

ETSN 2022

Des applications en physique en particulier
À la mesure de performance en général...
(oui... “Encore” de la métrologie...)

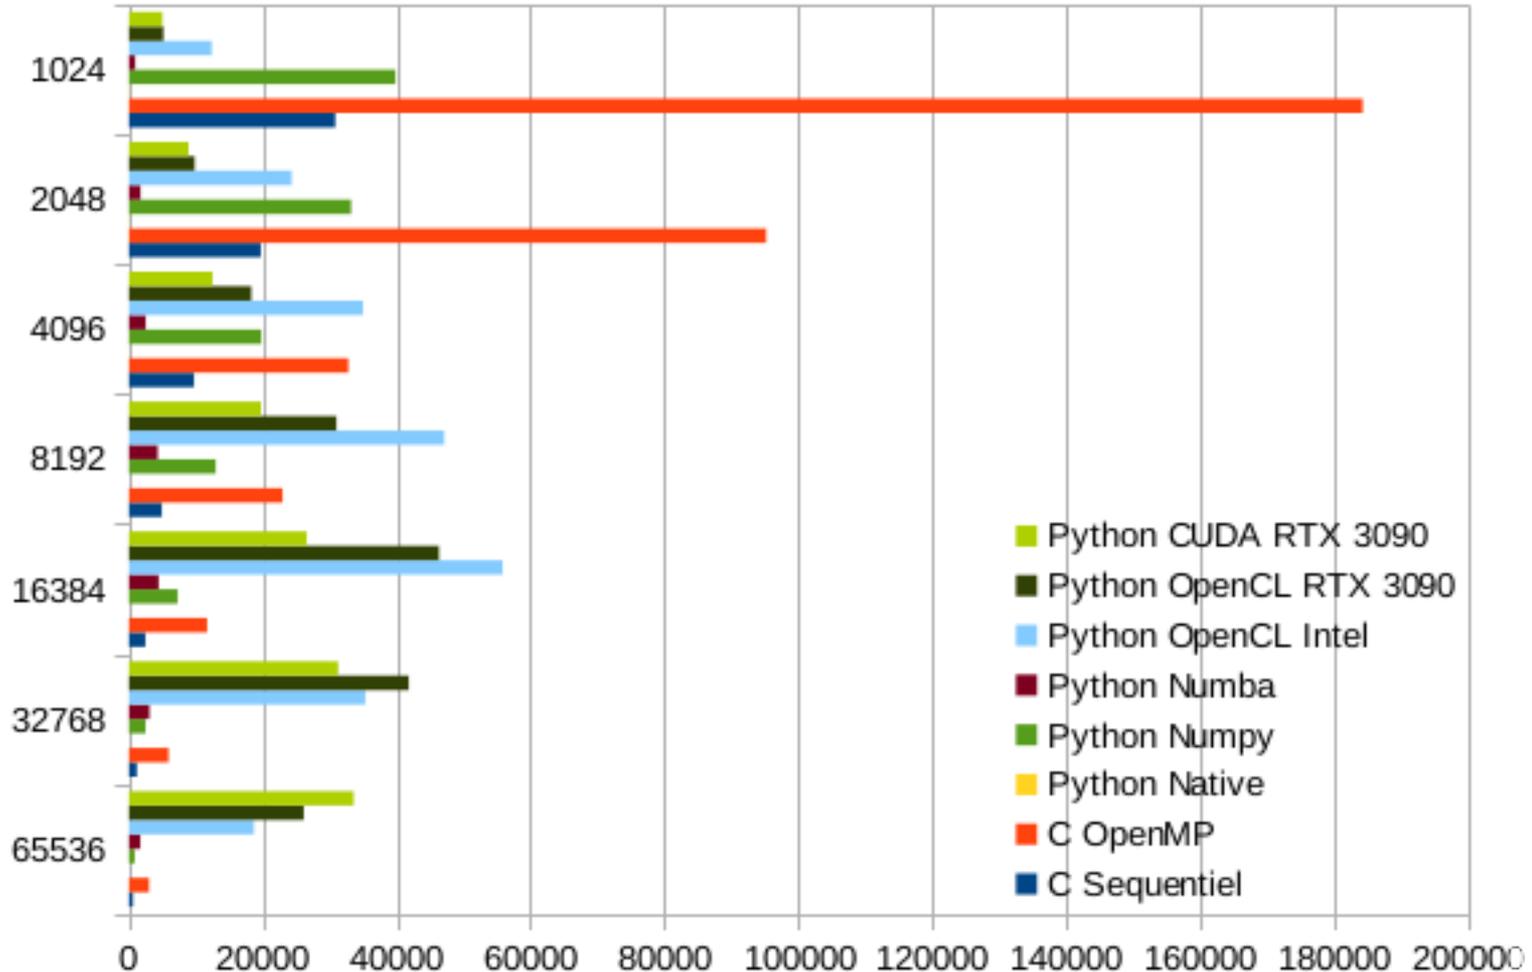
*“Tout ce que nous avons à décider,
c’est quoi faire du temps qui nous est imparti”*

Gandalf

Emmanuel Quémener

Implémentation « naïve » de la DFT

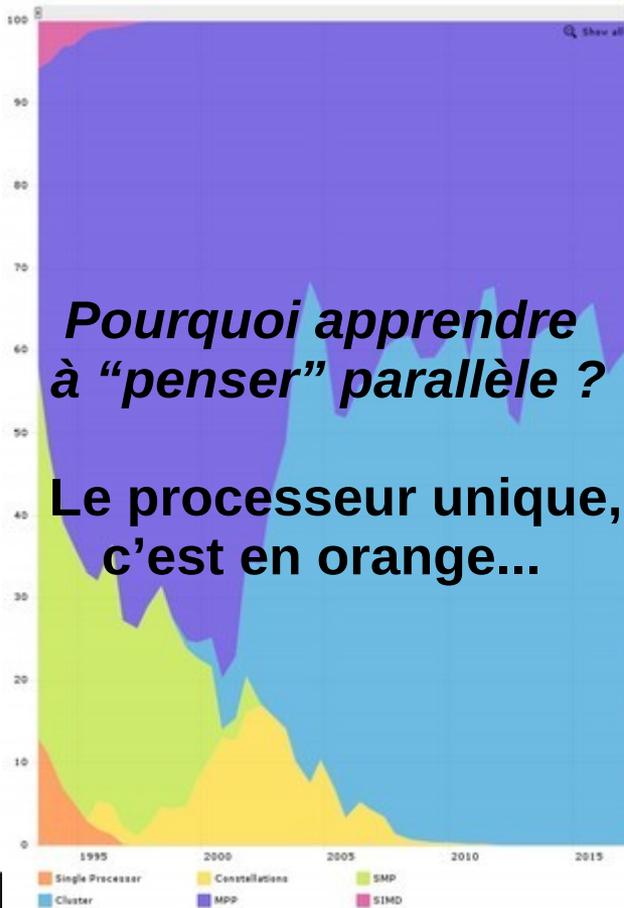
Des enseignements à la pelle...



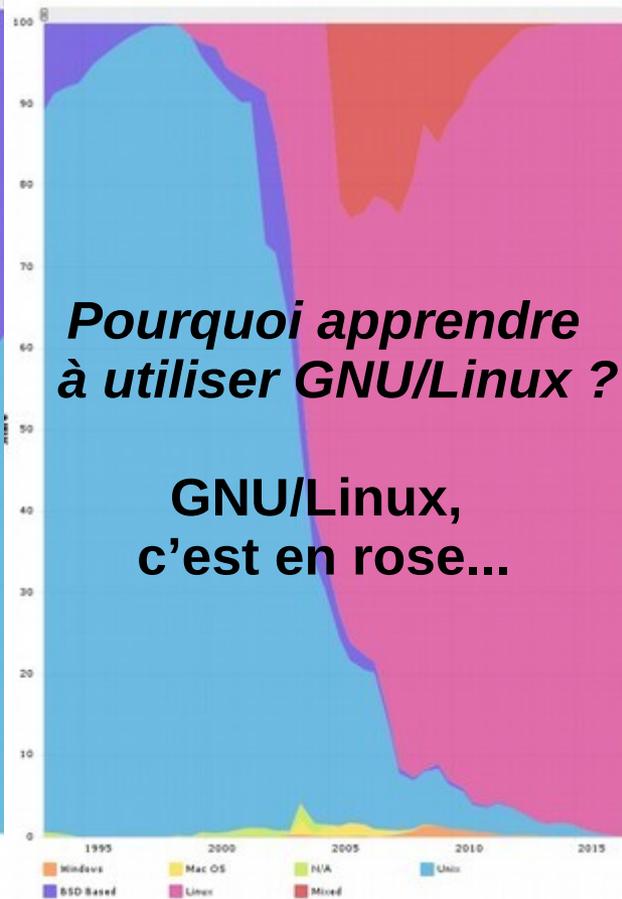
Le contexte : le TOP 500

Architectures, OS & accélérateurs...

Architecture - Performance Share



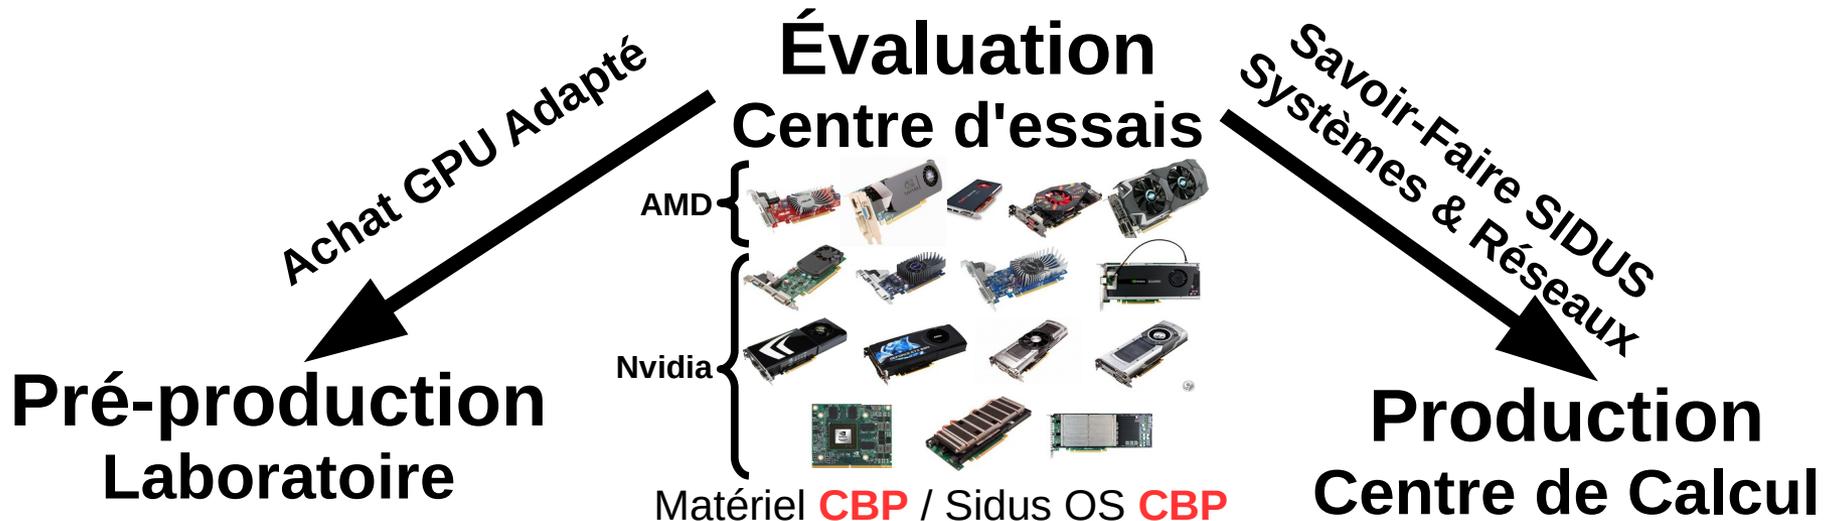
Operating system Family - Performance Share



Accelerator/CP Family - Performance Share



Et ça sert ? Un exemple d'interaction Entre CBP, laboratoire, Centre de Calcul



Matériel **LBMC** / Sidus OS **CBP**

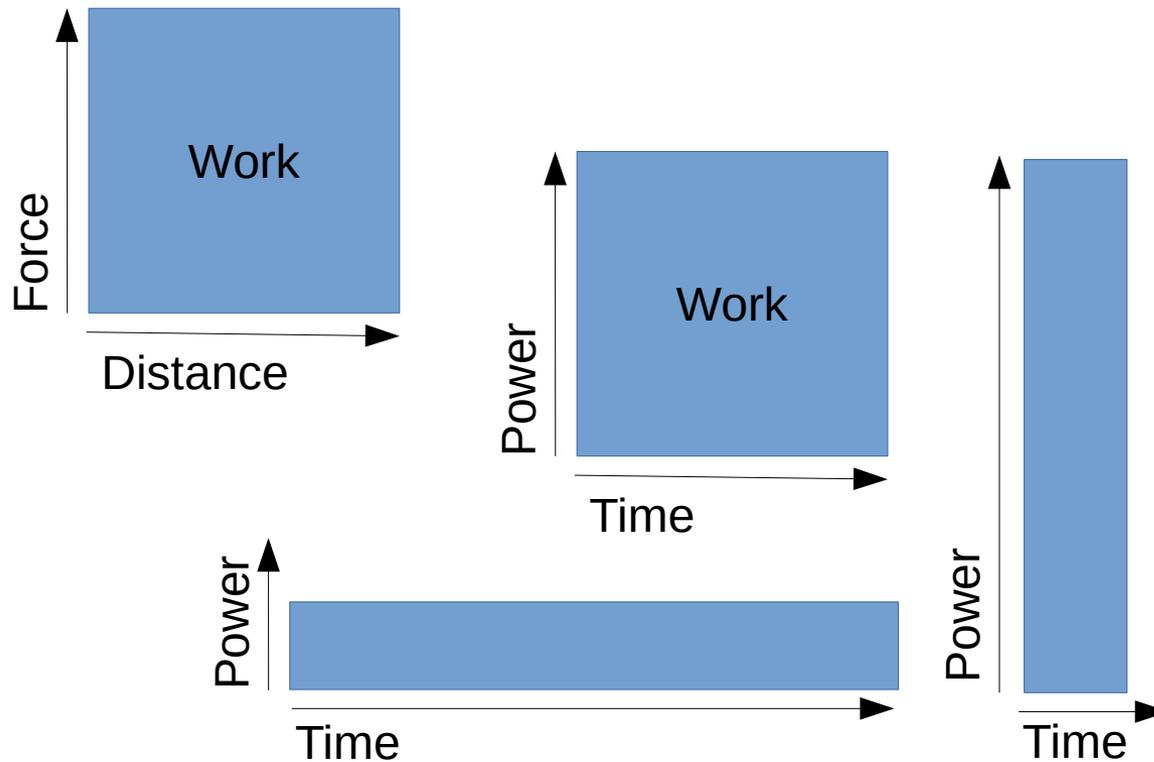
**Influence de l'achat
du socle matériel**



Matériel **PSMN** / Sidus OS **PSMN**

« Energie » en calcul scientifique...

Le point du vue du physicien



Mécanique

La puissance est définie
Comme le produit de :

- Fréquence
- Nombre d'unités
- Puissance unitaire

$$W = \int_{x_1}^{x_2} F dx = \int_{t_1}^{t_2} P dt$$

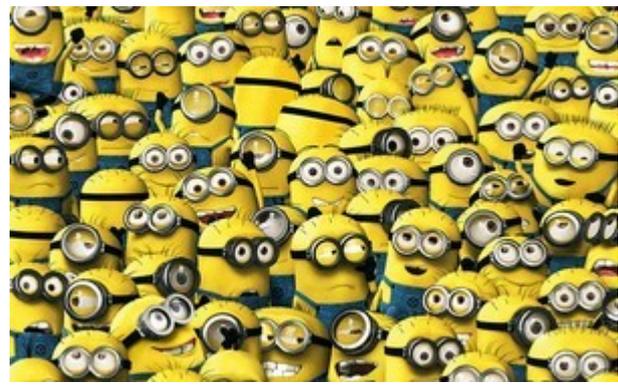
Caractérisation des « moteurs » de traitement à x0000 unités...

Des (multi|many)-cœurs aux myri-alus ? Un laboratoire de //isme sur puce

- Vous avez de 1 à plusieurs dizaines de milliers de EPU !
- Vous avez le choix entre : **CPU** **GPU**



ALU vectorielle



Comment les choisir, les distinguer pour les exploiter ?

Qu'est-ce donc que le Code ?

Un protocole d'expérimentation !

- Dans la cuisine :
 - Nous avons les ingrédients, mais nous voulons un plat !
- Dans le domaine scientifique, 3 formes :
 - Simulation : « Au service (discret?) de la théorie »
 - Traitement : pour expérimentateurs « exigeants »
 - Visualisation : voir (les choses) pour percevoir (leurs interactions) (et aussi partager !)
- Chaque exécution est une expérience (et une unique!)
 - Recettes : « codes » devenant des « processus »
 - Ustensiles : librairies, OS, matériels, réseaux, ...
 - Ingrédients : modélisation, données
 - Exécution : et une expérience NE peut se réduire à ses résultats !

Les familles de programmes

- Comment distinguer les différents codes que j'utilise ?
 - « Mon code à moi dont je suis fier ! »
 - Le code de mon chef
 - ou plutôt une stratification produite par des générations successives d'étudiants
 - Un code « métier »
 - Modèle Ikea : distribué avec des instructions de compilation
 - Modèle Crozatier : prêt à l'emploi
- Comme dans chaque famille, les problèmes avec l'héritage !
 - Dépendances avec :
 - Des bibliothèques génériques : BLAS, Lapack, FFTw
 - Des bibliothèques propriétaires : Mathworks, Intel, Nvidia, AMD, ...
 - Le matériel !

La performance, c'est quoi ?

- D'où ça vient ce mot ?
 - Cela vient de l'anglais : « accomplir » ou « réaliser »
 - C'est également : « manière de se comporter »
 - Mais aussi : « ensemble des possibilités optimales d'un appareil »
- La « performance » :
 - c'est d'abord « faire le job »
 - c'est aussi « le faire suivant des critères (à définir) »
 - c'est enfin « le faire le mieux possible », mais quel mieux ?

Performance :

Conditionnée par les objectifs

- La vitesse : Le temps écoulé (ou *Elapsed*) (mais seulement ?)
- Travail : immobilisation de ressources
- Efficacité: exploitation optimale des ressources
- Scalabilité : capacité à passer à une échelle supérieure
- Portabilité : intégration à d'autres infrastructures informatiques
- Maintenabilité : temps humain passé à maintenir le système
- Approche générale :
 - Définir un critère
 - Rechercher les valeurs extrémales sur un ensemble de tests pertinent

La vitesse comme critère

« Speed, I'm Speed... »

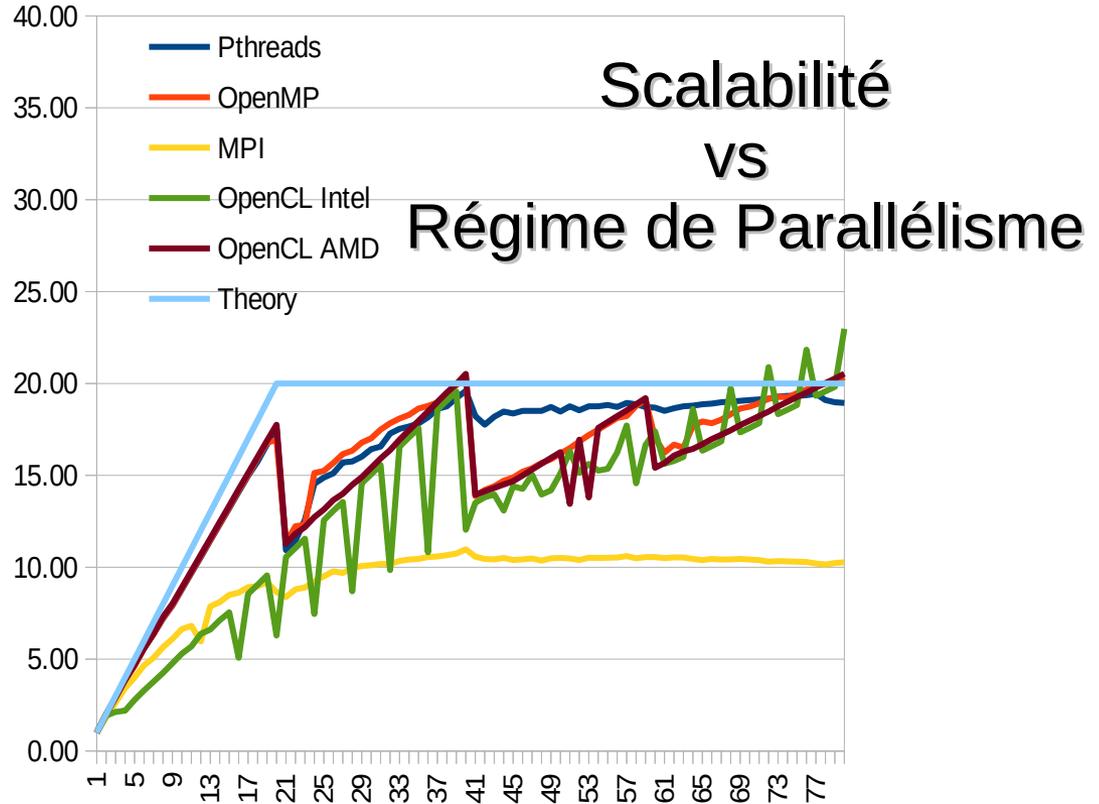
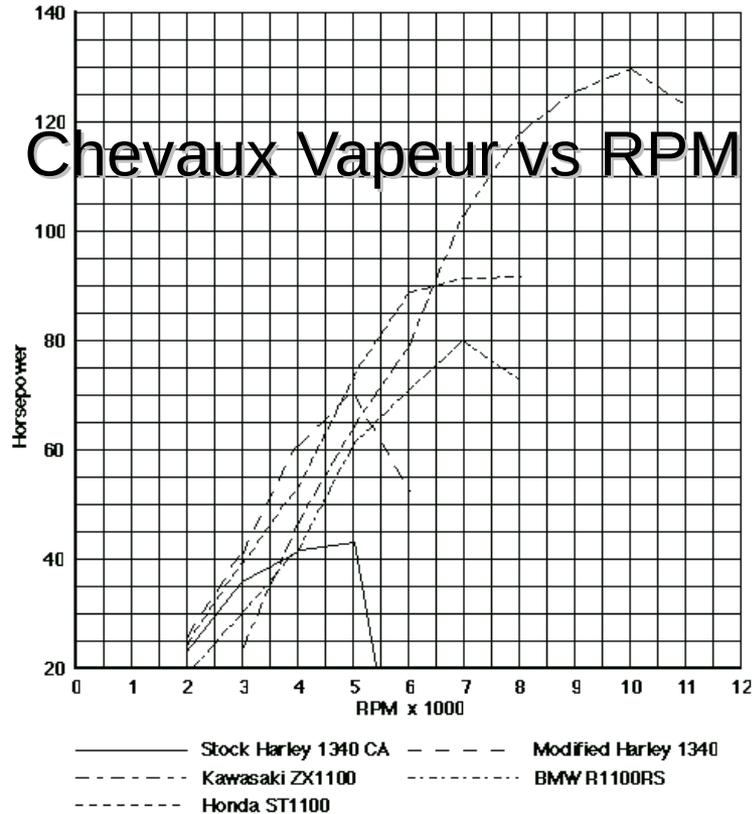
- Toutes les durées, et pas seulement le temps d'exécution
- Dans l'utilisation d'un code, les 3 coûts :
 - Coût d'entrée : apprendre à l'utiliser, l'intégrer à l'infrastructure, ...
 - Coût d'exploitation : le maintenir, l'utiliser
 - Coût de sortie : le remplacer par un autre code équivalent, ou une technologie équivalente
- Optimisation (et son biais) : $DD/DE > 1$ est-il pertinent ?
 - DE : Durée totale de toutes mes exécutions
 - DD : temps passé à tenter de minimiser la durée d'exécution
- Pour estimer ces valeurs :
 - Outils système, outils de métrologie dans les langages, les codes, les matériels, ...
- « Et après moi ? Le déluge ? » : quel avenir pour le code ?



