



# Performances et évolution de DACCOSIM sur architecture distribuée

**Cherifa Dad, Stéphane Vialle, UMI GT-CNRS, CentraleSupélec,  
Université Paris-Saclay, Metz**



**Jean-Philippe Tavella, Mathieu Caujolle, EDF Lab Paris-Saclay**

**Workshop POMME  
29-03-2016**

**1. DACCOSIM**

2. Problématique

3. Méthodologie

4. Use Case



5. Expérimentations et optimisations

7. Conclusion

8. Synthèse du projet

- Définition, architecture, synchronisation


- Distributed Architecture for Controlled CO-SIMulation
- Concevoir, distribuer une multi-simulation sur des nœuds multi-cœurs
- Dédicée pour les systèmes continus discrétisés à pas de temps
- FMU type co-simulation




- Deux mode de synchronisation :
  - Ordered
  - Overlapped

Cartographie des threads :

- thread pour les calculs
- threads de communication (inter- ou intra-nœud)
- thread de sauvegarde (IO)



- Les FMU d'une même couleur → le même nœud
- Copier / coller de parties du modèle



### Graphe de FMU

- ❖ Composants hétérogènes
- ❖ Composants fortement couplés
- ❖ Aucune information sur *l'intensité arithmétique* des composants
- ❖ Graphe de tâches contraint par des pas de temps

→ problème atypique à distribuer  
(pas un *graphe de tâches* std)

### Cluster de PC multi-coeurs

- Temps de calcul sur 1 cœur ?
  - Temps de calcul sur 1 nœud ?
  - Temps de calcul sur 1 cluster ?
- (le parallélisme ne sera pas parfait...)

→ Quelle distribution des FMU  
sur les nœuds et les cœurs ?

?

**Définir une démarche de distribution des FMU pour minimiser le temps global de multi-simulation**


- ✓ Équilibrage de charge
- ✓ Réduction du coût de communication
- ✓ Optimisation de l'usage des ressources



Définir les stratégies de distribution  
+ *tests et benchmarking*



Mesurer les temps de calcul  
(*benchmarking*)



Étudier les performances sur cluster de PC multi-cœurs  
(*benchmarking*)




Etudier l'impact du nbr de cœurs sur le temps de calcul  
(*benchmarking*)

-Description de use case

- Fourni par l'équipe ENERBAT
- Basé sur BuildSysPro (EDF Modelica library)
- Transfert de chaleur dans un immeuble à 3 étages

➤ Phénomènes physiques :


- *Conduction*
- *Convection*
- *Radiation longue d'onde*
- *Radiation solaire*




➤ *Boundary conditions :*

- *Données météorologiques*
- *Condition spécifique pour le vide sanitaire et le dernier étage*

## Benchmark fourni par Enerbat : transfert de chaleur dans des immeubles (3 étages) basé sur BuildSysPro (EDF Modelica library)



- ✓ un immeuble de 11 FMU
- ✓ niveaux de complexité 3 et 5
- ✓ réplication des immeubles jusqu'à 8



- ✓ Environnement : deux clusters d'exécution
  - 16 nœuds x 4 cœurs (Nehalem), 1Gbit/s
  - 16 nœuds x 6 cœurs (Sandy Bridge), 10Gbit/s

## 1. Caractérisation des FMU

Chaque FMU  $\langle tps\_calcul, tps\_control, tps\_comm \rangle$


Exécution sous des conditions réelles



### Résultats :

- Enerbat3\_05 : 2 grosses FMU, 4 moyennes (50% d'une grosse) et 5 négligeables
- Enerbat3\_03 : 2 grosses FMU, 4 moyennes (75% d'une grosse), 3 petites (20% d'une grosse) et 2 négligeables

## 2. Comportement sur un nœud multi-cœurs



Résultats sur 1 nœud à 6 cœurs :


$tps(6 \text{ FMU}, 1 \text{ nœud})$

>


$tps(1 \text{ FMU}, 1 \text{ nœud})$

Fig 1: computation time on a Sandy Bridge node

### 3 & 4. Comportement et stratégies sur cluster de multi-cœurs :



- Minimiser les communications inter-noeuds
- Équilibrer la charge des calcul entre les noeuds



- S1 : équilibrage de charge
- S2 : maximiser les comms. intra-noeud + équilibrage de charge

#### Résultats :

- ✓ Stratégie S2 meilleure que S1
- ✓ **Un speedup de 1,38** (sur 3 noeuds)
- ✓ Résultats identiques à [0.3% - 1%] près .... **en cours d'analyse.**


Fig 2: co-simulation time on a Nehalem PC Cluster

-Size up sur b buildings


**Réplication** : 1 building sur n1 nœuds → b buildings sur b × n1 nœuds

**Notation** : T(1 building, n1 nœuds) : répartition optimale sur n1 nœuds  
 T(b buildings, b × n1 nœuds)


On espère :  $T(b, b \times n1) = T(1, 1 \times n1) = C^{st}$  sur nos clusters



Enerbat3\_05 sur 4 nœuds (s1 : charge)



