PUGNÈRE Denis
CNRS / IN2P3 / IPNL

Comparatif des systèmes de stockage distribués en écriture intensive pour l'expérience WA105

ANF "Des données au bigdata: exploitez le stockage distribué !"
12-16 December 2016 - Complexe d'accueil de Gif-sur-Yvette

Plan de la présentation

Présentation de l'expérience à l’origine du besoin

Besoins de stockage de l’expérience

Plate-forme de tests

Méthodologie

Résultats des tests

Conclusion

(proto)DUNE http://www.dunescience.org/

- DUNE : Deep Underground Neutrino Experiment
- Expérience d'oscillations de neutrinos de nouvelle génération (mesure de la hiérarchie de masses, étude CP)

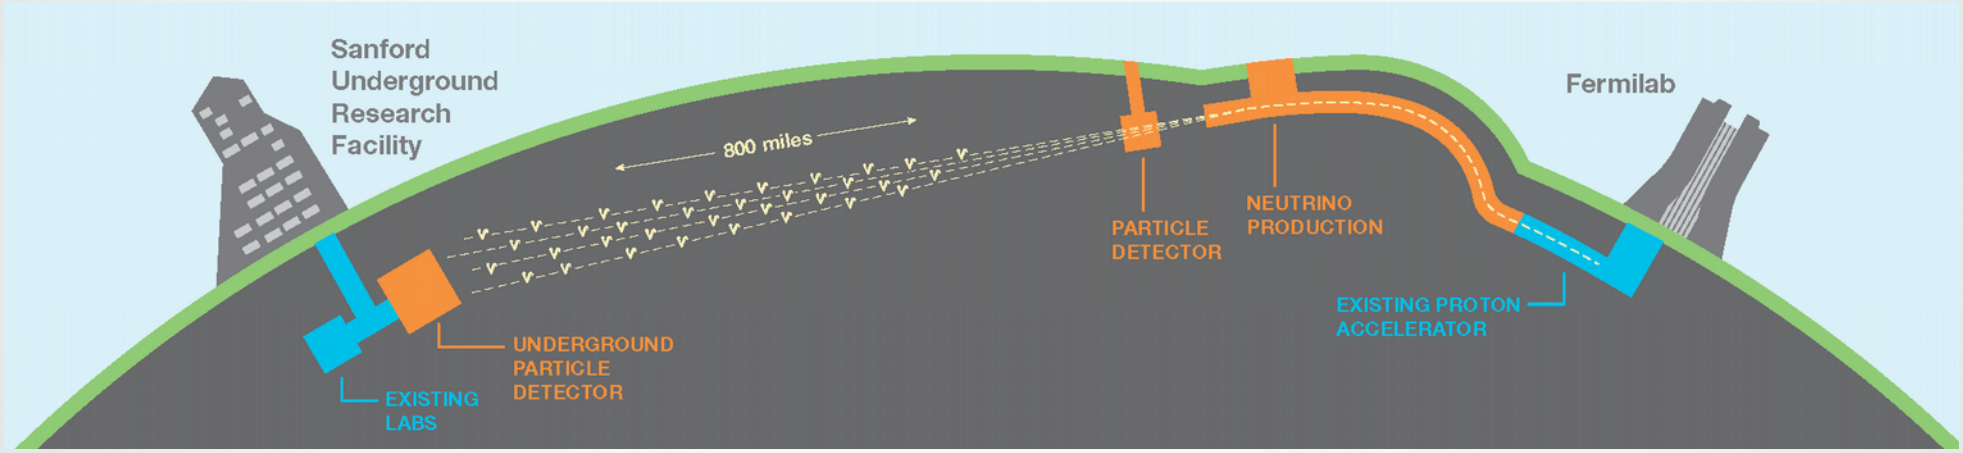

- Faisceau + détecteur proche @ Fermilab
- Détecteur lointain (TPC argon liquide) @ Sanford
- 2 technologies : single (US) / dual (Europe) phase
- 2 expériences protoDUNE @ CERN : NP02/WA105 (dual phase) et NP04 (single phase)

Dual-phase protoDUNE : WA105

WA105 DLAr 6x6x6m³ design

- Membrane GTT® tank with passive insulation
- Top deck with chimneys and insulation
- **6x6m² anode large readout area, 6m long drift length** (3ms max drift time @ 1kV/cm)
- Charged particle beam window
- 300 ton LAr instrumented: 7680 charge readout channels, 36 PMTs (baseline layout)

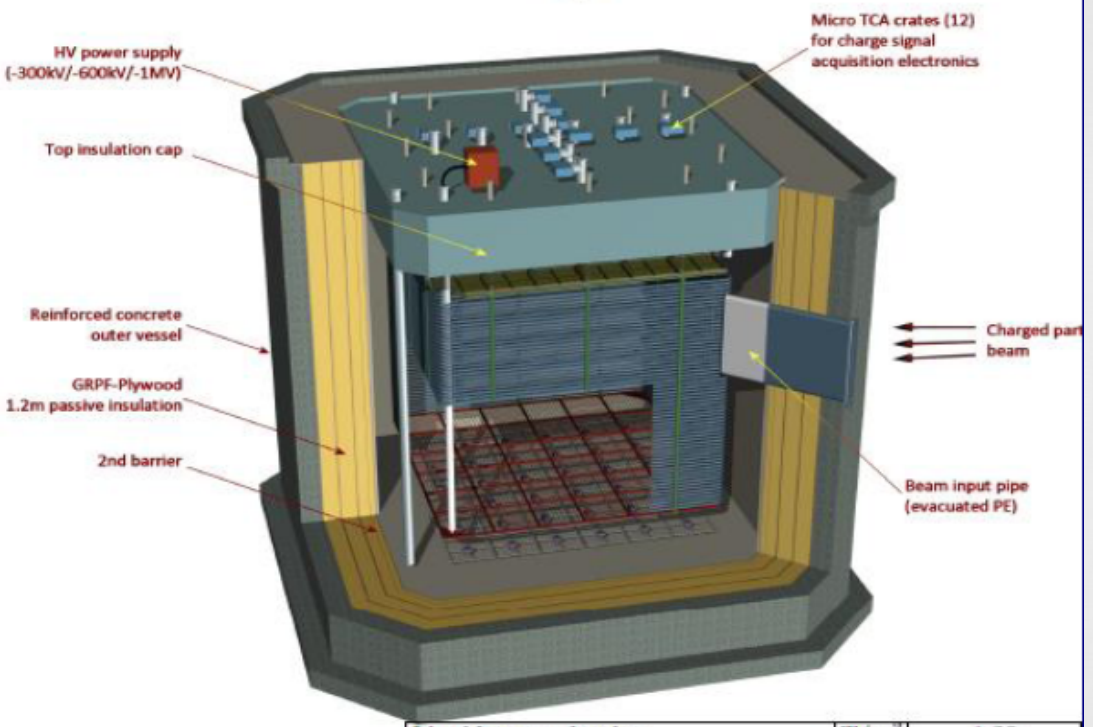

Liquid argon density	T/m^3	1.38
Liquid argon volume height	m	7.6
Active liquid argon height	m	5.99
Hydrostatic pressure at the bottom	bar	1.03
Inner vessel size (WxLxH)	m^3	8.3 × 8.3 × 8.1
Inner vessel base surface	m^2	67.6
Total liquid argon volume	m^3	509.6
Total liquid argon mass	t	705
Active LAr area	m^2	36
Charge readout module (0.5 x0.5 m^2)		36
N of signal feedthrough		12
N of readout channels		7680
N of PMT		36

WA105 µTCA-DAQ architecture

2 x 40 Gb/s

E.B.1

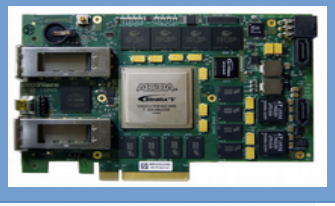

µTCA.1 option

View from anode with signal (1), suspension (2), HV(3), PMT(4), manhole (5), detail insertion (6), clean room IN/OUT (7) nozzles

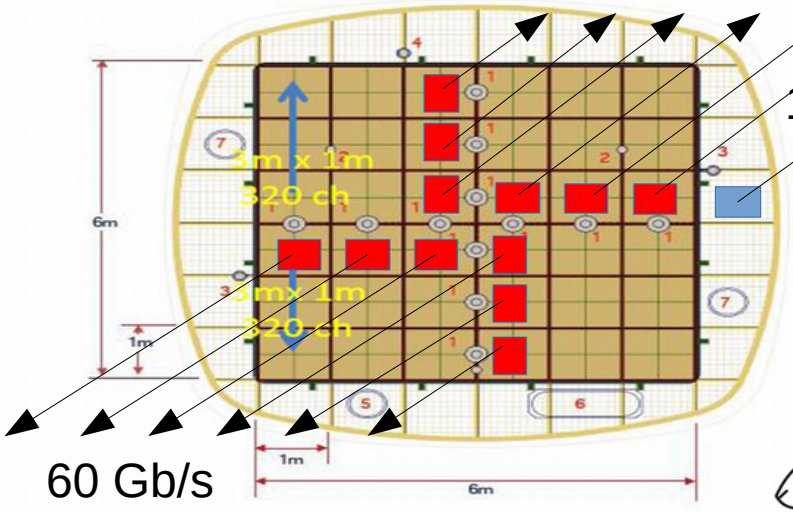

60 Gb/s

10 Gb/s

60 Gb/s

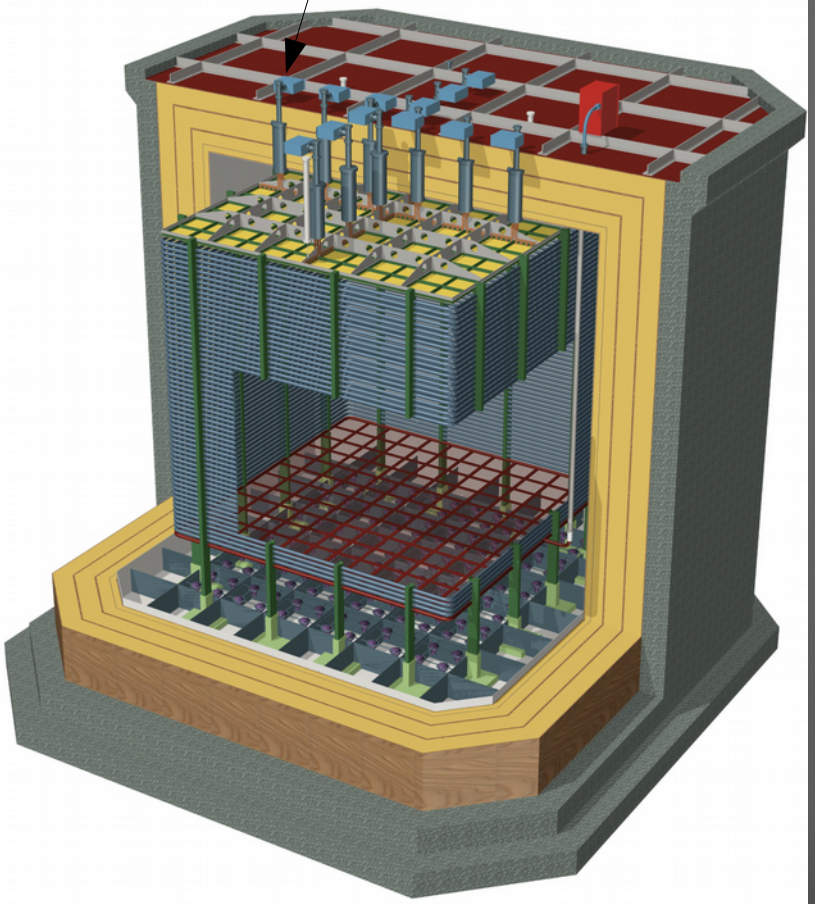

E.B.2

2 x 40 Gb/s

WA105 data network

B/E (storage/ processing)

Storage :
15 disks servers R730
2 metadata servers R630
1 config. server R430

Processing :
16 lames M630
16x24 = 384 cores

C.C.