Travail & Ressources Informatiques

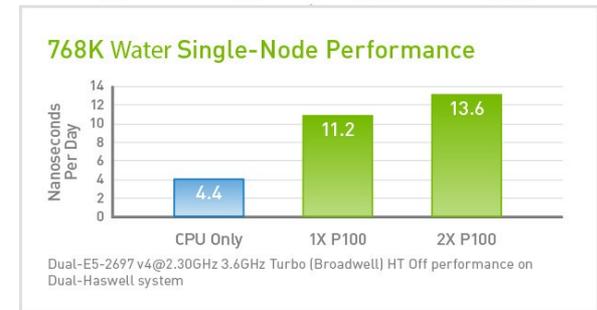
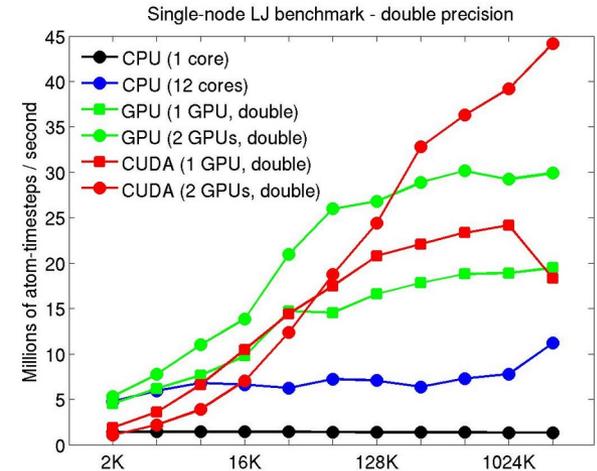
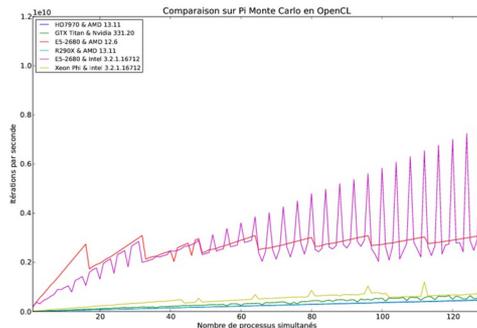
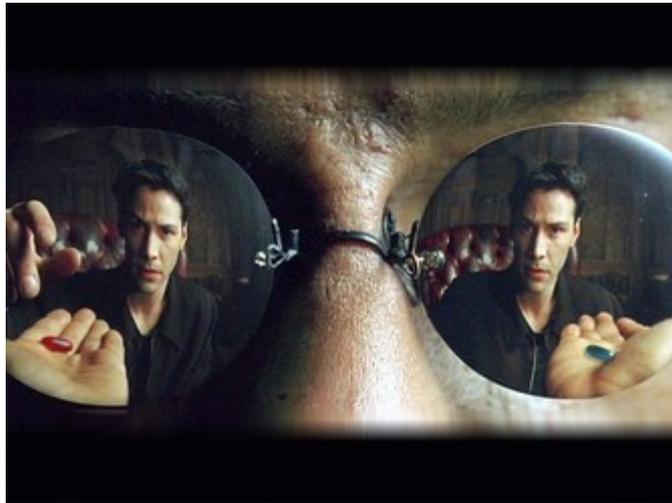
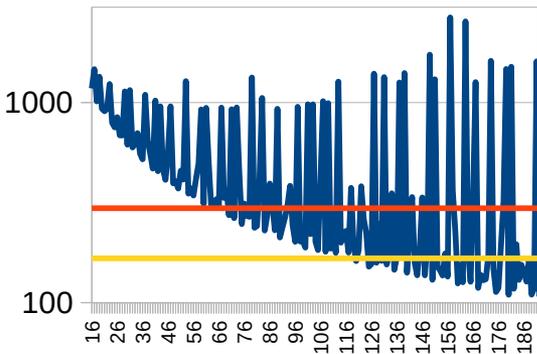
Un moteur comme source de puissance

Chart 5: Horsepower curves for 5 different motorcycles



- Quel comportement de ces « moteurs » à la charge ?
- Le « moteur », un « système » englobant matériel, OS et logiciels

Accélération GPU ? Vérité ou mensonge Prêt à prendre la « pilule rouge » ?



Cadre posé...

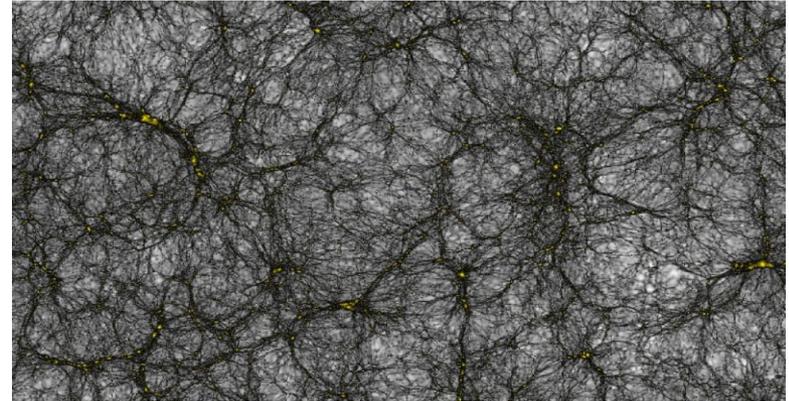
Quels codes à étudier ?

- Code « Ikea » : à compiler soi-même
 - PKDGRAV3 : astrophysique
 - Gromacs : chimie
 - D'autres...
- Code « à dépendances » :
 - Approche « intégrateur » :
 - BLAS avec xGEMM et les autres
 - Approche « développeur » :
 - Pi Dart Dash, Nbody, Splutter...

PKDGRAV3 : un client prometteur ... et une bonne exposition média !

- Caractéristiques :

- Open Source
- Hybride : MPI, OpenMP, Cuda



- Compilation « facile »

- Dans la doc (README) :
 - Quickstart : `./configure ; make`
 - Pour le support CUDA :
 - `./configure --with-fftw --enable-integer-positions --with-cuda`
 - `make -j 16`

PKDGRAV3 : compilation facile ?

Un peu plus compliqué sur Debian 9

- Pas de configure (donc nécessité de le générer) : `./autogen.sh`
- Nécessité de compiler avec fPIC (donc nécessité de modifier) :
 - `sed -i 's/compute_35/compute_35\ \-Xcompiler\ \-fPIC/g' configure.ac`
- Donc en fait, compiler PKDGRAV3 avec le support CUDA, c'est :
 - `cd /local ; git clone https://bitbucket.org/dpotter/pkdgrav3.git`
 - `PKDGRAV3=/local/pkdgrav3-$(date "+%Y%m%d") ; mv pkdgrav3 $PKDGRAV3`
 - `cd $PKDGRAV3`
 - `sed -i 's/compute_35/compute_35\ \-Xcompiler\ \-fPIC/g' configure.ac`
 - `./autogen.sh`
 - `./configure --with-fftw --enable-integer-positions --with-cuda`
 - `make -j 16`

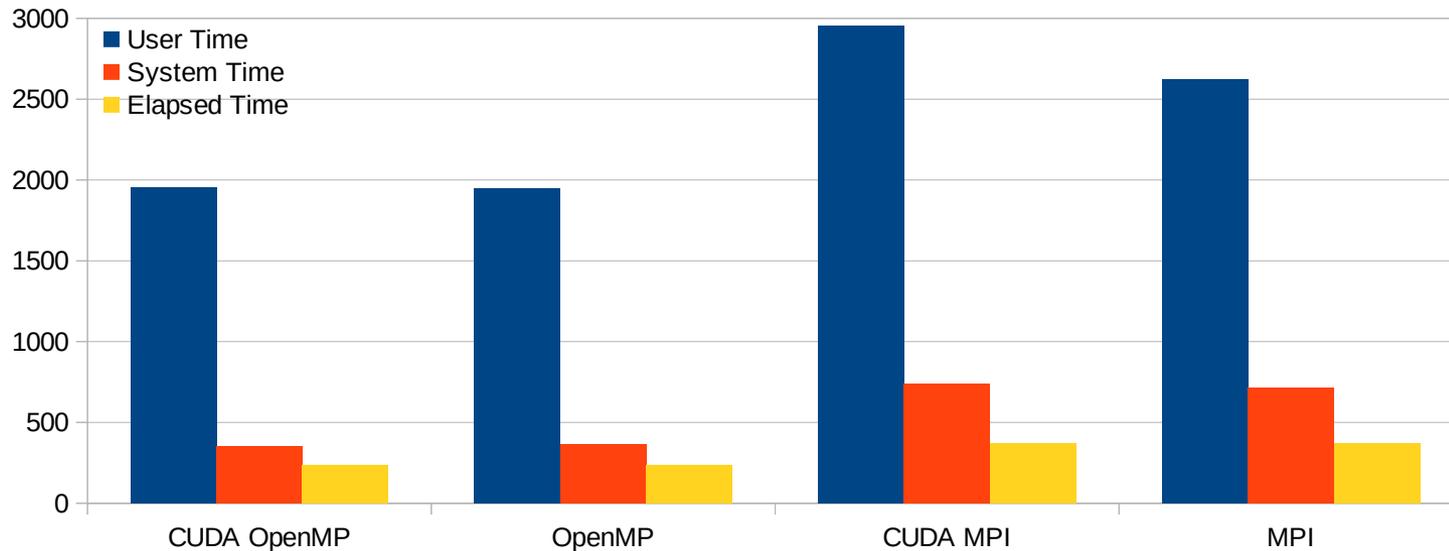
PKDGRAV3 : on veut comparer !

Donc, pour une pure « MPI »

- On ajoute aux commandes précédentes :
 - `mv pkdgrav3_mpi pkdgrav3_mpi_cuda`
 - `make distclean-recursive`
 - `./autogen.sh`
 - `./configure --with-fftw --enable-integer-positions`
 - `make -j 16`
- Et comme test ?
 - `cosmology.par` dans `examples...`

PKDGRAV3 : et les résultats ?

Sur une Tesla P100 & E5-2640v4



- Aucun gain !
- Tout se passe comme si le GPU était absent...
- Mais OpenMPI et le programme accèdent au périphérique...
- Bref, j'ai dû merdé quelque part mais je ne sais pas où...
 - En fait, il y avait une option à activer au lancement mais pas dans la documentation...

Gromacs : le bon « client » de la chimie

- Socle matériel : les plates-formes du CBP
 - 51 GPU différents, 20 types de CPU
- Socle logiciel : Debian 9.4 dite « stretch » en AMD64
- Caractéristiques :
 - Open Source
 - Hybride : multi-nœuds, multi-cœurs, multi-shaders
 - Possibilité d'exécution CPU (MPI+OpenMP), CPU+GPU
 - Paramétrage facile du parallélisme et du choix du GPU

Gromacs : phase préparatoire

En lisant la documentation

- Expansion archive, déplacement, création dossier, déplacement
 - `tar xzf gromacs-2018.1.tar.gz ; cd gromacs-2018.1 ; mkdir build ; cd build`
- Paramétrage compilation avec options :
 - `cmake .. -DGMX_BUILD_OWN_FFTW=ON -DREGRESSIONTEST_DOWNLOAD=ON`
- Compilation et installation
 - `make ; make check ; sudo make install`
- Chargement de l'environnement :
 - `source /usr/local/gromacs/bin/GMXRC`

Gromacs : phase préparatoire

Nos contraintes & nos 1^{ers} déboires

- Plusieurs contextes : à chaque processeur/GPU, sa compilation
 - Plusieurs dossiers d'installation des exécutables
- Compilateurs standards Stretch : gcc, g++ version 6.3
- Lancement cmake : KO

```
CMake Error at cmake/gmxManageGPU.cmake:289 (message):
  NVCC/C compiler combination does not seem to be supported.  CUDA frequently
  does not support the latest versions of the host compiler, so you might
  want to try an earlier C/C++ compiler version and make sure your CUDA
  compiler and driver are as recent as possible.
Call Stack (most recent call first):
  CMakeLists.txt:582 (gmx_gpu_setup)

-- Configuring incomplete, errors occurred!
See also "/local/Gromacs/gromacs-2018.1/build_CUDA/CMakeFiles/CMakeOutput.log".
See also "/local/Gromacs/gromacs-2018.1/build_CUDA/CMakeFiles/CMakeError.log".
```

- Trouver un autre compilateur !

Gromacs : phase préparatoire

Les déboires continuent

- Passage sur clang version 3.8, mais...

```
-- Adding work-around for issue compiling CUDA code with glibc 2.23 string.h
CMake Warning at cmake/gmxManageGPU.cmake:272 (message):
  To use GPU acceleration efficiently, mdrun requires OpenMP multi-threading.
  Without OpenMP a single CPU core can be used with a GPU which is not
  optimal. Note that with MPI multiple processes can be forced to use a
  single GPU, but this is typically inefficient. You need to set both C and
  C++ compilers that support OpenMP (CC and CXX environment variables,
  respectively) when using GPUs.
Call Stack (most recent call first):
  CMakeLists.txt:582 (gmx_gpu_setup)
```

- Exécution dégradée (pas de OpenMP)
 - Phases cmake & compilation effroyablement lente (plus de 10x)
 - Finalement crash à la compilation... :-(
- Passage sur compilateur plus ancien 4.9

Gromacs : phase préparatoire

Importation d'un vieux compilateur

- Exploitation des « snapshots » : tout le script d'installation...
 - `wget http://snapshot.debian.org/package/gcc-4.9/4.9.4-2/`
 - `mkdir gcc-4.9.4`
 - `cd gcc-4.9.4`
 - `wget -O DebianSnapshot-gcc-4.9.4.html http://snapshot.debian.org/package/gcc-4.9/4.9.4-2/`
 - `egrep '(_amd64.deb|_all.deb)' DebianSnapshot-gcc-4.9.4.html | awk -F\" '{ print $2 }' | grep -v kfreebsd | grep -v lib32 | grep -v libx32 | sort -u | grep -v multilib | xargs -l '{}' wget http://snapshot.debian.org/'{'}`
 - `sudo dpkg -i *deb`
 - `sudo apt-get -f install`
- Ca y est ! Un vieux compilateur prêt pour la route...

Gromacs : enfin la compilation !

Tout le script, pour un CUDA

- `mkdir -p /local/Gromacs/ ; cd /local/Gromacs/`
- `wget ftp://ftp.gromacs.org/pub/gromacs/gromacs-2018.1.tar.gz`
- `export GPU=GTX1080Ti`
- `export CC=/usr/bin/gcc-4.9 ; export CXX=/usr/bin/g++-4.9`
- `export GMXINSTALL=/scratch/Gromacs/2018.1`
- `export GMXSRC=/local/Gromacs/gromacs-2018.1`
- `tar xzf gromacs-2018.1.tar.gz ; cd gromacs-2018.1`
- `mkdir -p $(dirname $GMXINSTALL) ; mkdir $GMXSRC/build_${GPU}`
- `cd $GMXSRC/build_${GPU}`
- `cmake .. -DGMX_BUILD_OWN_FFTW=ON -DGMX_GPU=on -DREGRESSIONTEST_DOWNLOAD=ON -DCMAKE_INSTALL_PREFIX=${GMXINSTALL}_${GPU}`
- `make -j 16 ; make check ; make install`

Gromacs : cas d'usage Nvidia

Paramètres d'exécution

- Tâche coûteuse (et parallélisée) : mdrun
 - -ntmpi : contrôle du nombre de processus MPI concurrent
 - -ntomp : contrôle du nombre de processus OpenMP concurrents
 - -gpu_id : contrôle l'exécution sur un (ou plusieurs) GPU
 - -nb cpu : contrôle l'exécution sur uniquement le CPU
- Si aucun paramètre donné : mdrun explore la machine
 - Autant de processus OpenMP que de cœurs détectés (si aucun OMP_NUM_THREADS)
 - Autant de processus MPI que de cœurs détectés (si OMP_NUM_THREADS mis à 1)
- Dans une exécution multigpu : -gpu_id 01 active le 0 et le 1
 - Pour les Nvidia, préférez la variable d'environnement : CUDA_VISIBLE_DEVICES

Le banc de test...

D'abord les 9 (GP)GPUs

- GPU de gamer Nvidia : pilote 375.82
 - GTX 1080Ti : architecture Pascal, 3584 cudacores, 1582 GHz
 - GTX 980Ti : architecture Maxwell, 2816 cudacores, 1075 MHz
 - GTX 780Ti : architecture Kepler, 2880 cudacores, 875 MHz
- GPGPU de Nvidia : pilote 375.82
 - Tesla P100 : architecture Pascal, 3584 cudacores, 1126 GHz
 - Tesla K80 : architecture Kepler, 2x 2496 cudacores, 560 MHz
 - Tesla K40m : architecture Kepler, 2880 cudacores, 745 MHz
- GPU de gamer AMD : pilote 17.40 (2482.3)
 - Vega 64 : architecture GFX900, 4096 streamprocessors, 1406 GHz
 - R9-Fury : architecture Fiji, 3584 streamprocessors, 1000 GHz
 - R9-295X2 : architecture Hawaii, 2x 2816 streamprocessors, 1018 GHz

Le banc de Test :

Ensuite leur socle, les 7 CPU

- Ryzen7 1800 : 8 cœurs, 16HT, 3.6 GHz
 - Socle du R9 Fury
- Skylake i7-6700K : 4 cœurs, 8HT, 4 GHz
 - Socle du Vega64 et du R9-295X2
- E5-2637v4 : 2x4 cœurs, 16HT, 3.5 GHz
 - Socle du GTX1080 Ti
- E5-2640v4 : 10 cœurs virtualisés, 2.4 GHz
 - Socle du Tesla P100
- E5-2637v2 : 4 cœurs virtualisés, 3.5 GHz
 - Socle du Tesla K40m
- E5-2607v2 : 2x4 cœurs, 2.5 GHz
 - Socle du GTX980Ti
- E5- 2620 : 6 cœurs, 12 HT, 2 GHz
 - Socle du GTX 780Ti

Gromacs : cas d'usage #1

« Test » Nvidia

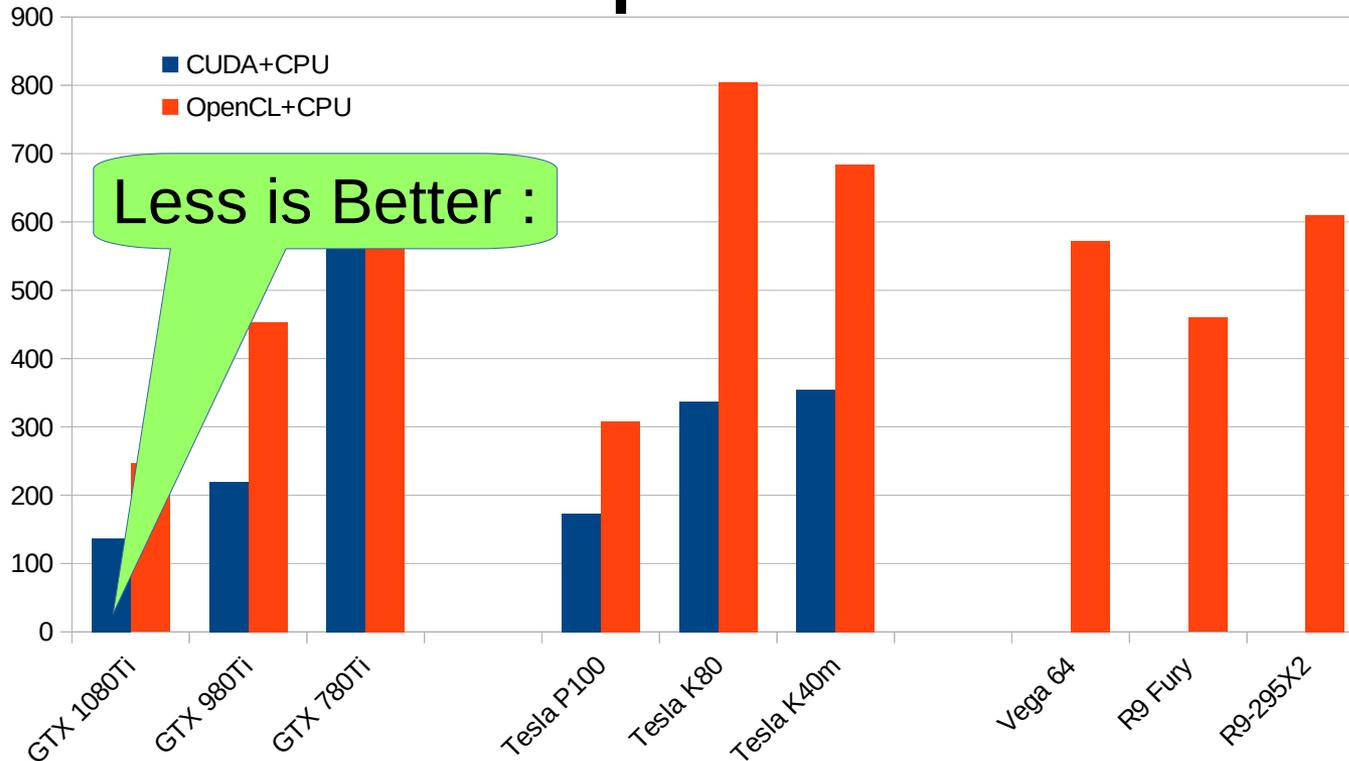
- Configuration des chemins et dossiers d'exécution
 - export GPU=GTX1080Ti
 - mkdir -p /scratch/Gromacs/Test/\${hostname}_\${GPU}
 - cd /scratch/Gromacs/Test/\${hostname}_\${GPU}
 - GRODIR=/scratch/Gromacs/2018.1_\${GPU}
 - source \$GRODIR/bin/GMXRC
- Chargement & expansion de l'archive de paramètres d'entrée
 - wget ftp://ftp.gromacs.org/pub/benchmarks/water_GMX50_bare.tar.gz
 - [-d water-cut1.0_GMX50_bare] && rm -r water-cut1.0_GMX50_bare
 - tar -zxvf water_GMX50_bare.tar.gz ; cd water-cut1.0_GMX50_bare/1536
- Exécution des tâches
 - \$GRODIR/bin/gmx grompp -f pme.mdp
 - /usr/bin/time \$GRODIR/bin/gmx mdrun -reseed -noconfout -nsteps 4000 -v -gpu_id 0

Gromacs : cas d'usage #1

« Test » Nvidia : sortie « time »

- TIME Command being timed: `"/scratch/Gromacs/2018.1_GTX980Ti_OpenCL/bin/gmx mdrun -reseedway -noconfout -nsteps 4000 -v -gpu_id 0"`
- TIME User time (seconds): 2767.16
- TIME System time (seconds): 25.98
- TIME Elapsed (wall clock) time : 452.90
- TIME Percent of CPU this job got: 616%
- TIME Average shared text size (kbytes): 0
- TIME Average unshared data size (kbytes): 0
- TIME Average stack size (kbytes): 0
- TIME Average total size (kbytes): 0
- TIME Maximum resident set size (kbytes): 4820892
- TIME Average resident set size (kbytes): 0
- TIME Major (requiring I/O) page faults: 39
- TIME Minor (reclaiming a frame) page faults: 1248968
- TIME Voluntary context switches: 288413
- TIME Involuntary context switches: 447953
- TIME Swaps: 0
- TIME File system inputs: 191072
- TIME File system outputs: 0
- TIME Socket messages sent: 0
- TIME Socket messages received: 0
- TIME Signals delivered: 0
- TIME Page size (bytes): 4096
- TIME Exit status: 0

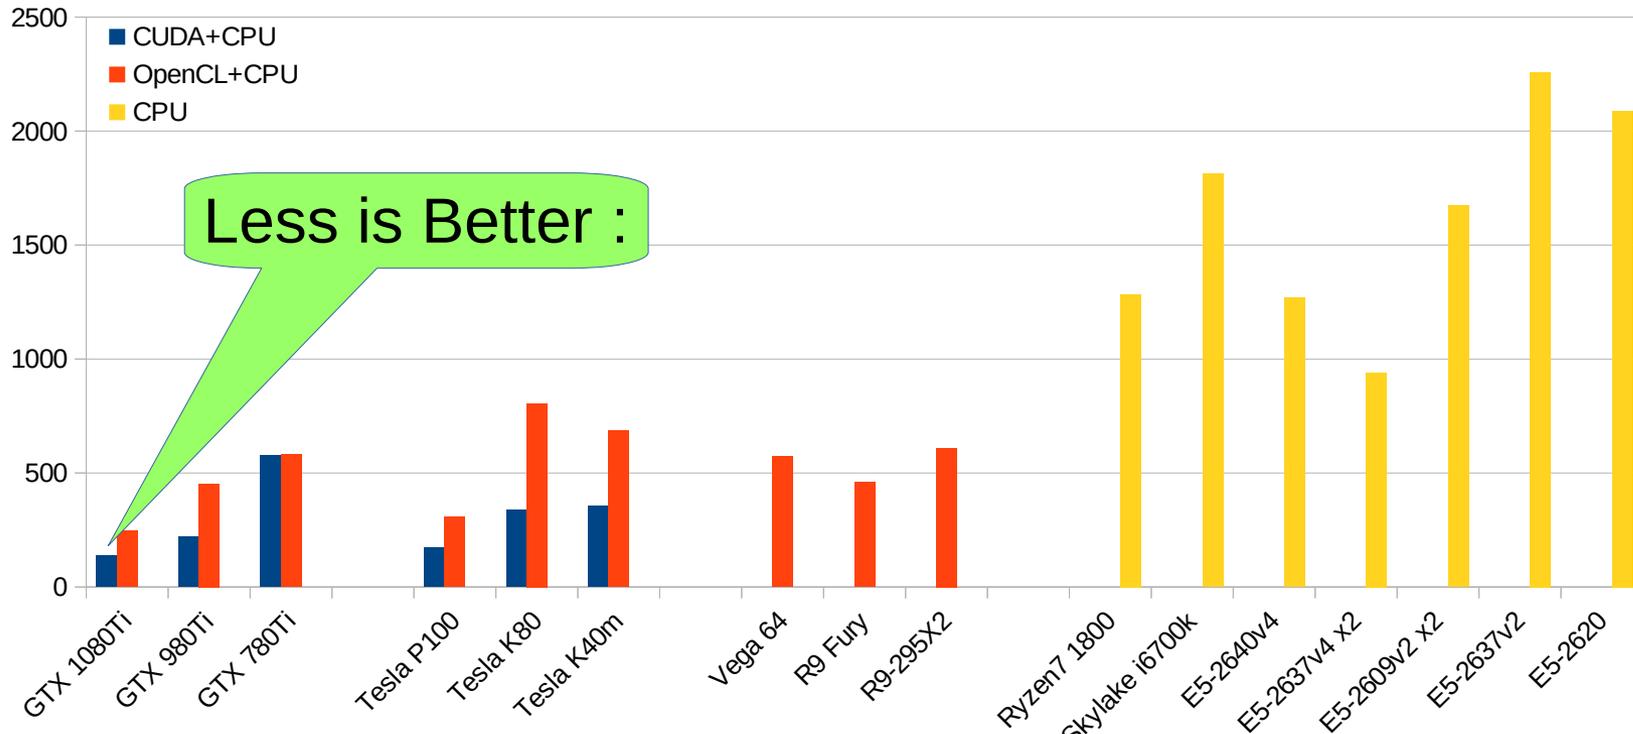
Cas d'usage #1 : test Nvidia D'abord pour les GPU...



