Ordonnancement sous contrainte d'énergie

Nicolas NAVET
INRIA projet TRIO
http://www.loria.fr/~nnavet

Certains exemples et représentations proviennent de :

- **« Voltage Scheduling Problem for Dynamically Variable Voltage Processors », T. Ishihara, Y. Yasuura**
- **« Energy-Centric Scheduling for Real-Time Systems », F. Gruian**

Le contexte (1/2)

- Pour

GSM

Ordinateurs portables

Implants medicaux

satellites

- Evolution actuelle:
  ↗ fréquences ⇒ ↗ consommation
  (ex: Pentium 4M 1.8Ghz=30W, 386=3W)

  or la technologie des batteries progresse peu …

- On estime que le CPU consomme entre 30% et 50% de l'énergie d'un ordinateur portable

Le contexte (2/2)

- Les contraintes de performances se traduisent en contraintes sur les dates d'échéances
- Comment diminuer la consommation CPU ?
  par réduction de la tension d'alimentation et donc la fréquence
- Les gains en autonomie sont importants

⇨ Ordonnancer, c'est ici choisir l'ordre ainsi que la fréquence de fonctionnement

Réduction de la consommation

- Technologies matérielles
  - taille transistors
  - codage Grey
  - alimentation des composants individualisée
  - circuits asynchrones
  - …
- Optimisation logicielles
  - remplacer op. mémoire-à-mémoire par registre-à-registre
  - inlining - loop unrolling
  - …
- Techniques hybrides
  - mise en veille de composants
  - **modification dynamique de la fréquence CPU**

Technologie des processeurs

- Vitesse fixe et mode(s) veille
  - au moins 2 modes : «normal» et «veille»
  - le pb est de sélectionner le mode de marche courant du système (*Dynamic Power Management* - DPM)
  - standard ACPI
- Vitesses (dynamiquement) variables
  - nombre de fréquences nécessairement fini
  - le pb est de d'adapter la fréquence de fonctionnement en ligne (*Dynamic Voltage Scaling* – DVS)
  - ex: *Crusoe*, *Pentium4M*, *LpARM* etc…

Modèle de consommation (1/4)

- Puissance dissipée en CMOS $\approx P_{dynamic} \sim \alpha \cdot f \cdot C \cdot V^2$
- Relation entre f et V: $f \sim V^{\gamma-1}$ Vitesse CPU: $S_f = \frac{f}{f_{ref}}$
- Puissance dissipée à la fréquence f : $P_f = P_{ref} \cdot S_f^{1+2/(\gamma-1)}$
- Énergie par cycle à la fréquence f :

$$e_f = \int_a^{a+1/f} P_f dt = \frac{1}{f} e_{ref} \cdot f_{ref} \cdot s_f^{1+2/(\gamma-1)} = e_{ref} \cdot S_f^{2/(\gamma-1)}$$

⇨ Pour $\gamma = 2$ (modèle MOSFET), l'énergie est quadratique en la vitesse – autres modèles: toujours convexe

Modèle de consommation (2/4)

- **Remarque :** fonctionnement lent > mode veille (DPM)

Une tâche de x cycles devant s'exécuter dans un temps T :

- x cycles à la fréquence f_{ref} puis veille: $E_{ref} = x \cdot e_{ref}$
- x cycles à la fréquence $f = x / T$:

$$E_f = x \cdot e_{ref} \cdot s_f^{\frac{2}{\gamma - 1}} \leq E_{ref}$$

- Plus généralement, du point de vue de la consommation, une vitesse unique jusqu'à l'échéance est la meilleure solution

Modèle de consommation (3/4)

- Exemple:

code: 10^9 cycles

D-A = 25s

Tension	Fréquence	Energie/Cycle
2.5 V	25Mhz	10nJ
4.0 V	40Mhz	25nJ
5.0 V	50Mhz	40nJ

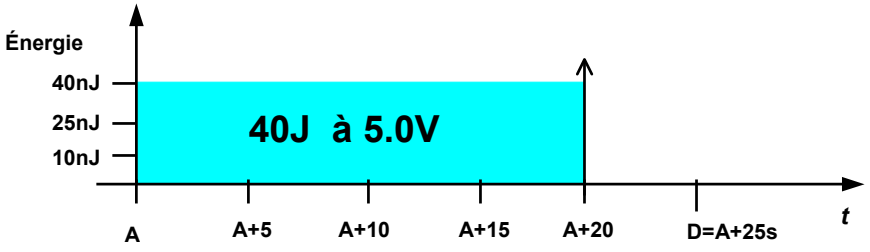

Fct à vitesse maximale

Modèle de consommation (4/4)

