

DE LA RECHERCHE À L'INDUSTRIE



EVOLUTION DES MACHINES ET IMPACT SUR LES MÉTHODES NUMÉRIQUES

GDR Mascot num | D Bouche et G Colin de Verdière

16/11/2015

www.cea.fr

Sommaire

Contexte

Power Wall

Memory Wall

Software

Méthodes numériques


Conclusion

Contexte

Ce qu'on constate sur les machines de puissance


Des architectures regroupant un grand nombre de noeuds complexes et hétérogènes

- des noeuds de plus en plus complexes



Des noeuds de plus en plus nombreux (≥ 5000)

- Architecture hybride
- Vectorisation
- Multithreading
- Grand nombre de coeurs
- Effets NUMA
- Mémoire par coeur réduite



Le powerwall


L'électricité, c'est cher...

1MW=1 Meuro/an



Premier défi: la puissance consommée

Tricastin © AFP/Fred Dufour



Contrainte : puissance consommée: $P = P_d + P_s$




- $P_d = C_e \times f \times V^2$ **dynamique**
- $P_s = V \times I_f$ **statique**

- I_f : courant de fuite
- C_e : capacité
- V : voltage (fonction croissante de f)
- F : fréquence

- **Pour limiter P , il faut**
 - Réduire le voltage
 - ex: Pentium 4 = 1.7V; Nehalem = 1.247V
 - Réduire la fréquence f
 - Nehalem = 2.8GHz, GPU = 1.1GHz
- **Capacité calcul en $N_c N_{op} f$**
 - $N_c N_{op}$ doit augmenter si f baisse
- **Conséquence**
 - N_c nombre de cœurs
 - N_{op} nombre d'op/cycle
- **Parallélisme**

- 1 coeur par processeur
- Fréquence f



Plus de performance = plus de coeurs

- Les solutions sont soumises aux contraintes du marché

- Ordinateurs hybrides /classiques
- Top500 : 8 hybrides dans le top 20 #1 et #2 sont hybrides

- Road Runner (le précurseur)

- Processeur de console de jeu



- La piste « GPU »

NVIDIA, AMD

- Monde du jeu et du graphique
- Un grand nombre de coeurs simples


- La piste « Manycore »

INTEL

- Monde du PC
 - Capitalise un écosystème logiciel existant
- Un nombre raisonnable de coeurs de puissance intermédiaire



- Demain, processeurs embarqués à faible consommation

- Monde du téléphone portable, des tablettes...



La piste "GPU"



- **NVIDIA & AMD**
- **travail sur les pixels : parallélisme massif**
- S'appuie sur des programmes à grand nombre de threads
- Le hardware introduit des contraintes sur le style de programmation
- Peut être vue comme une machine vectorielle (data parallel) : le processeur exécute la même opération sur un ensemble de données
- **Performance (potentielle...) élevée**
- Programmation spéciale
- Demande un CPU et un lien externe (PCIExpress, NVlink)
 - importance de la localité des données
 - coût des mouvements de données



The ROMEO machine @ URCA
 #184 Top500 06/14(384TFlop/s)
 #6 Green500
 NVIDIA K20X

La piste "Manycore"


- **Suivie par Intel**
- Garde la compatibilité avec architecture X86
- Revendique la simplicité de programmation
- Considéré par Intel comme "la" route vers l'Exascale
 - Evolution de tout l'écosystème logiciel à prévoir (quand même...)




