M2 Historique et Rappels : Systèmes temps réel et Ordonnancement

Université du Havre - UFR des Sciences et Techniques
Laboratoire LITIS

25 rue Philippe Lebon - BP 540
76058 LE HAVRE CEDEX
bruno.sadeg@univ-lehavre.fr

http://litis.univ-lehavre.fr/~sadeg/enseignement/enseignement.html
(voir titre : master2)

SOMMAIRE

- Historique
- Ordonnancement de tâches temps réel indépendantes :
  - Tâches périodiques
  - Tâches périodiques et apériodiques

- le temps a toujours joué un rôle important dans les services et les applications (informatique industrielle, télécommunications, …).
  Actuellement, le temps devient de plus en plus important.
  Exemples :

- En informatique industrielle : c'étaient les prémisses de *l'informatique temps réel,*

- En télécom :
  - (1) on cherche à a obtenir des débits élevés (borner la durée du trafic),
  - (2) on doit gérer plusieurs flux d'information => une synchronisation entre les flux est nécessaire (comme dans les applications multimédia),

  Quand on ne peut pas respecter les échéances, comme pour certains services : à chaque service on lui associe une qualité de service (QoS) qui doit être respectée : cela peut être le temps d'établissement d'une connexion, le temps de réponse d'une requête, etc.

Définition d'un système temps réel (STR)

- STR = système dont le comportement dépend non seulement de **l'exactitude** des traitements effectués, mais également de **l'instant** où les résultats de ces traitements sont fournis, c-à-d qu'un retard dans la production d'un résultat est considéré comme une erreur (pouvant entraîner de graves conséquences)

Exemples d'applications temps réel

- La commande de procédés industriels,
- Les systèmes embarqués,
- Le guidage de mobiles,
- La surveillance de centrales (thermiques, nucléaires, ...)
- Conduite d'expériences scientifiques,
- La fourniture d'images et de son pour les applications multimédia,
- Le suivi d'informations boursières,
- Le suivi opératoire en milieu médical,
- ...

Un exemple détaillé

- Un Système de vidéo-conférence sur un réseau local :

  => le système numérise l'image, puis la séquence. Il faut que le système traite 30 images/sec pour que l'image soit acceptable.

  => Plusieurs opérations vont s'enchaîner dans le temps : (1) numérisation, (2) compression, (3) transmission.

  La durée de ces opérations est le temps de latence du système.

  (La voix doit également être (1) numérisée, (2) compressée et (3) transmise).

  Il faut que le son et l'image soient synchronisés : un retard léger dans l'arrivée de l'un des flux est acceptable. Mais si le décalage est trop long, la scène devient incompréhensible

  => c'est le temps réel mou, ou échéances molles, relatives.

Types d’échéances et de systèmes temps réel

- Échéance dure (hard) : le dépassement de l’échéance provoque une exception dans le système (qui peut engendrer des dommages)

  ==> STR durs : les échéances ne doivent en aucun cas être dépassées

  (sinon catastrophe humaine ou industrielle ou économique, ...)

- Échéance molle, lâche (soft) : un dépassement d’échéance ne provoque pas d’exception dans le système

  ==> STR mous : les échéances peuvent être dépassées occasionnellement

  (ex. usine automatisée)

Caractéristique d'un système temps réel

- **La prévisibilité**, qui est un aspect important d'un STR.

  (Un STR doit être conçu tel que ses performances soient définies dans le **pire cas**, alors que dans les systèmes classiques, les performances sont définies en termes de **moyenne**).

- La prévisibilité est le fait de savoir à **l'avance** si un système va respecter ses contraintes temporelles (C.T.). Pour cela, il est nécessaire de connaître avec précision les paramètres des tâches : temps global de calcul de chaque activité, périodicité, date de réveil, etc.

  Ces éléments définissent le choix d'une politique d'ordonnancement des activités de manière à ce que le système soit prévisible.

Autre caractéristique

- **Le déterminisme** d'un STR : est le but à atteindre pour assurer la prévisibilité. Pour qu'un système soit prévisible, il faut qu'il soit déterministe. Donc enlever toute incertitude sur le comportement des activités (individuelles et mises ensemble).
- Dans un STR dur : on cherche à ce que toutes les échéances soient respectées
- Dans un STR mou : on cherche, par exemple, à minimiser le retard moyen des activités (ou maximise le nombre de tâches qui respectent leurs C.T., notamment les échéances).

Principales politiques d'ordonnancement classique

- **Objectifs** : maximiser le taux d'utilisation du processeur (temps où le processeur est actif sur le temps total) à> Déterminer quelle tâche prête doit être élue

1) Premier arrivé, premier servi (PAPS ou FIFO : les tâches de faible temps d'exécution sont pénalisées si elles sont précédées dans la file par une (ou des) tâche(s) de longue durée)
2) Plus court d'abord : remédie à l'inconvénient précédent. Minimise le temps de réponse moyen. Pénalise les travaux longs. Elle impose d'estimer les durées d'exécution des tâches (connues difficilement).
3) Temps restant le plus court d'abord : la tâche en exécution restitue le processeur lorsqu'une nouvelle tâche ayant un temps d'exécution inférieur à son temps d'exécution restant devient prête.
4) Tourniquet (Round Robin) : un quantum de temps pour toutes les tâches (ou spécifique à un groupe de taches selon la priorité) ...
5) Files multi-niveaux, ...

Constat

- Aucune des politiques classiques ne permet de remplir l'objectif principal d'un ordonnancement temps réel, c-à-d pas de prise en compte de l'urgence des tâches (délai critique)

==> Ordonnancement spécifique aux tâches temps réel

Terminologie pour l'ordonnancement des tâches temps réel

- **tâche** = unité de base de l'ordonnancement temps réel. Une tâche peut être (1) périodique ou apériodique, (2) à contraintes temporelles strictes ou relatives.
- **Modèle de tâche** : paramètres chronologiques (des délais) et chronométriques (des dates). Les paramètres de base d'une tâche sont :
- **r** : sa date de réveil, moment de déclenchement de la 1ère requête d'exécution
- **C** : sa durée maximale d'exécution (si elle dispose du processeur à elle seule)
- **D** : son délai critique (délai maximal acceptable pour son exécution)
- **P** : sa période (si tâche périodique)
- **Remarque** : Si tâche à contraintes strictes : l'échéance d = r + D, est la date dont le dépassement entraîne une faute temporelle.