- Les implémentations OpenCL sont 2x plus lentes
- Les GPU AMD sont au moins 4x plus lentes

Cas d'usage #1 : test Nvidia

Ensuite on rajoute les CPU

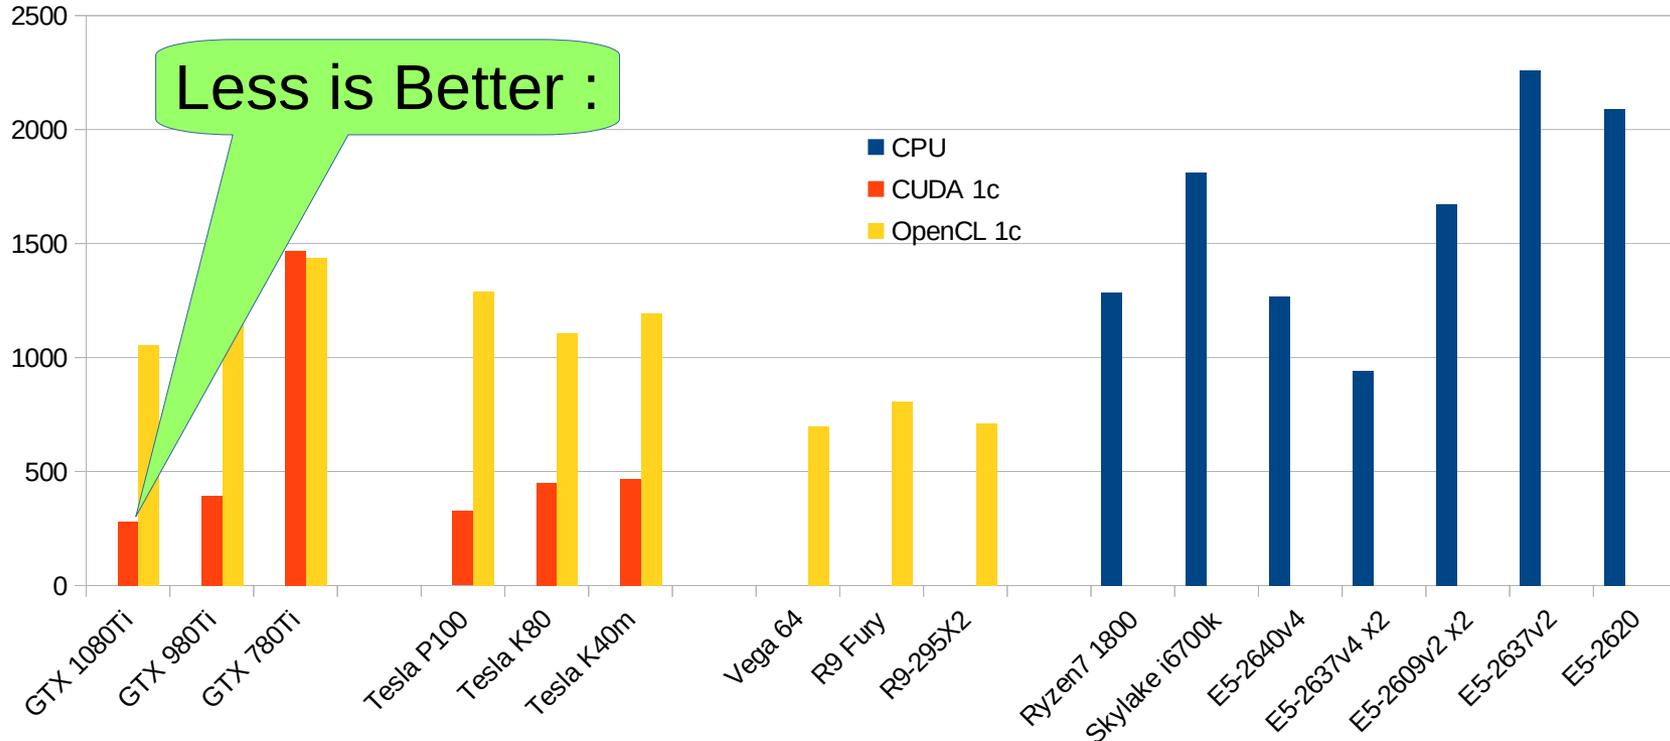


Less is Better :

- Les processeurs sont 10x plus lents que le GPU le plus rapide
- Les GPU sont au pire 2x plus rapide que le CPU le plus rapide
- Escroquerie ! Le programme est hybride (CPU/GPU)

Cas d'usage #1 : test Nvidia

Renormaliser : GPU sur 1 cœur...



- Le GPU le plus puissant sur 1 cœur CPU est 4x plus rapide que le CPU
- Les GPU sont dans tous les cas plus rapides que les assemblages de CPU
- Donc, utiliser des GPU pour Gromacs, c'est pertinent...

Gromacs : cas d'usage #2

« Test » Tutoriel Energie libre

- Configuration des chemins et dossiers d'exécution
 - export GPU=GTX780Ti
 - export GRODIR=/scratch/Gromacs/2018.1_\${GPU}
 - source \$GRODIR/bin/GMXRC
 - cd /scratch/Gromacs/Test ; mkdir \$(hostname)_\${GPU} ; cd \$(hostname)_\${GPU}
- Chargement & expansion de l'archive de paramètres d'entrée
 - tar xzf ../gromacs-free-energy-tutorial.tgz ; cd gromacs-free-energy-tutorial
 - SIZE=10
- Exécution des tâches
 - \$GRODIR/bin/gmx editconf -f ethanol.gro -o box.gro -bt dodecahedron -d \$SIZE
 - \$GRODIR/bin/gmx solvate -cp box.gro -cs -o solvated.gro -p topol.top
 - \$GRODIR/bin/gmx grompp -f em.mdp -c solvated.gro -o em.tpr
 - GMXLOG=GMXFE-\$(hostname)-\$SIZE-\$(date "+%Y%m%d%H%M").log
 - /usr/bin/time \$GRODIR/bin/gmx mdrun -gpu_id 0 -v -deffnm em >\$GMXLOG 2>&1
 - egrep time \$GMXLOG | grep -v timed

Gromacs : cas d'usage #2

« Test » Tutoriel Energie libre

- Une sortie beaucoup plus compacte :
 - TIME User time (seconds): 909.79
 - TIME System time (seconds): 4.95
 - TIME Elapsed (wall clock) time : 145.61

Cas d'usage #2 : test Tutorial

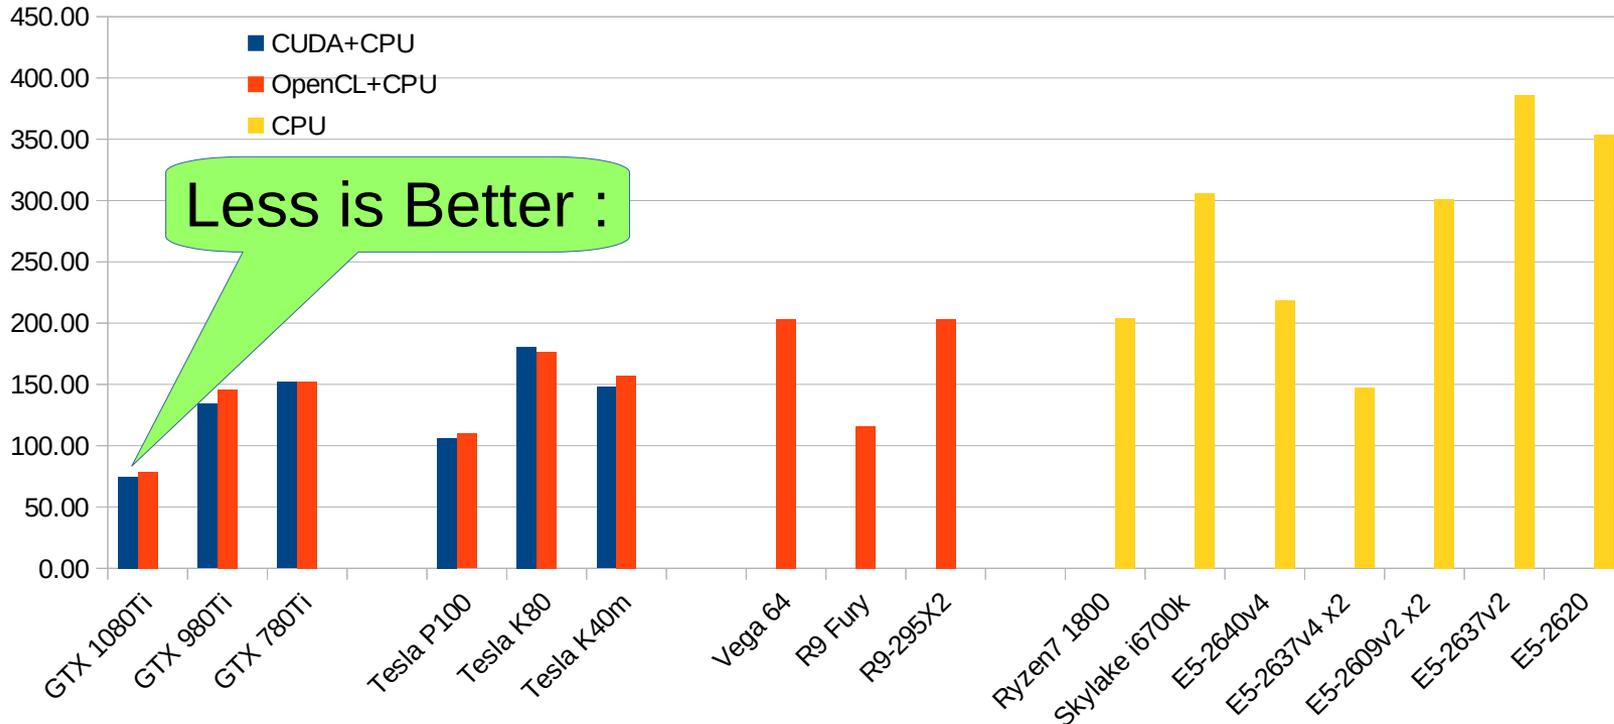
D'abord pour les GPU...



- Les implémentations OpenCL équivalentes à celles CUDA
- Les GPU AMD entre 2x et 3x plus lent que la meilleure

Cas d'usage #2 : test Nvidia

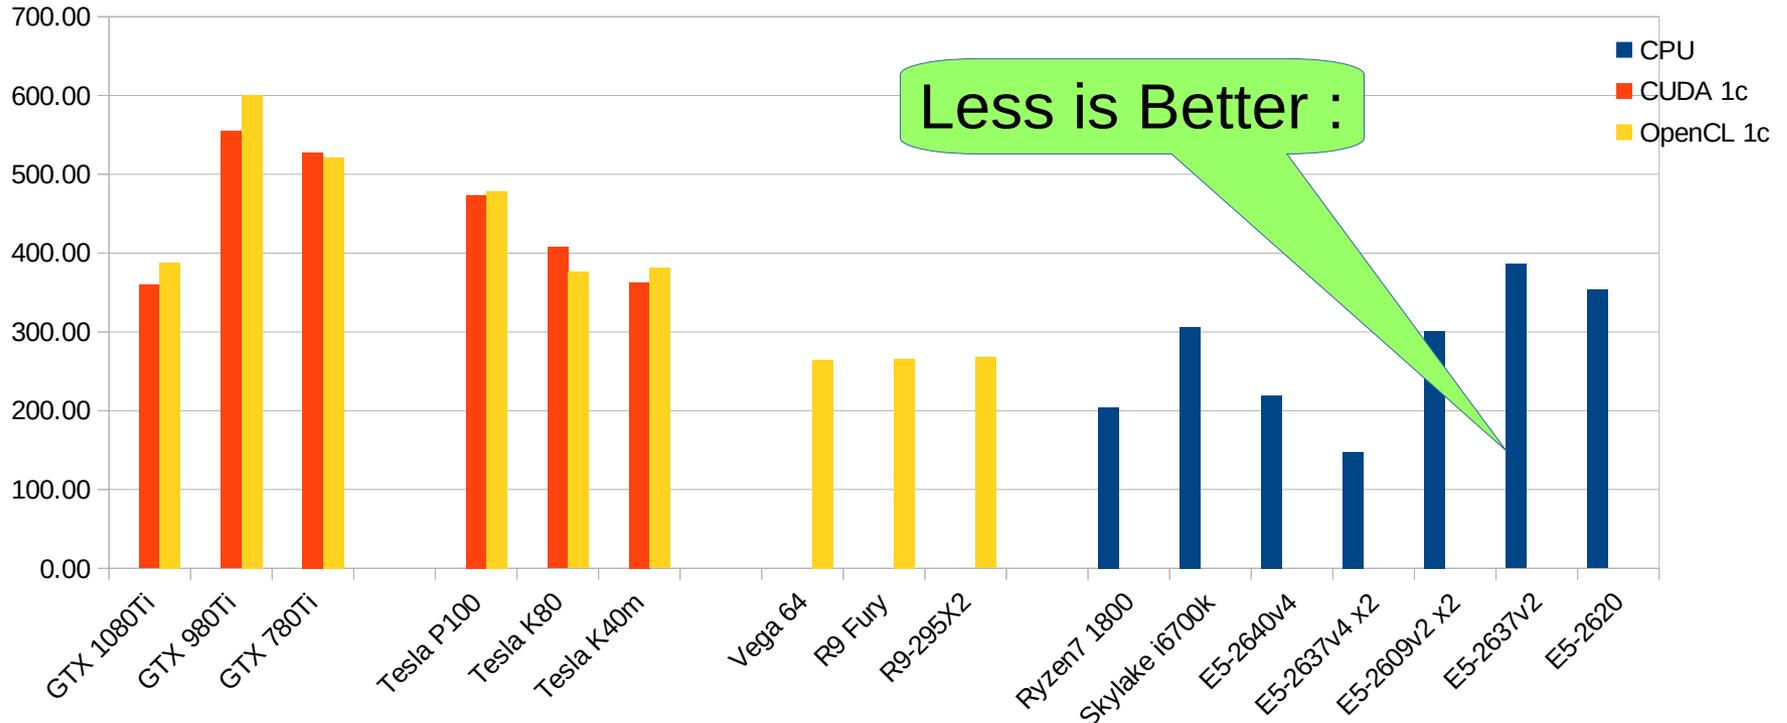
Ensuite on rajoute les CPU



- Les processeurs ne sont plus que 6x plus lents que le GPU le plus rapide
- Les GPU les moins rapides sont moins rapide que le CPU le plus rapide
- Et toujours l'escroquerie ! Le programme est hybride (CPU/GPU)

Cas d'usage #2 : test Nvidia

Renormaliser : GPU sur 1 cœur...



- Les GPU AMD sont plus rapides dans tous les cas que les Nvidia
- Les CPU sont généralement plus rapides les GPU
- Donc, utiliser des GPU pour Gromacs ici, attention !

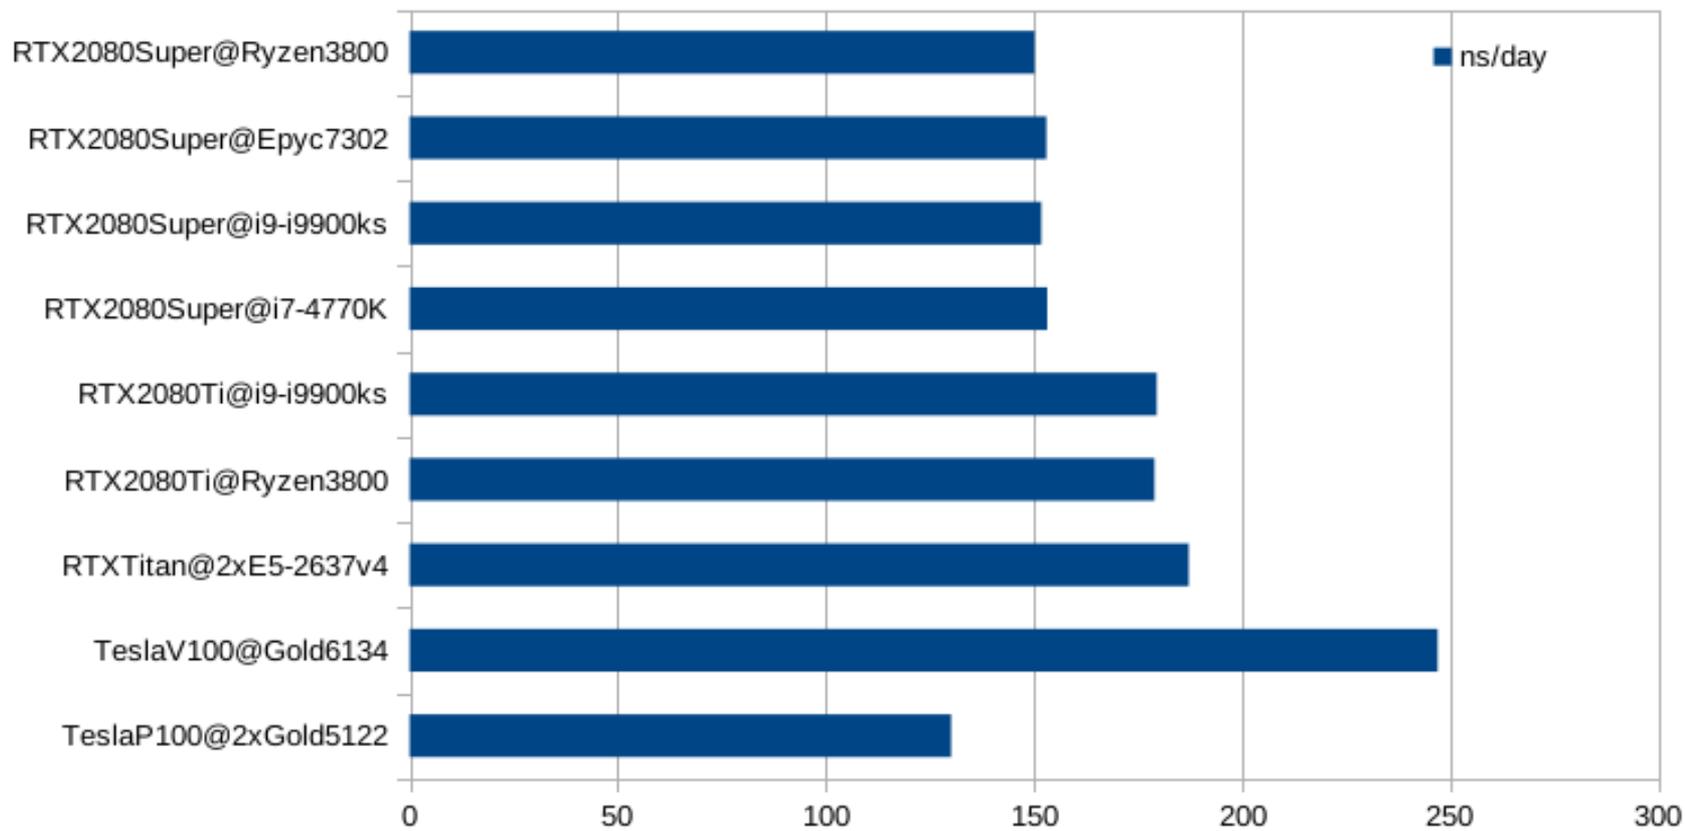
Gromacs : la conclusion

- GPU efficaces, MAIS dans un BON environnement
 - Le nombre de cœurs & la vitesse de la mémoire importants
- Implémentation CUDA toujours plus efficace
- Implémentation OpenCL en progrès
 - Mais 2x moins performante que la CUDA
- Exploitation de cartes de Gamer pertinente
 - Mais dans le cas de calculs en simple précision
- En gros, sans expérimentation, pas d'utilisation optimale...

Mais où est passé le facteur 100 de la pub ?