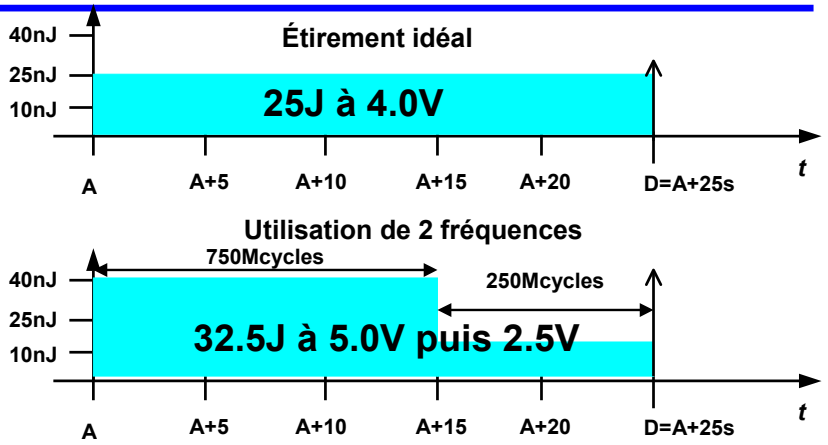

⇨si la vitesse idéale manque, l'utilisation des 2 vitesses adjacentes est la meilleure solution

Notions d'ordonnancement temps réel

- Modèles d'activité :
  - job : activité non récurrente ou
  - tâche : activité récurrente (généralement périodique) – les activations successives sont les instances de la tâche
- Caractéristiques des activités :
  - Ai : date de mise à disposition d'un job (ou d'une instance)
  - Ci : pire temps d'exécution d'un job (ou Worst-Case Execution Time - WCET) en général bien plus grand que le temps effectif (Actual E.T. ou AET)
  - Ti : période d'une tâche
  - Di : échéance d'un job

➢ Le problème principal du temps réel est la faisabilité du système (*i.e.* respect de toutes les échéances) …

Les ≠ stratégies d'ordonnancement

A. Politiques hors-ligne (ou statique): choix des fréquences effectué à la conception
B. Politiques en-ligne (ou dynamique): choix des fréquences effectué en-ligne

- Dans les 2 cas, l'ordre sur les activités est déterminé par un algorithme dynamique (le plus souvent, ex: EDF ou FPP) ou s'exécuter selon un cycle pré-calculé
- Les politiques en-ligne utilisent la connaissance des temps d'exécution réels (très ≠ du pire temps d'exécution)

Politiques hors-ligne

Classification selon le nombre de vitesses allouées:

I. Vitesse unique
II. Vitesse unique chaque tâche (*i.e.* pour toutes les instances d'une tâche récurrente)
III. Vitesse unique pour chaque instance d'une tâche
IV. Vitesse choisie pour un cycle d'horloge

Politiques en-ligne

I. Redistribution des temps d'exécution non-utilisés ('gain reclaiming')

II. Ordonnancement avec instrumentation du code ('compiler assisted scheduling' ou 'intra-task voltage scheduling')

➢ Les vitesses initiales sont calculées avec une stratégie hors-ligne

Politiques hors-ligne à vitesse unique

- Principes et limites
- Ordonnancement EDF ('Earliest Deadline First')
- Ordonnancement FPP ('Fixed-Priority Policy')
- Ordonnancement Round-Robin

Hors-ligne à vitesse unique (1/3)

- Objectif: déterminer la fréquence minimale admissible valable pendant toute la durée de vie du système
- Points + :
  - OS / CPU «standards» - pas d'overhead en-ligne
  - des résultats existent pour EDF, FPP, RR, … (possible si ∃ analyse d'ordonnançabilité pour la politique)
- Points - : performances ! L'activité la plus contrainte impose sa vitesse ..
- Nb: une telle politique peut néanmoins être optimale dans des cas particuliers (ex: EDF, Di=Ti, tâches synchrones)