Illustration : diagramme temporel d'exécution

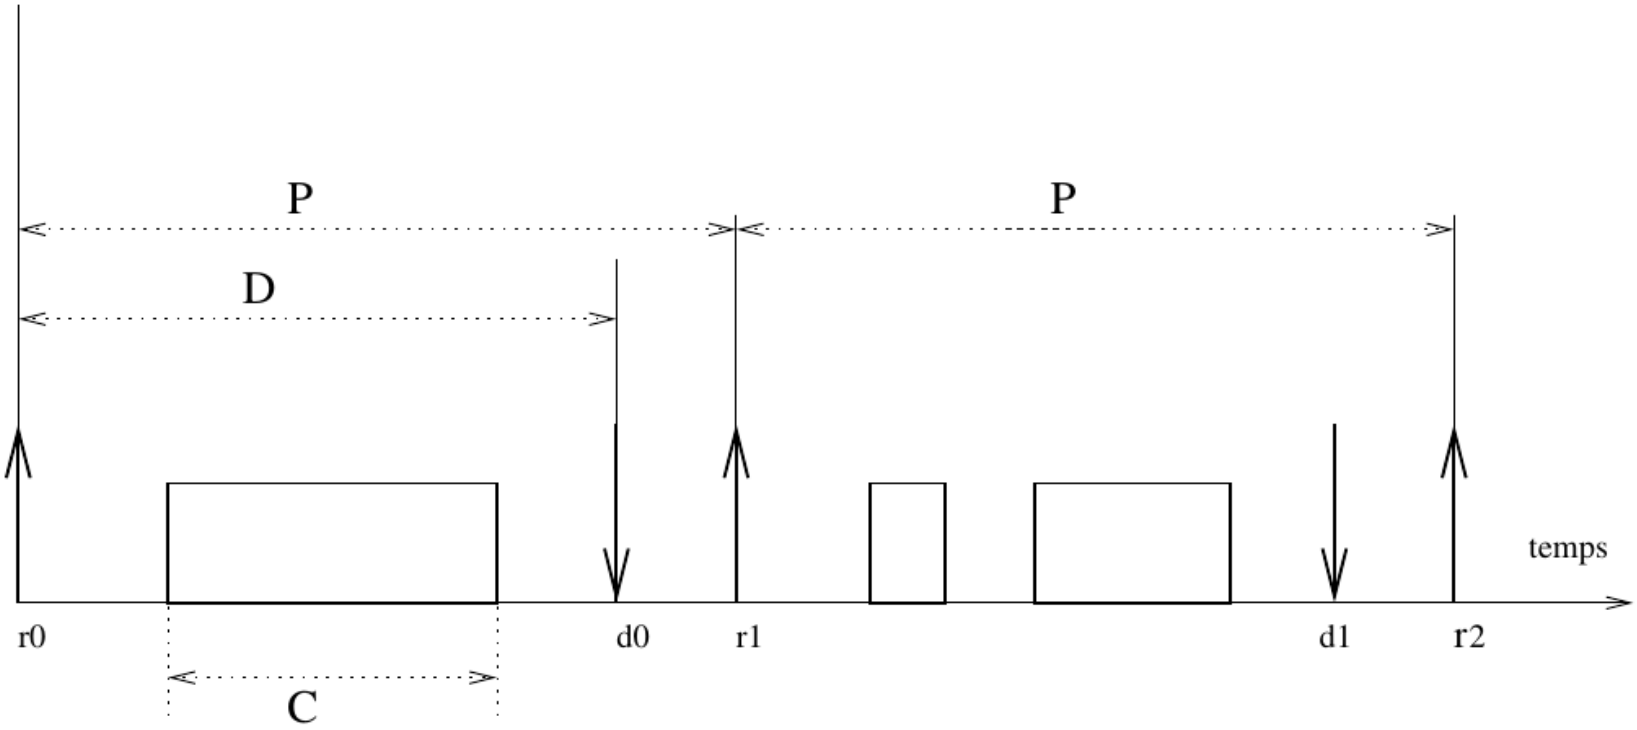

Figure: Modèle de tâches

Commentaires

$T(r_0, C, D, P)$ avec $0 \leq C \leq D \leq P$

$\mathbf{r_0}$: date de réveil, C : durée max d'exécution, D : délai critique, P : période

$\mathbf{r_k}$: date de réveil de la k-ème requête de la tâche. On a :

$$\mathbf{r_k} = r_0 + kP, \text{ représentée par } \uparrow$$

$\mathbf{d_k}$: échéance de la k-ème requête de la tâche. On a :

$$\mathbf{d_k} = r_k + D, \text{ représentée par } \downarrow$$

Remarque : une tâche est *à échéance sur requête* quand D = P, représentée par $\updownarrow$

Autres paramètres déduits

U = C / P (doit être ≤ 1) : facteur d'utilisation du processeur par la tâche

Ch = C / D (doit être ≤ 1) : facteur de charge du processeur

Paramètres dynamiques (pour suivre l'exécution d'une tâche dans le temps) :

s : date de début de l'exécution d'une tâche

e : date de fin d'exécution d'une tâche

D(t) = d – t : délai critique résiduel à la date t (0 ≤ D(t) ≤ D)

C(t) = durée d'exécution résiduelle à la date t (0 ≤ C(t) ≤ C)

Autres paramètres déduits

L = D – C : laxité nominale de la tâche, retard maximum pour son début d'exécution s quand la tâche s'exécute seule.

L(t) = D(t) – C(t) : laxité nominale résiduelle, retard maximum pour reprendre l'exécution d'une tâche si elle s'exécute seule,

TR = e – r : temps de réponse de la tâche,

CH (t) = C(t) / D(t) : charge résiduelle au temps t

Autres caractéristiques d’une tâche

- **préemptible** : tâche élue qui peut être arrêtée et remise à l’état prêt, pour allouer le processeur à une autre tâche,
- **non préemptible** : une fois élue, la tâche ne doit plus être interrompue jusqu’à la fin de la requête,
- **tâches indépendantes** : lorsqu’elles n’ont pas de relations de précédence, ni ne partagent des ressources critiques
- **tâches dépendantes** : dépendance statique ou dynamique

Ordonnancement temps réel

Son but : permettre le respect des contraintes temporelles des tâches d'une application quand elles s'exécutent en mode courant,

Il doit être **certifiable**, c-à-d prouver a priori le respect des C.T. des tâches d'une application (en régime courant)

En régime de **surcharge** (tâches supplémentaires suite à des anomalies : alarmes, variations des temps d'exécution, … => fautes temporelles) : l'ordonnancement doit offrir une tolérance aux surcharges (permettre une exécution dégradée, mais sécuritaire du système)

Définitions

Configuration de tâches : mise en jeu d'un ensemble de n tâches qui s'exécutent,

Départ simultané : même date de réveil (sinon départ **échelonné**),

Facteur d'utilisation du processeur pour n tâches périodiques : U = $\sum_{i=1}^{i=n} \frac{C_i}{P_i}$

Facteur de charge du processeur pour n tâches périodiques : CH = $\sum_{i=1}^{n} \frac{C_i}{D_i}$

Laxité du processeur à l'instant t, LP (t) = intervalle de temps à partir de t pendant lequel le processeur peut rester inactif sans remettre en cause le respect des échéances

Définition du problème d'ordonnancement

Le système de conduite d'une application temps réel doit piloter le procédé en ordonnançant les tâches avec 2 objectifs :

1) assurer le respect des C.T. en fonctionnement nominal,

2) atténuer les effets des surcharges et maintenir le procédé dans un état cohérent et sûr en fonctionnement anormal (pannes matérielles ou logicielles)
=> respecter au moins les CT des requêtes vitales pour le procédé.

L'algorithme d'ordonnancement fournit une description de la **séquence de planification** des tâches à effectuer de manière à respecter les CT.

Typologie des algorithmes d'ordonnancement

Hors ligne : l'algorithme construit la séquence complète de planification des tâches sur la base de tous les paramètres temporels des tâches.
=> Séquence connue avant l'exécution. Très efficace Mais cette approche statique est rigide, donc elle ne s'adapte pas aux changements de l'environnement

En ligne : capable à tout instant de l'exécution d'une application de choisir la prochaine tâche à ordonnancer, en utilisant les informations des tâches déclenchées à cet instant. Ce choix peut être remis en cause par l'occurrence d'un nouvel événement.
Cette approche dynamique offre des solutions moins bonnes (car elle utilise moins d'informations) et entraîne des surcoûts de mise en œuvre, MAIS
Avantages : permet l'arrivée imprévisible des tâches, autorise la construction progressive de la séquence d'ordonnancement.

Propriétés des algorithmes d'ordonnancement

Séquence valide : un algorithme d'ordonnancement délivre une séquence d'ordonnancement valide pour une configuration de tâches donnée si toutes les tâches respectent leur CT.

Une configuration est ordonnançable dès qu'il existe au moins un algorithme capable de fournir une séquence valide pour cette configuration.

Tests

Test d'ordonnançabilité : vérifie qu'une configuration de tâches périodiques donnée soumise à un algorithme d'ordonnancement peut être ordonnancée selon une séquence valide.

Test d'acceptabilité : un algorithme en ligne modifie dynamiquement la séquence d'ordonnancement à l'arrivée de nouvelles tâches (ou à la suite du dépassement d'échéances). Une tâche nouvelle peut être ajoutée à la configuration s'il existe au moins une séquence valide avec la nouvelle configuration (tâches existantes + celle ajoutée).

L'ensemble des conditions à satisfaire est le test d'acceptabilité ou routine de garantie.

Propriétés

Période d'étude ou intervalle d'étude : Pour valider une configuration de tâches périodiques et apériodiques, on effectue une analyse temporelle de l'exécution de la configuration durant cet intervalle.