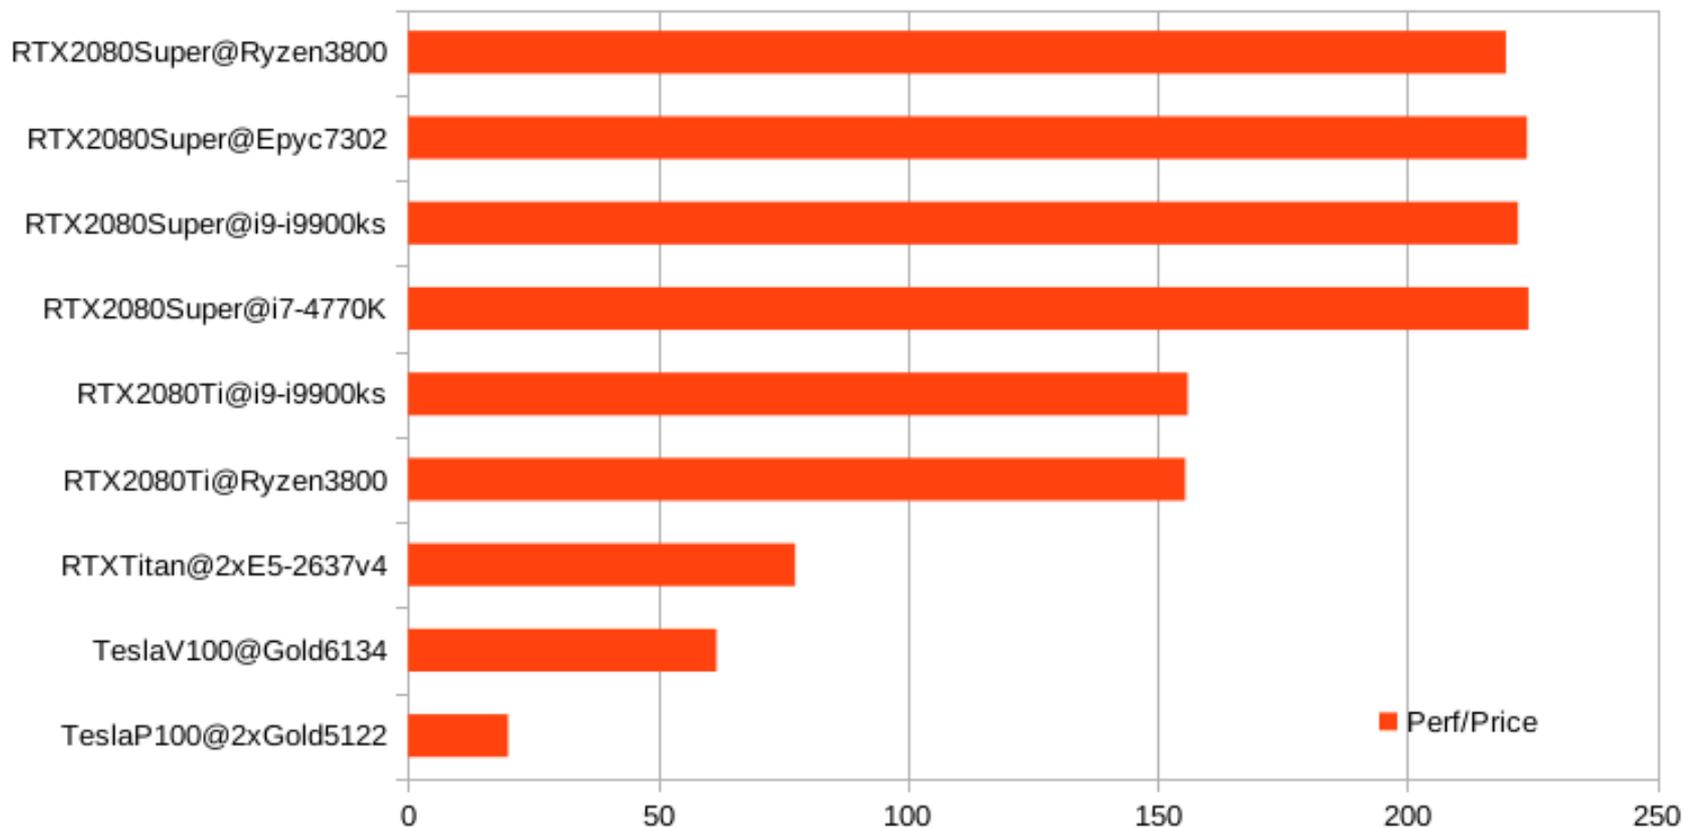
Un code « métier » propriétaire Amber9

- Si seulement la performance compte...



Un code « métier » propriétaire Amber9

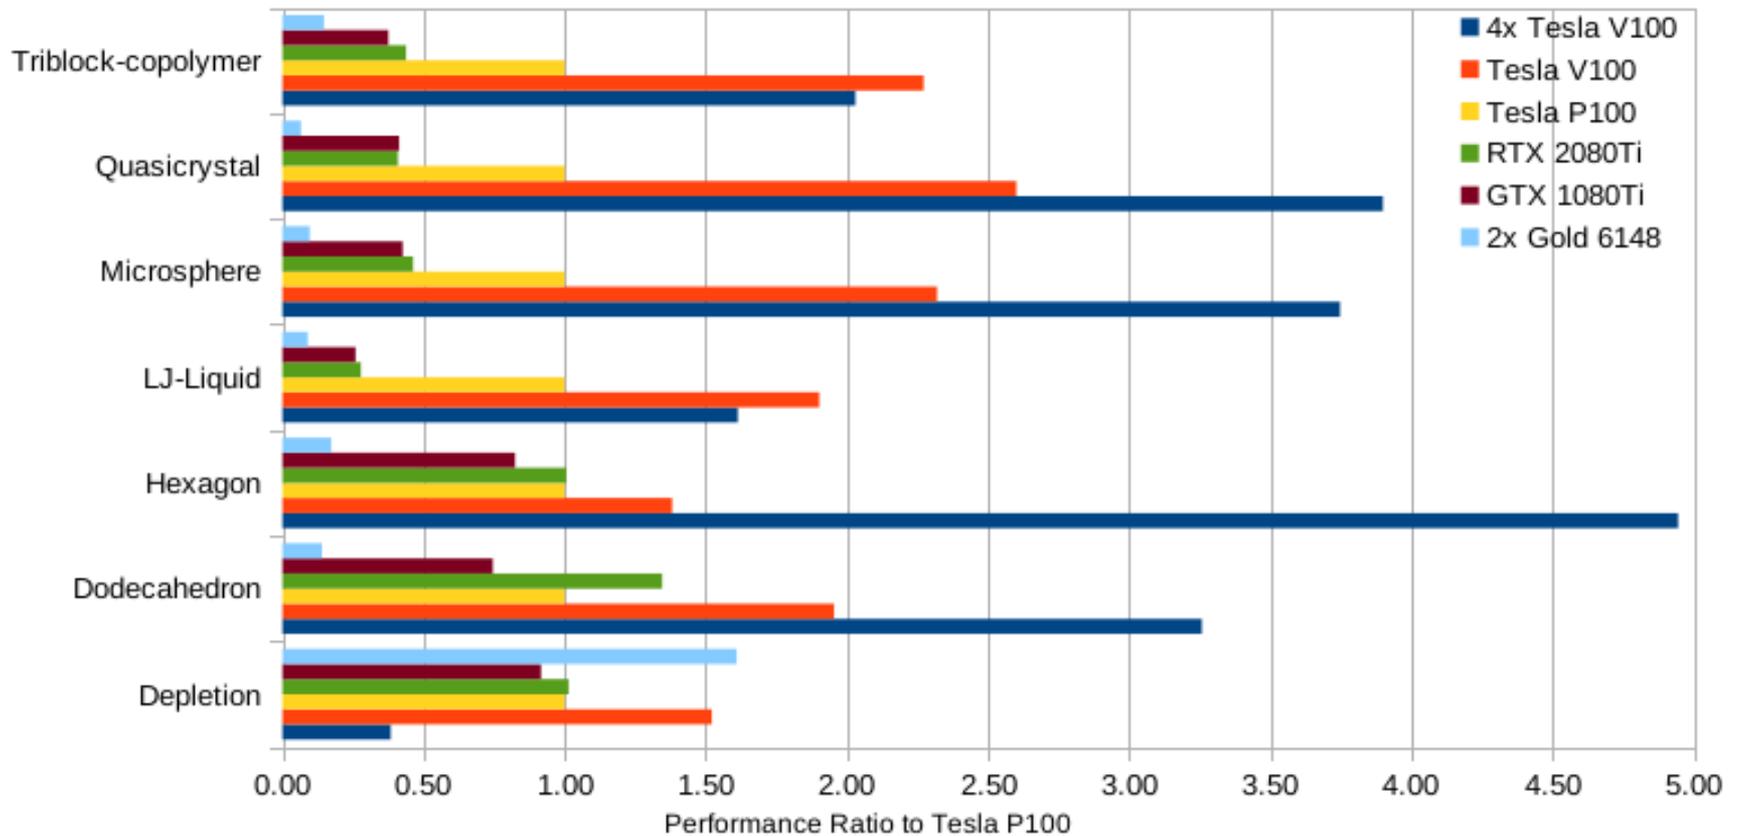
- Si vous avez un budget limité...



Un « monstre » : une C4140...

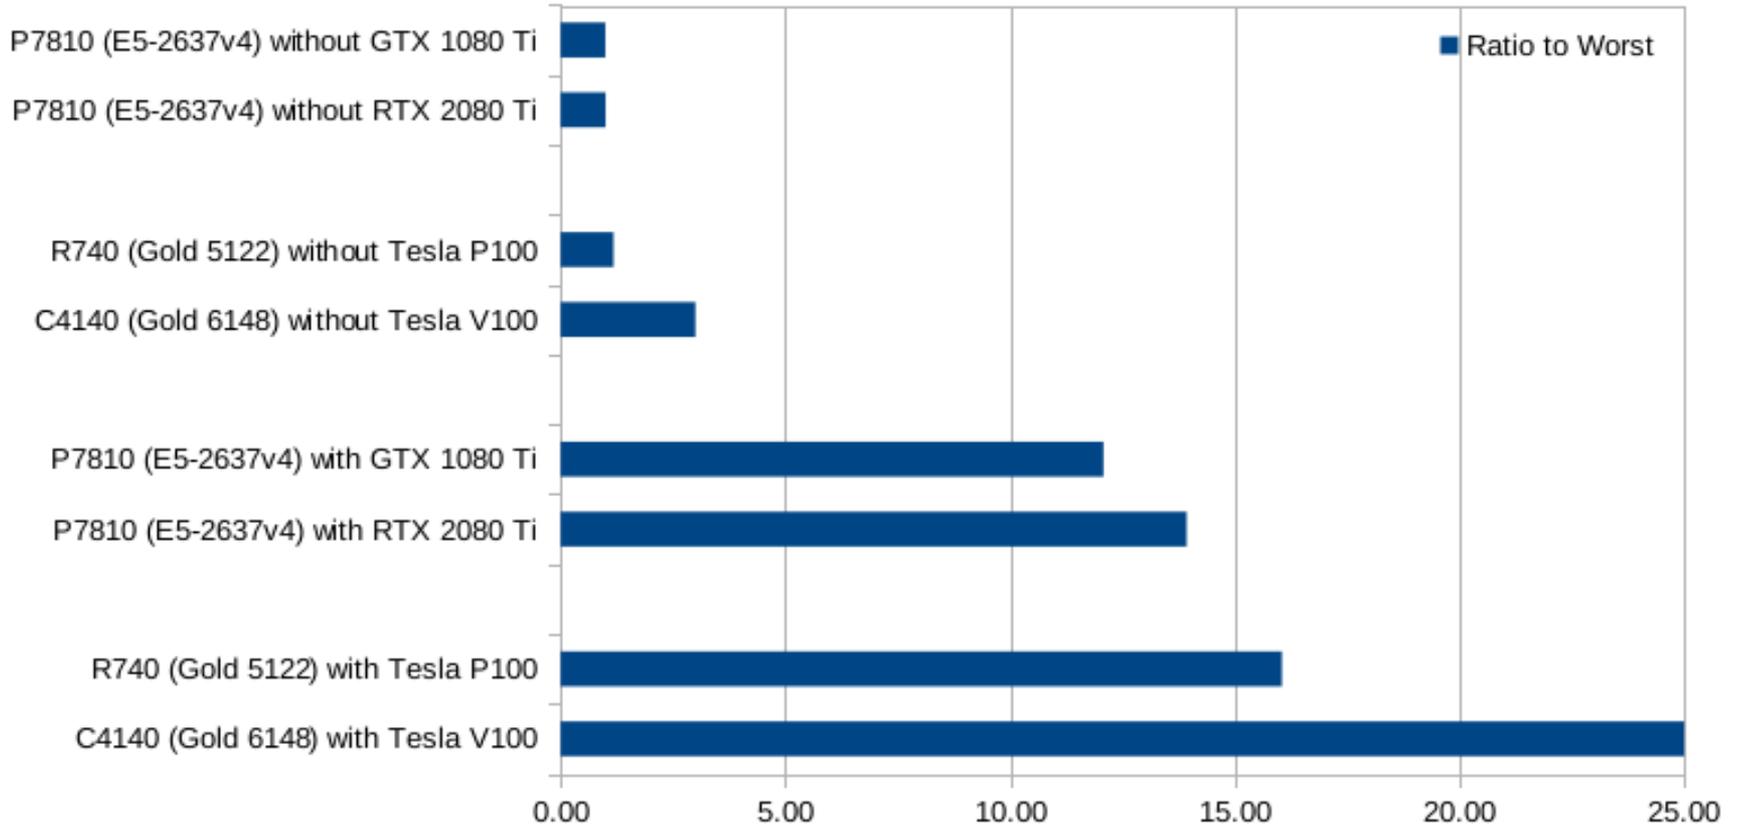
2 CPUs 24 cœurs, 4 GPGPU V100

- Sur le code Hoomd (en C++/CUDA, API en Python)

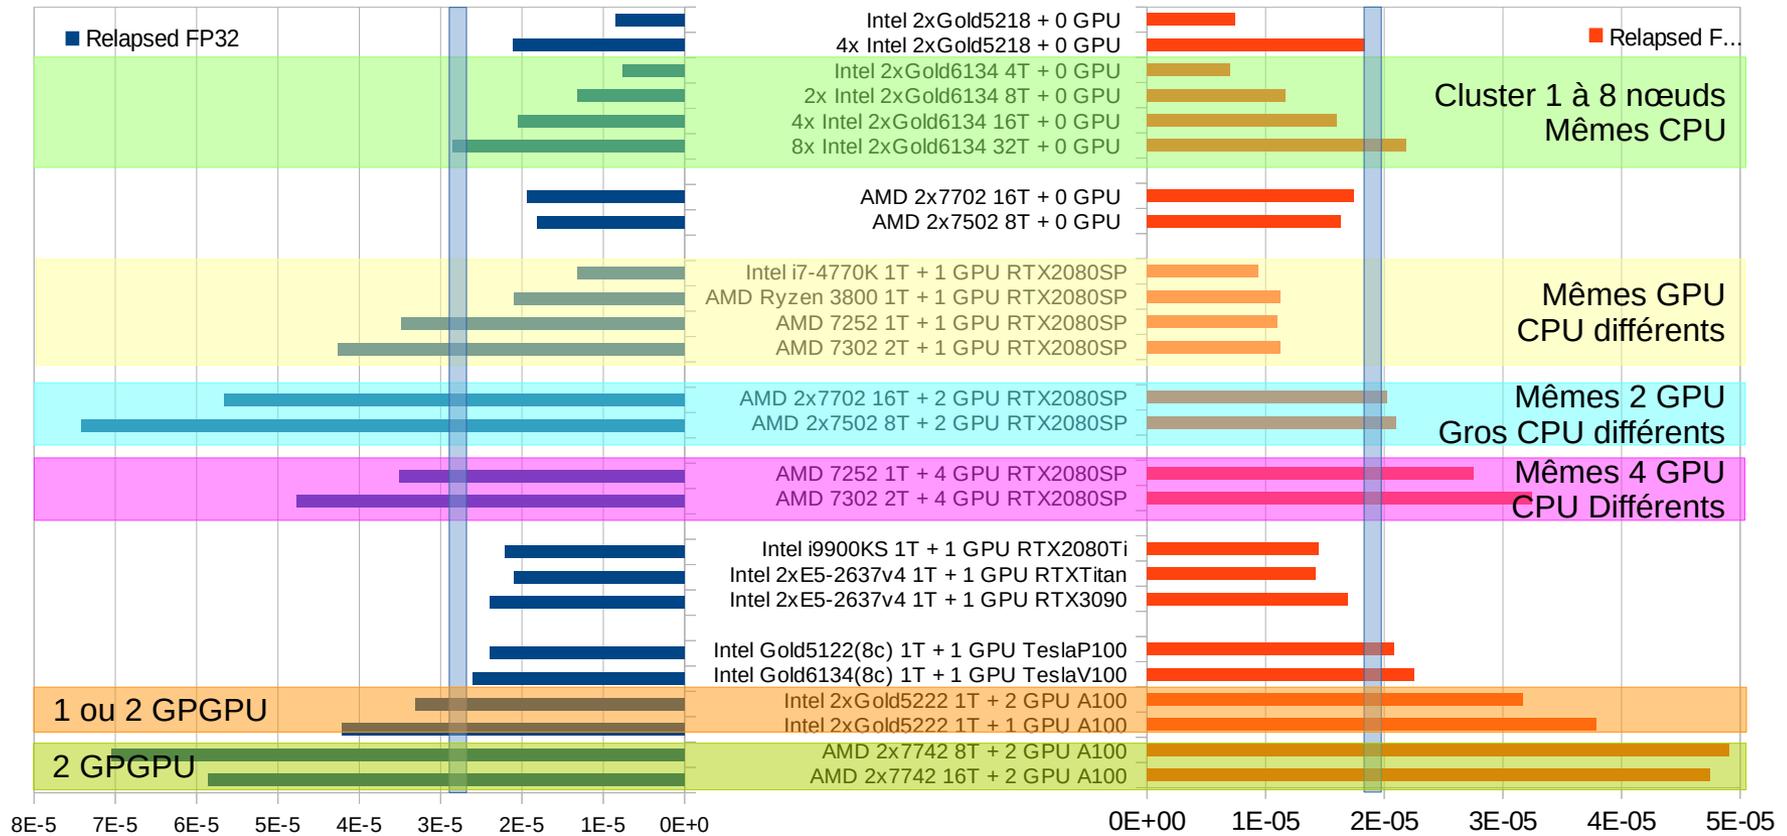


Tensorflow & CIFAR10

- La performance, oui, mais à quel prix ?



Code « métier » trhybride : GENESIS ... et un même cas d'usage !



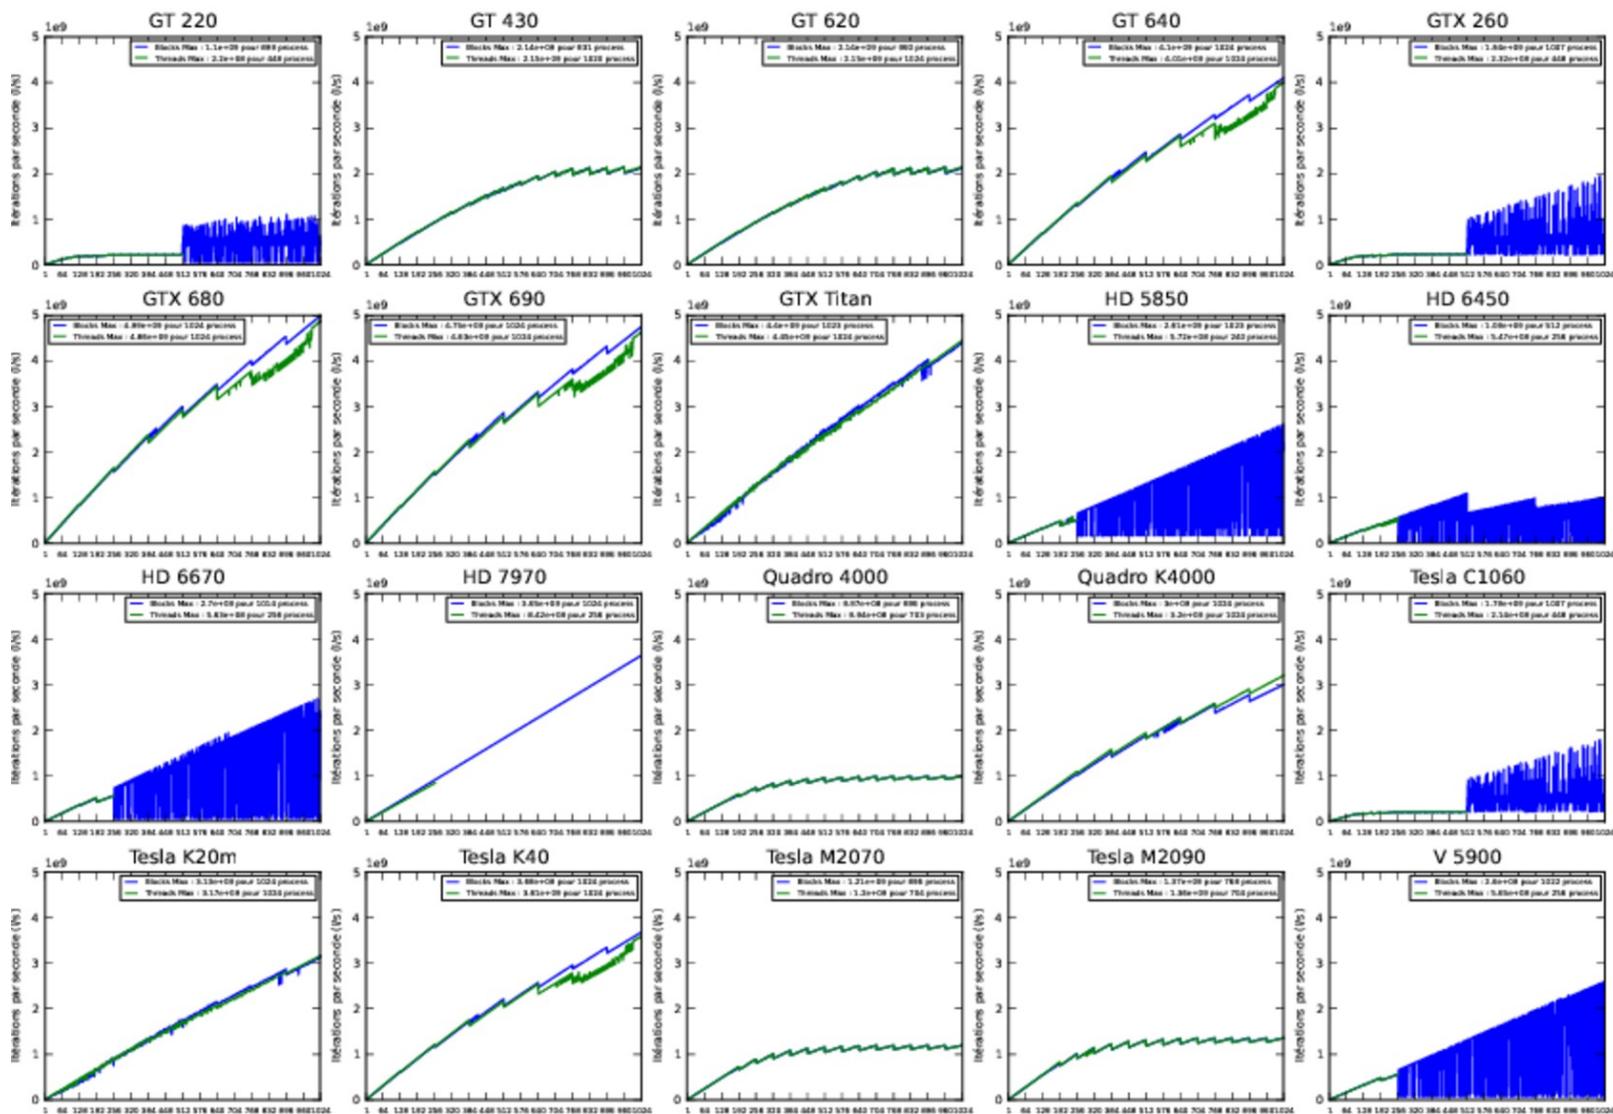
Comme quoi, difficile de se projeter sur une performance...

Des « trucs » bizarres...

