

Minimiser l'impact des communications lors de l'ordonnancement d'applications parallèles temps réel sur des multi-cœurs

Thèse de doctorat

Benjamin Rouxel

Équipe Pacap/Cairn

Directeur: Isabelle Puaut

Co-directeur: Steven Derrien

Institut de Recherche en Informatique et Systèmes Aléatoires

Systemes embarqués temps réel


- Spécialisés
- Autonomes
- Capacité limitée



- Contraintes temporelles



Éléments de schématisation des systèmes temps réel mono-cœur




Estimation du
pire temps
d'exécution

Stratégie
d'ordonnancement

Estimation du pire temps d'exécution sur 1

- Mesures
- Statique

Wilhelm'2008




Stratégie d'ordonnancement mono-cœur

Définition


- Déterminer l'ordre d'exécution des tâches

Taxonomie *George'96*

- *Davis'09* Hors-/En-ligne
- (Non-)pré-emptif
- Priorité statique/dynamique
- Dirigé par le temps/des événements



Éléments de schématisation des systèmes temps réel multi-cœur



Estimation du
pire temps
d'exécution

Stratégie
d'ordonnancement

Stratégie de
placement

Gestion des
ressources
partagées


Placement & ordonnancement

Définition

- Déterminer le cœur et l'ordre d'exécution des tâches

Taxonomie *George'96* *Davis'09*


- Hors-/En-line
- (Non-)pré-emptif
- Priorité statique/dynamique
- Dirigé par le temps/des évènements
- Partitionné
- Global



Gestion des ressources à l'ordonnancement



	Pire contention	Contention considérée	Sans contention
Accès mémoire bloquants	<i>Tendulkar'14</i> <i>Alhammad'14</i>	<i>Nguyen'17</i> <i>Puffitsch'15</i> <i>Skalistis'17</i> Contribution 1	<i>Becker'16</i> <i>Alhammad'14</i>
Accès mémoire masqués	<i>Kudlur'08</i> <i>Cho'09</i>		<i>Becker'18</i> Contribution 2



Contributions principales

Contribution 1 :


- **Génération d'ordonnancements consciente des interférences**

Contribution 2 :

- **Génération d'ordonnancements masquant les latences de communication**


Quantifier les interférences en ordonnant hors-ligne

Exemple



Contributions (1): Réduire les délais de contention

Application en graphe



Pire temps
d'exécution

- **Traitement**
- **Communication**

Stratégie d'ordonnancement

- **ILP**
- **Heuristique**




Connaissance




du logiciel
de l'ordonnancement

Ordonnancement conscient de la contention



- Hors-ligne
- Partitionné
- Dirigé par le temps
- Non-préemptif


Architecture multi-cœur




Graphe d'application & Modèle d'exécution

- Graphe orienté acyclique (DAG)
- Modèle d'exécution prédictible (AER)

Maia'2016




Acquisition - Exécution -
Restitution



Architecture matérielle & modèle de communication

- Architecture multi-
cœur
 - Mémoire ScratchPad (SPM)
 - Bus arbitré avec une politique FAIR-Round-Robin
- Enslow'197*



$T_{\text{créneau}}$: temps max
d'accès
Accès mémoire bloqué

Information temporelle des phases

Pire temps d'exécution pour la phase: *exécution*


- En isolation des autres tâches
- Utilisation des méthodes statiques de l'état de l'art

Pire temps d'exécution pour les phases: *acquisition/restitution*

- Utilisation d'un modèle du bus
- Nécessite de déterminer la contention (nombre d'interférences)

Calcul du coût de communication


Arbitrage
FAIR-Round-
Robin



délai = **#interférence** + Temps
d'accès **nce**

Calcul du pire degré d'interférence

Pire degré d'interférences: $\text{NBCœurs} - 1$



Calcul du degré d'interférence à l'ordonnancement

Calcul du degré d'interférence

- **Nombre de cœurs ayant des phases chevauchantes**




Connaissance

- **Seules les tâches concurrentes se chevauchent** du logiciel


- Fermeture transitive du DAG avec l'algorithme de Warshall

- **Chevauchement des phases i et j**



Calcul du degré d'interférence à l'ordonnancement

 Connaissance
de
l'ordonnancement



$$\text{Nombre d'interférence}_i^X = \sum_{p \in P} \left[\bigvee_{j \in T \vee \text{concurrent}(i, j)} ((\text{recouvre}(X_i, \text{acquisition}_j) \vee \text{recouvre}(X_i, \text{restitution}_j)) \wedge \text{placé}(j, p)) \right]$$

où X peut représenter une acquisition ou res



 Connaissance
du logiciel

Technique d'implémentations

- **Programmation linéaire en nombre entiers (ILP)**
 - Solution exactes
 - Lent
- **Forward List Scheduling (FLS)**
 - Solutions approximées
 - Rapide