=> Pour les tâches **périodiques, cet intervalle est :** $[\min\{r_{i0}\}, PPCM(P_i)]$

où P_i = période de la tâche i.

Souvent, $\min\{r_{i0}\} = 0$, donc on a l'intervalle d'étude : $[0, PPCM(P_i)]$.

Algorithmes En ligne, à priorité constante

- Rate Monotonic (RM)
- Inverse Deadline (ID) ou Deadline Monotonic (DM)

Algorithme En ligne, à priorité variable)

- Earliest Deadline (ED) ou Earliest Deadline First (EDF)
- Least Laxity (LL) ou Least Laxity First (LLF)

Ordonnancement de tâches indépendantes

A. Algorithme En ligne, à priorité constante (où D=P)

A.1. Rate Monotonic (ou RM) : priorité d'une tâche = f(sa période). La tâche de plus petite période est la plus prioritaire. L'algorithme est optimal dans la classe des algorithmes à priorité constante pour une configuration de tâches à échéances sur requête. Dans ce cas, on connaît une condition suffisante d'existence d'une borne minimale pour l'acceptation d'une configuration de n tâches :

$$\sum_{i=1}^{n} \frac{C_i}{P_i} \leq n(2^{\frac{1}{n}} - 1)$$

- **Remarque** : Cette borne est le pire cas. Elle tend vers log 2 quand n est très grand (c-à-d 69%). En pratique, elle peut être dépassée (en moyenne, elle est de 88%)

Exemple d'ordonnancement avec RM

La figure 3 montre l'exemple d'un ordonnancement "Rate Monotonic" pour 3 tâches périodiques à échéance sur requête (échéance = période).
T1 (r0 = 0, C = 3, P = 20), T2 (r0 = 0, C = 2, P = 5), T3 (r0 = 0, C = 2, P = 10).

Tâche de plus haute priorité : T2 , tâche de plus basse priorité : T1.
La période d'étude est l'intervalle [0, ppcm(20, 5, 10)] = [0, 20].

Les 3 tâches respectent leur CT car la condition suffisante est vérifiée :
on a bien 3/20 + 2/5 + 2/10 = 0.75 (< 0.779),
MAIS on trace le chronogramme (voir figure).

Remarque : l'utilisation de la période comme critère d'ordonnancement limite l'application de "Rate Monotonic" aux seules tâches où l'échéance est égale à la période (échéances sur requête).

Chronogramme de ces tâches avec 'Rate Monotonic'

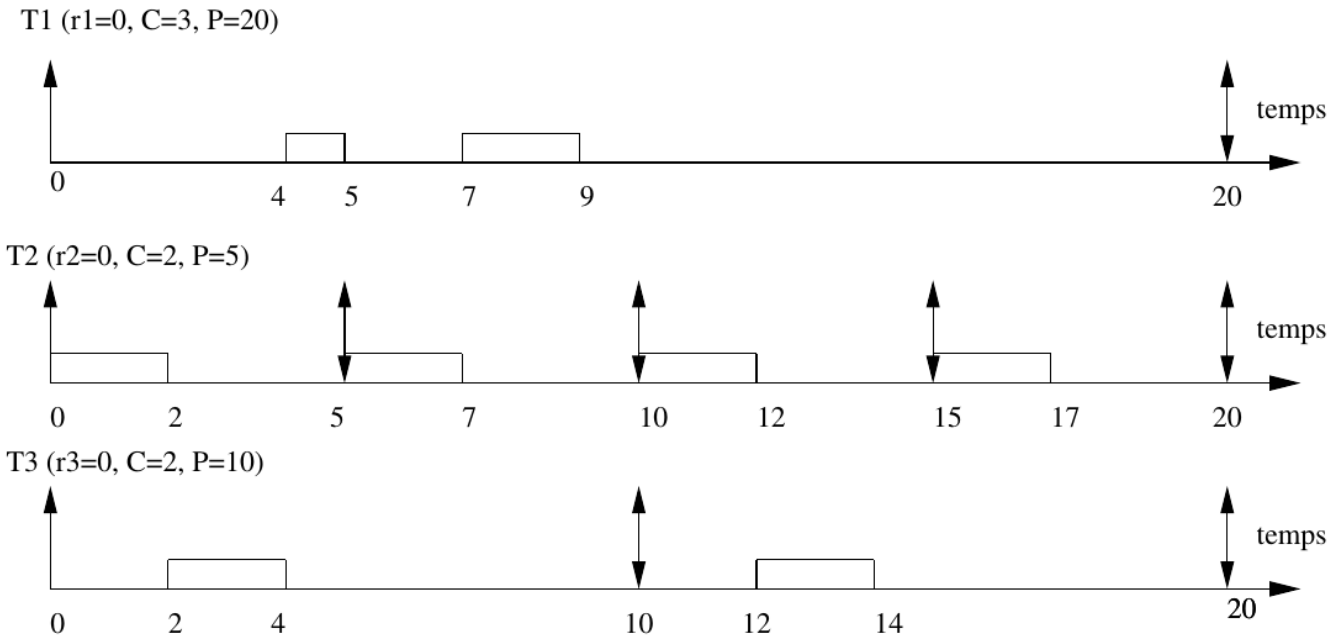

Figure: Ordonnancement "Rate Monotonic"

Figure 3 : Ordonnancement "Rate Monotonic"

Ordonnancement de tâches indépendantes
Algorithme En ligne, à priorité constante (où D <> P)

A.2. Inverse Deadline ou Deadline Monotonic :

priorité d'une tâche = f(son délai critique).

La tâche la + prioitaire est celle de + petit délai critique.

Cet algo est égal en performances à "Rate Monotonic" pour les tâches à échéances sur requête, et meilleur pour les autres types de configurations de tâches.

Condition suffisante d'acceptabilité :

$$\sum_{i=1}^{n} \frac{C_i}{D_i} \leq n(2^{\frac{1}{n}} - 1) \text{ (facteur de charge)}$$

Exemple d'ordonnancement avec 'DM' (ou 'ID')

La figure 4 montre l'exemple d'un ordonnancement "Deadline Monotonic" pour 3 tâches périodiques :

T1 (r0 = 0, C = 3, D = 7, P = 20), T2 (r0 = 0, C = 2, D = 4, P = 5),
T3 (r0 = 0, C = 2, D = 9, P = 10).
Tâche de plus haute priorité : T2 , tâche de plus basse priorité : T3 .

La condition suffisante n'est pas vérifiée : 37 + 24 + 9 2 = 1.14 > 0.77.

Cependant, le chronogramme construit sur la période d'étude montre qu'elles sont ordonnançables sans faute temporelle.
Où l'intervalle d'étude est [0, ppcm(20, 5, 10)] = [0, 20]

Chronogramme de ces tâches avec 'Deadline Monotonic'