10 Gbps *15* *3* *10 Gbps* *10 Gbps*

20 Gbps comp. data out

20 Gbps *CERN C.C.*

C.R.

130 Gbps raw data out

40 Gbps

Event building workstations

C.R.

B/E (sorting/ Filtering/ Clock)

4 = 160 Gbps

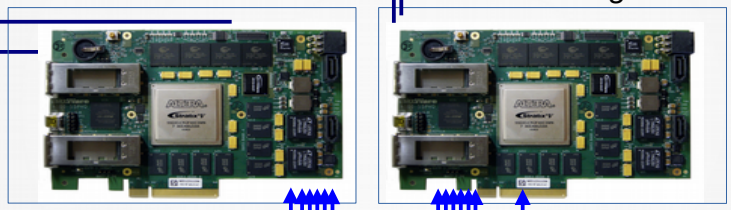

Top of cryostat

Raw / Compressed data

10 Gbps

6 = 60 Gbps

6+1 = 70 Gbps max

10 Gbps

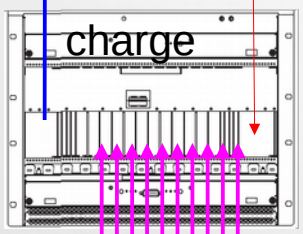

F/E-out : Charge + PMT

10 *Raw data : charge*

Raw data : light

PC :
WR slave
Trigger board

Triggers : Beam Counters

C.R.

F/E-in

LAr

Besoins de stockage de l’expérience

- Taille 1 Po (buffer local de 1 à 3 jours de prise de données)
- La solution de stockage doit pouvoir :
  - absorber 130Gb/s de débit aggrégé (60Gb/s + 70Gb/s) en écriture pendant la phase de debug (données non comprimées)
  - Pendant phase de production : Facteur de compression (Huffman) estimé a ~90 %
  - Permettre la lecture des données pendant l’enregistrement afin de déterminer la qualité des données
    - Analyse : suppression des cosmiques, sélection
    - Contrôle du comportement des détecteurs

      => Prise de décision : stopper / continuer la prise de données
  - La recopie des données vers le stockage central du CERN (EOS)

- Non pris en compte au moment de cette étude :
  - Débit nécessaire à la reconstruction des données (traitement online) : les contraintes de temps ne sont pas encore connues.
    - Le nombre d'évennements non connu
    - Quantité CPU nécessaire non connue
  - La quantité de données supplémentaires nécessaires au traitement des données :
    - Merging
    - Fichiers de logs, états
  - La quantité de workers de la ferme de calcul locale devant accéder aux données

Besoins de stockage de l’expérience : nécessité de tests

- Devis commerciaux initiaux : 2 à 4 * le budget de l'acquisition de l'expérience **sans engagement sur la performance**

- Recherche de candidats de systèmes de stockage :
  - Sachant exploiter efficacement les capacités des serveurs de données
  - **Économes en cycles CPU coté client**

- Objectif de ce 1er test :
  => Trouver les paramètres optimaux permettant d'atteindre l'objectif de débit / client
  => Trouver les paramètres optimaux permettant d'optimiser l'accès au stockage
  - => Caractériser les systèmes de stockage sous l’angle de la performance en écriture

Plateforme ...temporaire… de tests

Client : Dell R630
- 1 CPU E5-2637 @ 3.5Ghz (4c, 8c HT),
- 32Go RAM 2133 Mhz DDR4
- 2 * Mellanox CX313A 40Gb/s
- 2 * 10Gb/s (X540-AT2)
- CentOS 7.0

MDS / Managment : 2 * Dell R630
- 1 CPU E5-2637 @ 3.5Ghz (4c, 8c HT),
- 32Go RAM 2133 Mhz DDR4
- 2 * 10Gb/s (X540-AT2)
- Scientific Linux 6.5 et Centos 7.0

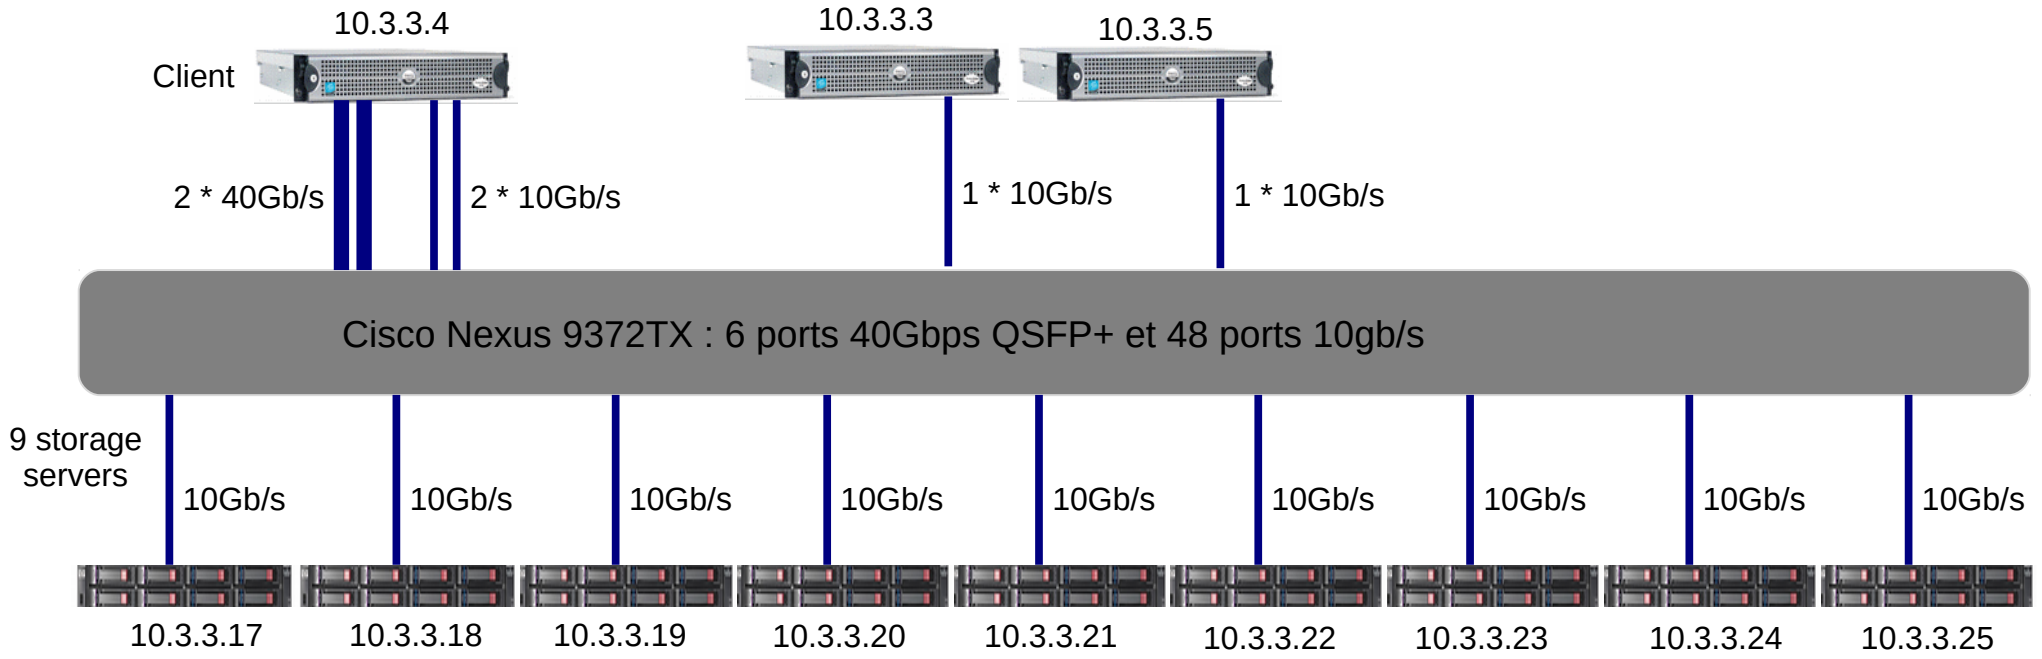

9 Sorage Servers : (9 * Dell R510)
- 2 * CPU E5620 @ 2.40GHz (4c, 8c HT), 16Go RAM
- 1 carte PERC H700 (512MB) : 1 Raid 6 12HDD 2TB (10D+2P) = 20TB
- 1 Ethernet intel 10Gb/s (X520/X540)
- Scientific Linux 6.5

Systèmes de stockage testés

	Lustre	BeeGFS	GlusterFS	GPFS	MooseFS	XtreemFS	XRootD	EOS
Versions	v2.7.0-3	v2015.03.r10	3.7.8-4	v4.2.0-1	2.0.88-1	1.5.1	4.3.0-1	Citrine 4.0.12
POSIX	Oui	Oui	Oui	Oui	Oui	Oui	via FUSE	via FUSE
Open Source	Oui	Client=Oui, Serveur=EULA	Oui	Non	Oui	Oui	Oui	Oui
MDS nécessaire	Oui	Metadata + Manager	Non	Non	Metadata + Manager		Oui	Oui
Support RDMA / Infiniband	Oui	Oui	Oui	Oui	Non	Non	Non	Non
Striping	Oui	Oui	Oui	Oui	Non	Oui	Non	Non
Failover	M + D (1)	DR (1)	M + D (1)	M + D (1)	M + DR (1)	M + DR (1)	Non	M + D (1)
Quota	Oui	Oui	Oui	Oui	Oui	Non	Non	Oui
Snapshots	Non	Non	Oui	Oui	Oui	Oui	Non	Non
Outils de déplacement des données	Oui	Oui	Oui	Oui	Non	Oui	Non	Oui

(1) : M=Metadata, D=Data, M+D=Metadata+Data, DR=Data Replication

Notes sur les systèmes de stockage testés

Tous sont dans la classe « software defined storage »

- Systèmes de fichiers :
  - GPFS, Lustre et BeeGFS sont connus dans le monde HPC (High Performance Computing) : ce sont des systèmes de fichiers parallèles performants en présence de nombreux clients et de nombreux serveurs de données.
  - Je souhaitais aussi en profiter pour tester GlusterFS, MooseFS, XtreemFS pour connaître leurs caractéristiques
- Systèmes de stockage :
  - XRootD est un protocole de transfert de données très populaire en High Energy Physics, il s'intègre bien avec ROOT (le framework et le format de fichier)
  - EOS : est un système de stockage massif (135PB @CERN), dont l'accès est multi-protocole (XRootD, https, webdav, POSIX-like FUSE)

Tous ces systèmes ont leur avantages et inconvenients respectifs, non discutés ici

Méthodologie adoptée

1 : Tests réseau

+

2 : Tests du client

+

3 : Tests du stockage

+

4 : Tests de la chaine complète

Tests principalement protocolaires :