Hors-ligne à vitesse unique (2/4)

- EDF [Gru02]: utilisation du test de Lui et Layland pour des tâches périodiques avec $D_k = T_k$
- Principe: les tâches sont faisables sous EDF ssi

$$\left(U_T = \sum_{\tau_i} C_i / T_i \right) \leq 1$$

La vitesse minimale acceptable est donc

$$S_{edf} = U_T$$

- Nb: pour des échéances quelconques, il faut utiliser le test (seulement suffisant) :

$$\left(U_T = \sum_{\tau_i} C_i / \min(D_i, T_i) \right) \leq 1$$

Hors-ligne à vitesse unique (3/4)

- FPP [Gru02]: utilisation du test de Lui et Layland pour des tâches périodiques avec $D_k = T_k$
- Principe: les tâches sont faisables sous FPP si

$$U_T = \sum_{\tau_i} C_i / T_i \leq m \cdot (2^{1/m} - 1)$$

La vitesse minimale acceptable est donc

$$S_{fpp} = \frac{U_T}{m \cdot (2^{1/m} - 1)}$$

- Pb: Le test n'est que suffisant et non nécessaire .. Il existe un test suffisant et nécessaire (dit test de Lehoczki)

Hors-ligne à vitesse unique (4/4)

- Round-Robin [BrNa04]: pas de test de faisabilité, il faut faire un calcul de temps de réponse pour chaque job ou instance …
- Observations :
  - la faisabilité n'est pas monotone en la vitesse
  - la vitesse nécessaire sous RR est toujours supérieure à la vitesse requise sous EDF (S*edf*)
  - un job qui finit plus tôt que prévu peut entraîner la non-faisabilité du système (mécanismes en-ligne)
- Algorithme: en partant de S*edf*, choisir la première vitesse disponible qui soit admissible

Politiques hors-ligne vitesse choisie par instance

- Principes et limites
- Ordonnancement EDF :
  - algorithme classique de Yao et al.
  - une solution algorithmiquement moins complexe

Hors-ligne - vitesse choisie par instance (1/x)

- Objectif: déterminer la fréquence de chacune des instances des tâches (ou des jobs) de telle façon à minimiser la consommation
- Points + :
  - efficacité très supérieure à une solution à vitesse unique
  - des résultats optimaux existent pour EDF et FPP
- Points - :
  - changements de fréquences effectués au niveau de l'ordonnanceur : adaptation de l'OS ..
  - nécessite de calculer et de stocker les fréquences pour (au minimum) un PPCM des périodes .. d'où l'intérêt des politiques à changements de vitesse par tâche

Hors-ligne - vitesse choisie par instance (2/x)

- La politique FPP: prouvé NP-difficile et approximation (1+ε) [YuKi2003]
- Le cas EDF: algo. classique de Yao [YaDeSh95]
  - facteur de charge : $U(t_1,t_2)=\dfrac{\sum_k C_k \cdot 1_{[t_1 \le A_k < t_2]} \cdot 1_{[D_k \le t_2]}}{t_2 - t_1}$
  - faisabilité ssi $\forall t_1,t_2 \;\; U(t_1,t_2) \le 1$
  - algorithme:

1) $[a,b[= \underset{t_1,t_2}{\operatorname{argmax}} U(t_1,t_2)$; fixer $S_{EDF}[a,b[= U(a,b)$

2) retirer $[a,b[$ et revenir en 1)

Hors-ligne - vitesse choisie par instance (3/x)

- Étape 2 de l'algorithme de Yao : suppression de l'intervalle [a,b[(dit intervalle critique)

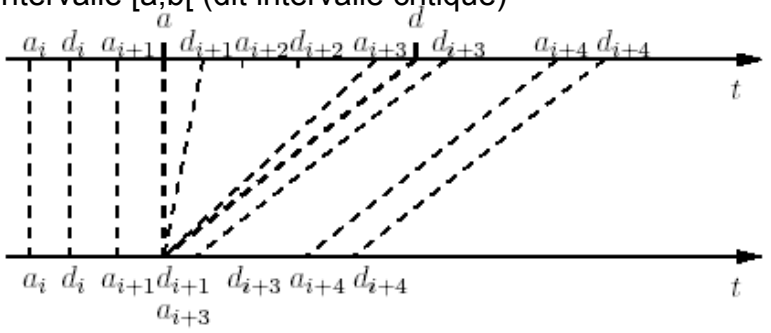

Complexité : $O(n \wedge 3)$ où *n* est le nombre d'instances

Nb: le premier intervalle critique détermine la faisabilité des tâches sous EDF : test de Spuri en $O(n \wedge 2)$