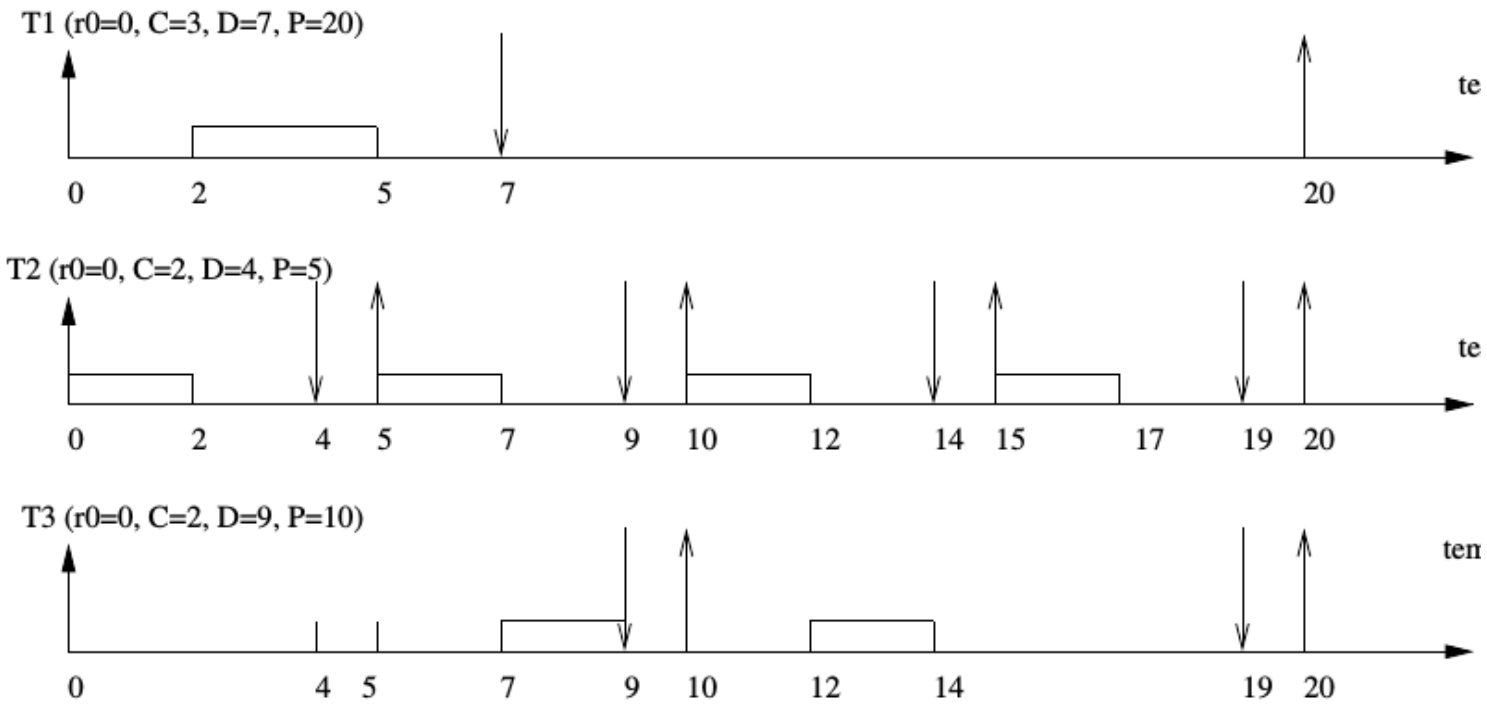

Figure: Ordonnancement "Inverse Deadline ou Deadline Monotonic"

Figure 4 : Ordonnancement "Inverse Deadline" ou "Deadline Monoton

Ordonnancement de tâches indépendantes

B. Algorithmes en ligne à priorité variable : ED ou EDF

La priorité d'une tâche varie dans le temps.

B.1. Earliest Deadline : (ED) : La + haute priorité à l'instant t est accordée à la tâche dont l'échéance est la + proche (EDF : Earliest Deadline First).

Pour les tâches à **échéances sur requête**, une **CNS** d'ordonnancement est :

$$\sum_{i=1}^{n} \frac{C_i}{P_i} \leq 1$$

Pour des tâches **périodiques quelconques**, une **condition suffisante** est :

$$\sum_{i=1}^{n} \frac{C_i}{D_i} \leq 1$$

et une condition nécessaire est : $\sum_{i=1}^{n} \frac{C_i}{P_i} \leq 1$

Exemple

La figure 5 montre l'exemple d'un ordonnancement "Earliest Deadline" pour 3 tâches périodiques. T1 (r0 = 0, C = 3, D = 7, P = 20),
T2 (r0 = 0, C = 2, D = 4, P = 5), T3 (r0 = 0, C = 1, D = 8, P = 10).

La CS : 3/7 + 2/4 + 1/8 est > 1, donc cond. Suffisante non respectée. On trace le chronogramme sur l'intervalle d'étude [0, ppcm(20, 5, 10)] = [0, 20] :

- à t=0 : au réveil des 3 tâches, T2 prioritaire, elle s'exécute pendant 2 unités.
- à t=2, T2 termine. C'est T1 la + prioritaire. Elle s'exécute pendant 3 unités de temps.
- à t=5, T1 se termine et T2 se réveille de nouveau (car période 5), mais c'est T3 qui est cette fois la + prioritaire car son échéance est 8, elle s'exécute pendant une unité.
- Ici, on voit que les priorités des tâches varient dans le temps : par exemple, à t=0, c'est T2 qui est plus prioritaire (que T1 et T3), mais à t=5, c'est T3 la plus prioritaire.

Chronogramme de ces tâches avec 'ED' (ou 'EDF')

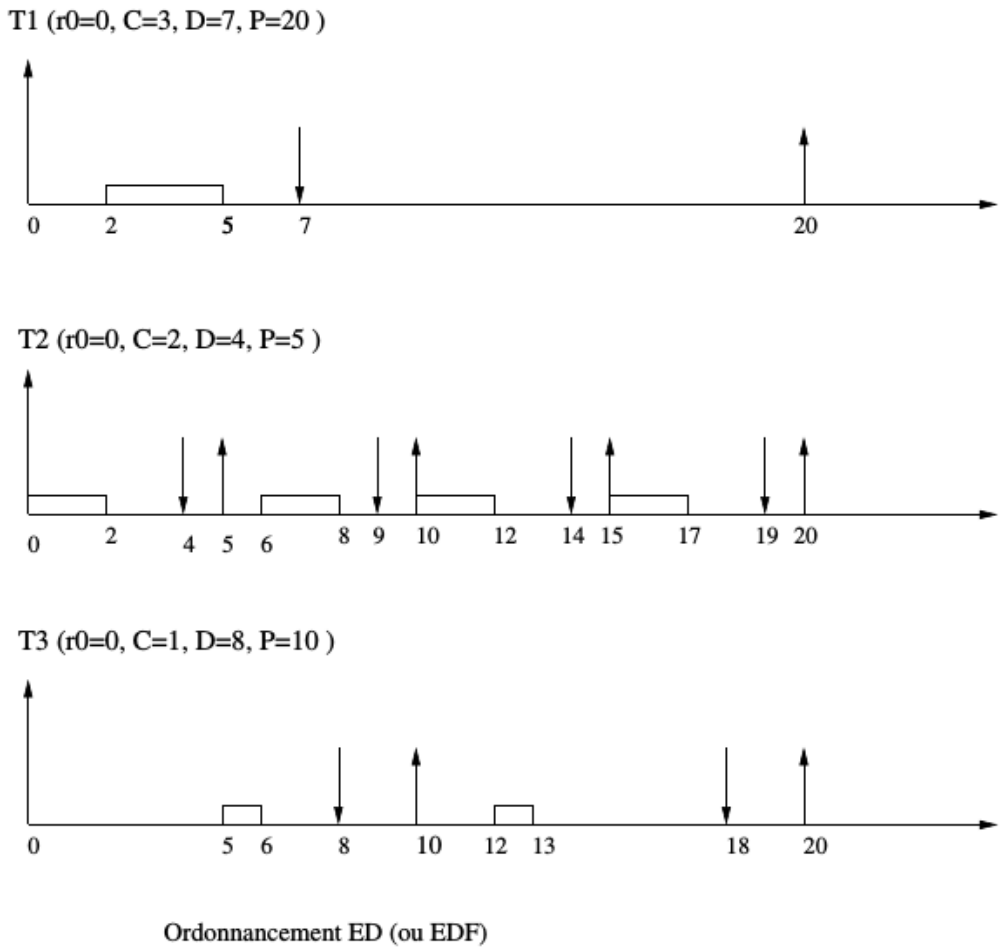

Figure 5 : Ordonnancement "Earliest Deadline"

Ordonnancement de tâches indépendantes
Algorithmes en ligne à priorité variable : LLF

La priorité d'une tâche varie dans le temps.

B.2. Least Laxity (LL) : La tâche de + haute priorité à l'instant t est celle qui a la + petite laxité dynamique L(t) (LLF : Least Laxity First (LLF)).

Cet algorithme est optimal et les conditions d'ordonnançabilité des tâches sont les mêmes que pour Earliest Deadline. Les séquenecs produites par LL sont équivalentes à celles produites par ED lorsque les valeurs des laxités sont calculées aux dates de réveil. Par contre, si on calcule la laxité à chaque instant alors la séquence produite par LL entraîne plus de changements de contextes que par ED.

