

# Retour sur les Jdev 2015

## Un peu de données, un peu de calcul

---

### T3 Atelier 6

**Julia** pour vos calculs scientifiques intensifs

### T3 GT 5

Différentes méthodes d'**optimisation** d'un code **Python**

### T3 Atelier 8

**Python**, apprentissage statistique et analyse de données pour la modélisation prédictive

### T8 GT 3

Validation et vérification de son logiciel scientifique : analyse, développement, exploitation

### T8 Atelier 2

Programmation **GPU** moderne. Cuda est-il encore compliqué en 2015 ?

### T8 Atelier 5

Structuration des données avec **HDF5**

# julia , pour vos calculs scientifiques intensifs

---

- Implémentation :
  - Langage de programmation récent (2013) et toujours en développement destiné au calcul scientifique (version 1.0)
  - Open source (licence MIT)
  - Mode interactif et compilé (à la volée)
- Alternative/complément aux langages R/Matlab /Python
- Un mode parallèle (par défaut se lance sur 1CPU)
- Doc dispo sur le site des JDEV :  
pdf complet + TP :  
[https://github.com/mcanouil/Presentation/tree/master/JULIA\\_TP](https://github.com/mcanouil/Presentation/tree/master/JULIA_TP)  
Tuto : <http://julialang.org/learning/>  
Tips : <https://github.com/JuliaLang/julia/tree/master/contrib>

▮ **Scikit (<http://scikits.appspot.com/scikits>)**

Un ensemble de bibliothèques spécialisées basées sur SciPy

▮ **Learn (<http://scikit-learn.org/stable/>)**

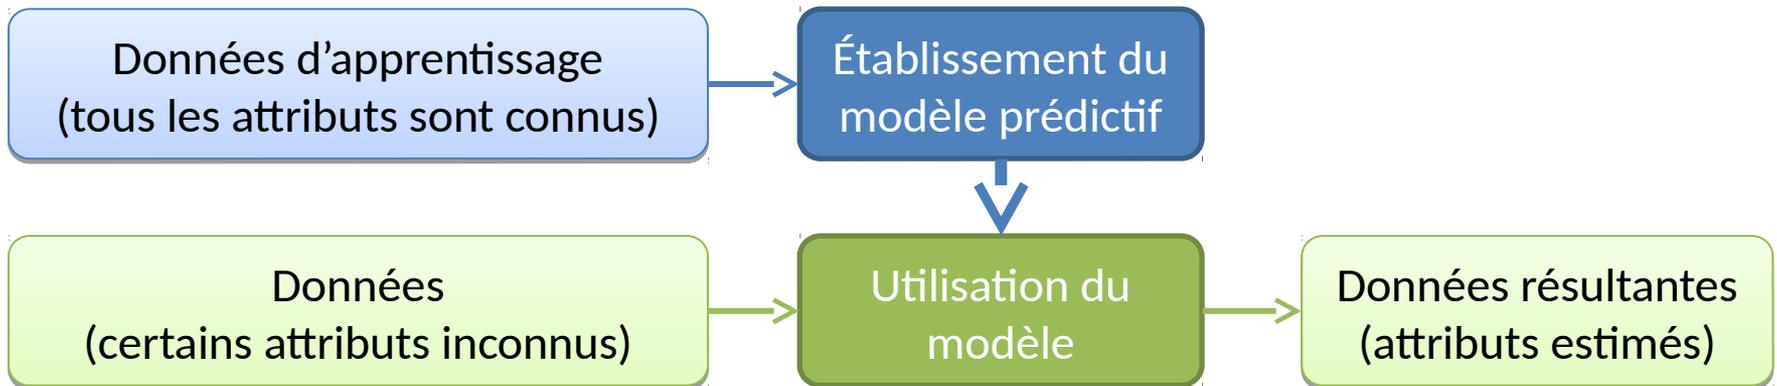
Pour le machine learning et data mining

▮ **Doc présente sur le site des JDEV :**

support du tutorial : [https://github.com/ogrisel/parallel\\_ml\\_tutorial](https://github.com/ogrisel/parallel_ml_tutorial)

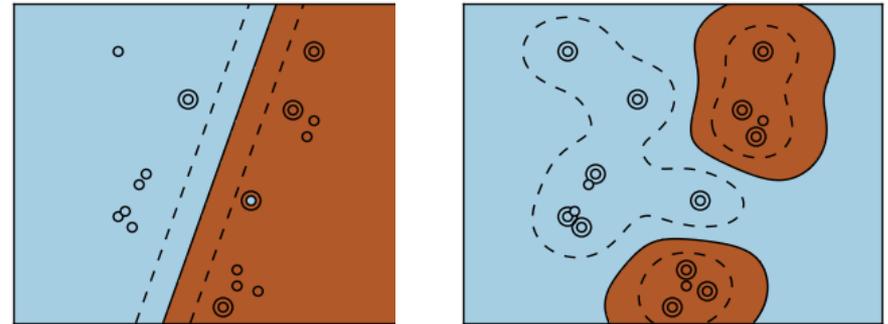
Doc de scikit-learn : <https://scikit-learn.org>