Hors-ligne - vitesse choisie par instance (4/x)

- Une solution moins complexe que l'algo. de Yao
  - $A(t)$: fonction d'arrivée de travail
  - $D(t)$: quantité de travail à faire avant t
  - $u(t)$: vitesse du processeur en l'instant t
  - $U(t) = \int_0^t u(s)\,ds$
  - $T = \max D_i$ est l'horizon d'optimisation

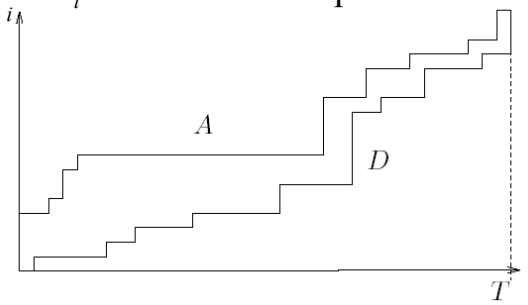

Hors-ligne - vitesse choisie par instance (5/x)

- Problème :

trouver $u(t)$ qui minimise $\int_0^T g(u(t))\,dt$ sous les contraintes:

- $\int_0^t u(s)ds \le A(t) \quad \forall t \in [0,T]$
- $\int_0^t u(s)ds \ge D(t) \quad \forall t \in [0,T]$
- $u(t) \ge 0$

➢ Pour des tâches à contraintes FIFO $(A_i \le A_j \rightarrow D_i \le D_j)$ sous EDF, le respect de ces contraintes garantit la faisabilité du système

Hors-ligne - vitesse choisie par instance (6/x)

- Solution pour des tâches FIFO (ie. des tâches t.q. $A_i \le A_j \rightarrow D_i \le D_j$) [GaNaWa03]:

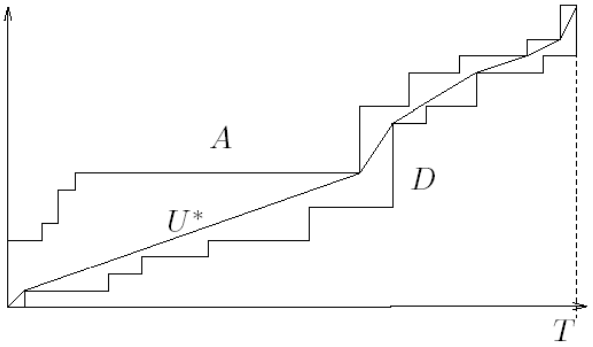

U^* est le plus court chemin de 0 à T

Hors-ligne - vitesse choisie par instance (7/x)

- Étapes:
  - la solution optimale est unique et valable pour toutes les fonctions convexes croissantes
  - $g(x) = \sqrt{1+x^2}$ est convexe croissante - la longueur de *u(t)* est $L = \int_0^T \sqrt{1+u^2(s)}\,ds$ - la solution optimale qui minimise L est donc le plus court chemin
- Avantages:
  - complexité : *O(n log(n))*
  - extensions possibles : nombre de vitesses finies, nombre de changements de contexte minimum, tâches fluides …

Hors-ligne - vitesse choisie par instance (8/x)

- Pour des tâches quelconques [GaNa04]

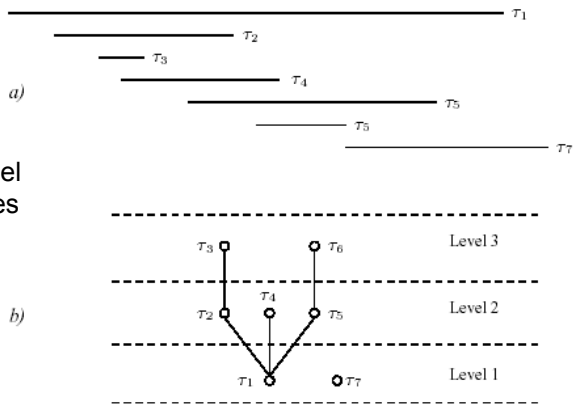

Relation d'ordre partiel « inclus dans » sur les intervalles [Ai,Di]