- Protocoles TCP / UDP : iperf, nuttcp...
- Saturation des interfaces : Algorithmes de contrôle de congestion : cubic, reno, bic, htcp...
- UDP : % de perte de paquets
- TCP : nombre de retransmissions
- Drop de paquets
- Puis reste des tests en TCP, flux en écriture

Connaître précisément quel flux peut générer le client :

Test initiaux => optimisations => caractérisation

- Optimisations :
  - Bonding réseau : test des algorithmes LACP, balance-alb, balance-tlb
  - Optimisation buffers réseau : modif /etc/sysctl.conf
  - Utilisation de Jumbo frames (MTU 9216)
  - Charge CPU : répartition des IRQ sur tous les coeurs
    - chkconfig irqbalance off ; service irqbalance stop
    - Mellanox : set_irq_affinity.sh p2p1

Tests individuels des éléments de stockage :

- Iozone / fio / dd : benchmark du système de fichier local

Tests de la chaine complète :

- Sur le client
  - Stockage : Iozone, fio, dd, xrdcp
  - Réseau / système : dstat
- Sur les éléments de stockage : dstat

1-a. Tests réseau entre 2 clients

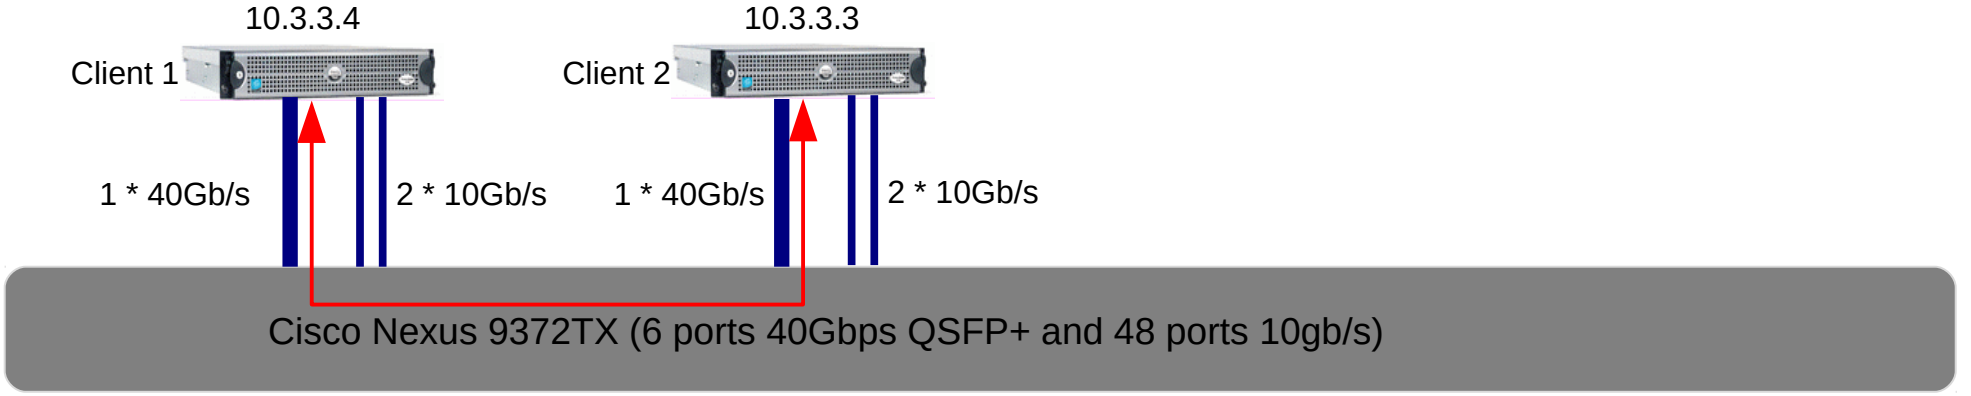

Quel est le comportement des flux réseau entre 2 clients avec pour chacun 1 * 40Gb/s + 2 * 10Gb/s ?

- Tests réalisés avec beaucoup de paramètres réseau :
  - net.ipv4.tcp_congestion_control = cubic, MTU=9216, irq affinity on all CPU cores, tuning mellanox,
  - Bonding, tests plusieurs algorithmes : mode=balance-tlb, balance-alb (xmit_hash_policy=layer2 ou layer3+4), but not LACP (IEEE 802.3ad)
- Network bandwidth tests between **only 2 « clients » with 1*40Gb/s + 2*10Gb/s each** (nuttcp, 5 seconds test)
  - **Only 1 flow** between 10.3.3.3 et 10.3.3.4 : TCP = **34746 Mb/s (0 TCP retrans)**, UDP = 38561Mb/s (2.74 % UDP packet losses)
  - **1 processus, 6 flows** between 10.3.3.3 et 10.3.3.4 : TCP = **35058 Mb/s (0 TCP retrans)**
  - **6 processus (1 flow / processus)** between 10.3.3.3 et 10.3.3.4 : TCP = **39532 Mb/s (0 TCP retrans)**

Comparaison : 1 vs 6 processes :

- Comparaison de bande passante de :
  - 1 process qui génère 6 flux
  - 6 processus, 1 flux / processus
- 30 secondes test
- Carte 40Gb/s proche de la saturation
- Le flux ne passe pas par les cartes 2*10Gb/s (all bonding algorithms tested)
- +12.7 % quand les flux sont générés par 6 processus indépendants