Tuto complémentaire écosystème Python : <https://scipy-lectures.github.io/>

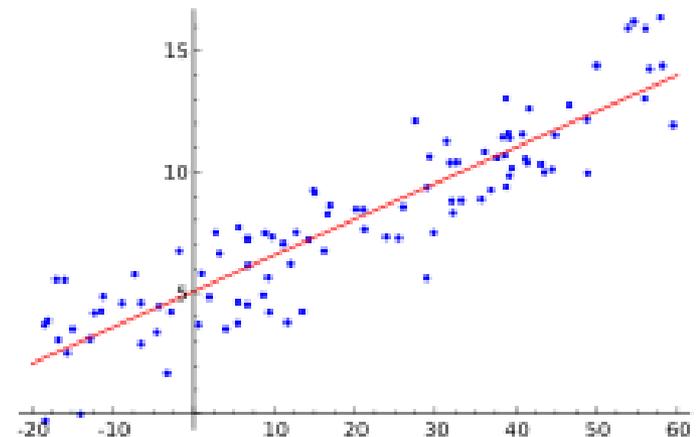


## → “Supervised learning”

**Classification:** classifier les nouvelles données dans des catégories, ou sous-ensembles (attribut inconnu = catégorie d'appartenance)

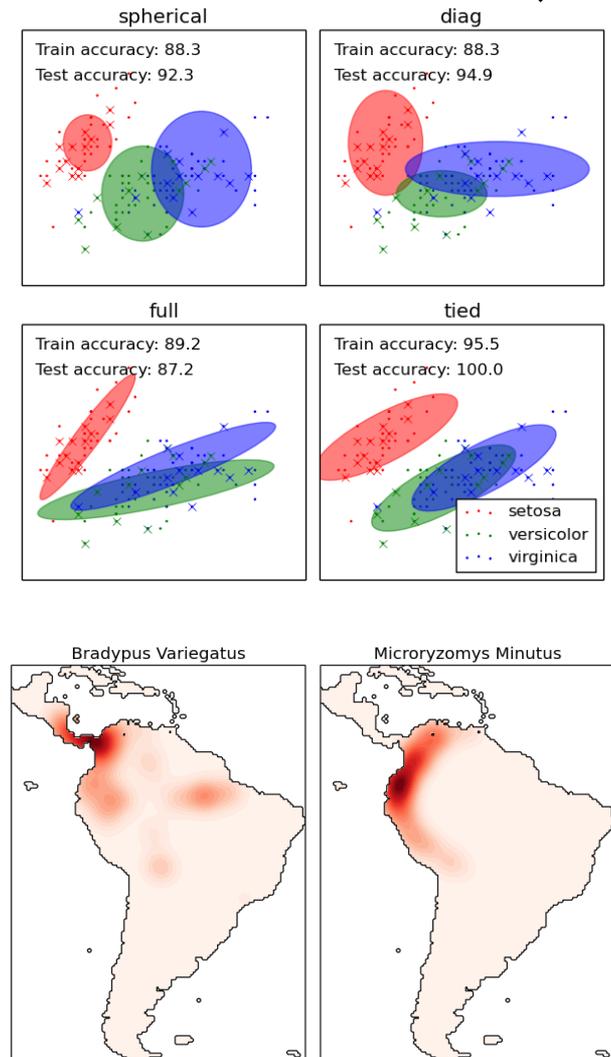


**Régression:** établissement de règles numériques pour estimer les valeurs des attributs manquants



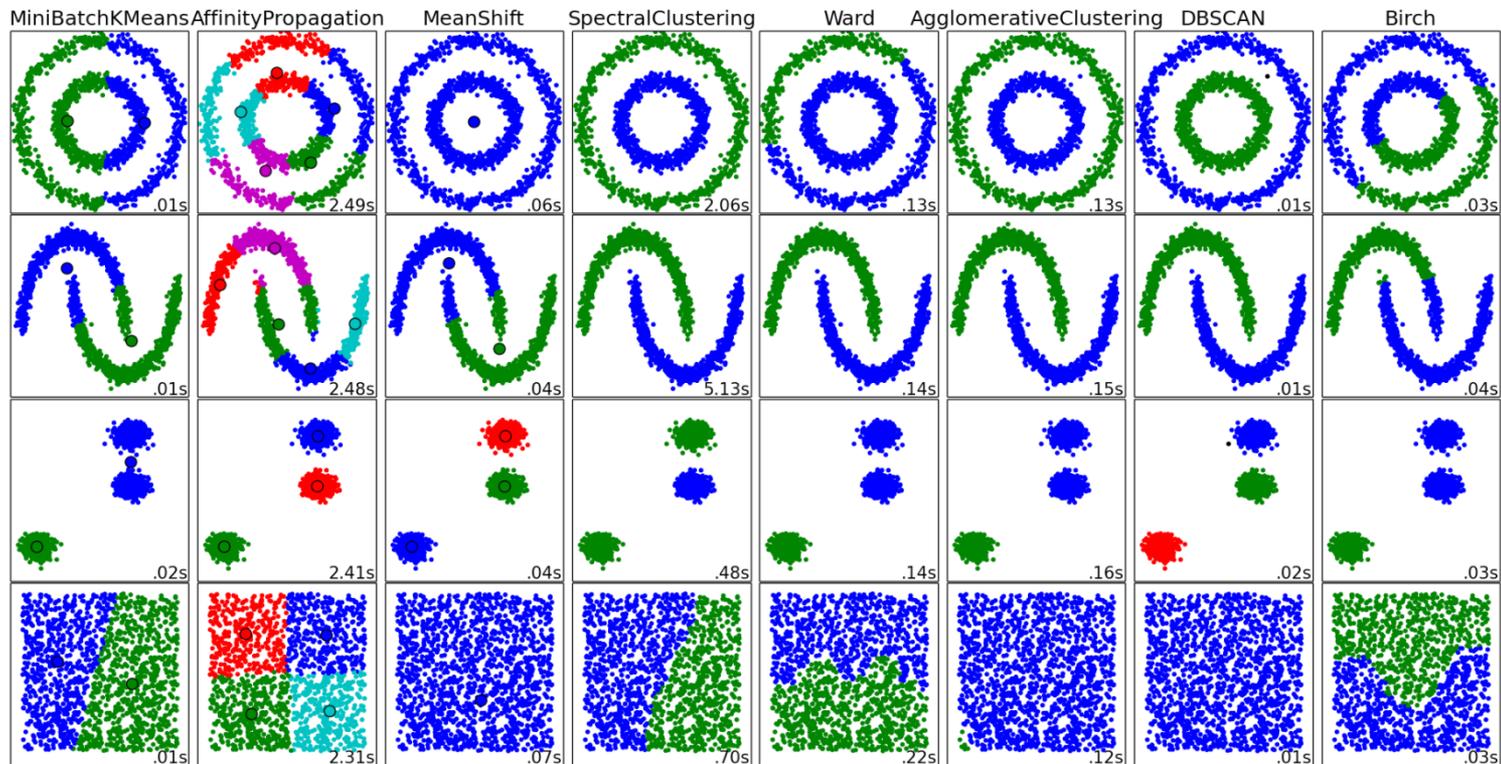
# → « Unsupervised learning »

Ici on a plus de données complètes. Ces outils permettent de générer des groupement (clustering) de données ou des visualisations statistiques (density estimation) en analysant les similitudes entre les attributs des données



# Beaucoup d'algorithmes disponibles

## Choix par la documentation et évaluation par tests



# Python: optimisations

---

- | Utiliser la vectorisation des opérations avec numpy
- Compiler
  - - avec Cython : Mixer du C/C++ avec du code python
  - Ou avec Numba : Compiler du python avec les optimisations C/C++
- Paralléliser avec la lib multiprocessing (pools de tâches)
- Calculer sur GPU
  - PyCuda (inclure du code Cuda dans python)
  - Numba (peut compiler du code python vers du Cuda)
  - Remplacer BLAS par nvBLAS dans numpy (uniquement pour les opération matricielles) <http://scelementary.com/2015/04/09/nvidia-nvblas-in-numpy.html>

# Retour sur les Jdev 2015

## Un peu de données, un peu de calcul

---

T3 Atelier 8

**Python**, apprentissage statistique et analyse de données pour la modélisation prédictive

T3 GT 5

Différentes méthodes d'**optimisation** d'un code **Python**

T8 Atelier 6

**Julia** pour vos calculs scientifiques intensifs

**T8 Atelier 2**

Programmation **GPU** moderne. Cuda est-il encore compliqué en 2015 ?