Tianhe-2, NUDT, China
 #1 Top500 06/14
 33,86 petaflops
 32000 Ivy-Bridge
 48000 Xeon Phi (KNC)
 Bientôt 100 petaflops avec
 les « China accelerators »



Stacked memory



HMC by Micron



Up to 72 Intel Architecture cores based on Silvermont (Intel® Atom processor)

- Four threads/core
- Two 512b vector units/core
- Up to 3x single thread performance improvement over KNC generation

Full Intel® Xeon processor ISA compatibility through AVX-512 (except TSX)

6 channels of DDR4 2400 MHz -up to 384GB

36 lanes PCI Express* Gen 3

8/16GB of high-bandwidth on-package MCDRAM memory >500GB/sec

200W TDP

• Architecture

- 72 coeurs + 4 threads / coeur
- **Multithreading nécessaire**

• 2 unités vectorielles 512b par coeur

- L'essentiel de la puissance de calcul du KNL
- **Programmation vectorielle obligatoire**

• Mémoire stackée [HMC] (B/W ↑, latence ≡)

- Impact sur les codes (placement en mémoire)

• Effets NUMA internes

N_c nombre de coeurs : 72
 N_{op} nombre d'op/cycle : 32

72 x 32 x 1,3 GHz : 3 TFlops

- Seule manière de booster la puissance de calcul au niveau d'un cœur : l'énergie nécessaire pour une opération dépend peu de la taille des registres
- Déjà utilisé sur le Cray1 
- Apparaît sur les processeurs classiques il y a quelques années
- Registres d'abord de taille modeste : 128 bits (2 opérations DP)
- Puis la taille des registres augmente : 256, puis 512 bits (KNL, mais aussi futures génération de processeurs classiques)
- Les 2 registres réalisent chacun 8 opérations simultanées fusionnées (fused multiply add : $d=a.b +c$), comptant pour 2 opérations : $2 \times 8 \times 2 = 32$
- Programmation spécifique

```
do i = 1, n
  a(i) = b(i) + c(i)
end do
```

$$\begin{pmatrix} a_1 \\ \dots \\ a_n \end{pmatrix} = \begin{pmatrix} b_1 \\ \dots \\ b_n \end{pmatrix} + \begin{pmatrix} c_1 \\ \dots \\ c_n \end{pmatrix}$$

En un cycle d'horloge (1 ns),
on fait peu de chemin...

**Second défi : les mouvements de
données**

$C=2.997925 \cdot 10^8$ m/s

1ns \Leftrightarrow 30cm !

- Calculer peut être plus économique que déplacer des données
- Hierarchies Mémoire et coûts associés

NUMA

L1\$

small size (kB), small latency (~1cy) , high B/W

medium size (kB), medium latency (~14cy), high B/W

larger size (MB), high latency (~40 cy)

very high latency (~140 cy), focus on bandwidth


very high latency (~140 cy), focus on storage size

• L2\$

■ L3\$


- MCDRAM (KNL)

- DDR4




Credit Bill Dally, NVIDIA, SC10

- **Mettre le GPU au plus près du CPUs**
- Plus de communications via le PCI-Ex
- Gestion des ressources plus facile pour les développeurs
- **Contraintes**
- modification de l'O/S
- Un écosystème logiciel pour ces architectures
 - Quels standards ?
 - AMD : OpenCL, OpenMP 4.0
 - NVIDIA : CUDA, OpenACC
- **Pas encore applicable au HPC**
- marché = laptops, tablettes, smartphones
- évolution rapide : à suivre...




AMD Kaveri
NVIDIA Tegra k1



Remarque : chez Intel, les processeurs classiques ont déjà ce type d'architecture

- Processeur Intel Haswell



Un lien plus rapide : le NVLINK

- Machine Coral : GPU + IBM Power 9

- IBM Power 9 + NVLINK + Volta

- <http://info.nvidianews.com/rs/nvidia/images/Coral%20White%20Paper%20Final-3-2.pdf>


- NVLINK

- PCI-Express Gen3 12 GB/s

- Nvlink 1 64 GB/s


- Disponible sur génération Pascal de GPU

- Nvlink 2 vitesse au moins doublée



Coral : machines de classe 100 Pflops
précurseurs de l'exascale

- Coral vs top 500



LLNL & ORNL

- IBM + NVIDIA
- Power 9 + Volta
- NVLINK-2
- Mellanox Infiniband
- ~150 PFlops
- ~8 MW
- MPI + OpenMP 4


