



Systemes Hautes Performances

Introduction


Elisabeth Brunet
CSC5001 - Septembre 2020





Calcul et simulation scientifiques

- **Essentiels pour l'innovation scientifique et industrielle**
- **Nombreux domaines d'application**
 - Météorologie, astrophysique, nanosciences, etc.
 - Automobile, aéronautique, 7ème art, défense, etc.
- **Simulation nécessaire lorsque les problèmes sont ...**
 - ...trop complexes
 - ...trop massifs
 - ...trop chers
 - ...trop dangereux
 - ...prédictifs





Calcul et simulation scientifiques

- **Beaucoup de calcul**
 - **Manipulation de masses de données**
 - **Contraintes de temps**
 - **Conséquences**
 - Accroissement des ressources de calcul
 - Parallélisation des problèmes
- Pour aller toujours plus vite
- mais surtout traiter des problèmes toujours plus gros






Optimisation des plates-formes

- **Capacités des composants tirées au maximum**
- **Diversité des processeurs**
 - Architectures grand public boostées
 - Architectures spécialisées
 - Processeurs Alpha, MIPS, Cray, Power, Sparc, NEC, etc.
 - Jeux d'instructions
 - Mode de fonctionnement :
 - Processeur vectoriel
 - Exécution de la même instruction sur chaque entrée d'un tableau
 - Processeurs Cray, unité de calcul AltiVec, instructions SSE
 - Processeur Cell

Processeur Cell

- **Processeur conçu par IBM, Sony et Toshiba**
- **Février 2005**
- **Modèle d'architecture totalement différent**
 - 1 processeur *maître* PPE de type PowerPC
 - 8 co-processeurs SPE vectoriels
 - Bus interne d'interconnexion EIB
- **Performances maximales théoriques**
 - 230,4 GFLOPS en simple précision
 - Initialement pour le multimédia (PS3, etc.) mais détourné par le HPC
- **Extrêmement difficile à programmer**
 - Abandonné en 2009






Optimisation des plates-formes


- **Capacités des composants tirées au maximum**
- **Diversité des processeurs**
 - Architectures grand public boostées
 - Architectures spécialisées
 - Adjonction de co-processeurs
 - FPGA : circuit logique programmable
 - GPU : Graphics Processing Unit

GPU Computing

- **1 GPU = centaines de cœurs limités**
 - pas d'allocation dynamique de mémoire
 - pas de pile, donc pas de récursion
- **Conçu pour le calcul 3D en synthèse d'image**
 - API 3D : OpenGL, DirectX
- **Orientation calcul parallèle**
 - Nvidia : Architecture Tesla(2006), Fermi(2009) / API CUDA
 - AMD : Archi RadeonHD / API ATI Stream SDK
 - API unifiée GPU+CPU : OpenCL (2008)



- **Résurrection de la loi de Moore**
 - Projet Larabee (non abouti)
- **Traitement vectoriel distant**
 - Adapté au calcul «naturellement parallèle»
 - Transfert de données via PCIe
 - 1 *noyau* exécuté par tous les threads
 - Rapatriement des résultats via PCIe
- ➔ Interactions CPU/GPU lentes





Optimisation des plates-formes

- **Capacités des composants tirées au maximum**
- **Diversité des processeurs**
 - Architectures grand public boostées
 - Architectures spécialisées
 - Adjonction de co-processeurs
 - Agrégation massive de ressources
 - Réseaux haute performance
 - InfiniBand, Myrinet, 10G-Ethernet, etc.
 - Topologies
 - Supercalculateurs : plate-formes propriétaires
 - Grappes : machines dites *grand public* interconnectées par un réseau point-à-point
 - Grilles : supercalculateurs/grappes interconnectés par un réseau longue distance





Bilan des ressources de calcul dans le HPC

- **Architectures hybrides**
- **Composants tous à la pointe de la technologie**
- **Explosion de la puissance de calcul**
 - 1 nœud surpasse une grappe de mono-processeurs
 - Échelle actuelle : le petascale, voire l'exascale
 - Recensement dans le Top500



- Classement bi-annuel des 500 machines les plus puissantes du monde





Top500 de juin 2020

Rmax et Rpeak en Tflop/s
Power en kW

- 1 Fugaku** – A64FX48C 2.2GHz, Tofu Interconnect – Fujitsu RIKEN Center of Computational Science (Japan)
#coeurs = 7,299,072 Rmax = 415,530 Rpeak=513,854 Power=28,335
 - 2 Summit** – IBM POWER9, NVIDIA Volta GV100 – Oak Ridge National Lab (USA) → **#1 en 2018**
coeurs=2,414,592 Rmax=148,600 RPeak=200,794 Power=10,096
 - 3 Sierra** – IBM POWER9, NVIDIA Volta GV100 – Lawrence Livermore National Lab (USA)
#coeurs=1,572,480 RMax=94,640 RPeak=125,712 Power=7,438
 - 4 Sunway TaihuLight** – Sunway MPP (Chine)
#coeurs=10,649,600 RMax=93,014 RPeak=125,435 Power=15,371 → **#1 en 2016**
 - 5 Tianhe-2A** – Intel Xeon E5-2692v2, Matrix 2000 – National Super Computer Center in Guangzhou (Chine)
#coeurs=4,981,760 RMax=61,444 RPeak=100,678 Power=18,482 → **#1 en 2013**
-
- 500 Graham** Huawei X6800 V3, Xeon E5-2683 v4 16C 2.1GHz, Infiniband EDR/FDR, NVIDIA Tesla P100 (Canada)
#coeurs=5,1200 RMax=1,228 Rpeak=2,641 Power =546 → **#96 en 2017**