T8 GT 3

Validation et vérification de son logiciel scientifique : analyse, développement, exploitation

T8 Atelier 5

Structuration des données avec **HDF5**

# Calcul GPU : Intro

---

- Graphics Processing Units : circuit intégré présent sur les cartes graphiques qui assurent les fonctions de calcul de l'affichage
- Maintenant utilisé pour faire du calcul hautement parallèle (GPGPU : General Purpose GPU)
- Plusieurs constructeurs Nvidia, AMD, Intel

# GPU : Architecture

---

## Sur un GPU :

Plusieurs multiprocesseurs (MP) avec chacun:

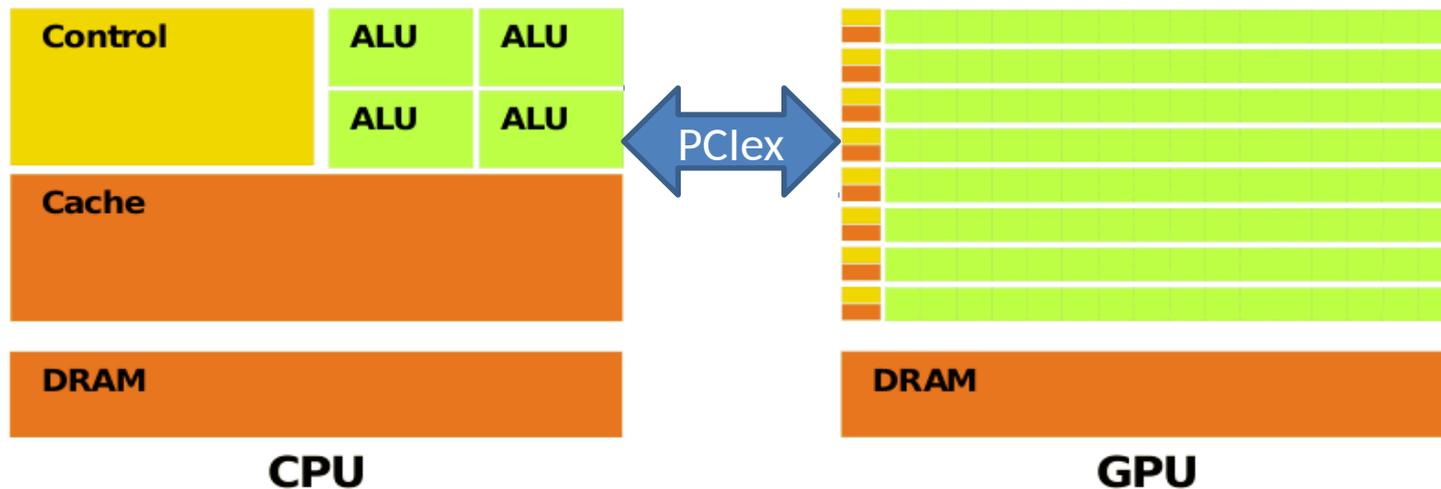
- Un cache
- Une unite de controle
- Plusieurs coeurs