Programmation linéaire en nombre entiers (ILP)

Rappel

- **Fonction objectif (maximiser ou minimiser)**
- **Ensemble de variables et d'inégalités linéaires (contraintes)**
- **Formalisation non-ambigüe**

Notre implémentation ILP consciente de la contention

- **Objectif: minimiser la taille de l'ordonnancement**
- **Contraintes de placement**
 - Une tâche est placée sur un et un seul coeur
- **Contraintes d'ordonnancement**
 - Pas de chevauchement de phases de même type sur le même coeur
 - Précédences entre phases et entre tâches
- **Calcul des coûts de communication**

Forward List Scheduling (FLS)

Rapp
el

- **Heuristique**
- **Solutions approximées**
- **Pas de remise en question des décisions passées**
- **Passage à l'échelle**

Notre implémentation FLS consciente de la contention

- **Ordonner les tâches**
- **Essayer de placer une tâche le plus tôt sur chaque coeur**
 - Pas de chevauchement de phases de même type sur le même coeur
 - Précédences entre phases et entre tâches
 - Calcul des coûts de communication
- **Garder le placement/ordonnancement avec la longueur minimale**
- **Recommencer avec une autre tâche**

Problèmes cachés ici, mais détaillés dans la thèse:

- Générer un ordonnancement sans contention
- Calculer les interférences modifie les décisions passées



Dégradation de l'heuristique comparé à l'ILP

- **Générateur de graphes de tâches (TGFF)** *Dick'1998*
- **Cas de tests synthétiques, large ensemble de topologies**
- **Paramètres:**
 - Nombre de graphes : 50
 - Nombres de tâches : [5 ; 69]
 - Nombre de coeurs: {2, 4, 8, 12}
 - $T_{\text{créneau}}$: [1 ; 10]
 - Timeout : 11h

Dégradation de l'heuristique comparé à l'ILP

Dégradation

- Minimal : 0 %
- Moyenne : 2 %
- Maximal : 20 %



Temps de génération moyen

- ILP : 4,2 heures
- FLS : 1,5 secondes

Gain d'amélioration du pire cas (NBCores-1)


- Base : contention pessimiste
- Suite de cas de tests STR2RTS
- Cas de tests réels
- Graphe de type fork-join
- Flux de données fixes → WCET connu à la compilation

Rouxel'2017

- #Tâches : [7;201]
- Largeur max : [2;36]
- Nombre de coeurs:
 {2,4,8,12}
- $T_{\text{créneau}}$: [1;10]

Gain d'amélioration du pire cas (NBCores-1)

■ gain d'amélioration du pire avec la conscience des interférences



**59% en
moyenne**



Conclusions contribution 1

Objectif

- **Améliorer l'estimation pessimiste des interférences à l'ordonnancement hors-ligne**


Leçons

- **Apprentissage de calcul des interférences**
- **Faible dégradation de l'heuristique**
- **Amélioration du pire cas**


Limite

- **Gain similaire aux ordonnancements sans contention**


Zoom sur un ordonnancement sans contention




 Masquer les communications



Masquer la latence des communications




 Fragmenter les communications




~~7~~
1

69unités de temps

Fragmenter les phases de communication




**Gain :
20%**



~~7~~ ~~69~~ 6 unités de temps

Contributions (2): Cacher les délais de communication

Graphe d'application




Pire temps
d'exécution

- **Communication**

Stratégie
d'ordonnancement

- **ILP**
- **Heuristique**

Architecture multi-cœur




Masquer les communications



Fragmenter les communications


Ordonnancement sans contention & schéma d'allocation



- Hors-ligne
- Partitionné
- Non-préemptif

Support matériel

- Moteur d'accès direct à la mémoire (DMA)
- SPM à double accès



ILP masquant les communications fragmentées

- **Objectif: minimiser la longueur de l'ordonnancement**
- **Contraintes de placement**
- **Contraintes d'ordonnancement**
 - Aucun chevauchement des phases de communication
- **Contraintes de réservation de mémoire en SPM**
 - Une phase de communication est allouée à une et une seule région
 - Aucun chevauchement des temps de réservation