Top 5 français de juin 2020

Rmax et Rpeak en Tflop/s
Power en kW

- **15. PANGEA III** – IBM POWER9, NVIDIA Volta GV100 – Total Exploration Production
#coeurs=291 024 Rmax=17860 Rpeak=25025 Power=1367
- **20. Terra-1000** – Bull Sequana X1000 – Xeon Phi 7250 – CEA
#coeurs=561 408 Rmax=11965 Rpeak=23396 Power=3178
- **29 . Belenos** - Bull Sequana XH2000 , AMD EPYC 7742 64C 2.25GHz, Mellanox HDR100, Atos Meteo France
#coeurs=294,912 Rmax=7,683.4 Rpeak=10,469.4 Power=1,655
- **34 . JOLIOT-CURIE ROME**- Bull Sequana X1000 – Xeon Platinum – CEA/TGCC GENCI
#coeurs=197,120 Rmax=6,988 Rpeak=12,039.4 Power=1,436
- **49 . Pangea** - SGI ICE X, Xeon E5-2670 8C 2.600GHz – Total Exploration Production → #11 en 2016
#coeurs=220 800 Rmax=5283 Rpeak=6712 Power=4150
- **54. Jean Zay** – HPE SGI, Xeon gold6248 20C 2.5GHz, Nvidia Tesla V100 – CNRS / IDRIS-GENCI
#coeurs=93 960 Rmax=4478 Rpeak=7345 Power= ?

Countries System Share





Green 500 en 2020

- Meilleur ratio performance/consommation d'énergie

Rank	TOP500		Cores	Rmax (TFlop/s)	Power (kW)	Power Efficiency (GFlops/watts)
	Rank	System				
1	393	MN-3 - MN-Core Server, Xeon 8260M 24C 2.4GHz, MN-Core, RoCEv2/MN-Core DirectConnect, Preferred Networks Preferred Networks Japan	2,080	1,621.1	77	21.108
2	7	Selene - DGX A100 SuperPOD, AMD EPYC 7742 64C 2.25GHz, NVIDIA A100, Mellanox HDR Infiniband, Nvidia NVIDIA Corporation United States	272,800	27,580.0	1,344	20.518
3	468	NA-1 - ZettaScaler-2.2, Xeon D-1571 16C 1.3GHz, Infiniband EDR, PEZY-SC2 700Mhz, PEZY Computing / Exascaler Inc. PEZY Computing K.K. Japan	1,271,040	1,303.2	80	18.433
4	204	A64FX prototype - Fujitsu A64FX, Fujitsu A64FX 48C 2GHz, Tofu interconnect D, Fujitsu Fujitsu Numazu Plant Japan	36,864	1,999.5	118	16.876
5	26	AIMOS - IBM Power System AC922, IBM POWER9 20C 3.45GHz, NVIDIA Volta GV100, Dual-rail Mellanox EDR Infiniband, IBM Rensselaer Polytechnic Institute Center for Computational Innovations (CCI) United States	130,000	8,339.0	512	16.285

- **La plupart sont sont accelerator-based.**
- **Trend of aggregating many low-power processors tops the Green500**



Points critiques des applications HPC

En terme de mise en œuvre :

- **Problèmes classiques exacerbés**
- **Utilisation des ressources matérielles**
- **Distribution des données**
- **Diffusion des résultats**
 - Opérations collectives (*alltoall*, *broadcast*, réduction, etc.)
- **Problèmes liés à la taille des plate-formes**
 - Tolérance aux fautes, etc.

En terme d'efficacité :

- **Localité des données**
- **Granularité des données**
 - Équilibrage de charge coûteux



Assistance aux applications HPC

- **Interfaces d'abstraction du matériel**
 - Exemples : OpenCL, PVM, MPI, etc.
 - Pour garantir la portabilité logicielle



Assistance aux applications HPC

- **Supports d'exécution**

- Architectures multiprocesseurs

- Gestion du placement des fils d'exécution
 - Gestion du placement des données
 - Ordonnanceur de threads, Cilk, etc.

- Architectures distribuées :

- Distribution des données
 - Gestion des transferts de données
 - MPI, RPC, DSM , etc

- Architectures hétérogènes

- Équilibrage de charge
 - StarSs, Intel Ct, StarPU, etc.

Pour garantir la portabilité des performances!



Assistance aux applications HPC

- **Bibliothèques de plus haut niveau**

- Résolution intégrée de problèmes *classiques*

- FFT, algèbre linéaire (BLAS, etc.), résolution systèmes linéaires, etc.

- **Utilitaires**

- Analyse de performance (PAPI, Perf, Vampir, Scalasca, etc.)

- Détection de bugs (Valgrind, gdb, etc.)

- Tolérance aux pannes, aux fautes

-

- **Middlewares**

- Chaque brique développée de manière isolée

- Couplage de code

- Arbitrage des accès aux ressources physiques



Métriques

- **Performances dépendantes de plusieurs facteurs**
 - Fraction de l'application parallélisable
 - Qualité de l'ordonnancement sur les ressources de calcul
 - Surcoût introduit par la version parallèle
- **Speedup** : mesure l'accélération entre les versions parallèle et séquentielle
 - $Sp = T_{seq} / T_p$, où
 - Sp = speedup sur P processeurs
 - T_p = temps de la version parallèle sur P processeurs
 - T_{seq} = temps de la version séquentielle sur 1 processeur
 - Objectif ultime : $Sp = P$
- **Loi d'Amdahl** : borne d'accélération en fonction de la qualité de parallélisation
 - $R = 1 / ((1-S) + S/P)$, où
 - S = proportion de code parallélisé, P = le nombre de processeurs
 - L'accélération est bornée à $1/S$ - > ajout de processeurs rapidement inutile