Memoire vive partagée entre tous les MP

**Exemple** Nvidia Tesla K20 (type dispo sur CIMENT/Froggy: 9 x 2 x K20):

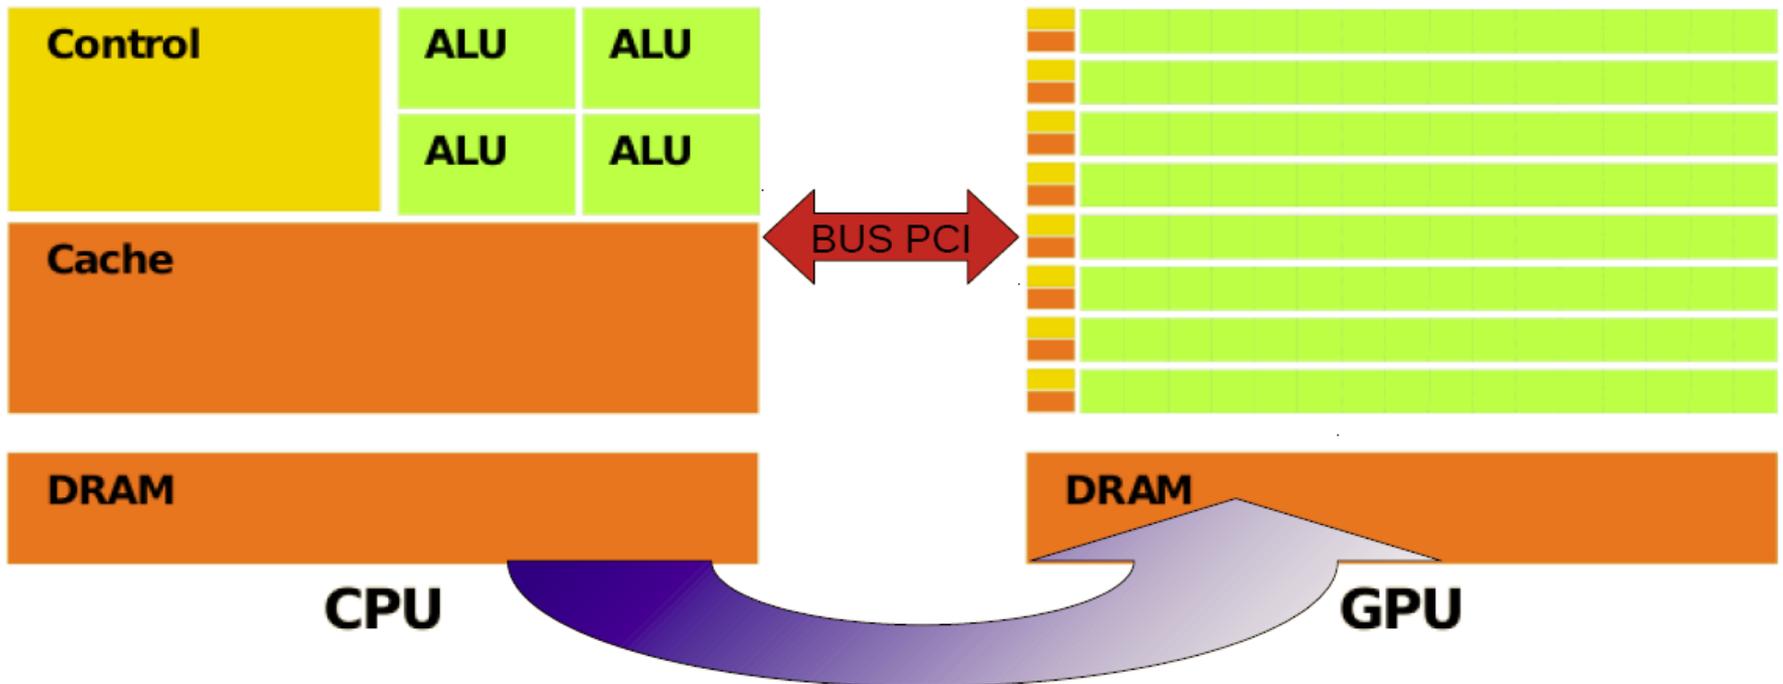
4,8 Go de memoire vive partagée

13 MP, 192 coeurs/MP (2496 coeurs au total)



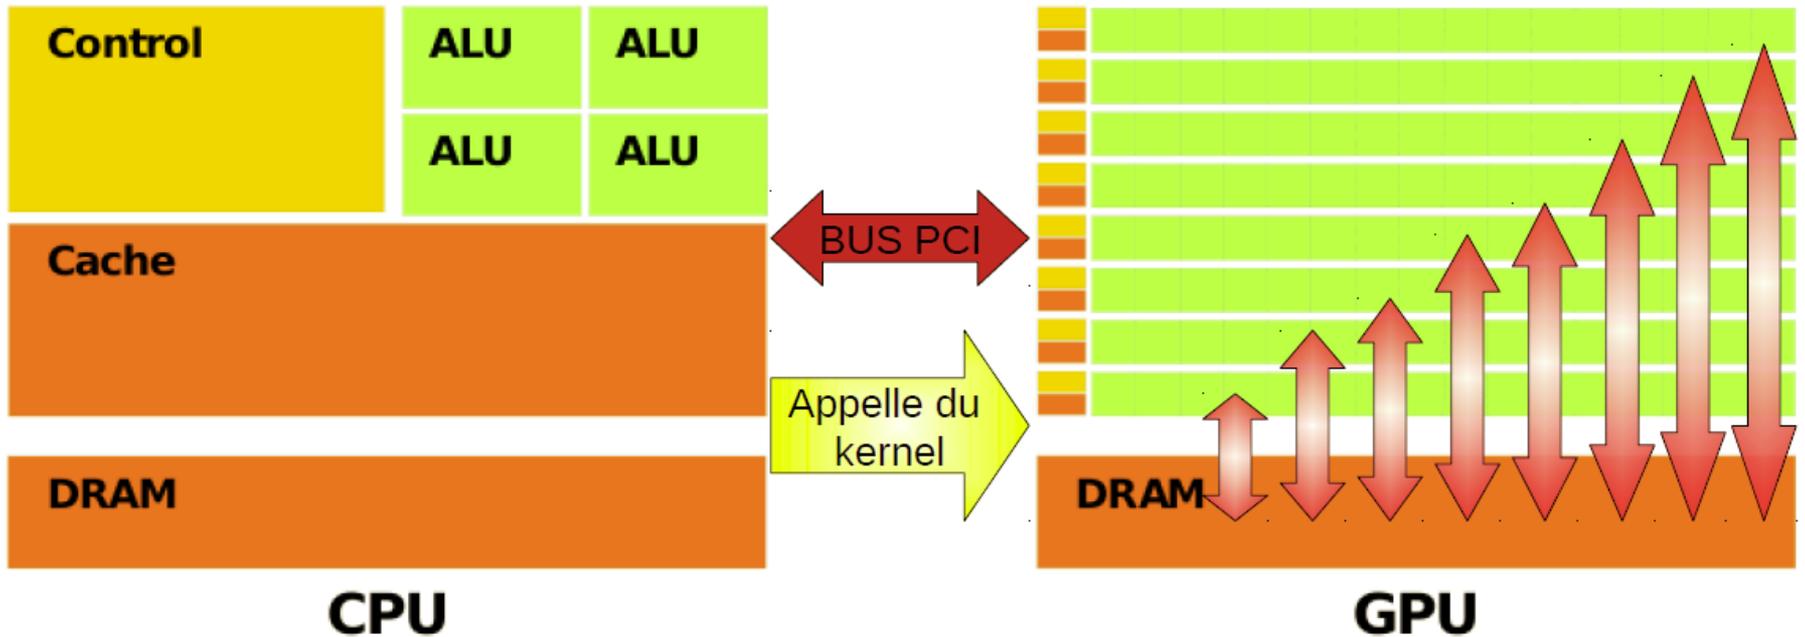
# GPU: Fonctionnement global

## 1°) Copie des données d'entrée



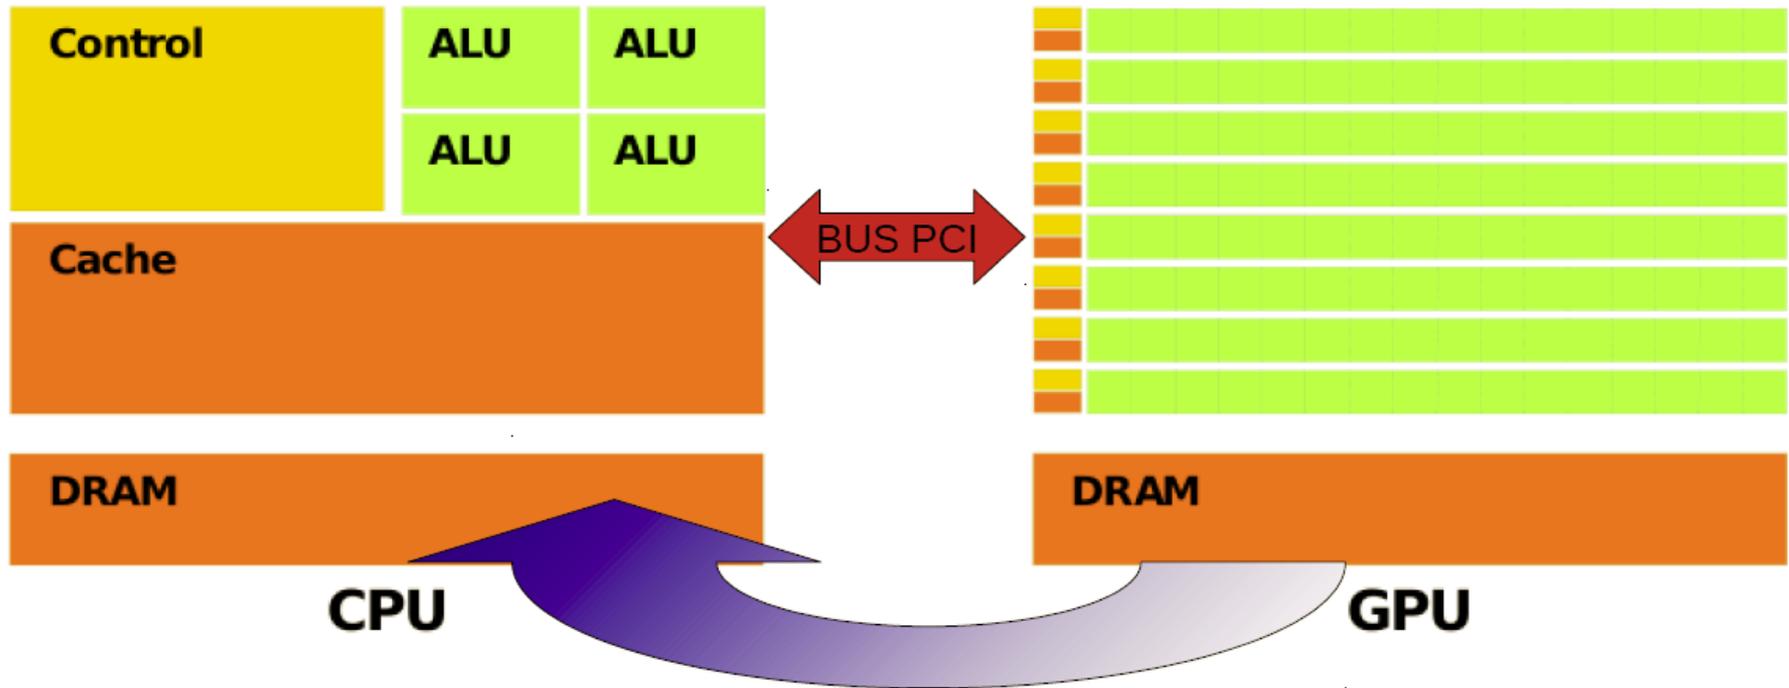
# GPU: Fonctionnement global

## 2°) Exécution des kernels parallèles



# GPU: Fonctionnement global

## 3°) Copie des données résultats



# GPU: Comment programmer ?

---

- | Coder le programme soi-même:
  - Cuda C/C++ (Nvidia)
  - OpenCL (générique?)
  - Directives OpenACC, OpenHMPP, OpenMP 4.0 (à base de #pragma en C)
  
- Utiliser des bibliothèques Cuda (Nvidia):
  - BLAS (Algèbres linéaire)
  - CuFFT (Transformée de Fourier rapide)
  - ...
  