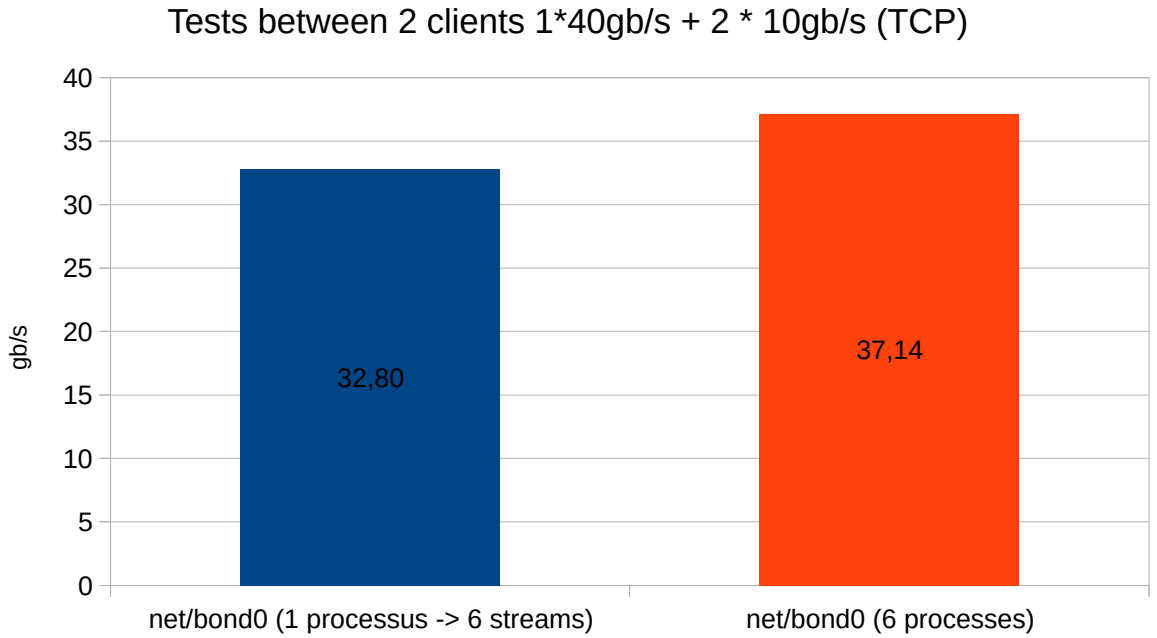

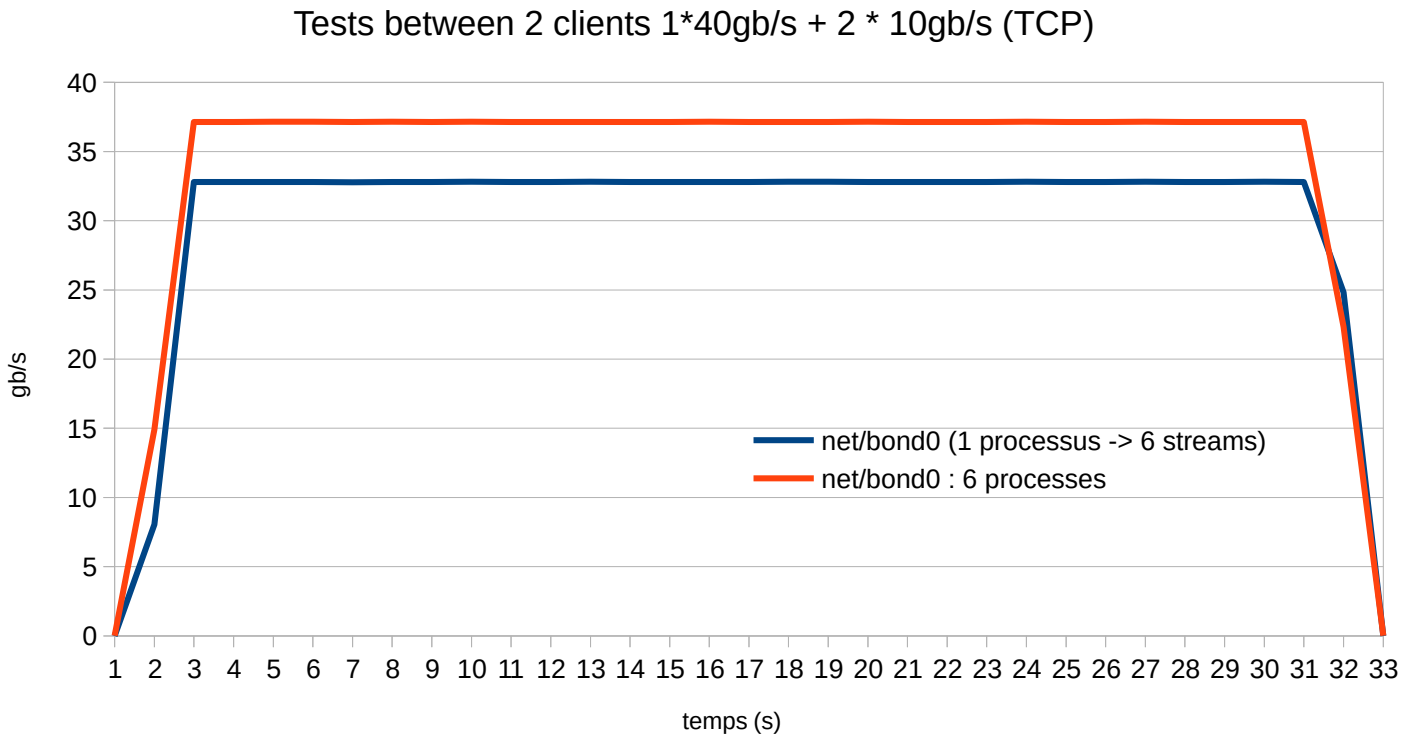

1. Tests individuels du réseau de chaque serveur

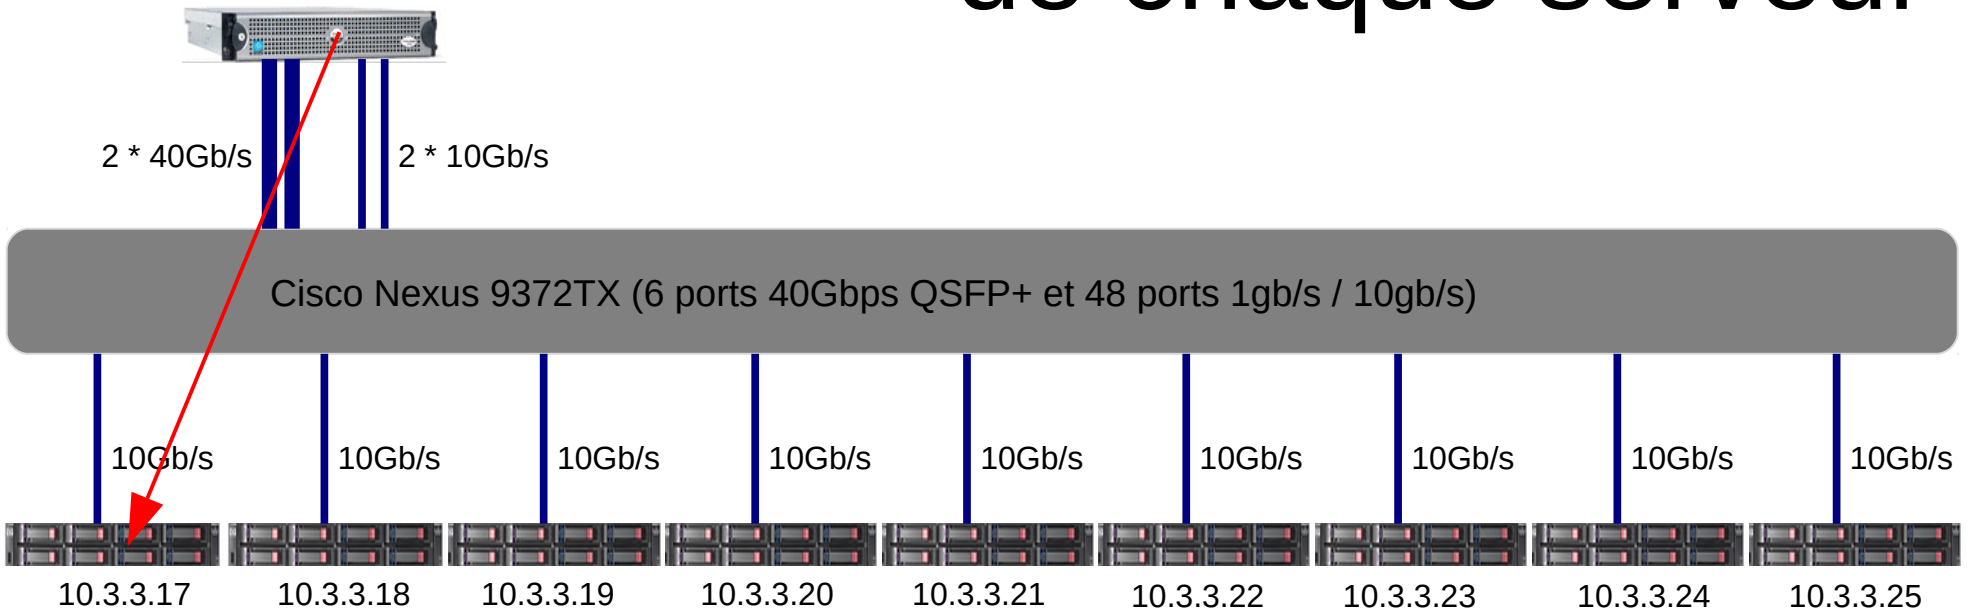

- Tests bande passante réseau de chaque serveur de stockage (nuttcp)
  - Individuellement : 1 flux TCP ou UDP vers 1 serveur :
    - TCP client → serveur : somme des 9 = 87561.23 Mb/s **(7k à 8k TCP retrans / serveur)**
    - TCP serveur → client : somme des 9 = 89190.71 Mb/s (0 TCP retrans / serveur)
    - UDP client → serveur : somme des 9 = 52761.45 Mb/s (83 % à 93 % UDP drop)
    - UDP serveur → client : somme des 9 = 70709.24 Mb/s (0 drop)
  - Étape utile : Identification de problèmes non détectés jusqu'à maintenant (changement de câbles de mauvaise qualité)

1-b. Tests réseau avec 2 clients et le système de stockage

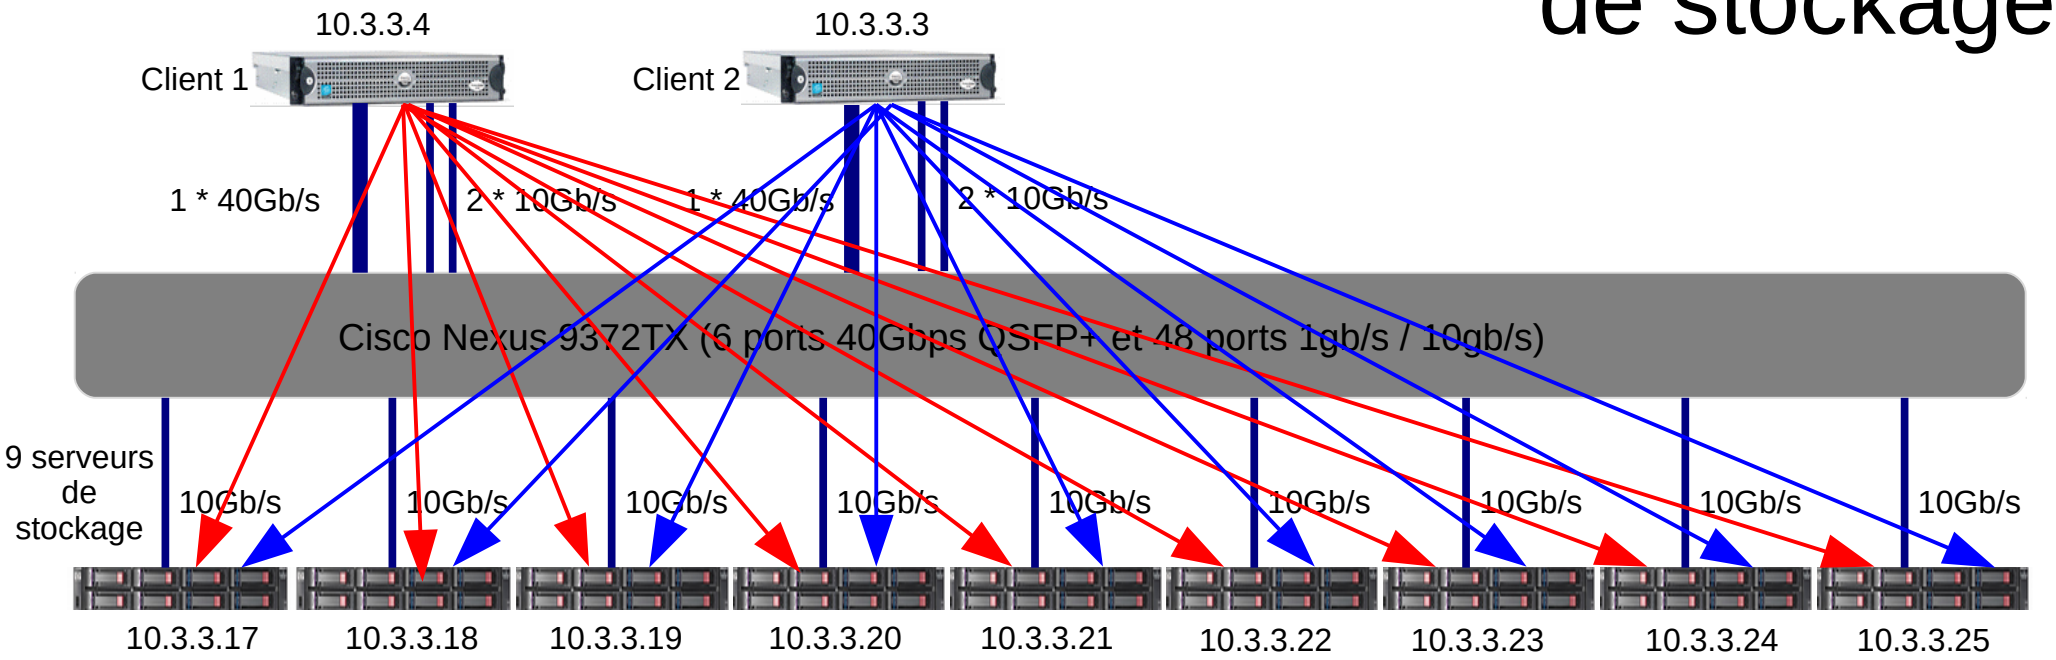

Comment se comportent les flux concurrents provenant de 2 clients, vers le stockage ?

- 2 clients, pour chaque client : **1 * 40gb/s + 2* 10gb/s, soit 120Gb/s max**
  - Envoi simultané de 9 flux réseau depuis chacun des 2 clients vers les 9 serveurs de stockage

    => Les flux passent bien par toutes les interfaces des clients (les 40gb/s mais aussi les 10gb/s)

    => 5k à 13k TCP retrans / client et / serveur

    => saturation du réseau des 9 serveurs de stockage à 92.4 %

- Test de répartition du trafic depuis 2 clients vers 9 serveurs de stockage : chaque client dispose de 1*40gb/s + 2*10gb/s
- mode=balance-alb xmit_hash_policy=layer3+4
- Test sur 30 secondes
- Les flux sont répartis sur toutes les interfaces des 2 clients
- Client 1 : 37.49 gb/s en moyenne
- Client 2 : 45.7 gb/s en moyenne
- Somme = 83.19 gb/s en moyenne
  = 92.4 % des 9 * 10gb/s
- La répartition du débit de chaque client dans le temps n'est pas uniforme

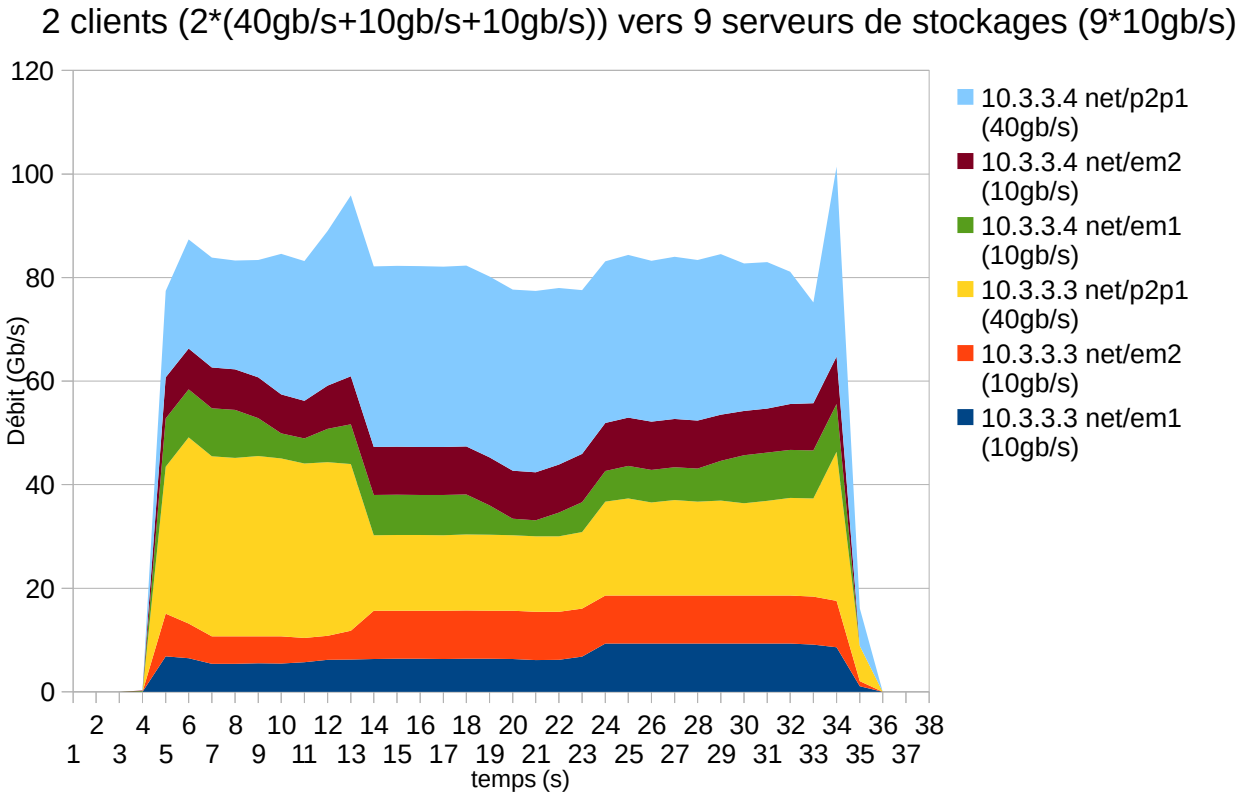

2 clients (2*(40gb/s+10gb/s+10gb/s)) vers 9 serveurs de stockages (9*10gb/s)