Enerbat3\_03 sur 3 nœuds (s2 : charge + comms)



### Expérience de « size up » :




Fig 3: Size up experiments on cl5 benchmark




Fig 4: Size up experiments on cl3 benchmark

Use case avec une complexité 5 :

- ✓ Les communications sont négligeables vis-à-vis la charge de calcul
- ✓ Stratégie : équilibrage de charge
- ✓ Réplication de la bonne répartition (n × 4 noeuds)

→ **Size up (presque) idéal**

Use case avec une complexité 3 :

- ✓ Communications non négligeables
- ✓ Stratégie : éq. de charge + comms
- ✓ Réplication de la bonne répartition (n × 3 noeuds)

→ **Les performances en 10Gb/s sont meilleures qu'en 1 Gb/s**


→ **Size up acceptable en 10Gb/s**

### Expérience de « passage à l'échelle » : profils d'accélération de pbs croissants

- ✓ Use case de complexité 3 (calcul & communication)
- ✓ Distribution élémentaire : 1 building sur 3 nœuds (stratégie « charge & comms »)
- Quelles accélérations pour des pbs plus gros (plus de buildings) ?
- Comportements similaires quand le problème grossit ?

$$T_{ideal}(b \text{ buildings}, n \text{ nœuds}) = T(b \text{ buildings}, 1 \text{ nœud}) / n$$

*Mais exécution sur 1 seul nœud pas toujours possible*




**Expérience de « passage à l'échelle » : profils d'accélération de pbs croissants**

- ✓ Use case de complexité 3 (calcul & communication)
- ✓ Distribution élémentaire : 1 building sur 3 nœuds (stratégie « charge & comms »)
- Quelles accélérations pour des pbs plus gros ?
- Comportements similaires quand le problème grossit ?

$$T_{ideal}(b \text{ buildings}, n \text{ nœuds}) = T(b \text{ buildings}, 1 \text{ nœud}) / n$$

*Mais exécution sur 1 seul nœud pas toujours possible*



**Résultats :**

- Tous les pbs accélèrent
- **Courbes de temps « parallèles »**  
Comportements similaires
- Un **bon speedup de 9,67** pour 5 buildings sur 15 nœuds hexa-cœurs (vs 1 nœud hexa-cœurs)
- Pas assez de nœuds pour pousser le pb avec 8 buildings...

Fig 5: CI3 benchmark time with 4, 5 and 8 buildings on 10Gb/s

## Améliorations des communications de DACCOSIM :

- Implantation actuelle avec la lib. « ZeroMQ »
- Beaucoup de petits messages : sensibles à la latence et à la Bw
- Perfs DACCOSIM sur Eth 10Gb/s > perfs sur Eth 1Gb/s



→ Exploiter des clusters HPC « **Infiniband** » (standard HPC)


→ Utiliser la lib. « **MPI** » implantée directement sur Infiniband [1]



## CEI 2015-2016 EDF-CentraleSupélec : « portage DACCOSIM sur MPI »

- 50% de DACCOSIM porté sur MPI
- **Mais ... plus lent que ZeroMQ sur Eth 10Gb/s**
  - ✓ petits messages pas adaptés à MPI
  - ✓ archi. logicielle de DACCOSIM conçue pour ZeroMQ
  - ✓ ZeroMQ conçu pour des réseaux std (efficace sur Ethernet)

→ DACCOSIM sur **ZeroMQ** et **MPI**, et sélection au runtime



Infiniband

Ethernet

[1] « Message passing on InfiniBand RDMA for parallel run-time supports ». University of Torino & University of Pisa.

- ❖ Benchmarks d'un *use case ENERBAT* avec deux complexités différentes sur deux clusters différents
- ❖ Comportement complexe des cœurs d'un nœud en fonction du nombre de FMU supportées
- ❖ Conception et expérimentation d'une méthodologie et de deux premières stratégies de distribution sur cluster
- ❖ Diminution significative du temps de multi-simulation
- ❖ Exécution jusqu'à 81 FMU sur 12 nœuds
- ❖ Première solution au dessus de MPI



### Prochaines étapes :

- Automatisation de la distribution des FMU sur les nœuds de calcul
- Optimisation de la taille des messages échangés entre FMU
- Implantation sur MPI (pour version ZeroMQ et MPI)
- Exec. sur clusters Infiniband d'EDF et tests à grande échelle (ENERBAT)

***Merci pour votre attention***



Cherifa Dad, Stephane Vialle, Mathieu Caujolle, Jean-Philippe Tavella, Michel Ianotto.  
*"Parallelization, Distribution and Scaling of Multi-Simulations on Multi-Core Clusters, with DACCOSIM Environment"*. Technical & Research report, EDF & CentraleSupélec. March 2016.  
<https://hal-centralesupelec.archives-ouvertes.fr/hal-01289194v3/document>