ANL

- INTEL + CRAY
- KNH (successeur du KNL)
- STL2
- ~180 Pflops
- 13 MW
- MPI + OpenMP 4

Évolutions logicielles

Mascotnum 2015

- Fortran / C++
- Déclin du FORTRAN ?
 - Encore une activité Open Source significative
- Des évolutions intéressantes du C++ à venir
 - Meilleure intégration des threads
- PGAS
- Concept intéressant encore loin de la production



Partitioned Global Address Space


- Le modèle MPI +X est (encore) le future
 - question : quel X ?
- Options non standard
 - CUDA
 - Intéressant pour apprendre le parallélisme massif
 - OpenACC
 - Un bon labo pour OpenMP 4.x
- Options standard
 - OpenMP 4
 - Le meilleur pari pour le futur
 - Poussé par le programme Coral
 - OpenCL
 - Largement disponible

Méthodes numériques

- Le boost sur la puissance de calcul ouvre des opportunités :
- Simulations numériques “Classiques”
 - Des simulations d'écoulements bien résolues : 10^{9-11} éléments aujourd'hui, 10^{12-14} sur machines exascale
 - résolution partielle de la malédiction de la dimension: simulations gyrocinétiques 5D
 - Prediction de la structure et des interactions entre molécules
 - structure électronique des matériaux, y compris avec électrons corrélés
- Couplage HPC / image-vision
 - structure des macromolécules biologiques par microscopie électronique et atomique
 - simulations Monte Carlo pour applications en radiothérapie
- Quantification des incertitudes et optimisation non-convexe

- **Parallelism 3 niveaux**
 - Entre nœuds de calcul : travail à répartir équitablement entre les noeuds
 - Dans les noeuds : multi ou manycore
 - Dans les coeurs : multithreading, unités SIMD (vectorielles)
- **Négliger un de ces niveaux : mauvaises performances**
 - Amdhal (scaling fort) et Gustavson (scaling faible) : même une petite fraction de code non parallèle limite drastiquement l'efficacité sur machines massivement parallèles
 - Les unités vectorielles sur Intel KNL réalisent 32 opérations simultanées: mal les utiliser limite l'efficacité à 1/32 du nominal...
- **La bande passante mémoire n'a pas crû autant que la puissance de calcul**
 - Mouvements de données plus coûteux que les calculs
 - Méthodes à faible intensité arithmétique limité par la bande passante : leur performance peut être une faible fraction du CPU crête
 - Problématiques d'optimisation de performance illustrées par le modèle roofline

- Roofline : visual estimation of algorithm's performance




Low AI BW limited algorithm

How to get closer to peak CPU ?


peak cpu quest : rise the ceiling

- Multithreading + efficient use of SIMD units (vectorisation) can enhance efficiency by several orders of magnitude (10-100)
- Vectorisation easier for regular data structures : finite differences, or structured meshes





peak cpu quest : push the ROOF

- Bandwidth can be reduced by parasitic memory traffic generated by cache misses, superfluous cache write allocations, etc.
- Regular access to data more efficient : again favoured by regular data structure (structured meshes)



peak cpu quest : move away from the ROOF





- Present and future machines :
- low byte/flop ratio
- Use high flop/byte algorithms



Example : Higher order stencils have higher arithmetic intensity

- Some algorithms are naturally suited to parallelism
 - Monte Carlo methods : widely used for particle transport
 - Particle swarms : efficient in non convex optimization
 - Regular meshes : simpler to scatter between nodes
- With the advent of parallel machines, this requirement became more important than operation count
- Others require more work
 - Fourier transforms
 - Plane wave methods for electronic structure computations
- But it does not mean that they are ruled out...