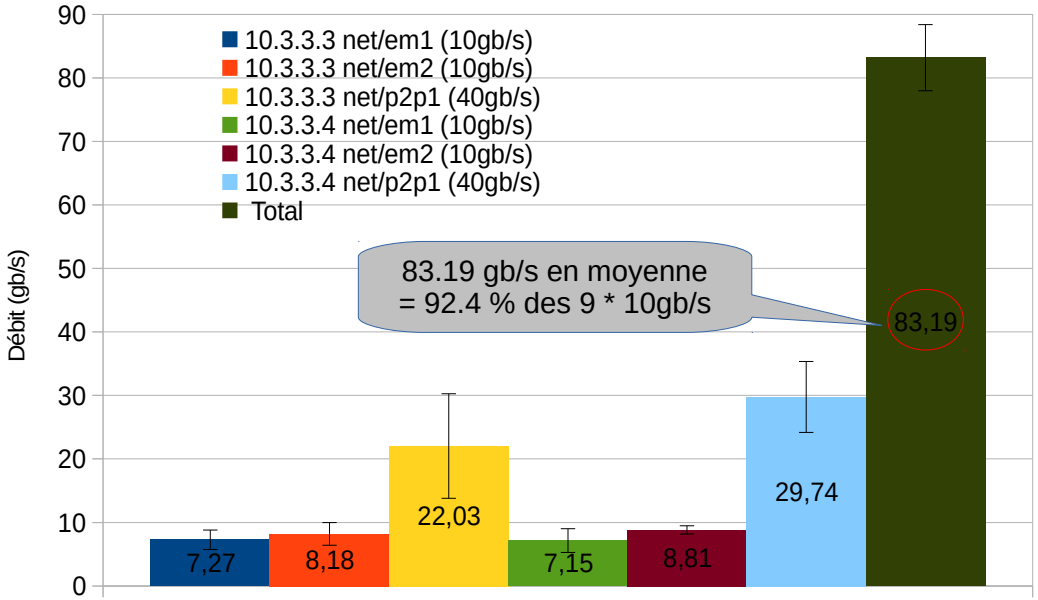

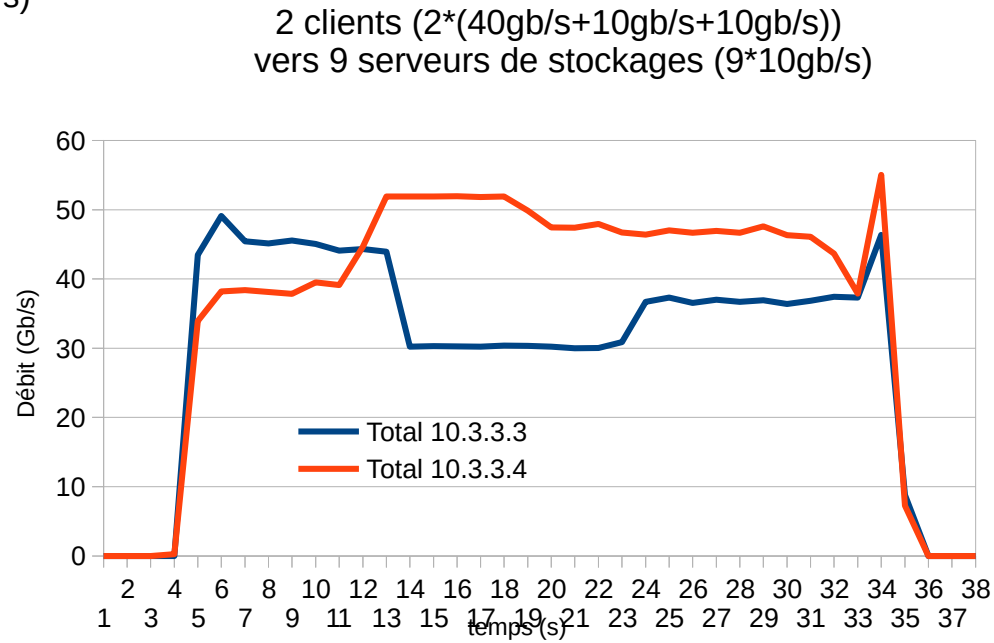

1. et 2. Tests du réseau (tous les serveurs simultanément) et du client

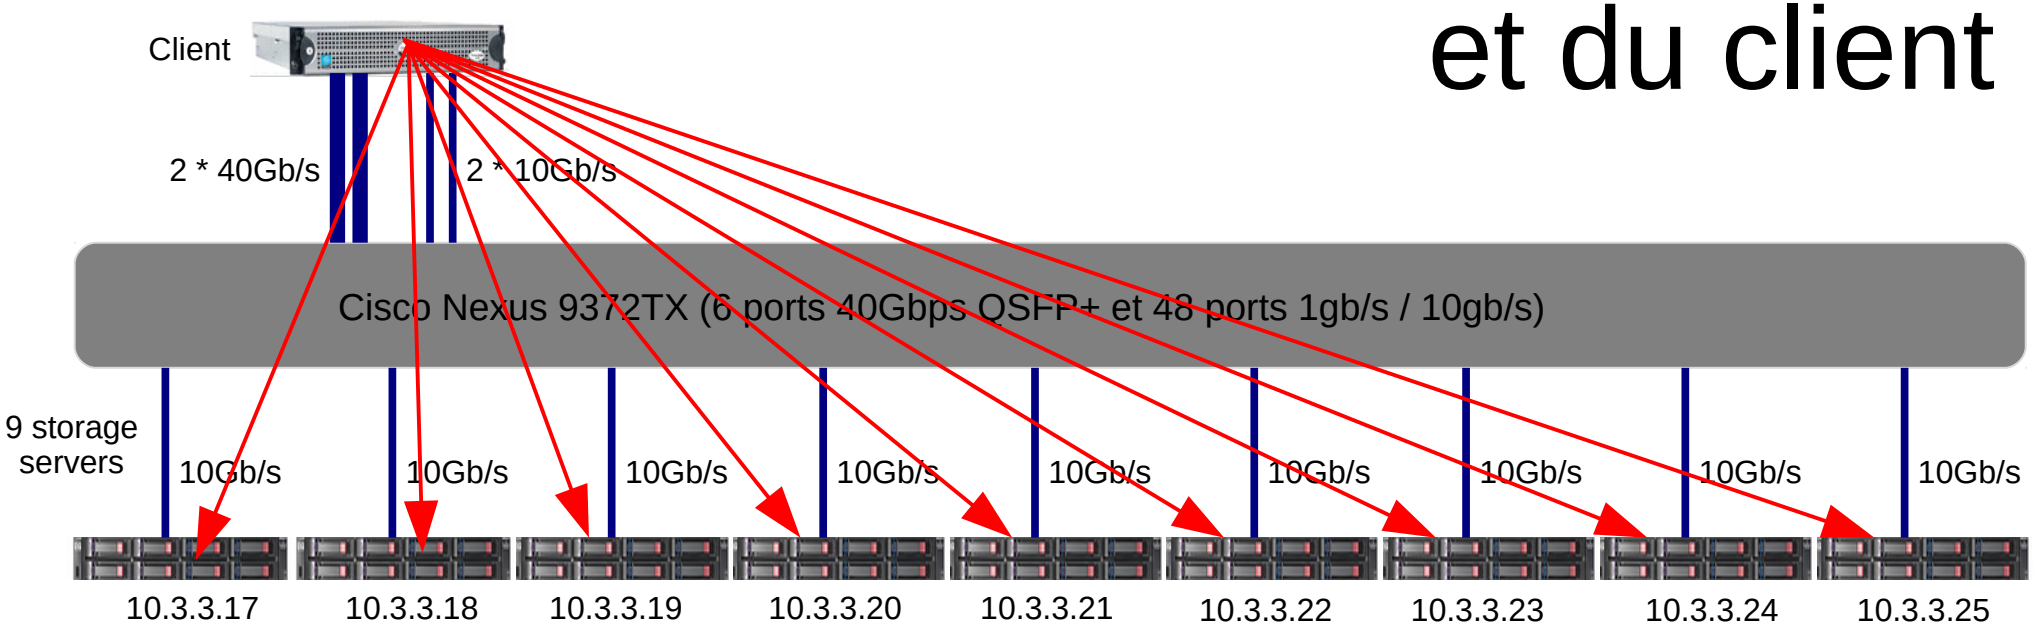

Comment se comportent les différents algorithmes de bonding ?