FLS masquant les communications fragmentées

- **Ordonner les tâches**
- **Essayer de placer une tâche le plus tôt possible sur chaque coeur**
 - Aucun chevauchement des phases de communication
- **Allouer les régions de la SPM**
 - Chercher une région déjà allouées mais non réservée sur la période d'utilisation de la tâche
 - Si non trouvée, créer une nouvelle région
 - Si pas assez d'espace mémoire, lever une exception
- **Garder le placement/ordonnancement avec la longueur d'ordonnancement minimale**
- **Recommencer avec une autre tâche**

Gain observé sur les benchmarks synthétiques

- Base : non-masqué et non-fragmenté
- Cas de tests synthétiques (TGFF)

Dick'1998




**8% en
moyenne**



Gain observé sur les benchmarks réels

- Base : non-masqué et non-fragmenté
- Cas de tests réels avec STR2RTS

Rouxel'2017



**4% en
moyenne**


Choix de la taille des fragments

Base : communications bloquantes

Rouxel'2017

Temps de génération m

- Pas de fragments : < 1
- successeurs : < 1 sec.
- $T_{\text{créneau}}$: > 5 min.
- TDE : < 4 min.



Implémentation de l'ordonnancement

- Kalray MPPA 256 Bostan
- 1 grappe, 16 coeurs
- 16 bancs mémoires privatisés
- 8 bus, arbitrage par priorités fixes
- Limité à 8 cœurs
- 1 coeur réservé: DMA applicatif
- WCET & coûts de communication mesurés

Gain d'amélioration du pire cas, base : *Pas de fragments*

- Par successeurs : 36 %
- Par $T_{\text{créneau}}$: 22 %
- Par taille de données : 12 %



Conclusions contribution 2

Objectif

- **Réduire la longueur d'ordonnancements sans contention**

Leçons

appreintes **Fragmenter les communications**

- **Amélioration du pire cas**

Limite

- **Graphe de type fork-join**

Conclusions

Objectif

- **Réduire l'impact des communications sur l'ordonnancement hors-ligne**

Méthodes

- **Réduire les délais de contention**
avec  Connaissance **&**  Connaissance de
- **Réduire la longueur d'ordonnancement**
avec  Masquer les communications **&**  Fragmenter les communications

Résultats

- **Gain en considérant les interférences**
- **Gain en augmentant les opportunités d**

Perspectives

- **Étendre vers les réseaux sur puces**
- **Autoriser les communications de SPM à SPM**
- **Étendre le calcul des interférences**
 - au modèle non-AER
 - au modèle pré-emptif
- **Affiner le calcul des interférences**
- **Améliorer l'implémentation sur le Kalray MPPA**

Merci pour votre
attention



Liste des publications

- Benjamin Rouxel, Steven Derrien, and Isabelle Puaut. Tightening contention delays while scheduling parallel applications on multi-core architectures. ACM Transactions on Embedded Computing Systems (TECS), 2017, vol. 16, no 5s, p. 164.
- Benjamin Rouxel, Steven Derrien, and Isabelle Puaut. Overlapping communications and computations in SPM-based multi-core architectures. Submitted to RTAS'2019.
- Benjamin Rouxel, and Isabelle Puaut. STR2RTS: Refactored StreamIT benchmarks into statically analyzable parallel benchmarks for WCET estimation & real-time scheduling. In : OASICS-OpenAccess Series in Informatics. Schloss Dagstuhl-Leibniz-Zentrum fuer Informatik, 2017.
- Martin Schoeberl, Benjamin Rouxel, and Isabelle Puaut, « A Time-predictable Branch Predictor », Symposium on Applied Computing (SAC), 2019.
- Damien Hardy, Benjamin Rouxel, and Isabelle Puaut, « The Heptane Static Worst-Case Execution Time Estimation Tool », in: 17th International Workshop on Worst-Case Execution Time Analysis (WCET 2017), vol. 8, 44 Schloss Dagstuhl-Leibniz-Zentrum fuer Informatik, 2017, pp. 1-812.