DYNAMICO : A new atmospheric dynamical core (T. Dubos LMD/X, Y. Meurdesoif CEA/LSCE)



- Tessellation of icosahedra
- Hexagonal mesh + 12 pentagons
- Removing mesh

Parallelism & HPC

- Implementation on semi-structured grid
 - 10 regular rhombus tiles, hexagons paved
 - Regular memory access, domain easy to cut up
- 1 MPI parallelism level (horizontal)
- 2 OpenMP parallelism level (horizontal & vertical)
- 99.7 vectorized (~60% peak perf. On SX8)


$$\frac{\partial m}{\partial t} + \frac{\partial W}{\partial \eta} + \nabla_{\eta} \cdot (\bar{m}^h u) \quad m = -\frac{1}{g} \frac{\partial p}{\partial \eta}$$

$$\frac{\partial m q}{\partial t} + \frac{\partial}{\partial \eta} (W \bar{q}^v) + \nabla_{\eta} \cdot (U \bar{q}^h) = S_q$$



$$\frac{\partial \Phi}{\partial \eta} + g \frac{m}{p^v} = 0$$

$$\frac{\partial u}{\partial t} + \frac{\partial u^v}{\partial \eta} \frac{W^{vh}}{\bar{m}^h} + (f + \nabla_{\eta} \times u) \times u \quad \text{TRISK}$$

$$+ \nabla_{\eta} \left(\frac{u^{2h}}{2} + \phi \right) + \bar{\theta}^h \nabla_{\eta} \pi = S_u$$





- Solve "primitive" equations on the sphere
- New numerical conservative schemes on staggered grid
 - TRISK scheme (Thuburn et al., 2010)



DYNAMICO : an Highly SCALABLE MODEL

Aquaplanet :
Dynamico : 32x32x10x39lvl Vs LMDZ 96x95x39



- Comparison with actual model (LMDZ)

- Decreasing time restitution
 - Factor 10 for low resolution
 - Up to x40 for High resolution

CINES Big Challenges 2014

- Simulating high resolution Saturn atmosphere
 - 12 Millions hours on OXYGEN supercomputer
 - Resolution up to 1/8° degrees
 - High Scalability tested up to 60 000 cores (hyperthreading)

Conclusion

Impact on codes

- Les progrès en calcul haute performance boostent les domaines classiques des simulations numériques et en ouvrent de nouveaux
- Pour tirer parti de ces potentialités, il faut revoir en profondeur nos méthodes numériques : le parallélisme inter and intra nœud massif, l'utilisation efficace des unités vectorielles, la localité, sont nécessaires et le resteront dans un futur prévisible
- Les méthodes à forte intensité calculatoire tirent un meilleur parti de la puissance de calcul et évitent le goulet de la bande passante
- L'adaptation des méthodes numériques a commencé, mais il reste un travail important pour tirer parti de la nouvelle génération de processeurs manycore
- Certains algorithmes, comme le Monte Carlo, les méthodes particulières, les calculs sur grilles régulières sont naturellement adaptées aux machines actuelles et futures
- Le Monte Carlo a l'avantage supplémentaire de répondre au problème de résilience (pannes et erreurs hardware)
- Les calculs d'incertitude basés sur des méthodes de Monte Carlo ont un bel avenir...

The big trends towards the Exascale

• Hardware

■ Reduce the electrical consumption of the compute units

- Ever more cores with a reasonable frequency
- Systematic usage of specialized units SIMD/SIMT

Multithread your code

Vectorize your algorithms

Use all units

■ Reduce the cost of data movements

- Unavoidable placement of CPUs and powerful SIMD units inside the same chip
- Integration of high performance network interfaces to the chip (SoC)
- Stacked memory to increase bandwidth
- More threads per cores to hide latencies

Work on data location(s)

Multithread your code

• Software

■ Necessary evolution of standards to cope with hardware evolution

- Don't rush on new fancy options, yet learn by experimenting on prototypes

■ Upgrade of the full software ecosystem

- Compilers, debuggers, profilers

• Challenges

■ Programming those processors at more than 10% of their peak

■ Optimize existing codes to fully utilize the platforms

MPI as usual
(PGAS maybe
one day?)