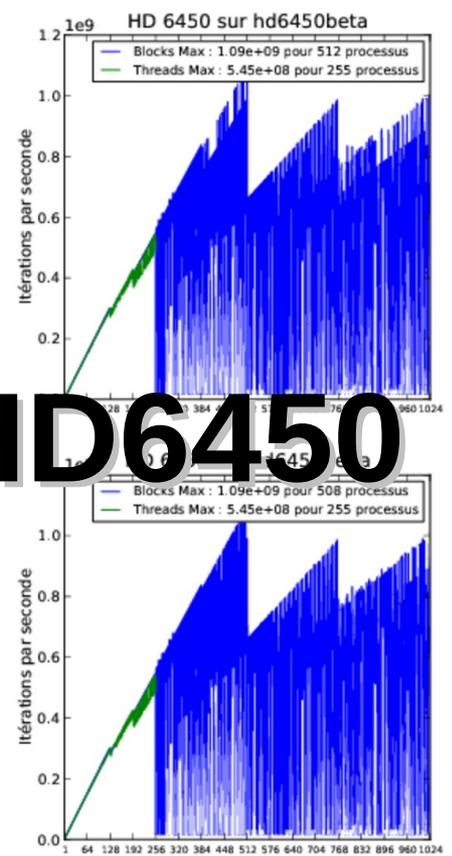
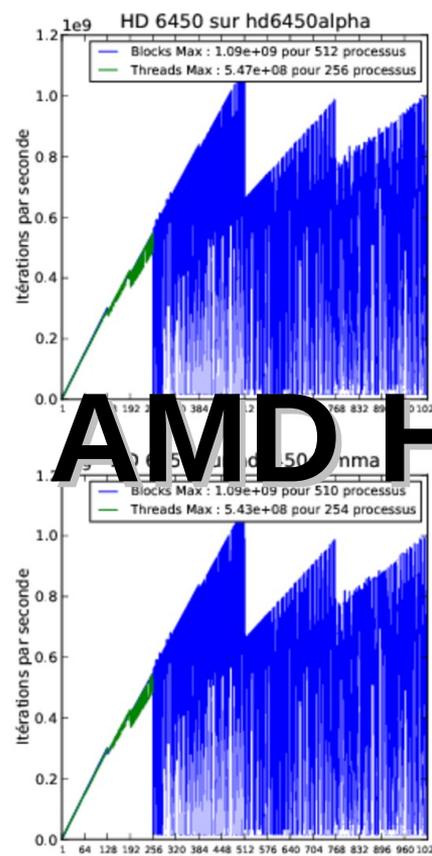
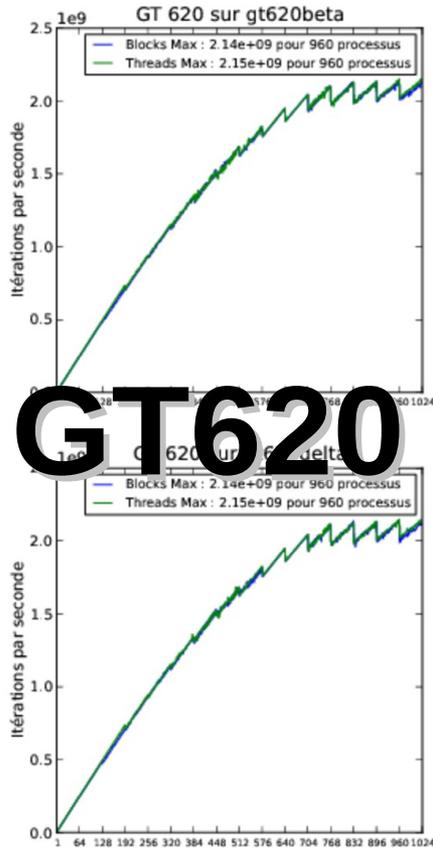
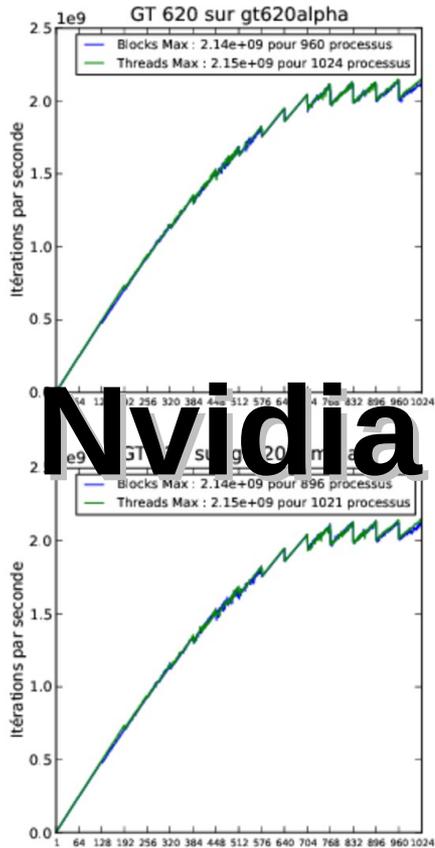
Petit florilège...

- Explorer l'architecture par « reverse engineering »...

Comportement de 20 (GP)GPU vs PR

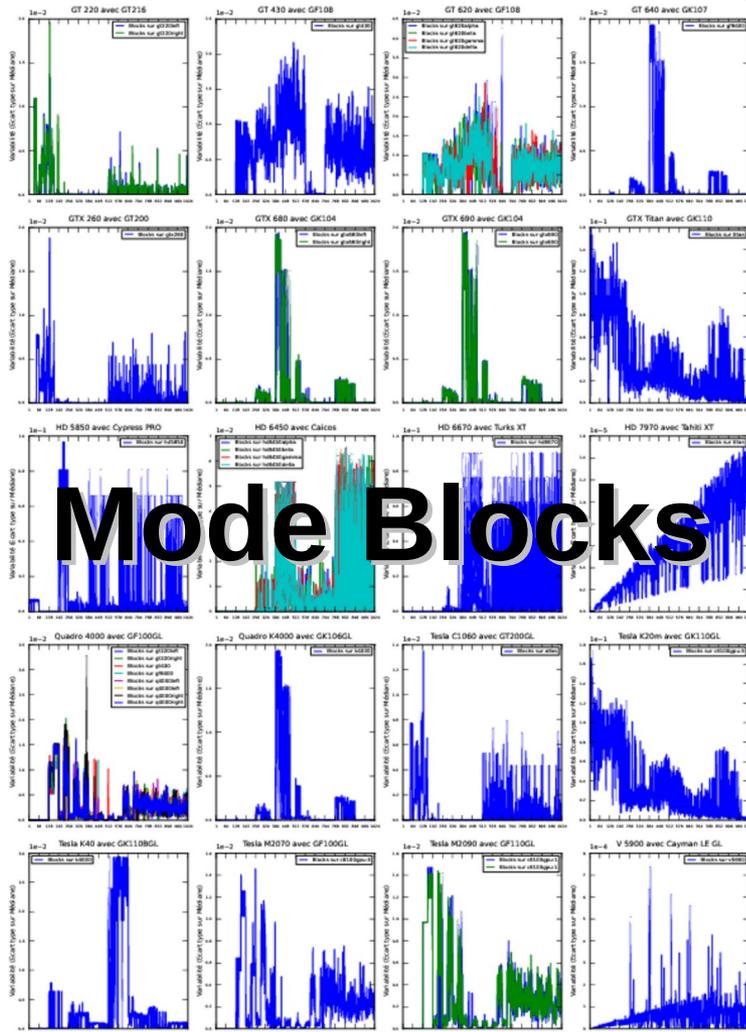


Enveloppes de parallélisme reproductibles ? Pour deux cartes spécifiques...

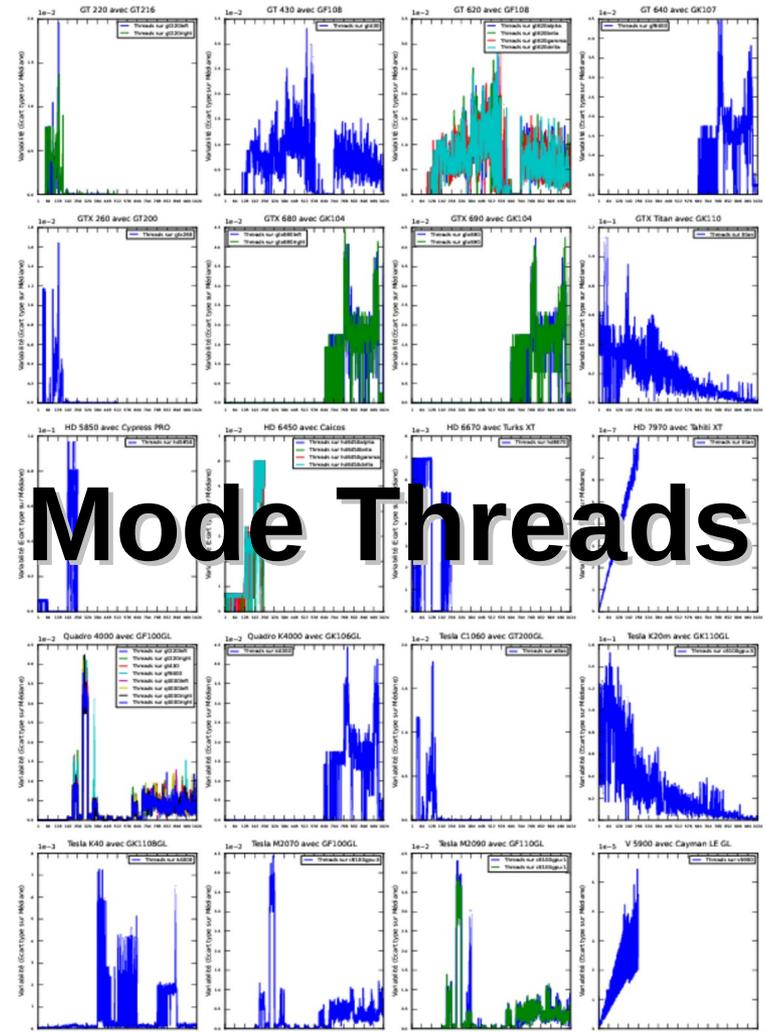


Nvidia GT620 AMD HD6450

Variabilité : un critère distinctif ! Quelle étrange propriété :-/ ...



Mode Blocks

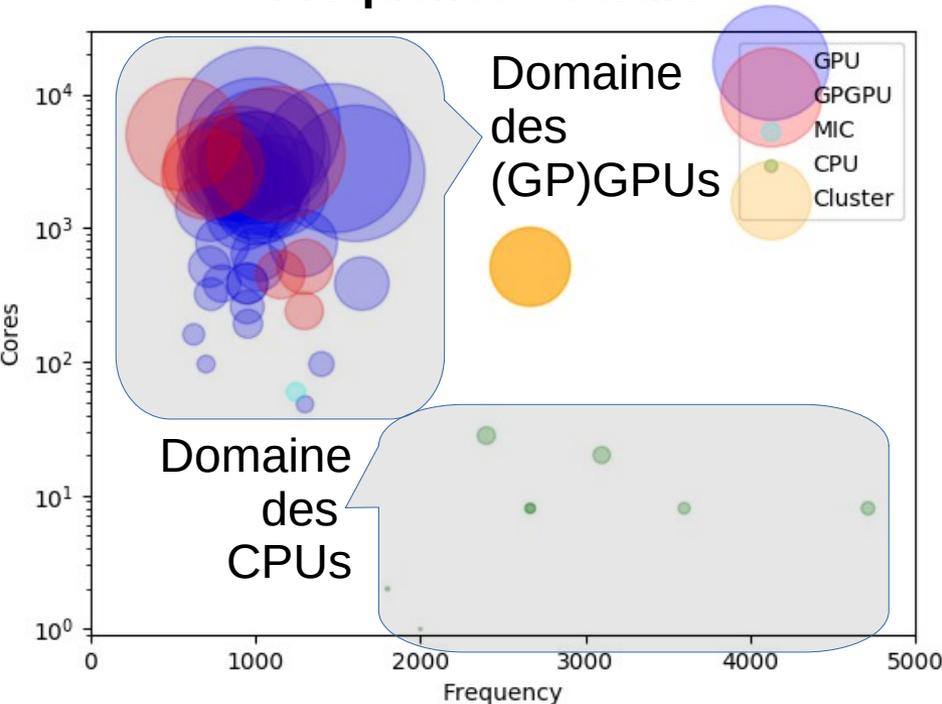


Mode Threads

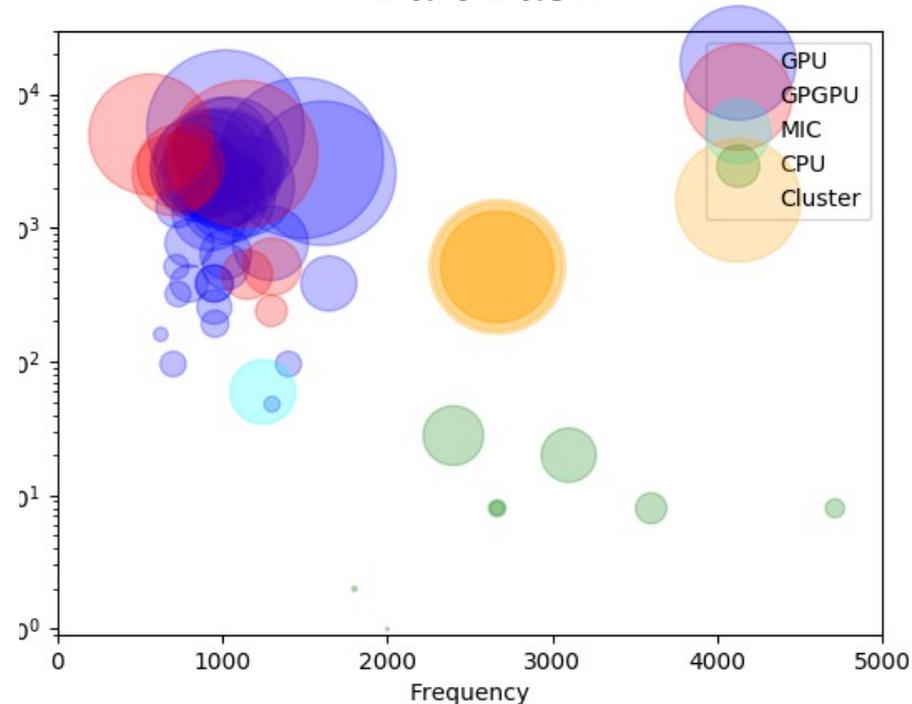
Représenter les performances...

Question de battement, de cœurs ?

Performance Théorique
Fréquence * cœurs



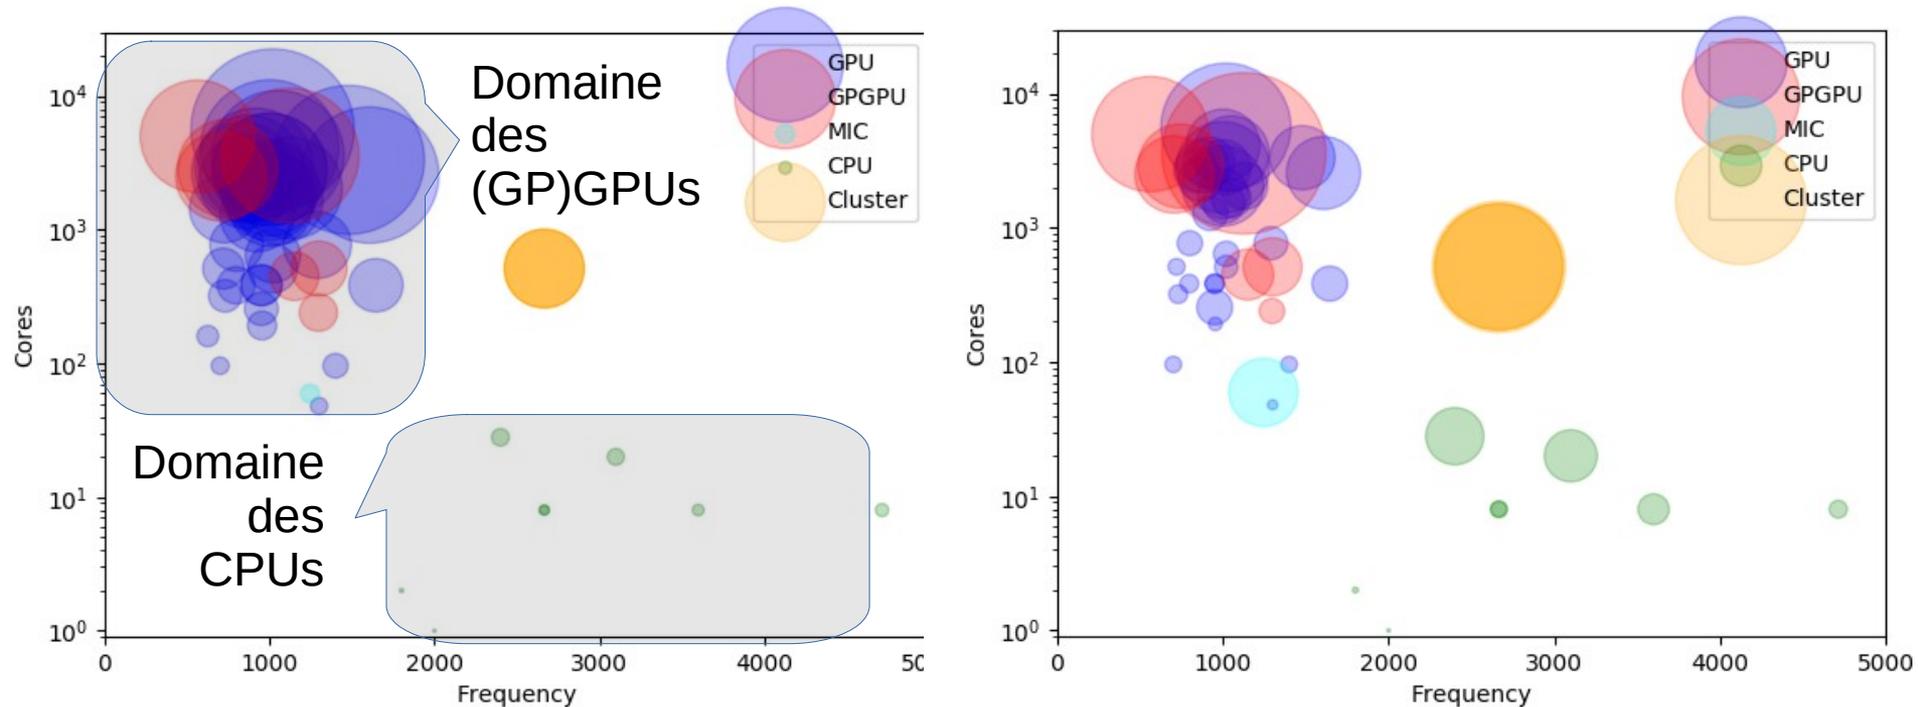
Performance en 32 bits
"Pi Dart Dash"



- Sur un GPU, cohérence entre performances théoriques & pratiques
- Sur un CPU, performance relative meilleure

La performance en informatique

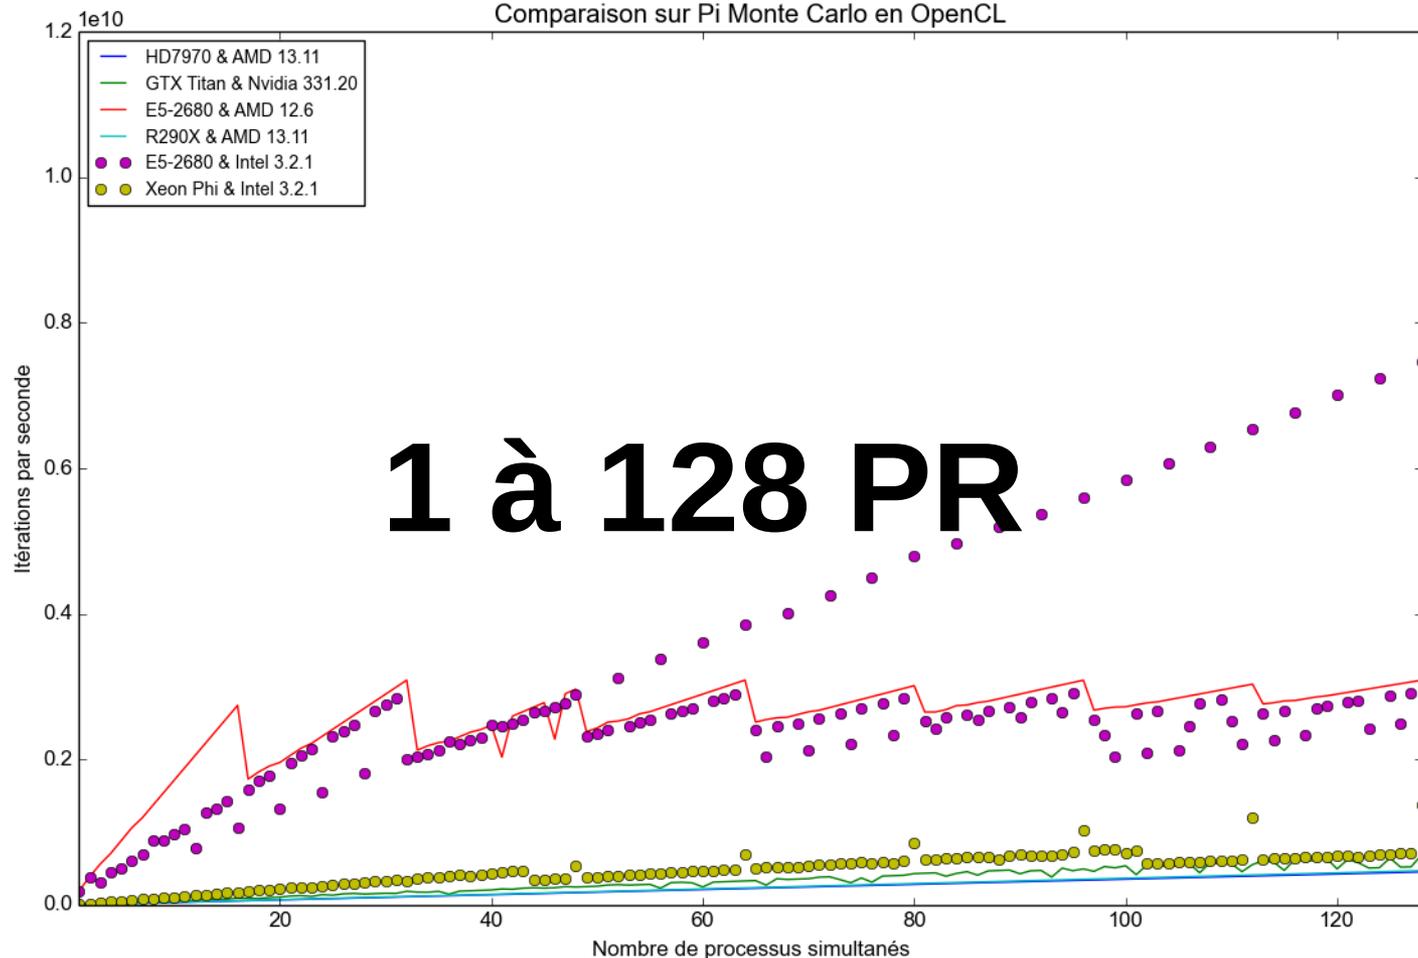
Question de battement, de cœurs, et de bits !