Exemple

Les figures 6 et 7 montrent l'ordonnancement avec LL pour les 3 tâches de l'exemple sur ED, avec un calcul de laxité effectué aux seules dates de réveil.

- à t=0, les 3 tâches sont réveillées. Laxité dynamique de T1 =7-3=4. Laxité de T2 =4-2=2. Laxité de T3 =8-1=7. C'est donc T2 (la + prioritaire) qui s'exécute à t=0 (pour 2 unités).
- à t=2, c'est T1 qui s'exécute (sa laxité [7-2-3] est plus petite que celle de T3 qui est [8-2-1]).
- à t=5, T2 se réveille de nouveau. Sa laxité dynamique (9-5-2 = 2ème échéance - temps courant - durée exécution) est égale à 2 , celle de T3 (8-5-1) est de 2 également (retard 'toléré' t.q l'échéance soit toujours respectée). On peut choisir T3 (cas a) ou t2 (cas b) pour être ordonnancée et s'exécuter.

Rappel : L(t) = D (t) – C (t) laxité nominale résiduelle, retard maximum pour reprendre l'exécution d'une tâche si elle s'exécute seule.

Chronogramme de ces tâches avec 'LL' : ici T3 élue à t=5

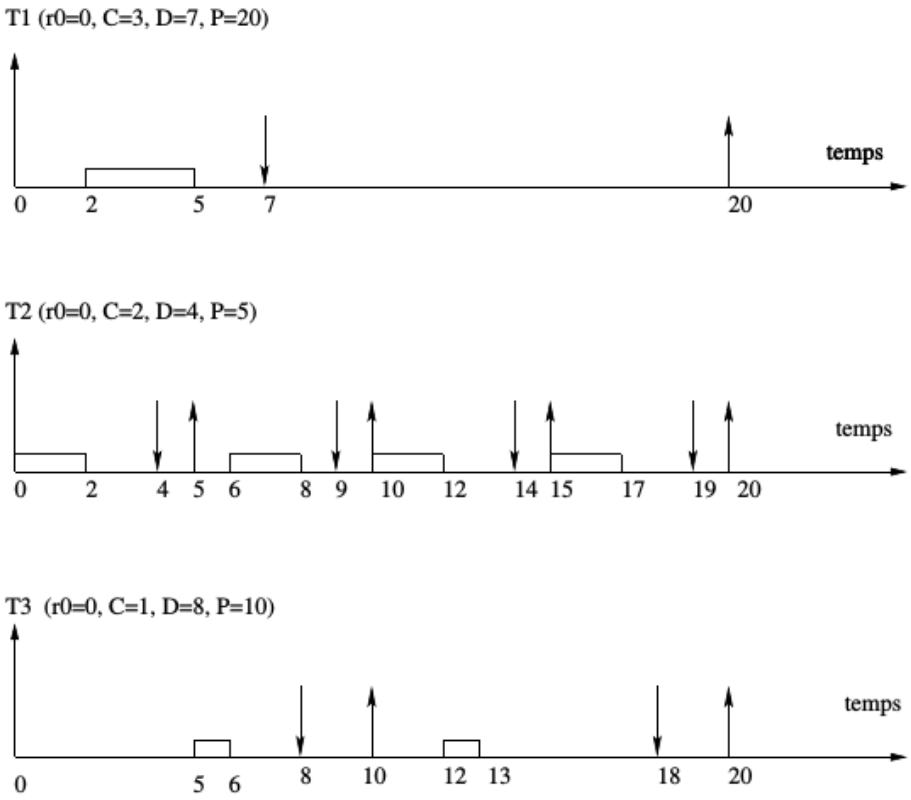

Figure: Ordonnancement "Least Laxity". Cas (a) : c'est T3 qui est élue à t=5

Figure 6 : Ordonnancement "Least Laxity"

Chronogramme de ces tâches avec 'LL' : ici T2 élue à t=5

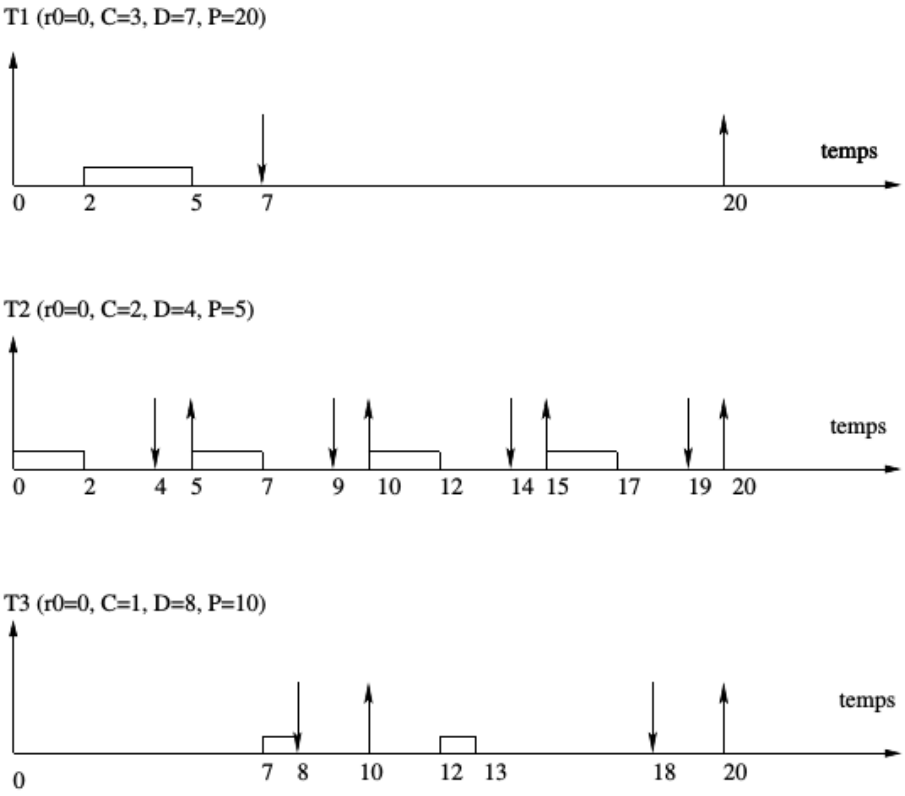

Figure: Ordonnancement "Least Laxity". Cas (b) : c'est T2 qui est élue à t=5

Figure 7 : Ordonnancement "Least Laxity"

Tâches périodiques et tâches apériodiques

Ce sont des algorithmes qui prennent en compte les tâches apériodiques.

Objectifs :

- les CT des tâches périodiques doivent être respectées et
- 1. soit minimiser le temps de réponse des tâches apériodiques à contraintes relatives (Best Effort),
- 2. soit maximiser le nombre de tâches apériodiques à contraintes strictes qui respectent leurs CT .

Tâches apériodiques à contraintes relatives :

1. Traitement en arrière-plan (BackgroundProcessing)

Principe : les tâches apériodiques sont ordonnancées lorsque le processeur est oisif (pas de tâche périodique prête).

S'il y a plusieurs tâches apériodiques, les tâches sont servies par dates de réveil (FIFO).

Ordonnancement “en arrière plan”

La figure montre un tel ordonnancement sur un intervalle égale à 2 fois la période d’étude d’une configuration de 2 tâches périodiques à échéances sur requête : T1 (r0 = 0, C = 2, P = 5), T2 (r0 = 0, C = 2, P = 10).

L’application de ’Rate Monotonic’ à cette configuration laisse le processeur oisif sur les intervalles [4,5], [7,10], [14,15] et [17,20].

La tâche apériodique Ta3 (r = 4, C = 2) survenant à t = 4 peut immédiatement commencer son exécution qu’elle finit sur le temps creux suivant c-à-d entre les temps t = 7 et t = 8.
La tâche apériodique Ta4 (r=10, C=1) qui survient à t=10 doit attendre le temps creux [14,15] pour s’exécuter. La tâche apériodique Ta5 (r=11, C=2) doit attendre le temps creux [17,20] pour s’exécuter.