Hors-ligne - vitesse choisie par instance (8/x)

- Notations:

- *K* est le nombre de niveaux dans le diagramme de Hasse
- $u_i^*(t)$ est la vitesse qui conduit au plus court chemin pour le pb restreint aux tâches de niveau *i*...K (cf. tâches FIFO)

- Algorithme:

1. pour *i*=1..K construire $u_i^*(t)$; $r_i = \sup_{0 \le t \le T} u_i^*(t)$

l'intervalle critique [a,b] est t.q. sa charge est $W_{[a,b]} = \sup_i r_i$

2. la vitesse sur [a,b] est $W_{[a,b]}$; on retire [a,b] et retour en 1.

- Complexité : O(n^2 K) dans le pire cas - O(n^2 log(n)) en moyenne (vs n^3 dans les 2 cas pour Yao)

Politiques hors-ligne vitesse choisie par cycle

- Ordonnancement stochastique

Ordonnancement stochastique (1/2)

- Objectif: Minimiser l'espérance de l'énergie consommée

avec: $$\overline{E} = \sum_{x=1}^{WCE} (1 - F(x)) \cdot e_x$$

· WCE : le nbre de cycles correspondant au WCET

· e_x : énergie consommée au cycle x

· $F(x)$: probabilité de terminer avant le cycle x

- Résultat [Gru02] : temps de cycle optimal k_y

$$k_y = (D - A) \cdot \frac{\sqrt[3]{1 - F(y)}}{\sum_{x=1}^{WCE} \sqrt[3]{1 - F(x)}}$$

Ordonnancement stochastique (2/2)

- Remarque : la vitesse augmente graduellement – les vitesses élevées ne seront généralement pas utilisées
- Problèmes:
  - nécessité d'une distribution des temps d'exécution
  - WCE est grand d'où la nécessité de travailler sur des groupes d'instructions : comment découper ?
  - transcription fréquences calculées vers les fréquences disponibles …
  - une tâche seule se verra allouer un temps (D-A), quid du cas multi-tâches ??

Politiques en-ligne

- Redistribution des gains ('Gain Reclaiming')
- Instrumentation du code ('Compiler Assisted Scheduling')

Redistribution des gains

- Idée : lorsqu'une tâche termine, on calcule la différence entre son WCET et son ACET. On redistribue le temps 'gagné' :
  - à la tâche qui débute son exécution [AyMe04]
  - à toutes les tâches en attente (selon le temps d'exécution [PiSh01], selon l'ordre …)
- Extension : ('speculative speed reduction')
  - on anticipe que les tâches en attente n'utiliseront pas leur WCET
  - … mais on fixe les vitesses de façon à pouvoir respecter les échéances si c'était le cas

Ordonnancement avec instrumentation du code

- Idée: évaluer en-ligne le pire temps d'exécution restant en insérant des points de mesure dans le code (ex: [ShLeKi01])
- Principe:
  - re-calcul du WCET restant après chaque section ('basic block')
  - répartition du gain sur les sections suivantes
- Problèmes:
  - nécessité d'instrumenter le code
  - choix de la bonne granularité d'instrumentation ??

