

GPU pour PAON4/Idrogen




O. Perdereau, R. Ansari

WORK IN PROGRESS


1/12/2020

The 21 cm H line

- introduced in astro (radio) in 1944
 - "isolated" line \Rightarrow enables tomography : $z \leftrightarrow \nu$
 - ground observations possible down to ~ 30 MHz (ionosphere) i.e. $z \sim 30$
- NB human-made perturbations (3/4/5G, TNT, FM, radars, ..)



21 cm in cosmology



Planck,
S4,
Litebird

Euclid


LSST, DESI

MSE

Two aspects : global spectrum shape & spatial anisotropies

LSS from 21 cm line Intensity Mapping (IM)

- broad ν band, low angular resolution instrument
- measure intensity at “each” frequency $\Rightarrow z$: “easy” tomography
- prices to pay :
 - ▶ low signal (detected up to now only in X-corr with surveys)
 - ▶ very high level of **foregrounds**
 - ▶ DAQ & calibration challenging
 - ▶ cosmological analysis : **HI power spectrum bias wrt matter's**



J. Petterson et al. arXiv:0902.3091




The idealized setup

(some) Requirements :

- large collecting surface (S/N ratio)
- large sky area
- moderate (0.1 deg) angular resolution
- broad ν range (large volume)

⇒ tentative solution(s) :


- packed interferometric array (angular res., high S/N at BAO scale)
- (semi) fixed antenna(s) in transit mode (large sky coverage, cost)
- sampling of full signal waveform → FFT, digital correlation, beam forming




PAON4

Collaboration between LAL, Obs. de Paris (Meudon, Nançay), IRFU
Characteristics :

- 4 dishes (~ 3 deg beams) in Nançay (~ 200 km south of Paris)
- 2 polar./antenna
- Frequency band 1250 - 1500 MHz (~ 1275 - 1480 MHz fiducial)
- ± 20 degrees from zenith
- transit observations ; ~ 24h scans (fixed elevation) since 2015
- test bench for electronics, DAQ, on-line computing, analysis
- J.E. Campagne et al., MNRAS in press



Le corrélateur de PAON4



- Corrélateur soft de PAON 4 \Rightarrow efficacité sur ciel \lesssim 10%
- Upgrade prévu : 2 nouvelles machines avec GPU (back-end)
- **objectif : gagner un facteur 4-6 d'efficacité**

Etapes du processing

- les machines du Front-End reçoivent des blocs d'échantillons : structure $S(t_n)$ ou $A(\nu_k)$ si FFT en amont
- éventuellement calculs des FFT
- séparation en 2 intervalles de fréquence et organisation
- envoi aux corrélateurs
- dans chaque corrélateur : **calcul des cross/auto-corrélations** entre feeds pour chaque bloc
- et **moyenne** de ces blocs dans un intervalle de temps (paramètre du système) :

$$\sum_n a_i^n[\nu_k] a_j^n[\nu_k]^*$$

Premiers tests

pc-bao2 : Dell PowerEdge 740 (40 Intel(R) Xeon(R) Silver 4210 @2.20GHz) + GPU Nvidia Quadro P4000 (8 Go)

serveur-paon4 : idem mais Tesla T4 (16 Go)

- calculs sur CPU
- calculs sur GPU :
 - ▶ **OpenCL** : standard ouvert conçu pour programmer des systèmes parallèles hétérogènes CPU+GPU
 - ▶ **CUDA** : API e.g. C(++) pour calculer sur GPU NVidia
 - ▶ **thrust** : analogue parallèle (CPU et/ou GPU) de la STL - NVidia
 - ▶ **CuBLAS** : implémentation de BLAS pour GPU - NVidia (CUDA)

Mon petit test (1)

- (cross)-corrélation = produit élément par élément de 2 vecteurs thrust avec transform + fonction ad-hoc

(...)

```
struct pxycon_functor
{
    __host__ __device__
    thrust::complex<float> operator()(const thrust::complex<float> & x,
    const thrust::complex<float> & y) const {
        return x*thrust::conj(y);
    }
};
```

(...)

```
thrust::transform( x.begin() , x.end() ,
                  y.begin(), output.begin() , pxycon_functor() );
```

(...)

⇒ remplit le `thrust::vector` avec $x \times y^*$

Mon petit test (2)

- moyenne de n cross-corrélations \Leftrightarrow produit matrice vecteur :

$$\begin{pmatrix} a_i^0[\nu_0]a_j^0[\nu_0]^* & \dots & a_i^n[\nu_0]a_j^n[\nu_0]^* \\ \vdots & \ddots & \vdots \\ a_i^0[\nu_M]a_j^0[\nu_M]^* & \dots & a_i^n[\nu_M]a_j^n[\nu_M]^* \end{pmatrix} \begin{pmatrix} 1/n \\ \vdots \\ 1/n \end{pmatrix} \quad (1)$$