Chronogramme : Ordonnancement “en arrière plan’

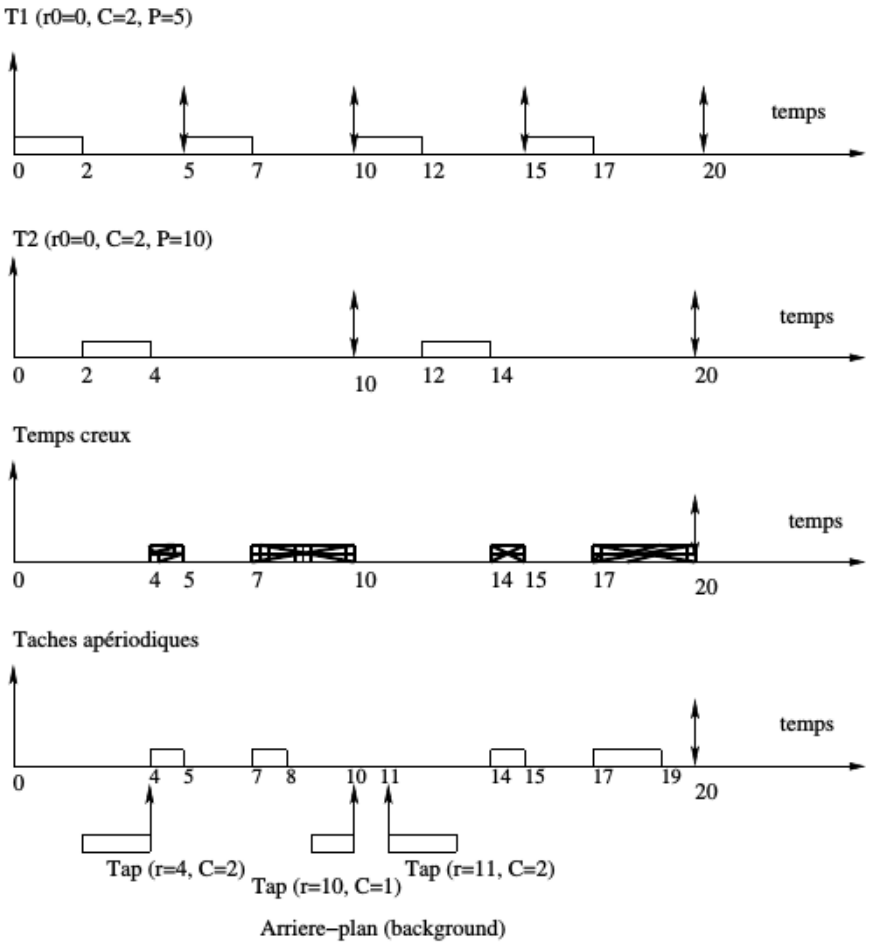

Figure 8 : Ordonnancement des tâches apériodiques“en arrière plan”

Remarque

Les + : la méthode d'ordonnancement en arrière-plan est simple et peu coûteuse et est applicable ∀ l'algorithme d'ordonnancement des tâches périodiques.

Les - : les temps de réponse des tâches apériodiques peuvent être mauvais, surtout si la charge des tâches périodiques est importante.

Tâches apériodiques à contraintes relatives :

2. Les serveurs de tâches

un serveur est **une tâche périodique** créée spécialement pour veiller à ordonnancer les tâches apériodiques. Le serveur est caractérisé par une période et un temps d'exécution (la capacité du serveur).

Cette tâche-serveur souvent ordonnancée avec le même algo que les autres tâches périodiques.

Une fois active, la tâche-serveur sert les tâches apériodiques dans la limite de sa capacité. L'ordre de service des tâches apériodiques ne dépend pas de l'algo d'ordonnancement des tâches périodiques (il peut être FIFO ou f(échéances) ou f(temps d'exécution), ...).

Il existe plusieurs types de serveurs : le plus simple est le serveur par scrutation.

Les serveurs de tâches : Traitement par 'scrutation' ("Polling")

- à chaque activation, le serveur traite les tâches apériodiques en attente depuis son activation précédente, jusqu'à épuisement de sa capacité (ou plus de tâches en attente).
- Si, lors d'une nouvelle activation, il n'y a aucune tâche apériodique en attente, le serveur se suspend jusqu'à la prochaine occurence : sa capacité (tps d'exécution) est récupérée par les tâches périodiques.
- La figure montre le fonctionnement d'un serveur par scrutation.
  Configuration : 2 tâches périodiques à échéances sur requête :
  T1 (r0 =0, C=3, P=20) et T2 (r0 =0, C=2, P=10).

- La tâche serveur est Ts (r0 =0, C=2, P=5) est de plus grande priorité (car plus petite période) avec "Rate Monotonic" appliqué pour ordonnancer les 3 tâches.
  On vérifie que la condition d'acceptabilité est remplie :
  $3/20 + 2/10 + 2/5 = 0.75 < 077$

Chronogramme : Ordonnancement “avec un serveur par scrutation”

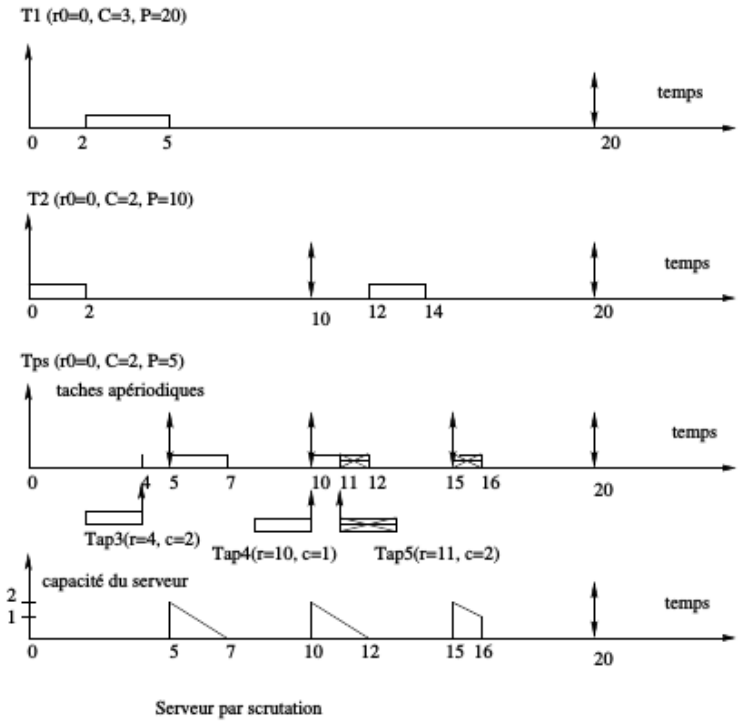

FIGURE: Ordonnancement “avec un serveur par scrutation”

Commentaires : avec “un serveur par scrutation”

- à t=0, aucune tâche apériodique, donc le serveur se suspend immédiatement. C’est T2, de priorité élevée suivante, qui s’exécute, puis c’est T1 .
- à t=4, la tâche apériodique Ta4 survient. elle doit attendre l’occurrence suivante du serveur (t=5) pour s’exécuter. Elle épuise alors toute la capacité (C=2) du serveur.
- à t=10, le serveur se réveille de nouveau, il sert la tâche apériodique Ta4 qui vient d’être activée. Puis il sert Ta5 . La tâche Ta5 ne peut pas s’exécuter entièrement car elle épuise la capacité restante du serveur.
  Elle doit attendre l’occurrence suivante du serveur à t=15 pour finir son exécution. Il reste encore une unité au serveur, il la perd car il n’y a aucune tâche apériodique à servir.

Commentaires : avec “un serveur par scrutation” (suite)

Faiblesses : lorsque le serveur est prêt, s’il n’y a pas de tâches apériodiques à traiter, sa capacité est perdue. Si des tâches apériodiques surviennent ensuite, elles doivent attendre l’occurrence suivante du serveur.

Amélioration : serveur “ajournable” : s’il n’y a pas de tâche apériodique à servir, le serveur prêt **conserve sa capacité**. Il est donc prêt à servir d’éventuelles tâches apériodiques qui surviennent.

Les serveurs de tâches : Serveur sporadique

Il améliore le temps de réponse des tâches apériodiques, sans diminuer le taux d'utilisation du processeur des tâches périodiques.