- Envoi de 9 flux TCP simultanés (1 vers chaque serveur) pendant 5 minutes (nuttcp)
  - 1er test : nous testons individuellement chaque carte 40Gb/s→ 9 serveurs : saturation de la carte 40Gb/s
  - 2eme test : Client Bonding avec seulement 2 * 40gb/s → 9 serveurs :
    - Algorithmes de bonding testés : mode=balance-alb, balance-tlb, LACP
    - Grande variation des mesures (sauf LACP), meilleur = LACP (802.3ad xmit_hash_policy=layer2+3)
  - 3eme test : Client bonding avec 2 * 40gb/s + 2 * 10gb/s → 9 serveurs :
    - Bonding testé : mode=balance-alb, balance-tlb mais pas LACP (incompatible)
    - Grande variation des mesures, meilleur = balance-alb xmit_hash_policy layer2+3

1er test

- 1er test : Client avec 1 * 40gb/s → 9 serveurs : saturation de la carte 40gb/s
  - Test avec la 1ère carte 40gb/s p1p1
  - Test avec la 2ère carte 40gb/s p2p1
- Test sur 5 minutes
- saturation de la carte 40Gb/s
- Peu de différence dans le débit observé entre les 2 cartes
- p1p1 : entre 55k et 143k TCP retrans / serveur
- p2p1 : entre 40k et 134k TCP retrans / serveur

Test saturation 1x40gb/s (p1p1), 9 flux vers 9 serveurs, TCP, 5 minutes

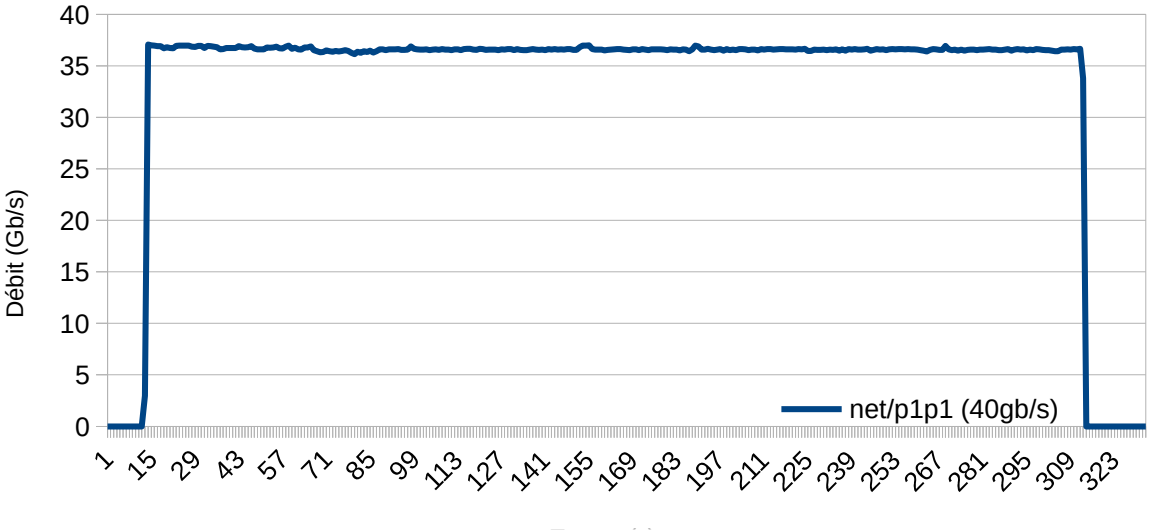

Test saturation 1x40gb/s (p2p1), 9 flux vers 9 serveurs, TCP, 5 minutes

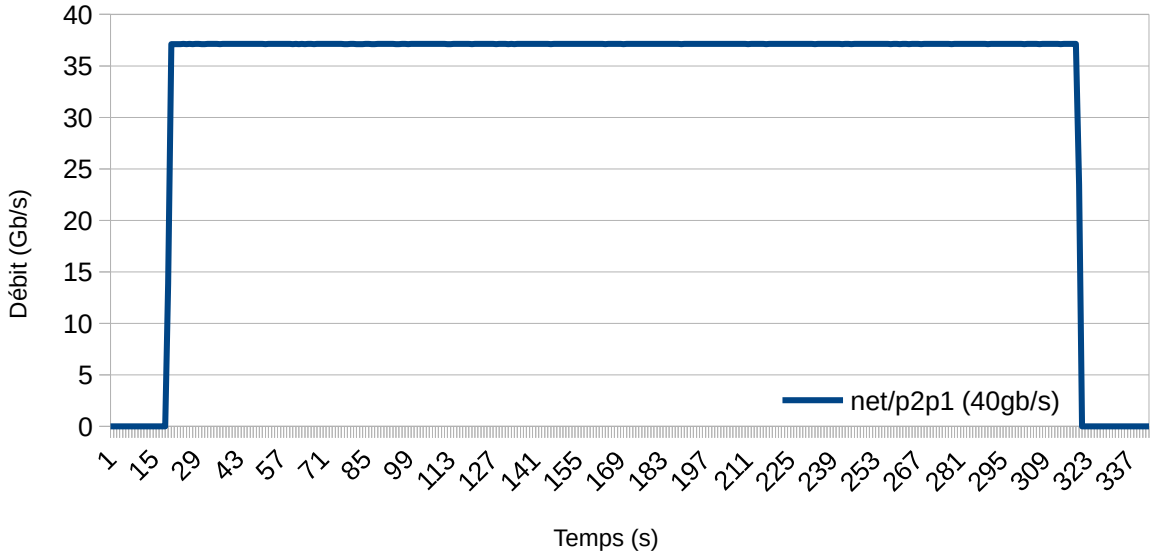

2ème test

1 client, 2*40gb/s, bonding balance-alb, xmit_hash policy=layer2

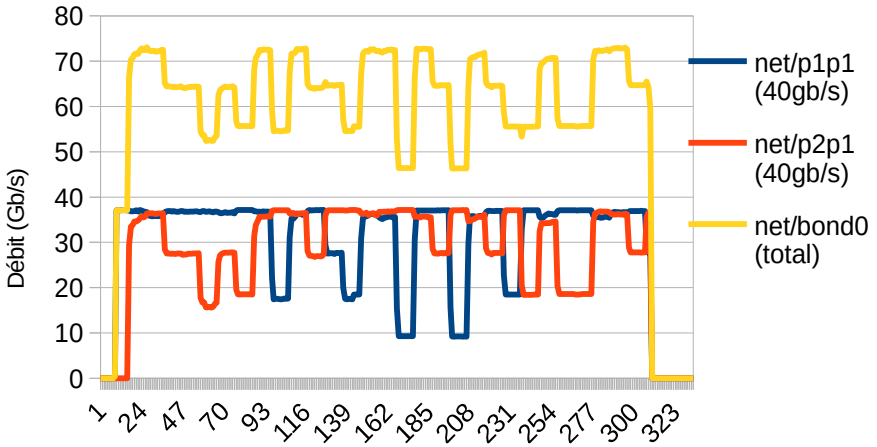

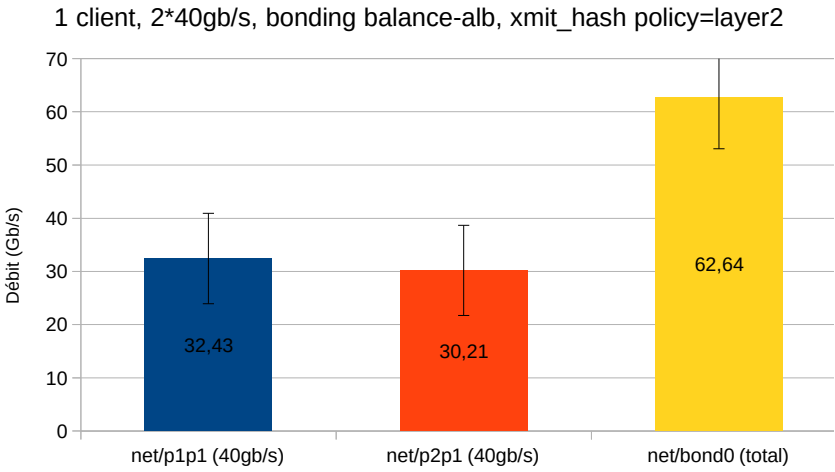

1 client, 2*40gb/s, bonding balance-alb, xmit_hash policy=layer2-3

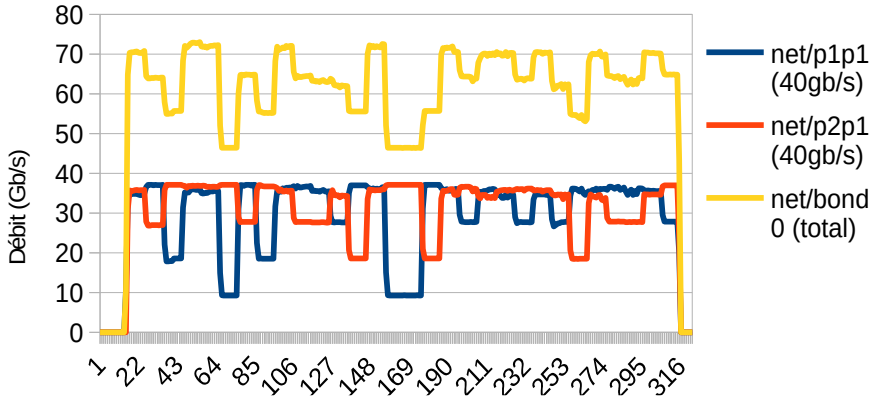

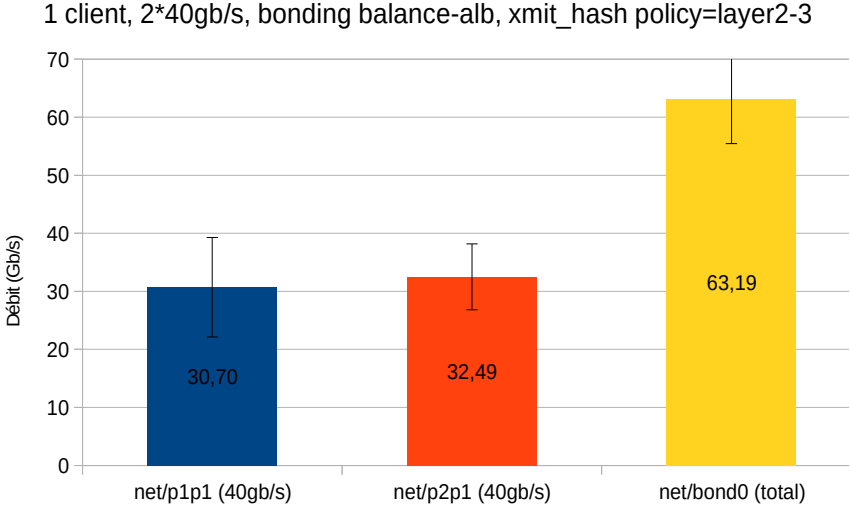

1 client, 2*40gb/s, bonding balance-alb, xmit_hash policy=layer3-4

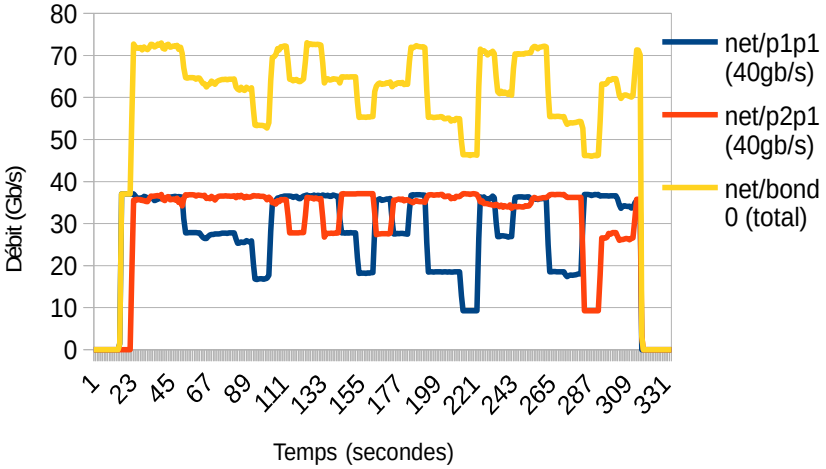

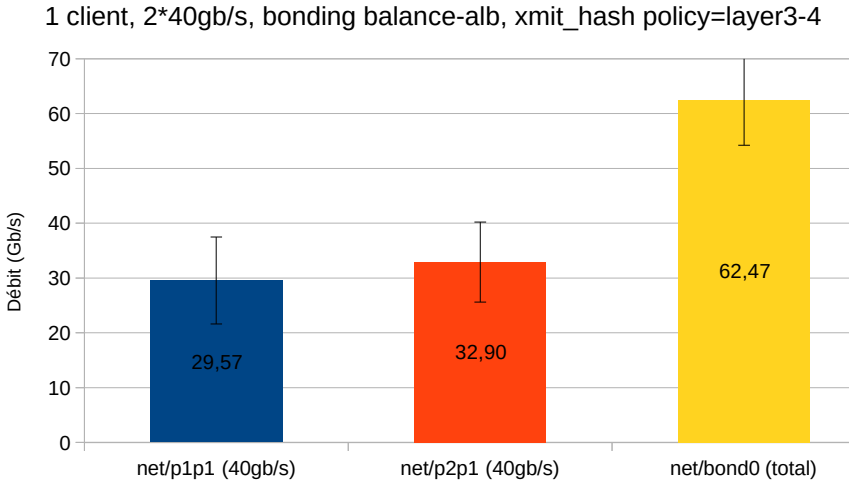

2ème test (suite)