- Ou même en python
  - PyCuda
  - nvBLAS

# GPU: Comment programmer ?

- Exemple minimaliste

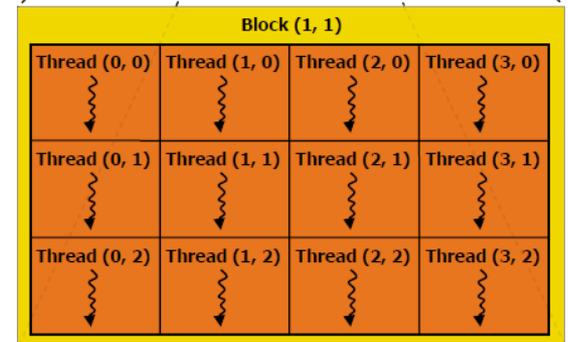
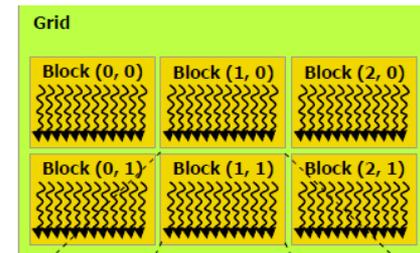
Exécuté sur le CPU

```
int main (void)
{
    type var ;           // Variable sur l'host
    type d_var ;        // Variable sur le device
    type N ;            // Nombre d'éléments
    int size = N*sizeof( type ) ; // Taille
    ...
    // Allocation de mémoire sur l'host
    var = (type*)malloc( size ) ;
    //Allocation de mémoire sur le device
    cudaMalloc( (void**)&d_var, size ) ;
    // Lancement de kernel sur le device, d_var en paramètre
    kernel<<<1,1>>>(d_var) ;
    // Copie de d_var vers l'host
    cudaMemcpy(var, d_var, size, cudaMemcpyDeviceToHost);
    ...
    // Libération de la mémoire de l'host
    free(var) ;
    // Libération de la mémoire du device
    cudaFree(d_var) ;

    return 0;
}
```

Exécuté sur le GPU

```
__global__ void kernel(type *var1)
{
    *var1 = ...
}
```



# GPU: Debug et profiling

---

- On compile avec nvcc (utilise le compilateur C/C++ par défaut pour le code CPU)
- On peut inclure des infos de débogage et remonter des timings automatiques pour le profiling
- Possibilité d'ajouter des traces qui seront visibles dans NVVP, surtout pour profiler aussi l'exécution de code CPU
- Outil graphique nvvp
- Outil de monitoring nvidia-smi
- Ces outils sont dispo sur CIMENT/Froggy/nœuds kepler

# GPU: Debug et profiling

The screenshot displays the NVIDIA Visual Profiler interface for a session titled '\*New Session'. The main window shows a hierarchical tree of GPU activity on the left and a corresponding timeline on the right. The tree includes:

- Process "add\_gpu" (11323)
  - Thread 677649056
    - Runtime API (cudaMemcpy)
    - Driver API
    - Profiling Overhead
  - [0] Tesla K20m
    - Context 1 (CUDA)
      - MemCpy (HtoD) (Memcpy HtoD [sync])
      - MemCpy (DtoH) (Memcpy DtoH [sync])
      - Compute (100.0% add(int\*, ...))
      - Streams (Default)

The timeline shows the duration of these operations. A 'Properties' window on the right provides summary statistics for the MemCpy (HtoD) operation:

MemCpy (HtoD)	
Duration	
Session	3.291 s (3,29)
Memcpyys	143.092 ms (
Invocations	1
Total Bytes	536.871 MB
Avg. Throughput	3.752 GB/s

At the bottom, the 'Analysis' tab is active, showing '1. CUDA Application Analysis' with introductory text:

The guided analysis system walks you through the various analysis stages to help you understand the optimization opportunities in your application. Once you become familiar with the optimization process, you can explore the individual analysis stages in an unguided mode. When optimizing your application it is important to fully utilize the compute and data movement capabilities of the GPU. To do this you should look at your application's overall GPU usage as well as the performance of individual kernels.

# GPU: Dans quels cas c'est adapté?

---

- **Relativement peu de RAM** (< 6 Go typiquement) donc sur des sous-ensemble restreints, il faut pouvoir découper le problèmes si possible de manière indépendante
- **Les copies CPU <-> GPU sont couteuses** donc:
  - Il faut pouvoir les limiter en favorisant 1 grosse copie
  - Ou les paralléliser avec les calculs
- Le mieux est d'avoir **bcp de calculs simples** sur « pas trop » de données
- Pour obtenir la meilleure parallélisation des threads, ils faut
  - un kernel avec peu de branchements (if/else) pour que tous fassent les mêmes opérations simultanément
  - Des données organisées de manière coalescente

# Retour sur les Jdev 2015

## Un peu de données, un peu de calcul

---

T3 Atelier 8

**Python**, apprentissage statistique et analyse de données pour la modélisation prédictive

T3 GT 5

Différentes méthodes d'**optimisation** d'un code **Python**

T8 Atelier 6

**Julia** pour vos calculs scientifiques intensifs

**T8 Atelier 2**

Programmation **GPU** moderne. Cuda est-il encore compliqué en 2015 ?

T8 GT 3

**Validation et vérification** de son logiciel scientifique : analyse, développement, exploitation

T8 Atelier 5

Structuration des données avec **HDF5**

# Logiciel de calcul: vérification & validation

---

Faire la différence entre

→ Vérification: adéquation entre les spécifications et les fonctionnalités proposées

→ Validation: les résultats du calcul sont conformes à la physique (au autre science) simulée

# Logiciel de calcul: Vérification

---

- Vérification
  - Tests unitaires et non- régression
  - Gestion des erreurs
  - Il existe pour ça des méthodes et outils maintenant largement connus et utilisés par les développeurs
  - Une bonne couverture de test a un coup non négligeable sur le développement du logiciel

# Logiciel de calcul: Validation

---

## Validation

### - Comparaison aux modèles analytiques

Souvent applicable uniquement pour des cas simple, donc on ne valide pas tout

### - Comparaison à des méthodes différentes (logiciels existants par exemple)

Les interfaces (échanges de données et cohérence physique des résultats comparés) est souvent complexe

→ Problème: cela demande parfois plus d'énergie de développer les méthodes de validation que le logiciel de calcul lui-même !

Solution: ... chacun trouve un compromis acceptable ...



# Retour sur les Jdev 2015

## Un peu de données, un peu de calcul

---

T3 Atelier 8

**Python**, apprentissage statistique et analyse de données pour la modélisation prédictive

T3 GT 5

Différentes méthodes d'**optimisation** d'un code **Python**

T8 Atelier 6

**Julia** pour vos calculs scientifiques intensifs

**T8 Atelier 2**

Programmation **GPU** moderne. Cuda est-il encore compliqué en 2015 ?

T8 GT 3

Validation et vérification de son logiciel scientifique : analyse, développement, exploitation

**T8 Atelier 5**

Structuration des données avec **HDF5**

# Atelier : Structuration des données avec HDF5

---

- HDF5 = Hierarchical Data Format 5
- Bibliothèque d'entrée-sortie parallèles utilisant MPI-I/O
  - → optimisation possible MPI-I/O
- Équivalent à READ/WRITE mais Portable (inter-plateformes)
- Fonctionnalités avancées
  - Description de données (dim, commentaires)
  - Compression à la volée
  - Compréhensible par bcp d'outils de visu (VisIt, ParaView, ...)
- Bindings en Python, C, C++ Fortran