Ce serveur est également une tâche périodique de plus haute priorité, qui conserve sa capacité de traitement si, à son réveil, il n'y a pas de tâche apériodique à servir. Mais, le serveur sporadique ne retrouve pas sa capacité initiale à chaque occurrence

Commentaires : “Serveur sporadique”

La figue montre le fonctionnement d’un serveur sporadique sur le même ensemble de tâches que précédemment : T1 (r0 =0, C=3, P=20) et T2 (r0 =0, C=2, P=10).
La tâche serveur est Ts (r0 =0, C=2, P=5).

- à t=0, le serveur se réveille, mais se suspend, car il n’a pas de tâches apériodiques à traiter (mais il conserve sa capacité, 2).
- à t=4, la tâche apériodique Ta3 survient. Elle est servie immédiatement entre t=4 et t=6 et consomme toute sa capacité. Comme le serveur s’est exécuté, une date de réinitialisation de sa capacité est calculée : ce sera t=4+5. La valeur de réinitialisation est 2.

Commentaires : “Serveur sporadique” (suite)

- à t=9, le serveur retrouve toute sa capacité, mais il se suspend car il n’y a pas de tâche apériodiques en attente.
- à t=10, la tâche Ta4 arrive et s’exécute tout de suite pendant une unité (C=1). Puis Ta5 arrive et commence à s’exécuter pendant une unité et elle est suspendue jusqu’à nouvelle occurrence du serveur (car sa capacité est épuisée). Une nouvelle date de réinitialisation de la capacité est calculée : t=10+5. La tâche Ta5 poursuivra son exécution pour une unité quand le serveur aura récupéré sa capacité à t=15. Il reste au serveur une unité qu’il récupérera à t=20.

Chronogramme : Ordonnancement “avec un serveur sporadique”

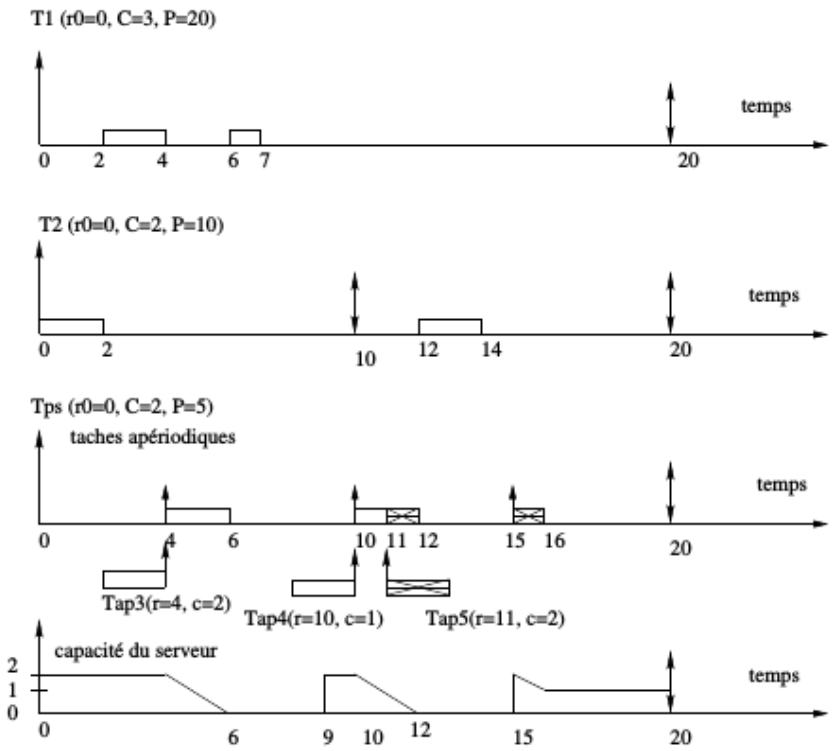

FIGURE: Ordonnancement “avec un serveur sporadique”

Tâches apériodiques à contraintes strictes

Les tâches apériodiques sont traitées sans hypothèse sur leur rythme d'arrivée. Elles sont ordonnancées selon "Earliest Deadline".

A chaque arrivée d'une tâche apériodique, une "routine de garantie" teste dynamiquement si la nouvelle tâche peut s'exécuter en respectant (1) ses CT, (2) celles des tâches périodiques et (3) celles des autres tâches apériodiques précédemment acceptées mais non terminées :
Si le test est positif, la tâche est acceptée.

Méthode pour tâches apériodiques à contraintes strictes

Il existe 2 politiques d'acceptation dynamique de tâches apériodiques qui favorisent toutes les 2 les tâches périodiques, car les tâches apériodiques génératrices de surcharge sont rejetées. Ces politiques sont applicables notamment sur un système réparti où un mécanisme de partage de charge permet de faire exécuter une tâche rejetée sur un site par un autre site moins chargé.

Ces 2 politiques sont :

1. Acceptation dans les temps creux d’une séquence rigide de tâches :

La méthode consiste à ordonnancer les tâches apériodiques dans les temps creux de la séquence d’ordonnancement “ED” des tâches périodiques.

C’est une politique proche de celle en ’arrière-plan’ vue précédemment, mais ici les tâches apériodiques ont des CT à respecter et sont elles-mêmes ordonnancées selon “ED” : à chaque réveil d’une tâche apériodique, une routine de garantie est exécutée.

Routine de garantie :

1) La routine teste l'existence d'un temps creux suffisant pour l'exécution de la tâche apériodique entre sa date de réveil et son échéance.

2) **Si ce temps creux existe**, alors elle vérifie que l'acceptation de la nouvelle tâche ne remet pas en cause le respect des CT de tâches apériodiques précédemment acceptées, non encore achevées (cette vérification ne concerne que les tâches apériodiques dont les échéances sont ≥ à celle de la nouvelle tâche).

3) Si au moins une des condition 1 ou 2 n'est pas satisfaite, alors la tâche est rejetée, sinon elle est ajoutée à l'ensemble des tâches apériodiques acceptées, pour être exécutée selon son échéance.

Exemple

La figure 9 montre que la configuration périodique “ED” présente, durant la période d’étude, trois intervalles de creux : [8,10], [13,15] et [17,20]. Les 3 tâches apériodiques Ta4 , Ta5 et Ta6 peuvent être acceptées dans ces temps creux :

Déroulement

- à t=4, Ta4 se réveille. Le temps creux existant entre sa date de réveil et son échéance est l'intervalle [8,10] = 2 unités, juste suffisantes pour exécuter la tâche. Ta4 dispose donc d'assez de temps pour s'exécuter dans le respect de ses CT, et comme il n'y a pas d'autre tâches apériodiques précédemment acceptées mais non terminée, elle est acceptée.
- à t=10, Ta5 se réveille. Le temps creux existant entre sa date de réveil 10 et son échéance 18, est de 3 unités (tout l'intervalle [13,15] + 1 unité de l'intervalle [17,20]). Il y a donc d'assez de temps pour exécuter Ta5 qui a un temps d'exécution égal à 1. Et comme il n'y a pas de tâches apériodiques acceptées et non terminées (Ta4 s'était exécutée entre 8 et 10), alors Ta5 peut être acceptée.

Déroulement (suite)

- à t=11, Ta6 se réveille. Le temps creux existant entre sa date de réveil 11 et son échéance 16 est de 2 unités ([13,15]), donc juste suffisant pour l'exécuter dans le respect de son échéance. Mais, il faut vérifier que son acceptation ne remet pas en cause les CT des autres tâches apériodiques acceptées non terminées (et d'échéances plus éloignées que la sienne). Ici Ta5, qui n'a pas encore commencé son exécution et dont l'échéance est 18. L'ordre d'exécution devient Ta6 puis Ta5 et on constate que chacune peut s'exécuter dans le respect de ses CT (car C=2 pour Ta6 et C=1 pour Ta5).