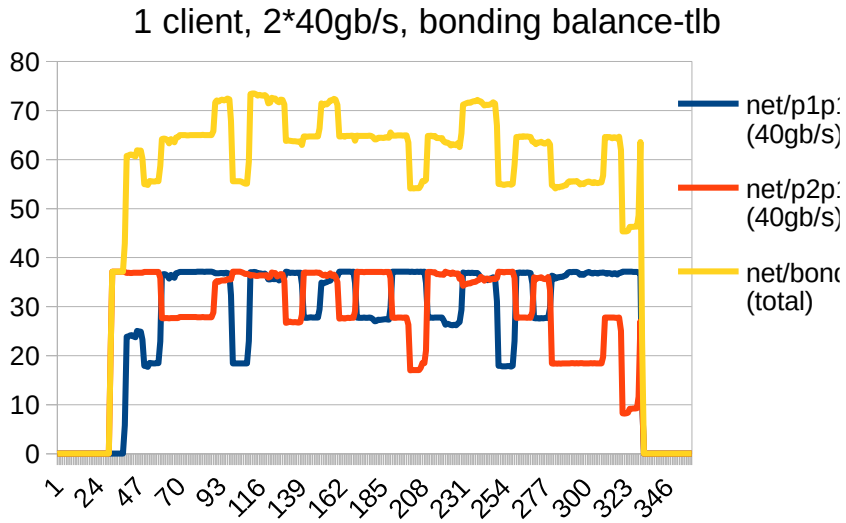

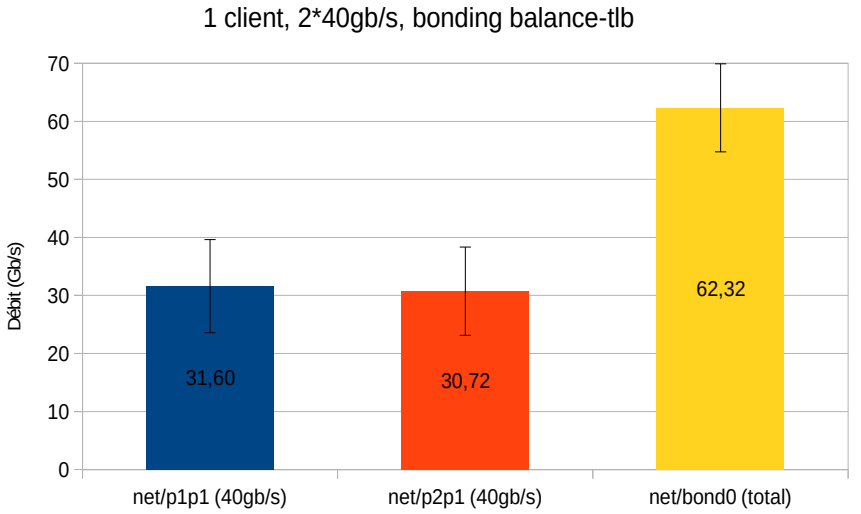

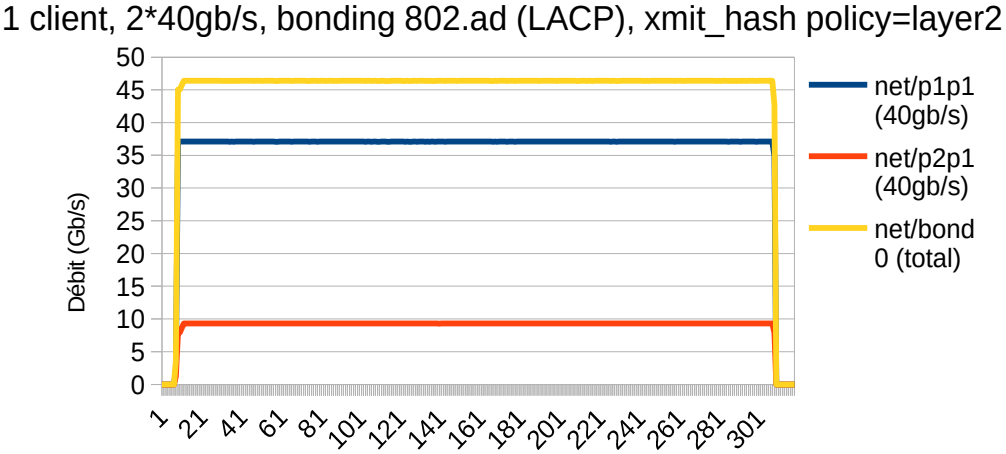

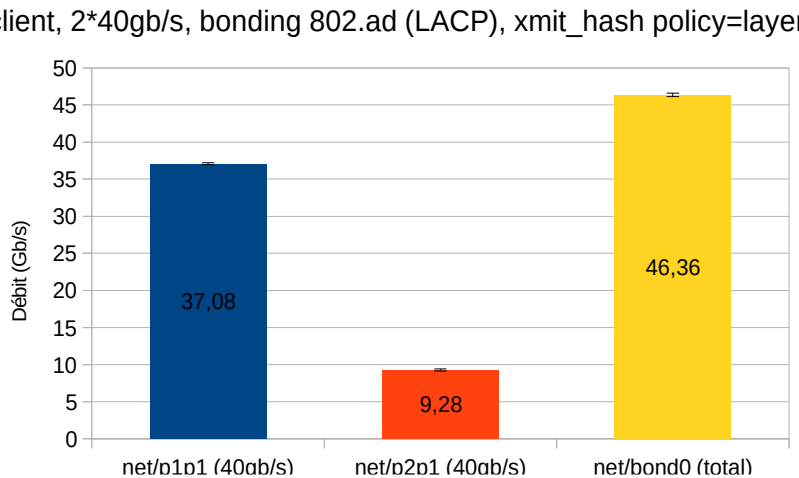

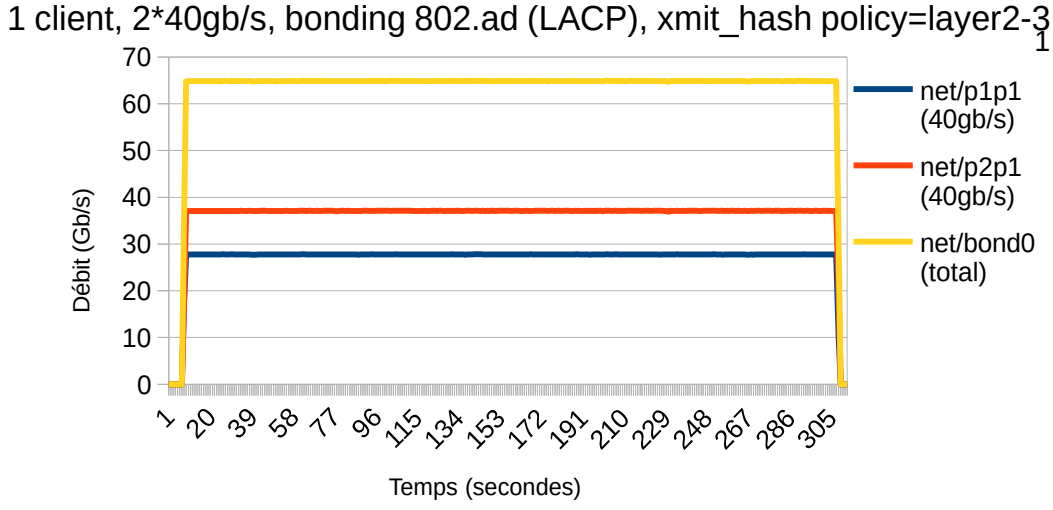

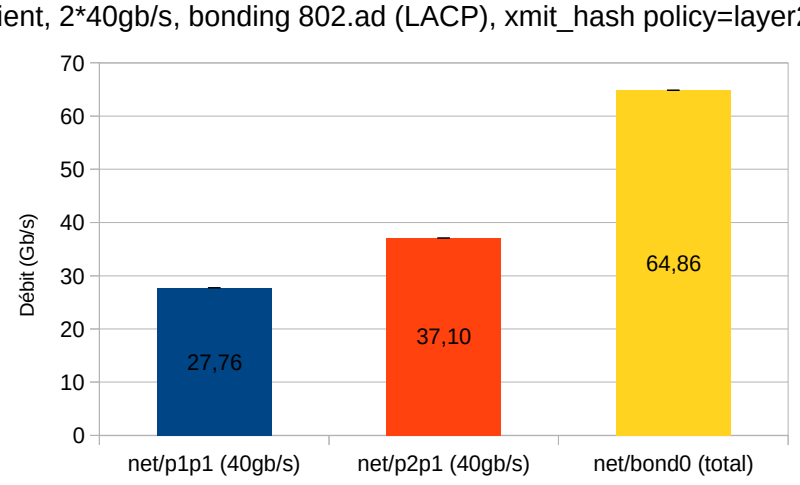

3ème test

Configuration bonding : mode=balance-alb xmit_hash_policy layer2+3

Débit TCP sortant (configuration 2*40Gb/s)

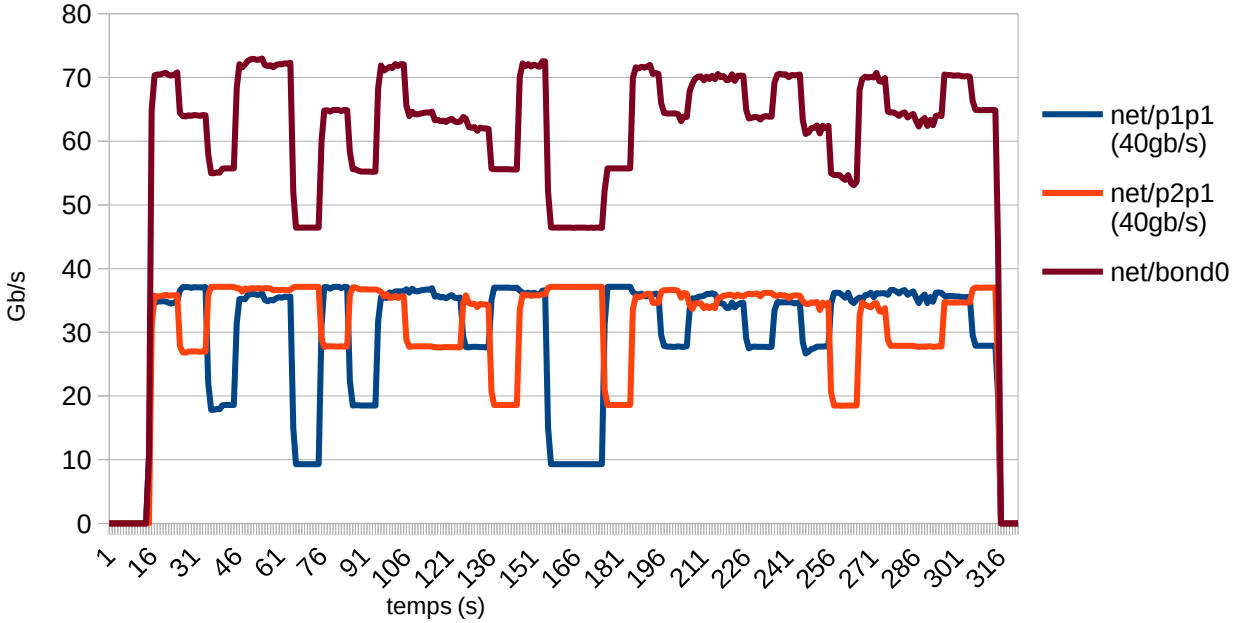

Débit TCP sortant (Configuration 2*40Gb/s)