- Sur un GPU, baisse très sensible des performances pour les GPU
- Sur un CPU, performance relative encore meilleure

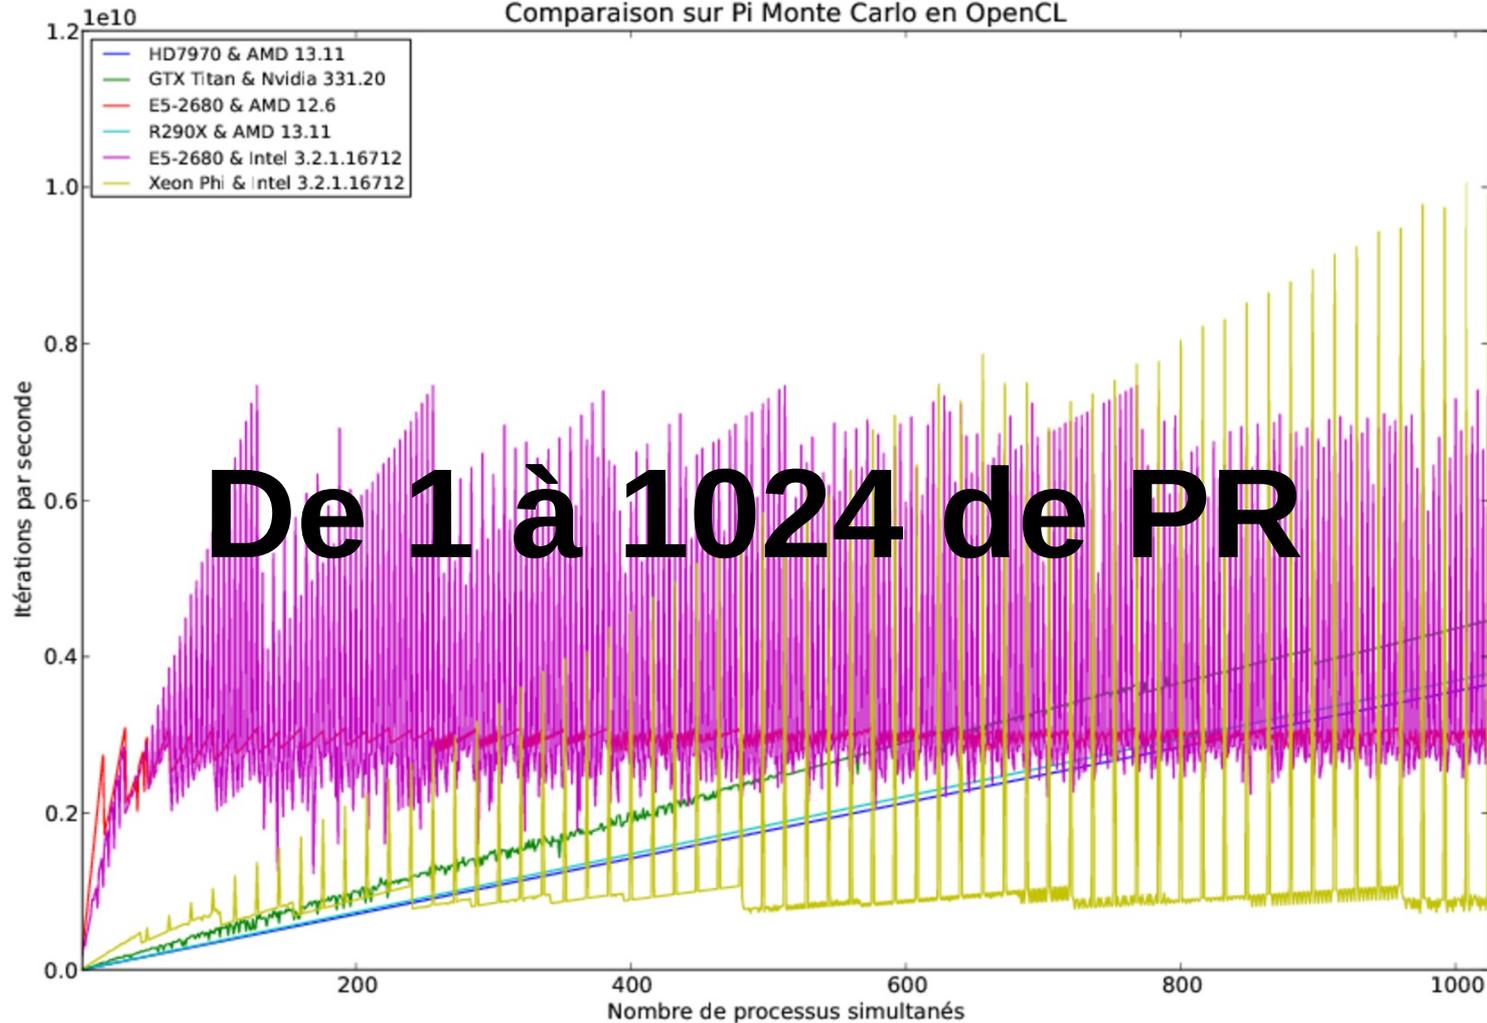
Petite comparaison entre *PU

Bas pararégime : le règne du CPU

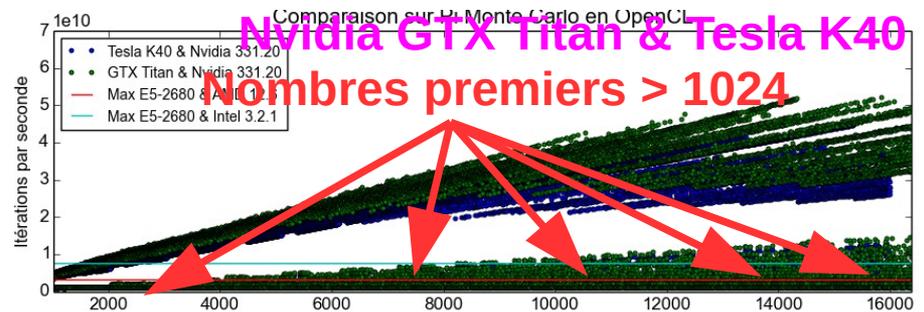
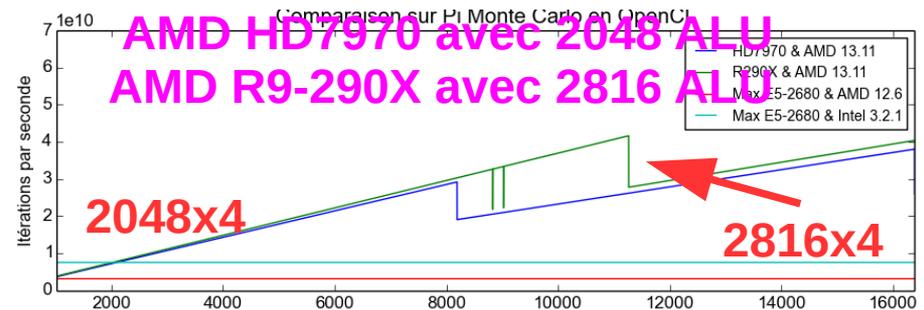
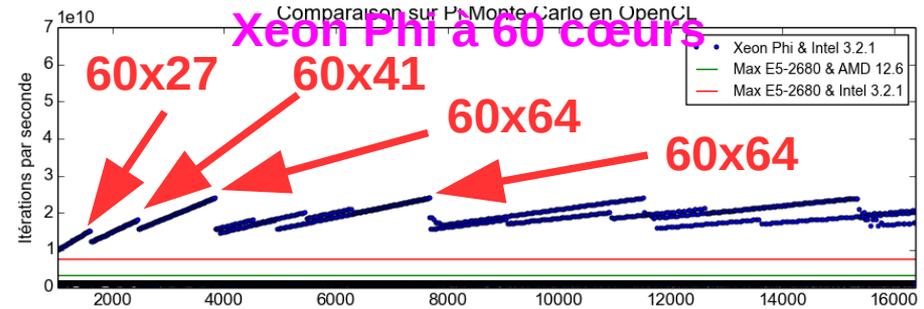
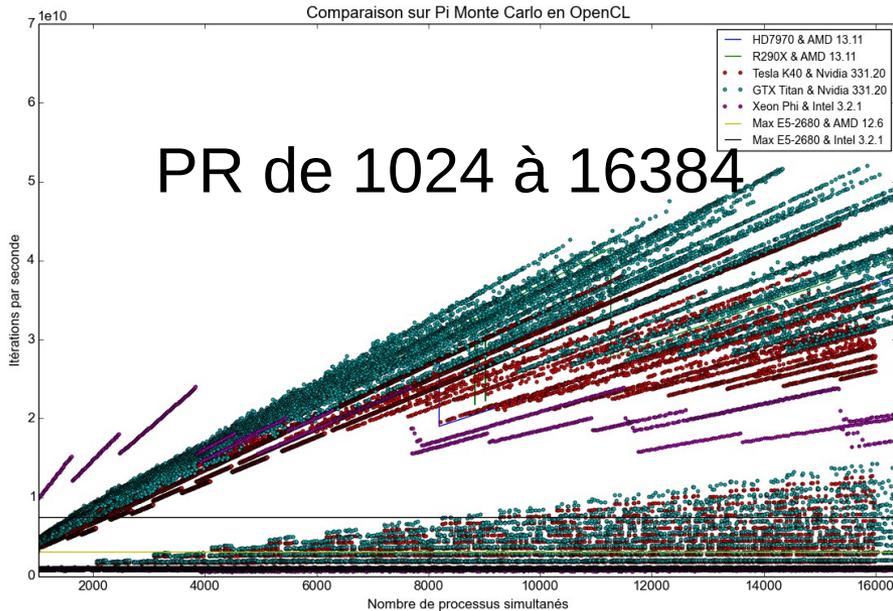


Les processeurs toujours efficaces

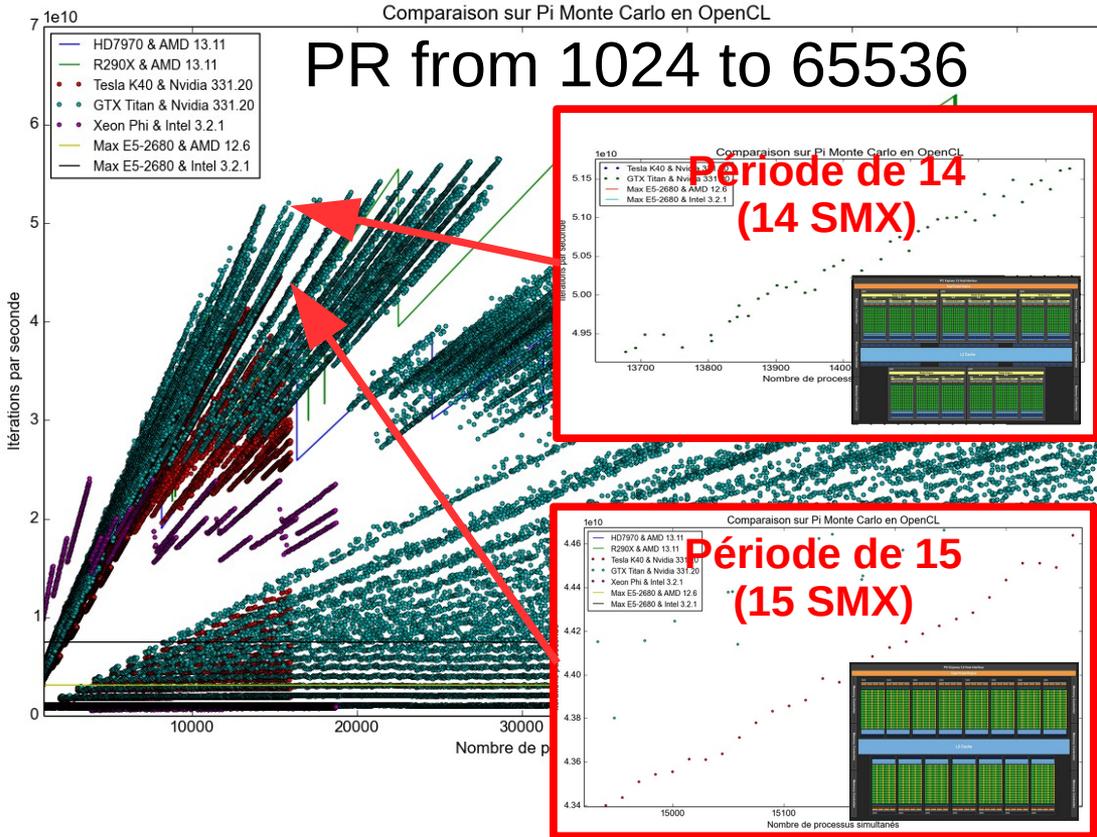
Le Xeon Phi « sort du bois »



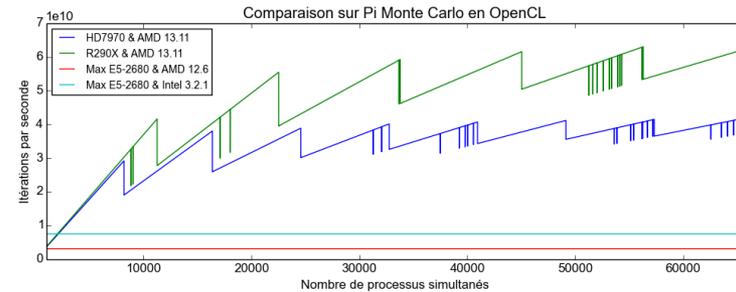
Exploration profonde de PR ParaRégime de 1024 à 16384



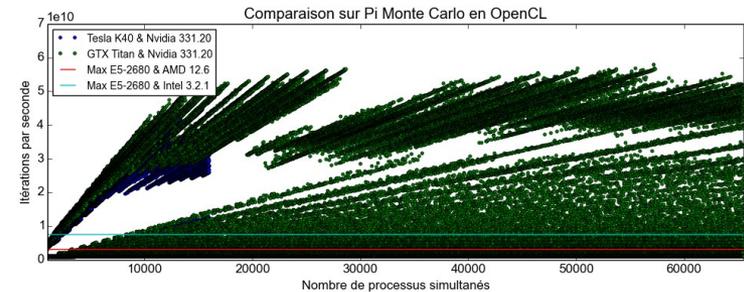
Investiguer la structure interne Par l'exécution de Pi Dart Dash



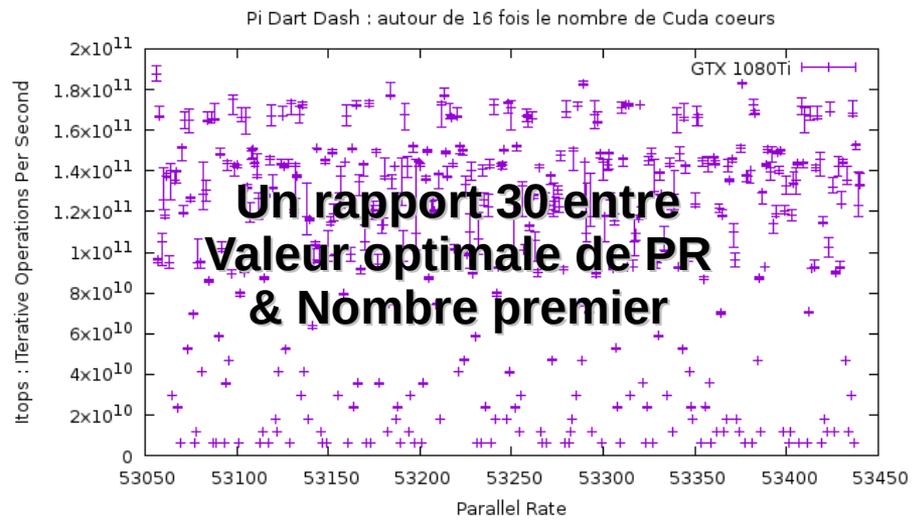
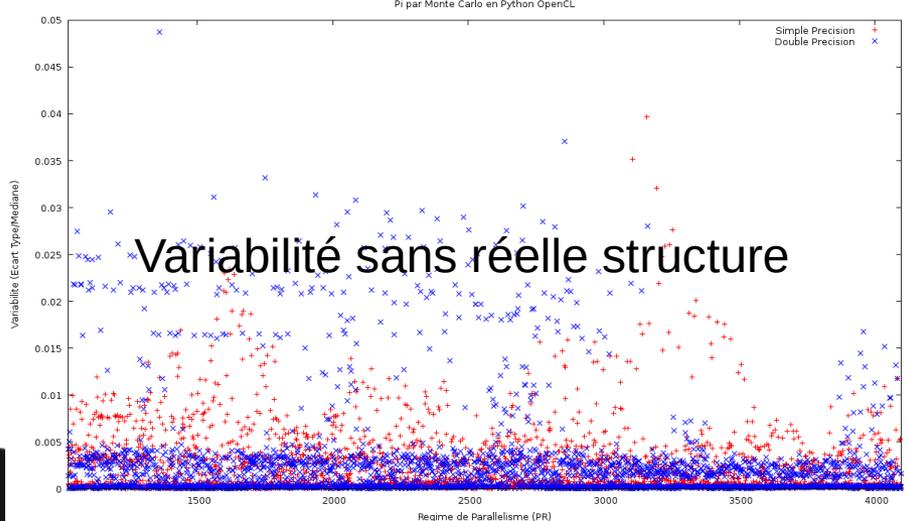
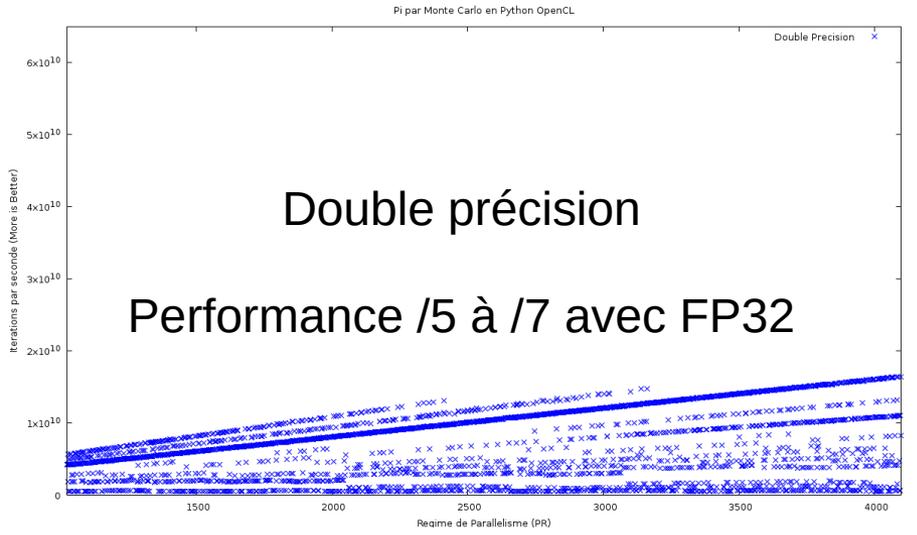
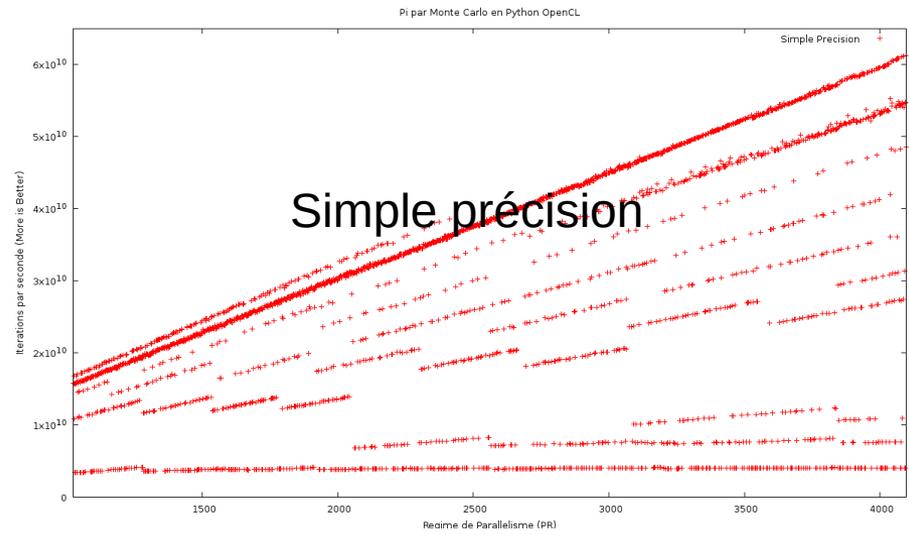
AMD HD7970 & R9-290
Longue Période : 4x nombre d'ALU



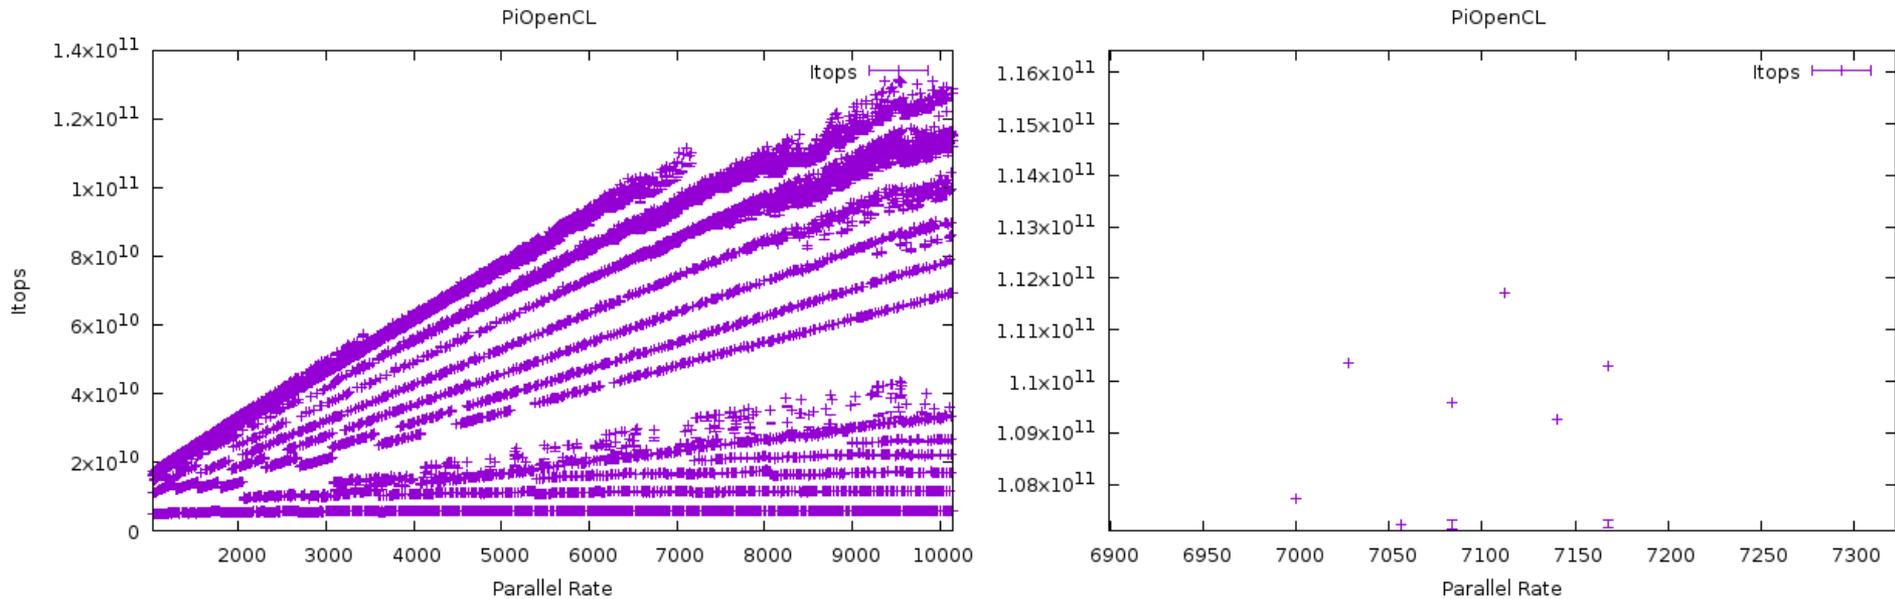
Nvidia GTX Titan & Tesla K40
Courte Période : nombre d'unités SMX



Et les dernières Nvidia GTX1080(Ti) Toujours affectées de bizarreries ?



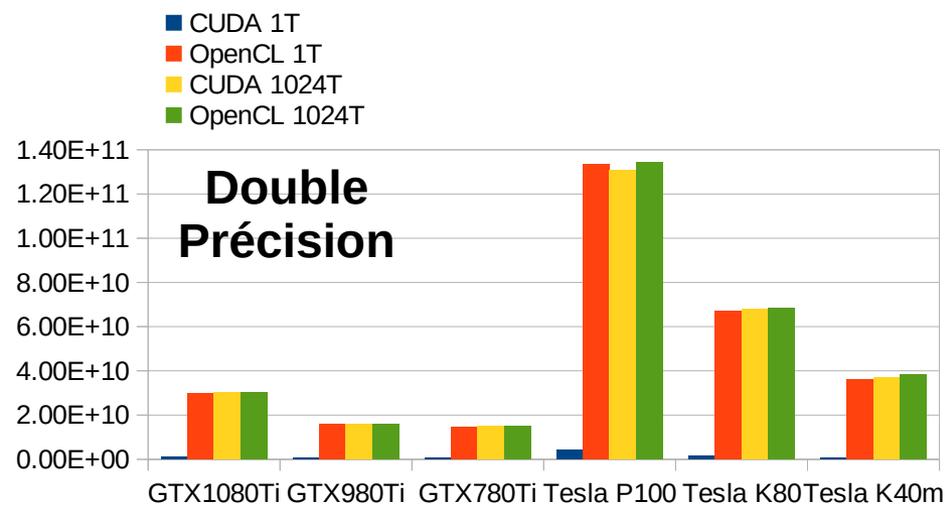
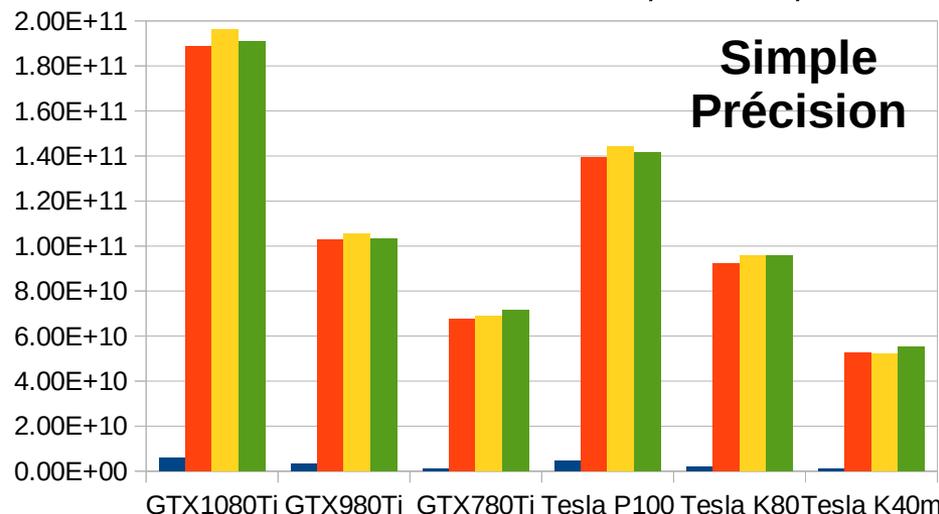
Et en passant sur un PiOpenCL en C pur ?