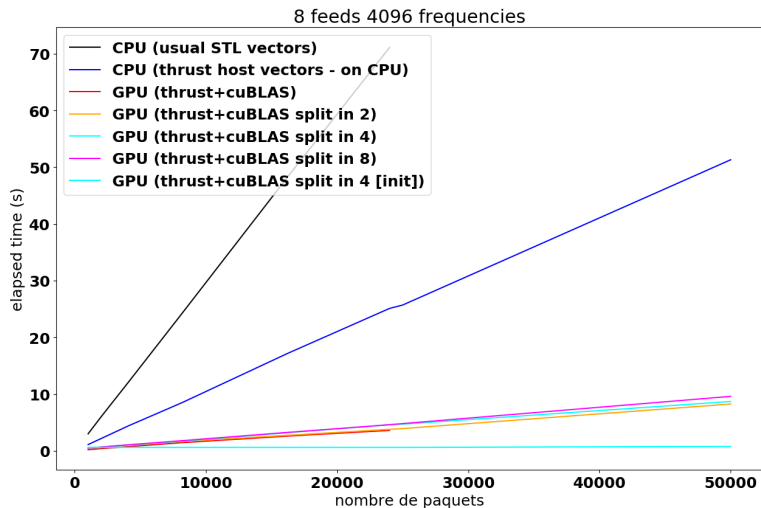
\Rightarrow utilisation d'une fonction de cuBLAS : `cublasCgemv` dérivée de `gemv` (BLAS) : produit matrice vecteur générique

(NB : demande quelques "cast" pour les containers vs thrust : `:vector`)

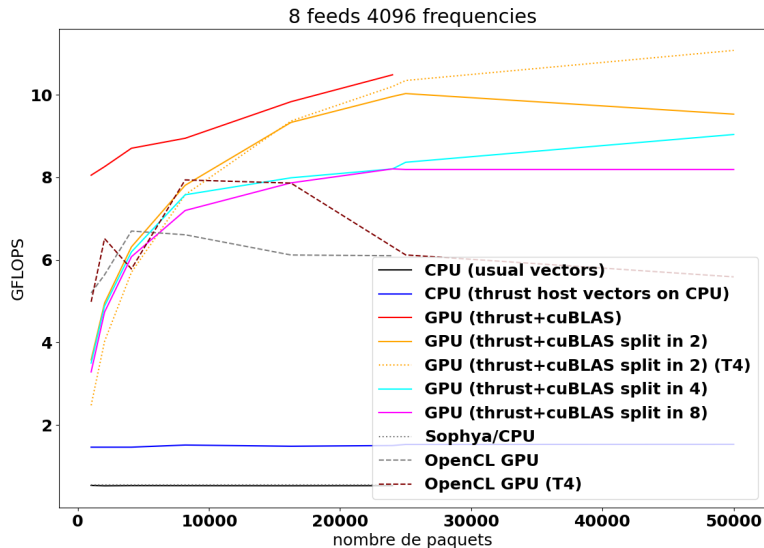
quelques paramètres

- 8 feeds dans PAON4
- data streams simulés comme des gaussiennes de moyenne 2 et sigma 3.5 (arbitraire !)
- chaque paquet de "FTT" comprend 4096 coefs complexes
- float précision
- je fait varier le nombre de paquets traités
- éventuellement traités en plusieurs blocs (mémoire du GPU)

Performances (1)

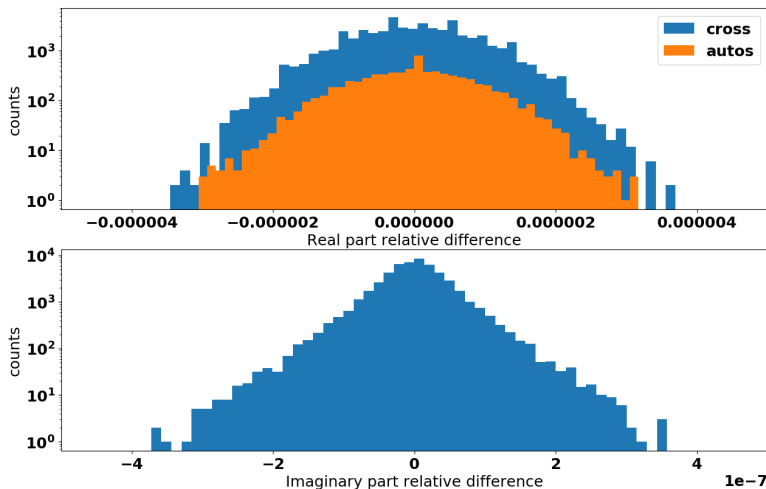


Performances (2)



Des résultats (un peu) différents


Differences between CPU and GPU results



Une comparaison entre les GPUs

GPU 1: NVIDIA Tesla T4

GPU 2: NVIDIA Quadro P4000



Petit bilan

- Sur PAON4 :
 - ▶ 8 coeurs Intel(R) Xeon(R) CPU E5620 @2.40GHz, 15Go RAM
 - ▶ 4 threads
 - ▶ 432 MFLOP/s sur chacun
- pc-bao2 / serveur-paon4 :
 - ▶ 40 coeurs Intel(R) Xeon(R) Silver 4210 CPU @2.20GHz, 62 Go RAM
 - ▶ Avec un GPU NVIDIA Quadro P4000 ou Testla T4
 - ▶ On arrive a ~ 8 GFLOP/s
- En ajoutant un second GPU on devrait gagner le facteur voulu (largement?)
- Diff'ERENCE P4000 vs Tesla T4 pas énorme?