Profils de consommation selon la stratégie

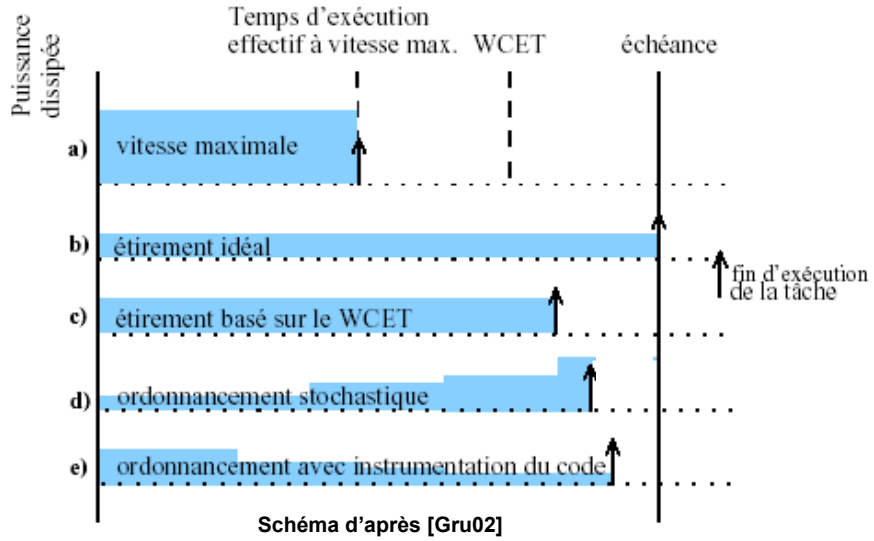

Schéma d'après [Gru02]

Conclusions (1/2)

- Le gain est fonction de la charge du système …
- La stratégie d'ordonnancement sera choisie en fonction :
  - des contraintes de l'OS, du CPU et de l'application
  - de l'écart entre le pire temps d'exécution (WCET) et le temps d'exécution effectif (AET)

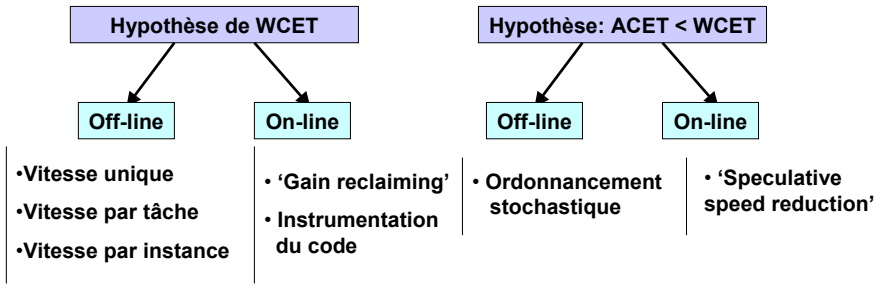

Conclusions (2/2)

- Des solutions d'ordonnancement efficaces existent dans la majorité des contextes ..
- Des modèles plus réalistes sont possibles:
  - prise en compte du temps de changement de fréquence et du temps minimum entre deux changements
  - toutes les instructions ne consomment pas la même énergie ..
  - modèles de batteries plus réalistes

⇨Les stratégies d'ordonnancement s'insèrent dans une approche de conception « système » qui intègre compilation, OS, architecture matérielle etc…

Références

- [YuKi03] H.-S. Yun and J. Kim. *On energy-optimal voltage scheduling for fixed-priority hard real-time systems*. ACM TECS, 2003.
- [YaDeSh95] F. Yao, A. Demers, and S. Shenker. *A scheduling model for reduced CPU energy*. Proc. IEEE FOCS, 1995.
- [GaNaWa03] B. Gaujal, N. Navet, C. Walsh. *Shortest path algorithms for real-time scheduling with minimal energy use*. submitted to ACM TECS, 2003. Available as INRIA Research Report RR-4886.
- [GaNa04] B. Gaujal, N. Navet. *A new EDF feasibility test*. To appear as INRIA Research Report, 2004.
- [BrNa04] R. Brito, N. Navet. *Low Power Round-Robin Scheduling*. To appear in Proc. RTS'04.
- [GaNa03] B. Gaujal, N. Navet. *Ordonnancement sous Contraintes de Temps et d'Énergie*, Actes École Temps Réel, 2003.
- [Gru02] F. Gruian. *Energy-Centric Scheduling for Real-Time Systems*. PhD thesis, Lund Institute of Technology, 2002.
- [AyMe04] H. Aydin, R. Melhem, D. Mosse and P.M. Alvarez. Power-aware Scheduling for Periodic Real-time Tasks. To appear in IEEE Transactions on Computers.
- [PiSh01] P.Pillai and K. G. Shin. *Real-time Dynamic Voltage Scaling for Low Power Embedded Operating Systems*. In Proceedings of the 18th Symposium on Operating System Principles, October 2001.
- [ShLeKi01] D. Shin, S. Lee and J. Kim. *Intra-task Voltage Scheduling for Low-Energy Hard Real-time Applications*. In IEEE Design and Test of Computers, March 2001.