- Les mêmes détections de nombres premiers
- Les mêmes max (x2 le nombre de shaders)

CUDA vs OpenCL : le match

- 6 cartes : 3 GPGPU, 3 GPU, 3 générations
- Un régime de parallélisme mixte :
 - Entre Blocks & Threads ou entre Work Items & Threads
 - (Blocks,Threads)=(CudaCores,1024) ou (CudaCores*1024,1)
 - CudaCores : 2816, 2880, 3584, 2x2496



Bref, pour ce code, CUDA~OpenCL, même mieux !

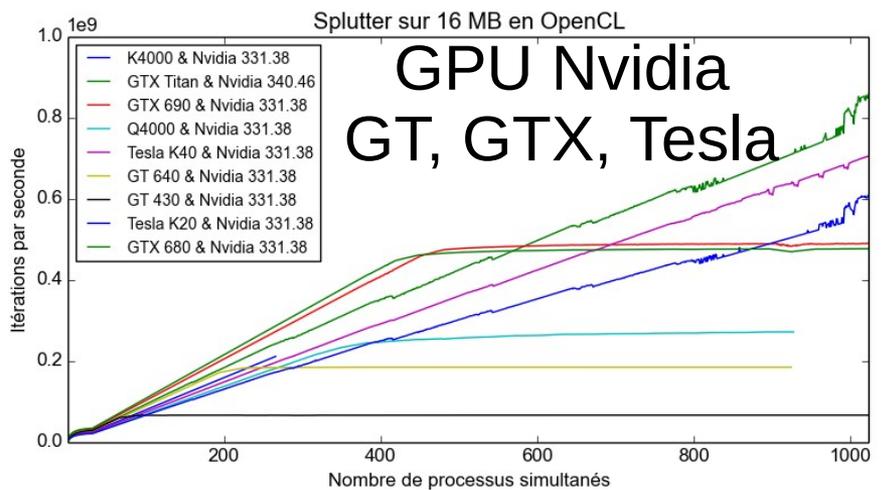
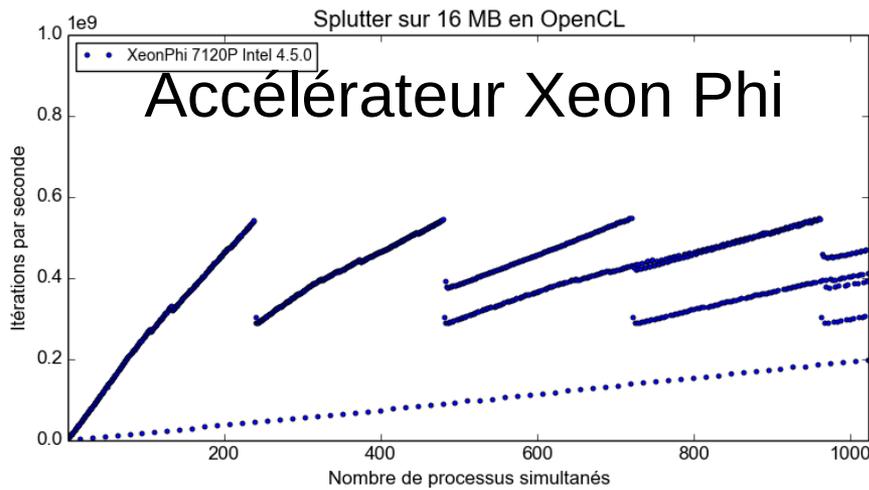
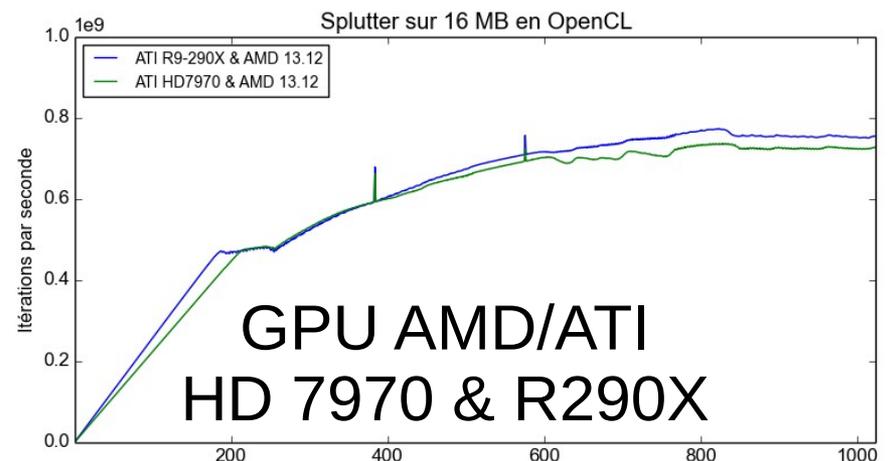
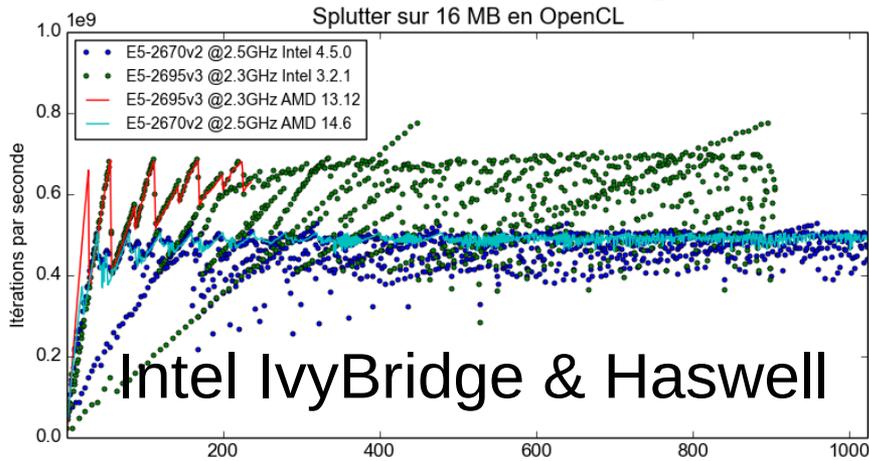
Un test « Memory Bound »

Le « postillonneur »...

- Le programme :
 - Je prends un espace mémoire
 - Je le transfère sur le périphérique (GPU ou CPU) : H2D
 - Pour chaque tâche parallèle, nombre équivalent d'itérations
 - Je tire un nombre aléatoire modulo l'espace mémoire
 - J'incrémente avec `atomic_inc` l'espace mémoire
 - Je récupère l'espace mémoire du périphérique : D2H
- La vérification : je somme les éléments de l'espace
 - Je dois retomber sur le nombre d'itérations sélectionnés
- Les observables : les 3 temps...
 - Le temps H2D, le temps de postillonnage, le temps D2H

Le « postillonneur » en OpenCL

Il y a 4 ans...



Et pour les GPU & CPU utilisés ?

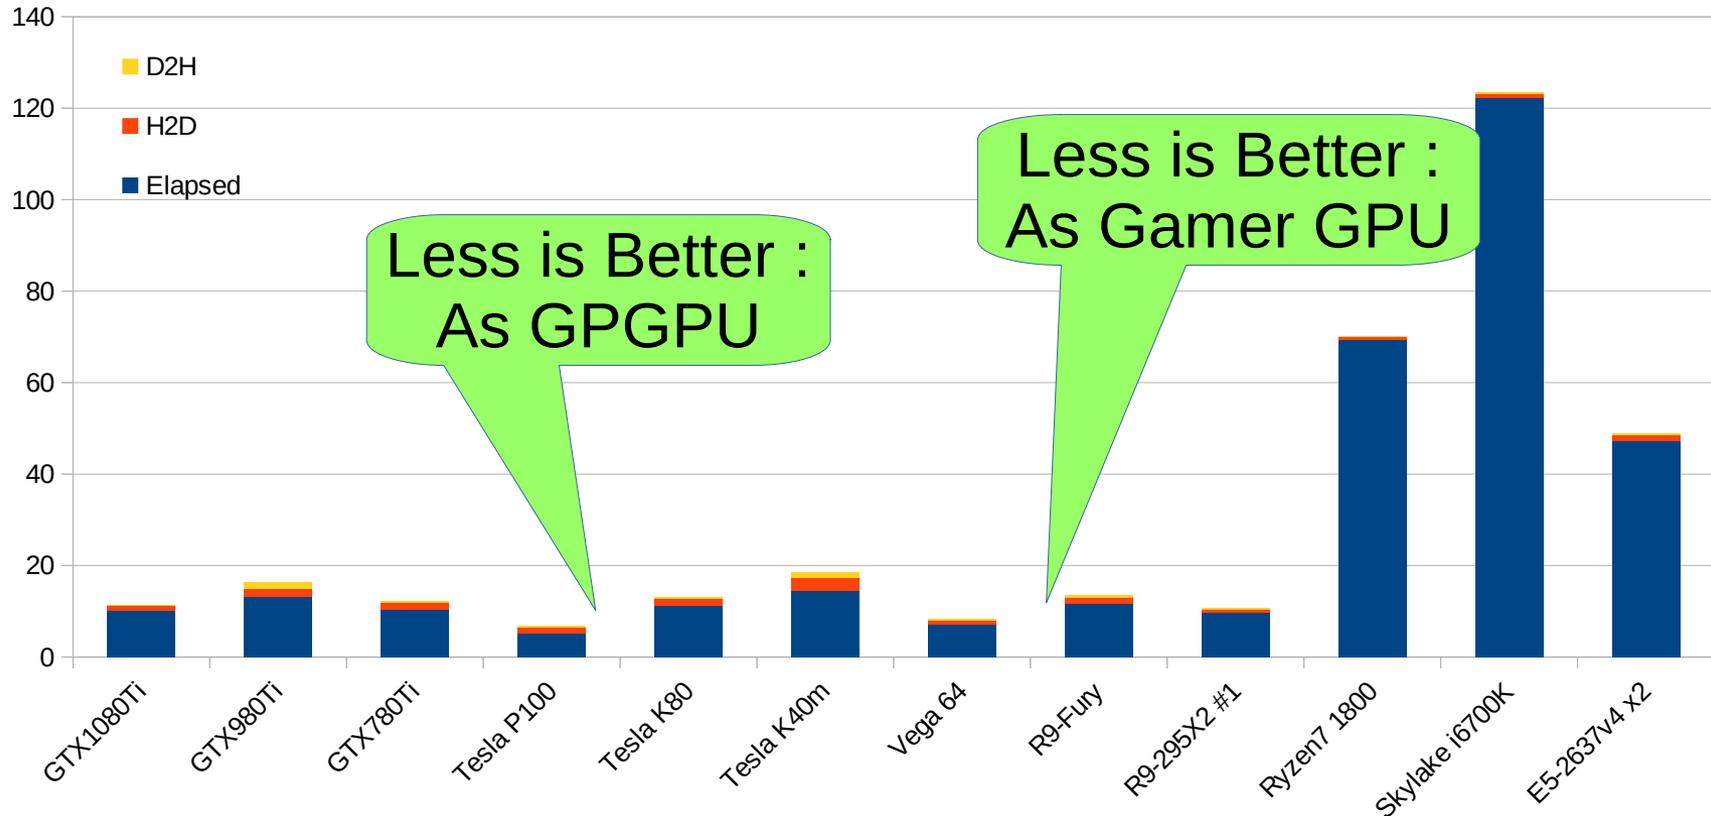
D'abord pour les 9 GPU...



- Un espace de 2GB (2^{29} de 32 bits), 32768 tâches
- 8.5 Milliards d'itérations (16 par tâche)

Et pour les GPU & CPU utilisés ?

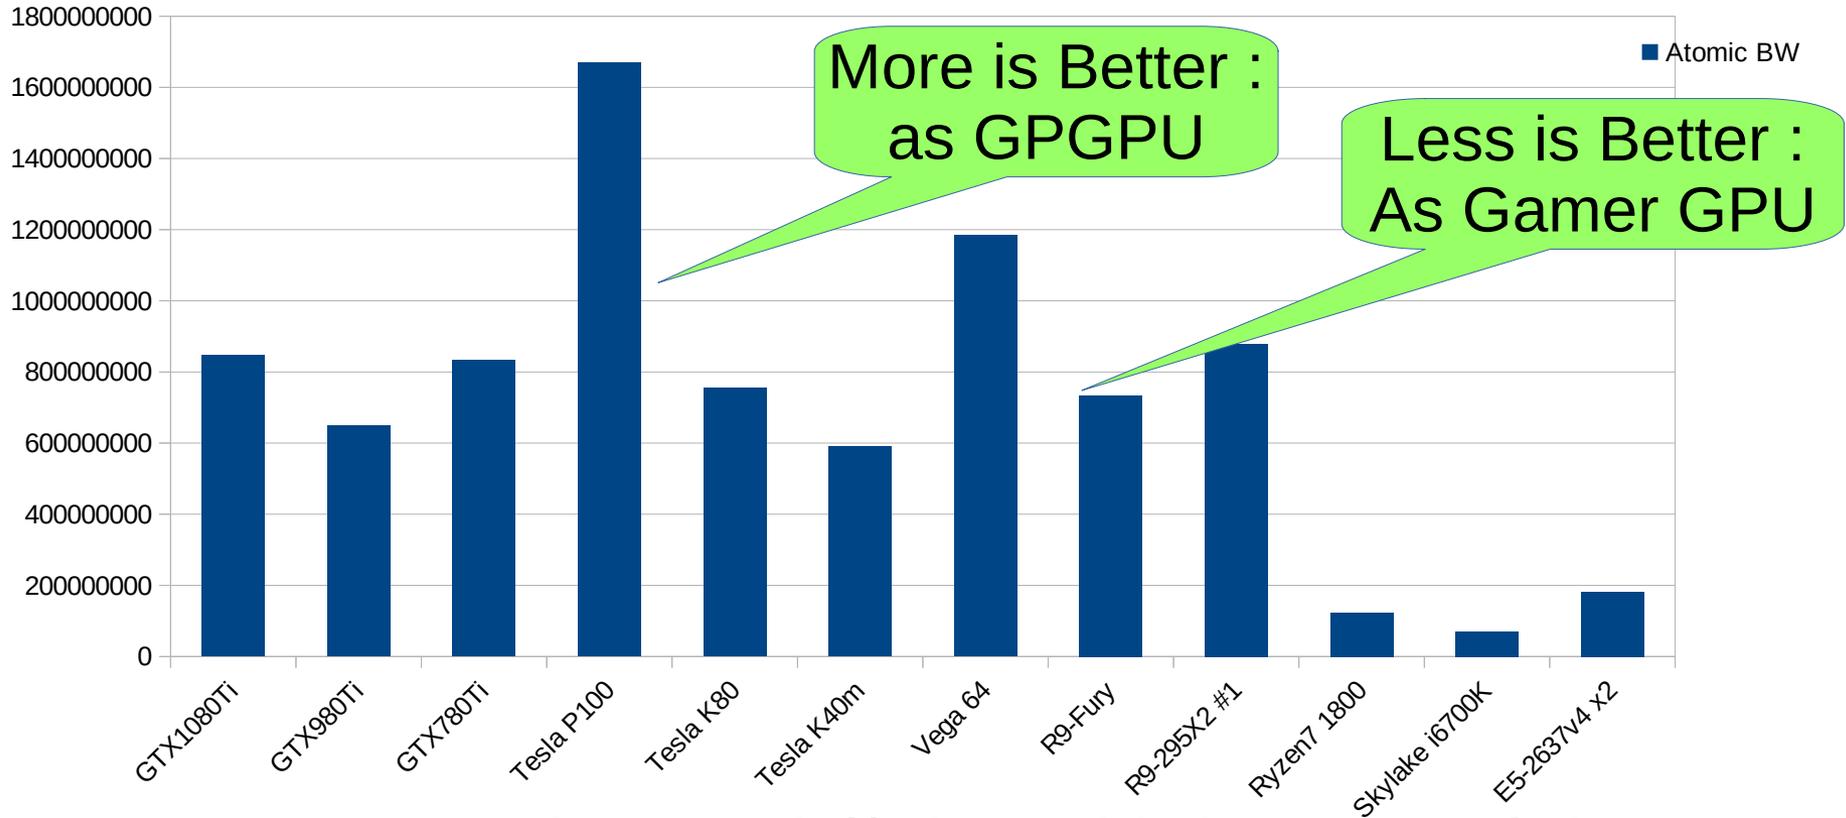
Les 9 GPU + les 3 meilleurs CPU



- Un espace de 2GB (2^{29} de 32 bits), 32768 tâches
- 8.5 Milliards d'itérations (16 par tâche)

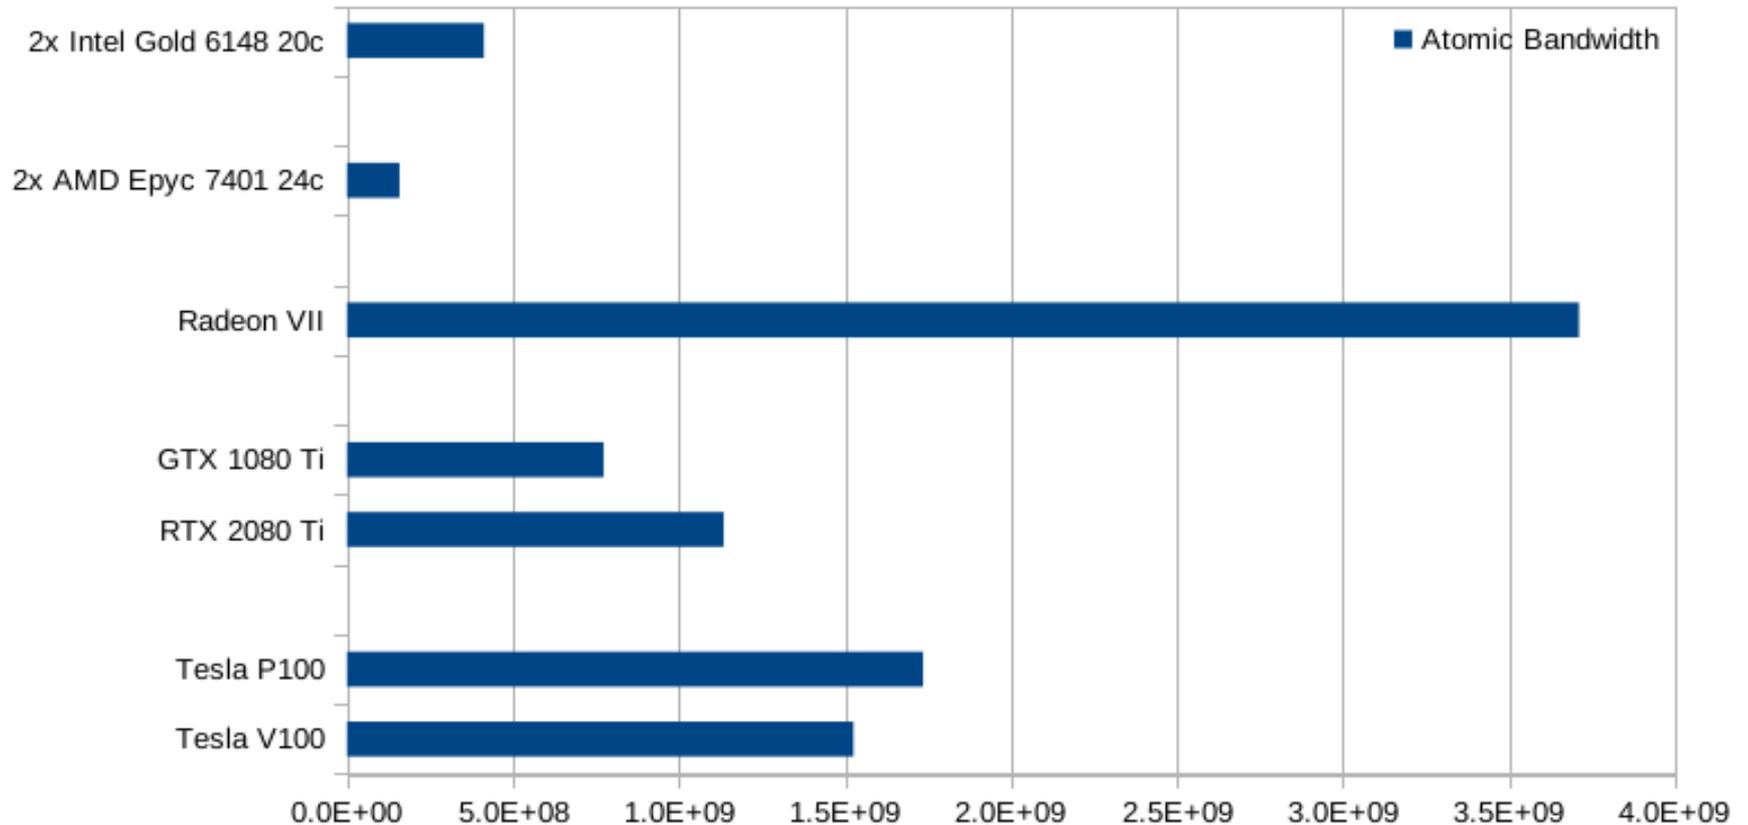
Et pour les GPU & CPU utilisés ?