Ordonnancement dans les temps creux : Routine de garantie

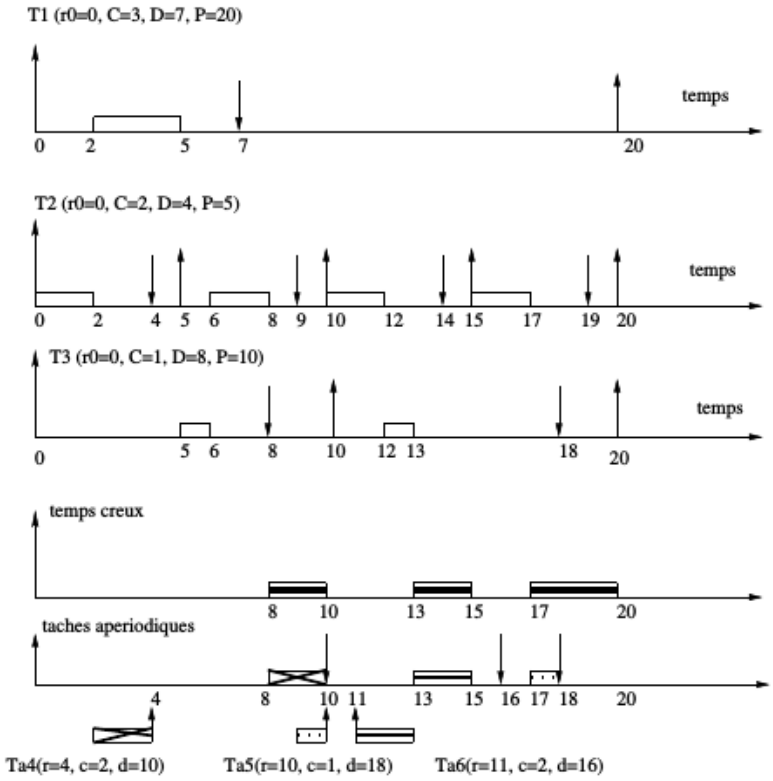

Figure: Ordonnancement “ dans les temps creux”

Figure 9 : Ordonnancement dans les temps creux

2. Acceptation des tâches apériodiques et ordonnancement conjoint aux tâches périodiques :

à chaque arrivée d'une nouvelle tâche apériodique, il y a construction d'une nouvelle séquence "ED" comprenant à la fois les tâches périodiques, les tâches apériodiques précédemment acceptées mais non terminées et la nouvelle tâche. Si la séquence peut être construite, alors la tâche est acceptée.

Les figures 17 et 18 montrent un exemple de fonctionnement et on voit que les 3 tâches apériodiques Ta4 , Ta5 et Ta6 peuvent être ordonnancées conjointement aux tâches périodiques.

A t=4, Ta4 se réveille. La séquence "ED" construite à t=4 comprend les tâches périodiques actives T1 (C(4)=1, d=7) et T3 , les requêtes à venir des tâches périodiques ainsi que la tâche qui arrive Ta4 . L'exécution de celle-ci sera planifiée entre t=8 et t=10. La séquence respecte les CT de toutes les requêtes qui la composent.

suite

- à t=10, Ta5 se réveille. La séquence “ED” construite à t=10 comprend les requêtes à venir des tâches périodiques T2 et T3 et celle de Ta5 . Ici aussi, la séquence “ED” permet le respect des CT de toutes les requêtes qui la composent. L’exécution de Ta5 acceptée est planifiée entre 13 et 14.
- à t=11, Ta6 se réveille (figure suivante 2.12). La séquence “ED” construite à t=11 comprend les tâches périodiques actives T2 (C(11)=1, d=14) et T3 , les requêtes à venir de la tâche périodique T2 ainsi que les tâches apériodiques Ta5 et Ta6 . La tâche Ta6 peut être ordonnancée sans remettre en cause, ni les échéances des tâches périodiques, ni celle de la tâche apériodique Ta5. Ta6 est donc acceptée.

Ordonnancement conjoint

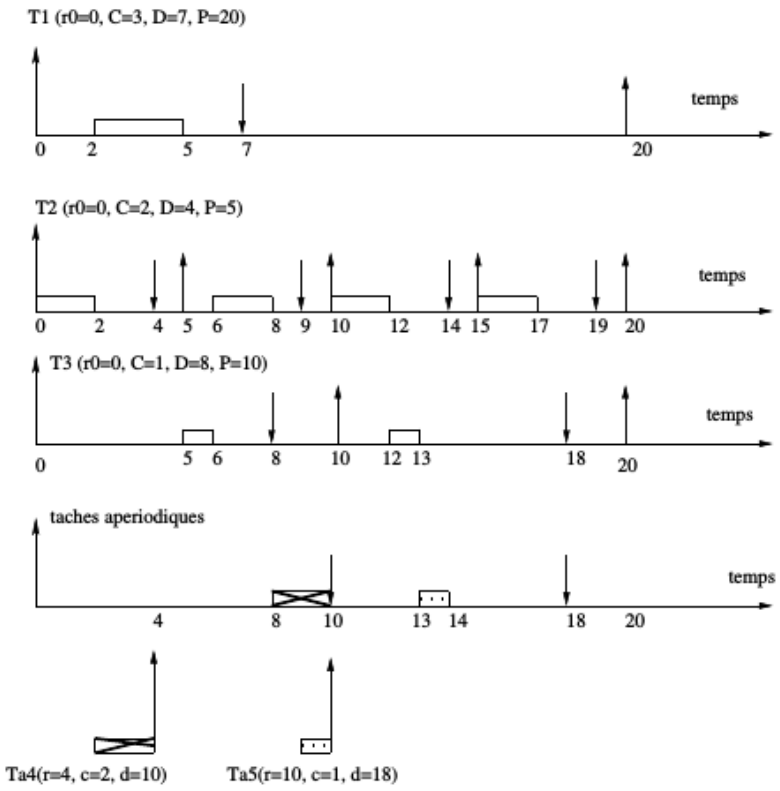

FIGURE: Ordonnancement “conjoint”

Ordonnancement conjoint

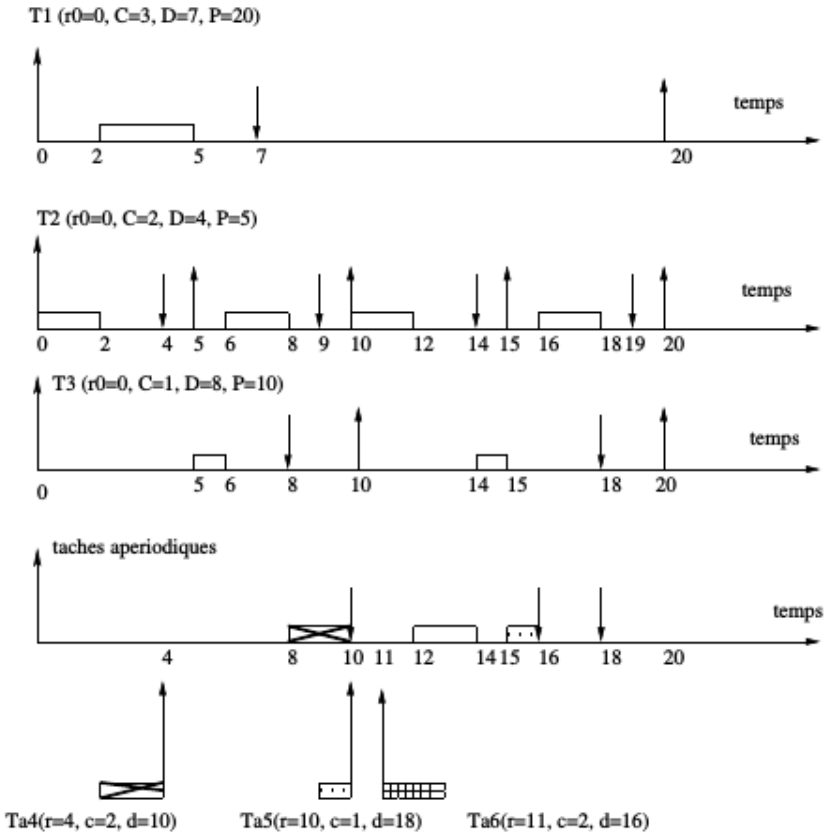

FIGURE: Ordonnancement “conjoint”