Schéma d'allocation mémoire en SPM

- Diviser la SPM en régions
- Allocation des phases de communication aux régions
- Assurer l'intégrité des données

Kim'2014



Vie des données acquises





Vie des données locales




Vie des données restituées

Construction de l'ensemble des tâches associées




Forward List Scheduling: adjusting the schedule



Pourquoi c'est difficile d'avoir des interférences précises

Multi-DAG, multi-période → Comment serait étendue la notion de makespan dans le cas d'application multi-périodiques ?

Cell processor



SPE : Synergistic Processing
SXU : Synergistic Execution
LS : Local Storage

James Kahle, Michael Day, Peter Hofstee, Charles Johns, Theodore Maeurer, and David Shippy. Introduction to the Cell multiprocessor. IBM Journal of Research and Development, 49(4/5):589-604, September 2005.

Complexité heuristique

Polynomial, degré 2

```

1 Function ListSchedule( $G = (T, E), P$ )
2   Elist  $\leftarrow$  BuildListElement( $G$ )
3   Qready  $\leftarrow$  TopologicalSortNode(Elist)
4   Qdone  $\leftarrow \emptyset$ 
5   schedule  $\leftarrow \emptyset$ 
6   while  $elt \in$  Qready do
7     Qready  $\leftarrow$  Qready  $\setminus \{t\}$ 
8     Qdone  $\leftarrow$  Qdone  $\cup \{t\}$ 
9     if  $elt$  is a read fragment  $\vee$   $elt$  is a write fragment then
10      ScheduleElement(Qdone,  $elt$ , null)
11    else if  $elt$  is an exec phase then
12      /* tmpSched contains the best schedule for the current task
13      tmpSched  $\leftarrow$  schedule with makespan =  $\infty$ 
14      foreach  $p \in P$  do
15        copy  $\leftarrow$  schedule
16        ScheduleElement(Qdone,  $elt$ ,  $p$ )  $\rightarrow O(|T|)$ 
17        tmpSched  $\leftarrow \min_{makespan}(\text{tmpSched}, \text{copy})$ 
18      schedule  $\leftarrow$  tmpSched
19    if all fragments and exec phase of the task  $i$  containing  $elt$  are in Qdone then
20      AssignRegion(schedule, Qdone,  $\tau_i^e, SS_t + CS_t, 0, infinity$ )  $\rightarrow O(|R|)$ 
21      foreach  $f \in F_i^r$  do
22        AssignRegion(schedule, Qdone,  $f, D_{(i,f)}^r, \rho_{(i,f)}^r, \rho_i^e + C_i$ )  $\rightarrow O(|F_i^r| * |R|)$ 
23      foreach  $f \in F_i^w$  do
24        AssignRegion(schedule, Qdone,  $f, \rho_i^e, \rho_{(i,f)}^w + DELAY_{(i,f)}^w$ )  $\rightarrow O(|F_i^w| * |R|)$ 
25  return schedule
  
```

$O(|P|)$

$O(|T|)$

$O(|R|)$

$O(|F_i^r| * |R|)$


$O(|F_i^w| * |R|)$

StreamIT description


Name	#Tasks	Width
802.11a	113	7
audiobeam	20	15
beamformer	56	12
compCnt	31	8
dct_comp	13	3
dct_verif	7	2
fft2	26	2
fft3	82	16
fft4	10	2
fft5	115	16
fhr	29	7
filterbank	53	8

Name	#Tasks	Width
fm	67	20
hdtv	150	24
merge	31	8
mp3	116	36
mpd	201	5
mpeg2	43	3
nokia	178	32
perftest4	16	4
tconvolve	75	36
tde	15	12
vocoder	115	17

Gain observé sur les benchmarks réels



2) Gain d'amélioration du pire cas (NBCores-1)



Gain similaire

Gestion des ressources à l'ordonnancement

	Pire contention	Sans contention	Contention considérée
Accès mémoire bloquants	<i>Tendulkar'14</i> <i>Alhammad'14</i>	<i>Becker'16</i>	<i>Nguyen'17</i> <i>Puffitsch'15</i> <i>Skalistis'17</i> Contribution 1
Accès mémoire cachés	<i>Kudlur'08</i> <i>Cho'09</i>	<i>Becker'18</i> Contribution 2	Composition →