Les 9 GPU + les 3 meilleurs CPU

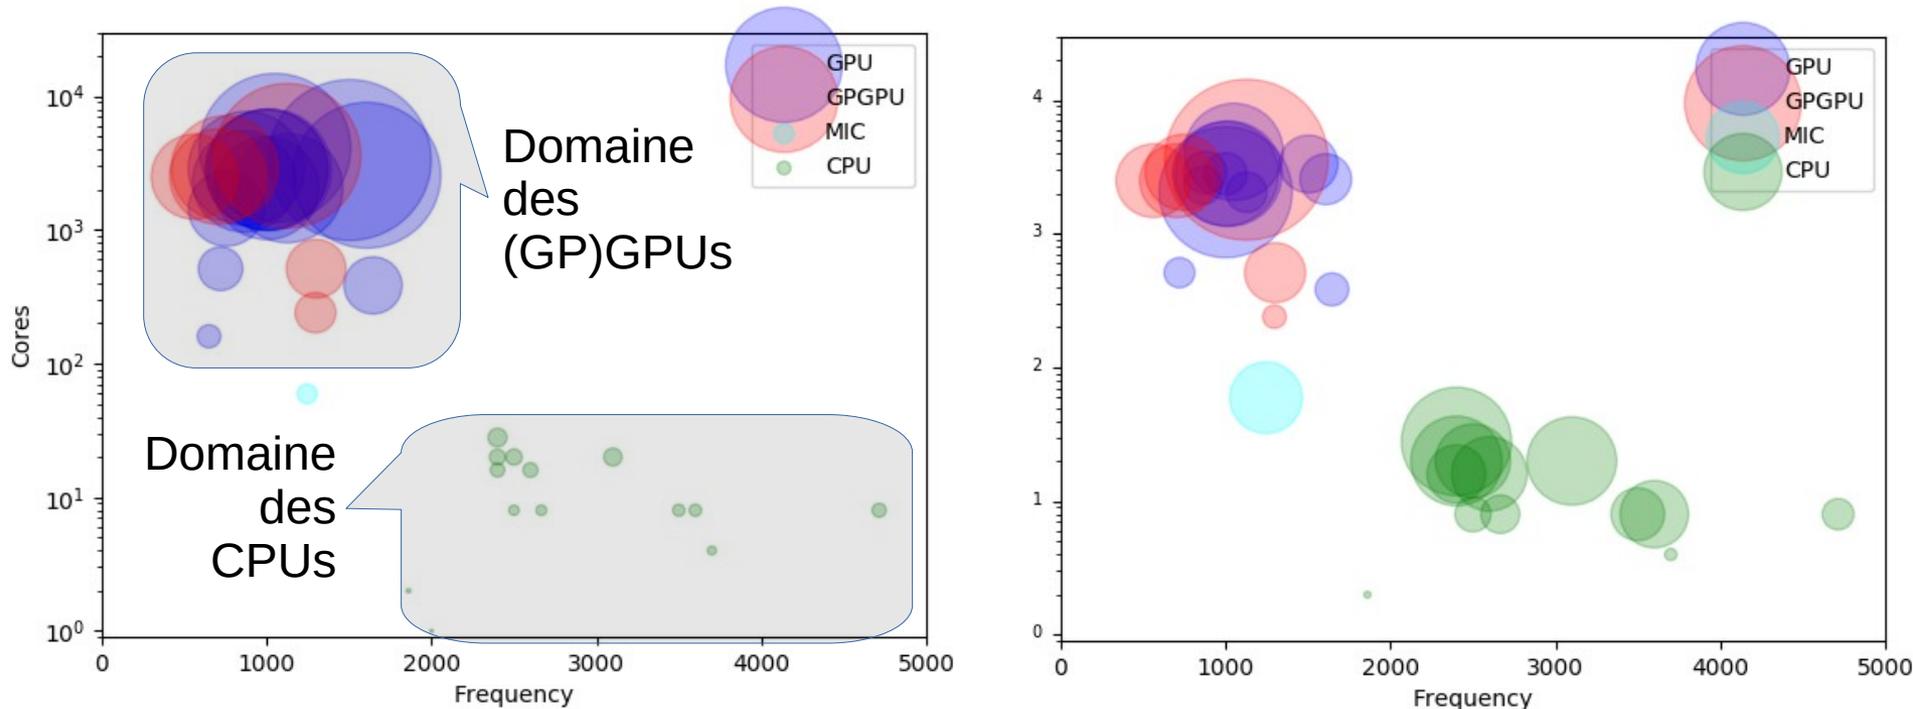


- Un espace de 2GB (2^{29} de 32 bits), 32768 tâches
- 8.5 Milliards d'itérations (16 par tâche)

Sur des architectures « récentes » Comme quoi, avec une AMD...



La performance en informatique Pour un code plus physique...

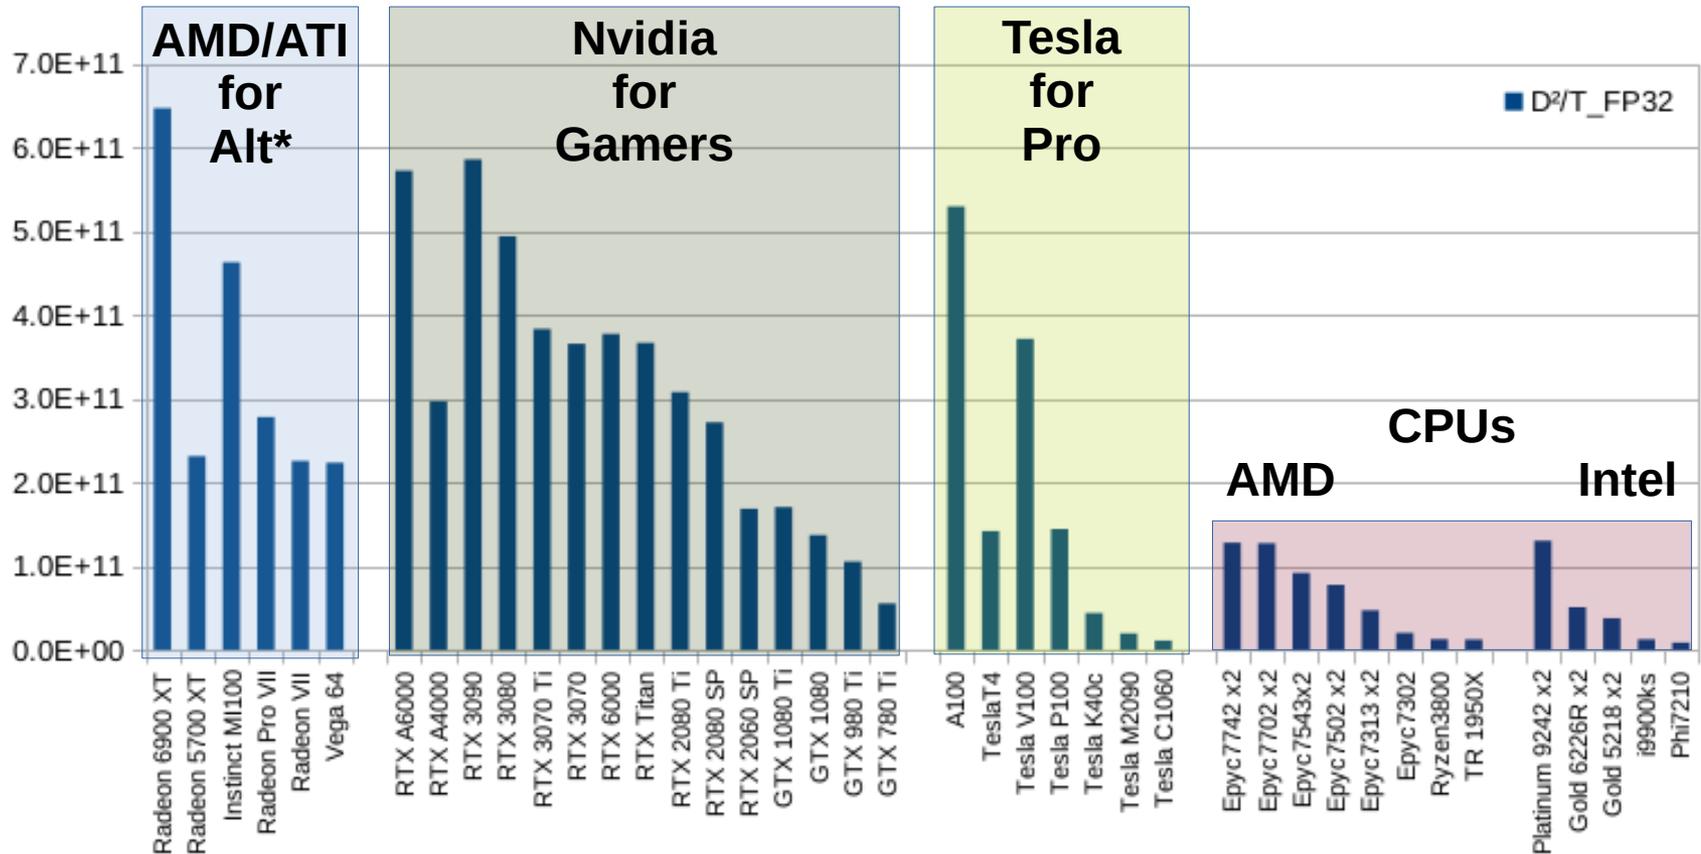


- Sur un GPGPU, performance stable
- Sur un GPU, baisse drastique de la performance (division par 20 en DP)
- Sur un CPU, performance relative meilleure

Nbody en FP32

de 32 à 1048576 particules

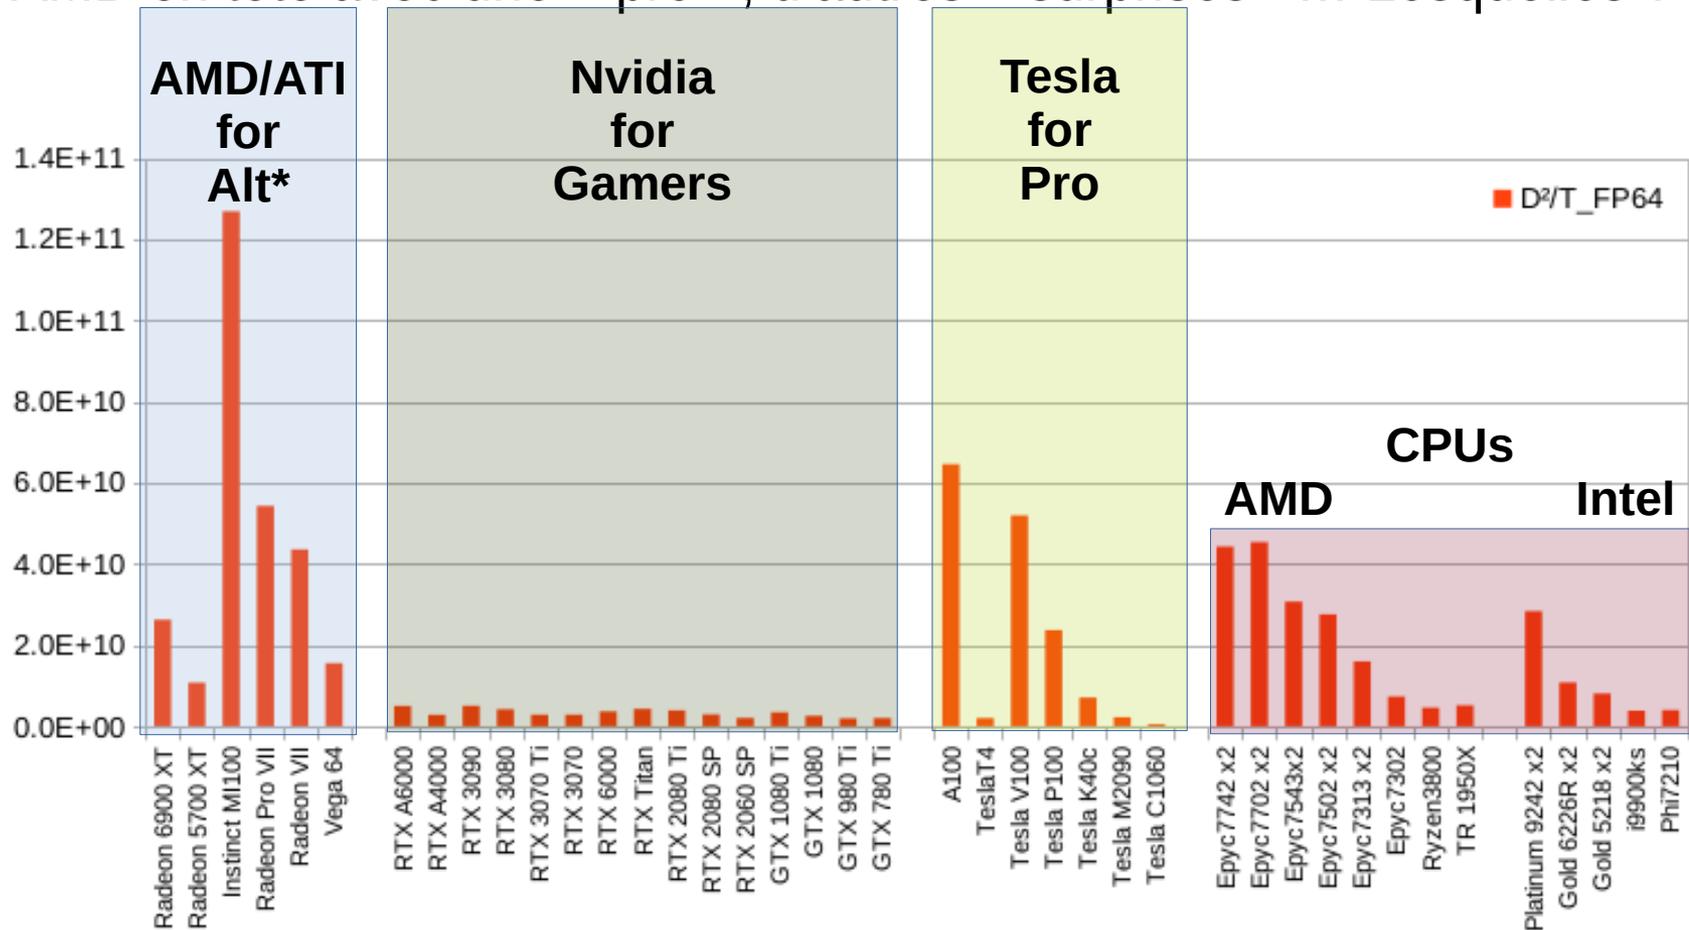
- AMD en tête avec une « gamer », des « surprises »... Lesquelles ?



Nbody en FP32

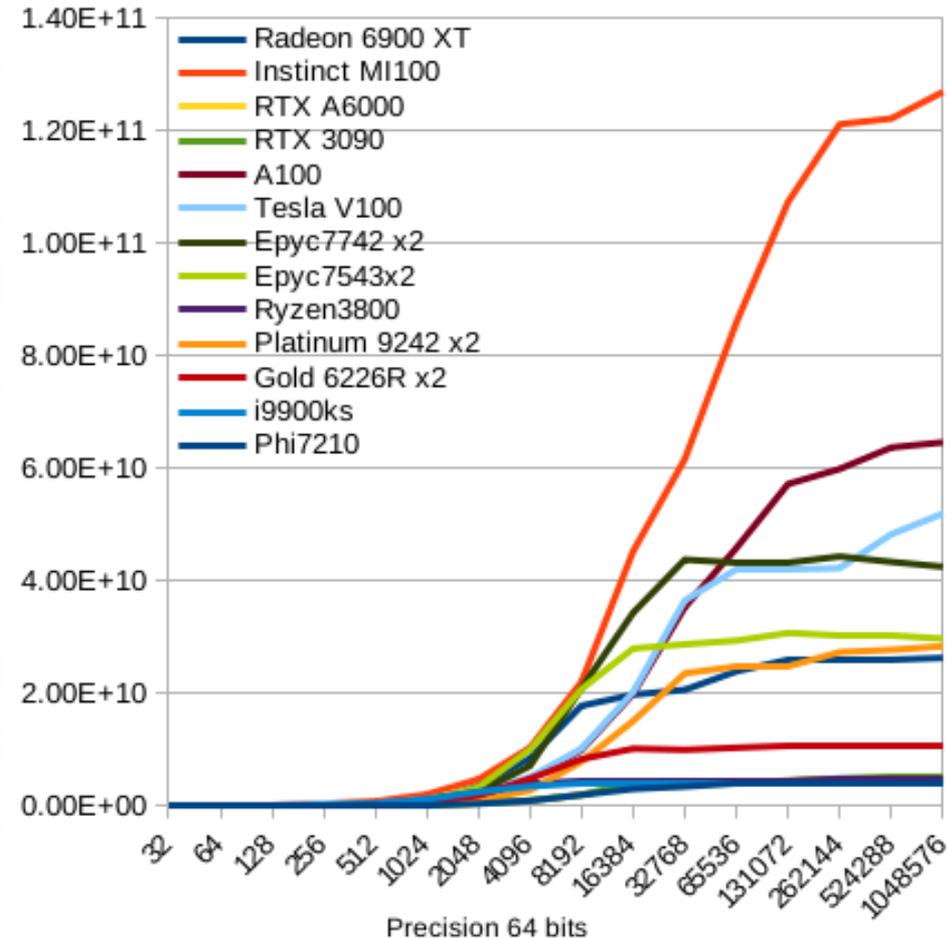
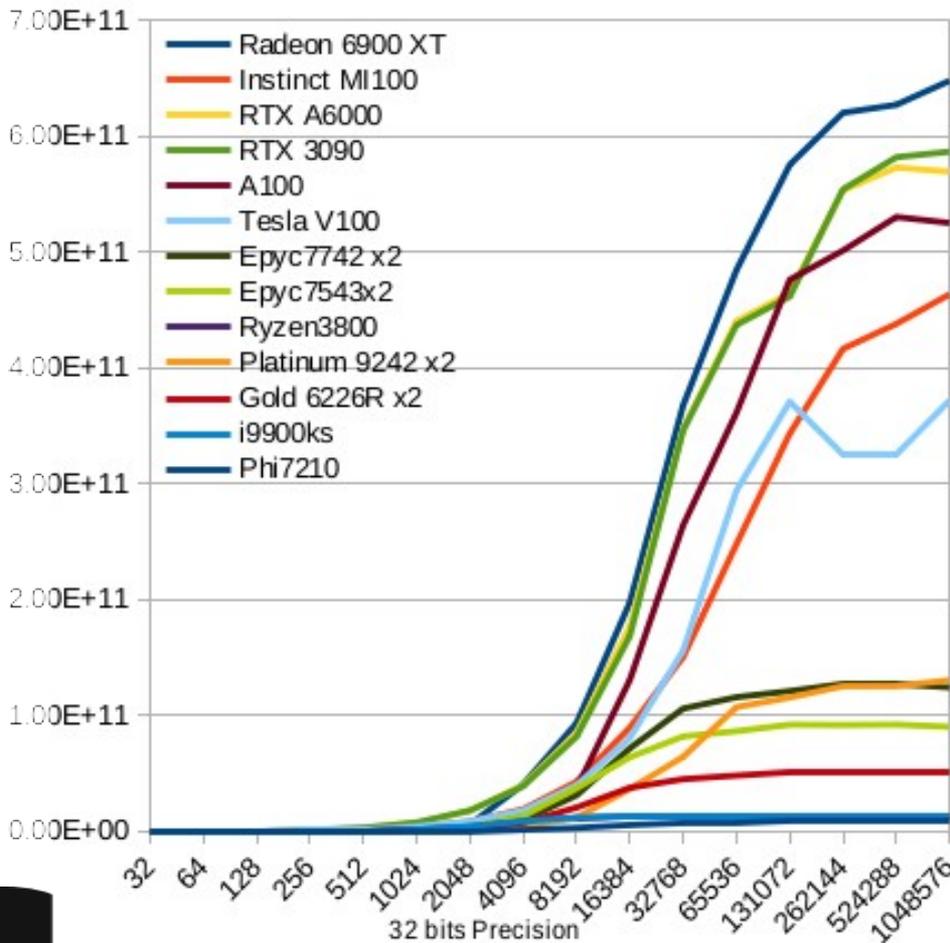
de 32 à 1048576 particules

- AMD en tête avec une « pro », d'autres « surprises »... Lesquelles ?

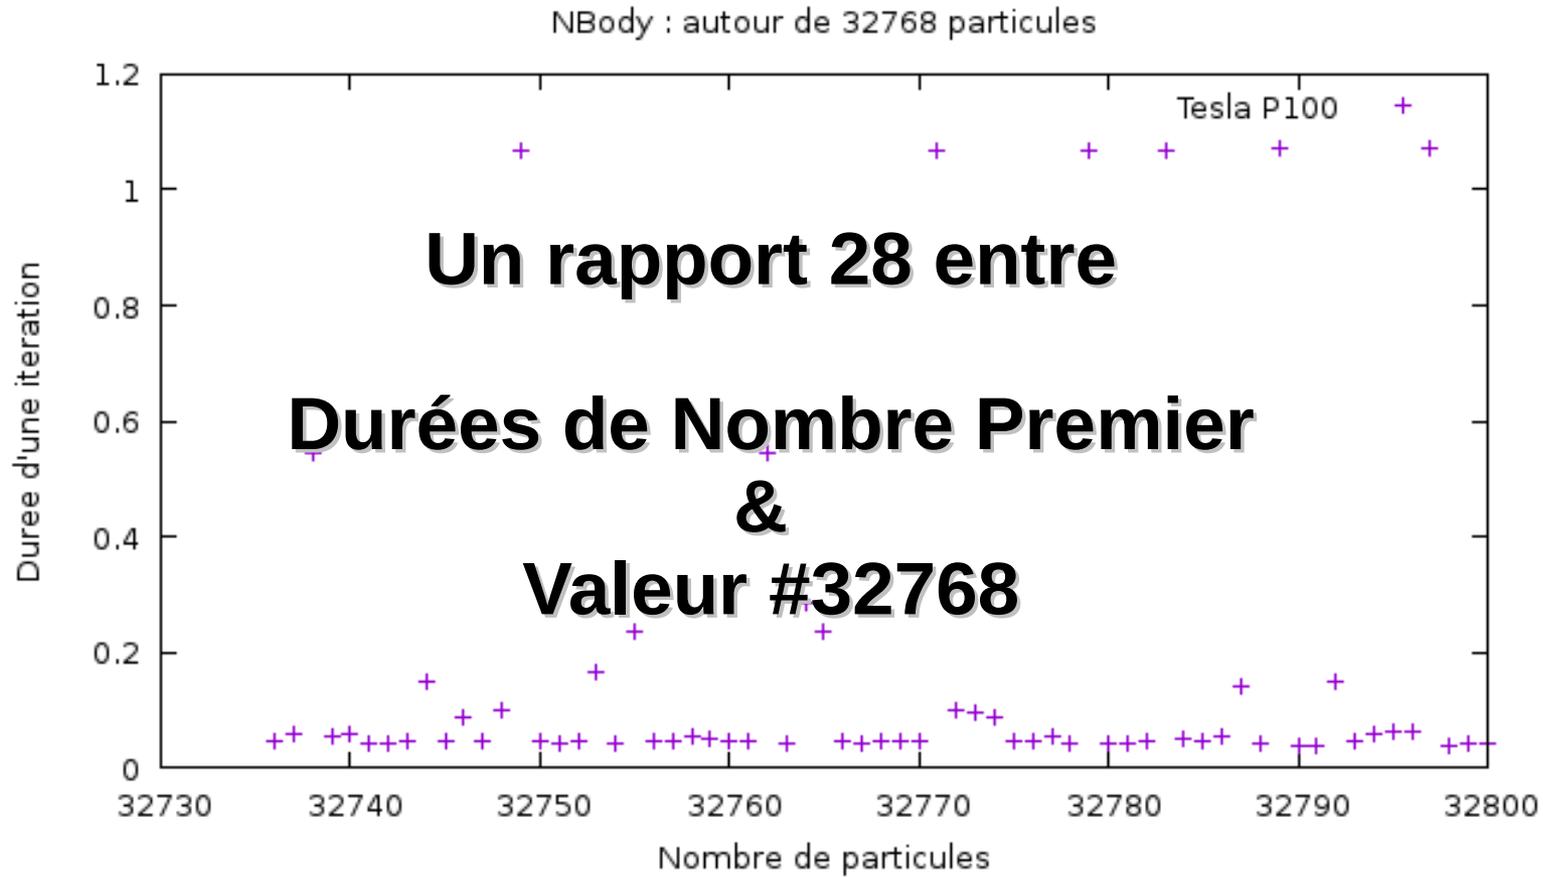


Des progressions en performance On retrouve les > 200000 tâches !

- Pour les CPU : > 32768 . Pour les GPU : > 262144 !



Et les effets « prime numbers » pour les cartes Nvidia ?



Quelques maximes...

- A chaque usage, son architecture optimale !
 - Un usage, c'est l'association d'une recette et ses ingrédients
- A chaque GPU, des régimes de parallélisme optimaux !
 - Encore faut-il les rechercher...
- A chaque tâche élémentaire, une charge conséquente !
 - Plusieurs centaines d'opérations minimum...

Mais à quoi ça sert tout ça ?

Caractériser & éviter les regrets...

- Ce qu'il faut retenir :
 - Dans une machine, en 2022, la puissance « brute » est dans le (gros) GPU
 - Pour un régime de parallélisme bas, le CPU enfonce le GPU
 - Un GPU n'est supérieur au CPU que pour PR > 1000 (en fait, ~1000000)
 - Le GPU n'atteint son optimum QUE pour certains PR
 - Sans une caractérisation, des déceptions à prévoir...
 - OpenCL est un bon compromis comme langage *PU
 - Python reste l'approche la plus rapide de OpenCL
- Ce qu'il faut faire : expérimenter !