
- Les lois de contrôle sont souvent robustes à  $K$  dépassements d'échéance parmi  $N$  activations successives
  - ⌘ La méthode d'analyse est donc à adapter.

# Besoin d'un langage support

- Un langage de description d'architecture pour les systèmes temps réel est nécessaire pour:
  - ⌘ Vérifier l'applicabilité de l'analyse de temps de réponse
  - ⌘ Automatiser le calcul (outils Cheddar, MAST)
- D'autres caractéristiques techniques devront être évaluées:
  - ⌘ Temps de transmission de messages sur un réseaux,
  - ⌘ Temps de réponse de bout en bout (tâches+messages),
  - ⌘ Fiabilité du système,
  - ⌘ Sécurité du système,
  - ⌘ ...
- D'autres modèles de tâches plus sophistiqués existent dans la littérature.
- Nous allons pour cela présenter un grand standard de modélisation pour le logiciel embarqué : AADL