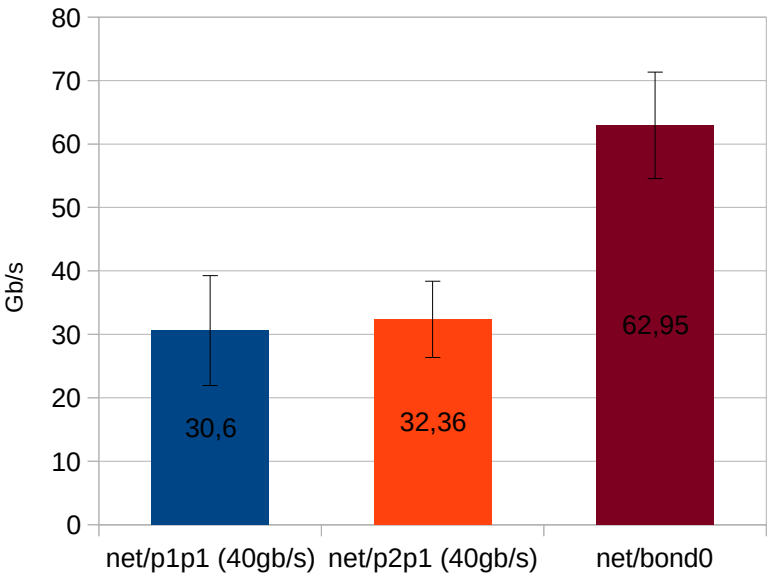

Débit TCP sortant (configuration 2*40gb/s + 2*10gb/s)

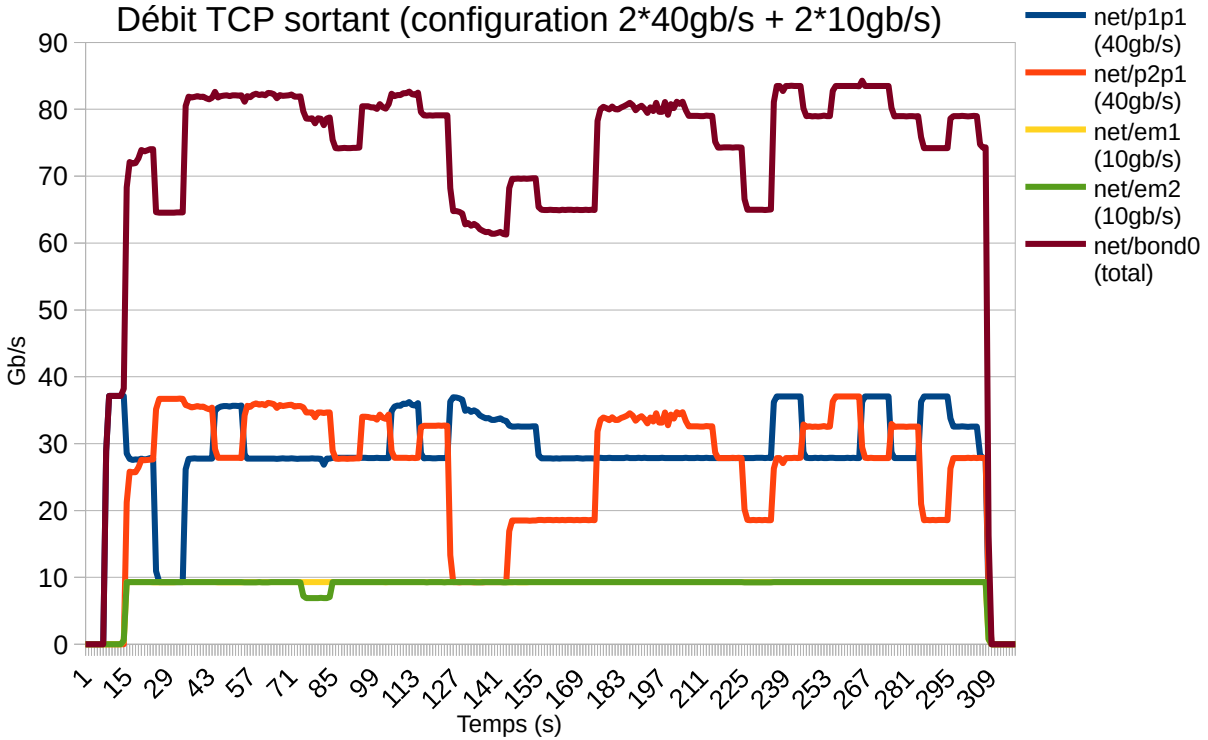

Débit TCP sortant (configuration 2*40gb/s + 2*10gb/s)

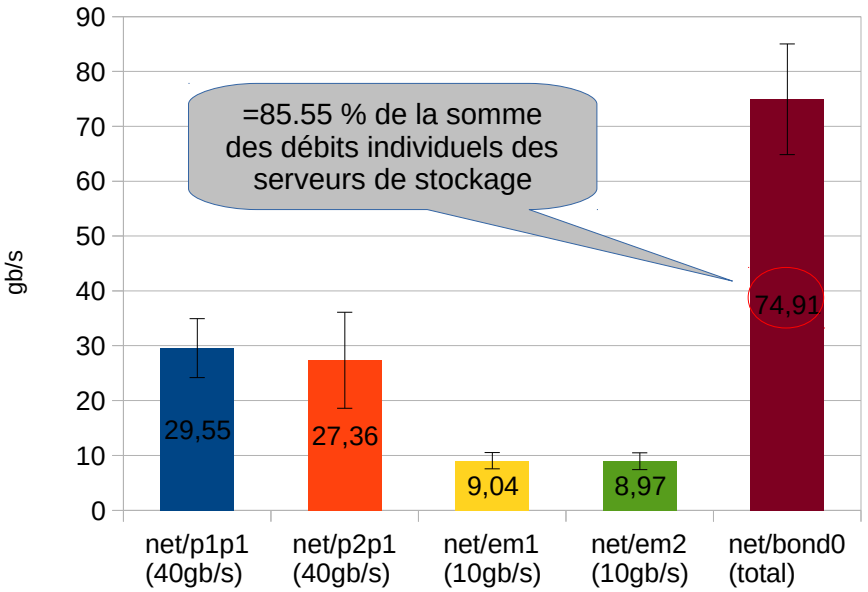

Benchmarks...

- En matière de benckmark, on trouve :
  - Pléthore d'outils (fio, iozone...),
  - Pléthore de tests (Read, write, sequential, random, mixed, block size, file size...)
  - Pléthore de résultats
- Mais : sur certains systèmes de fichiers distribués orientés « performance », les tests sont souvent réalisés dans un contexte HPC :
  - Tests en fonction du nombre de serveurs de données
  - Tests en fonction du nombre de clients (> 1)

Exemple de benchmark (sur le nombre de serveurs)

Shared file access (1)

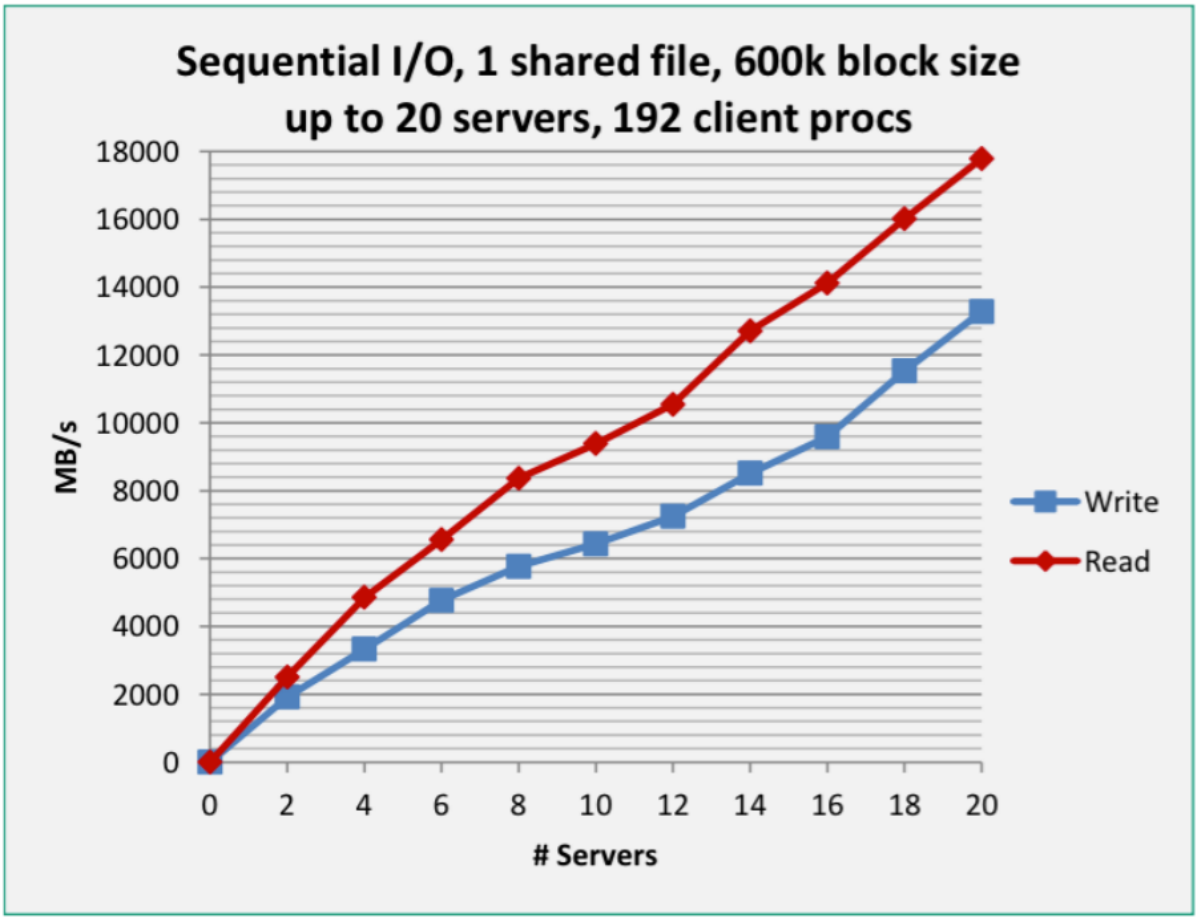

Slide by Christian Mohrbacher

Fraunhofer ITWM

Source : https://indico.cern.ch/event/346931/contributions/817830/attachments/684674/940478/beegfs-at-desy.pdf

Exemple de benchmark (sur le nombre de clients)

Streaming Throughput (3)

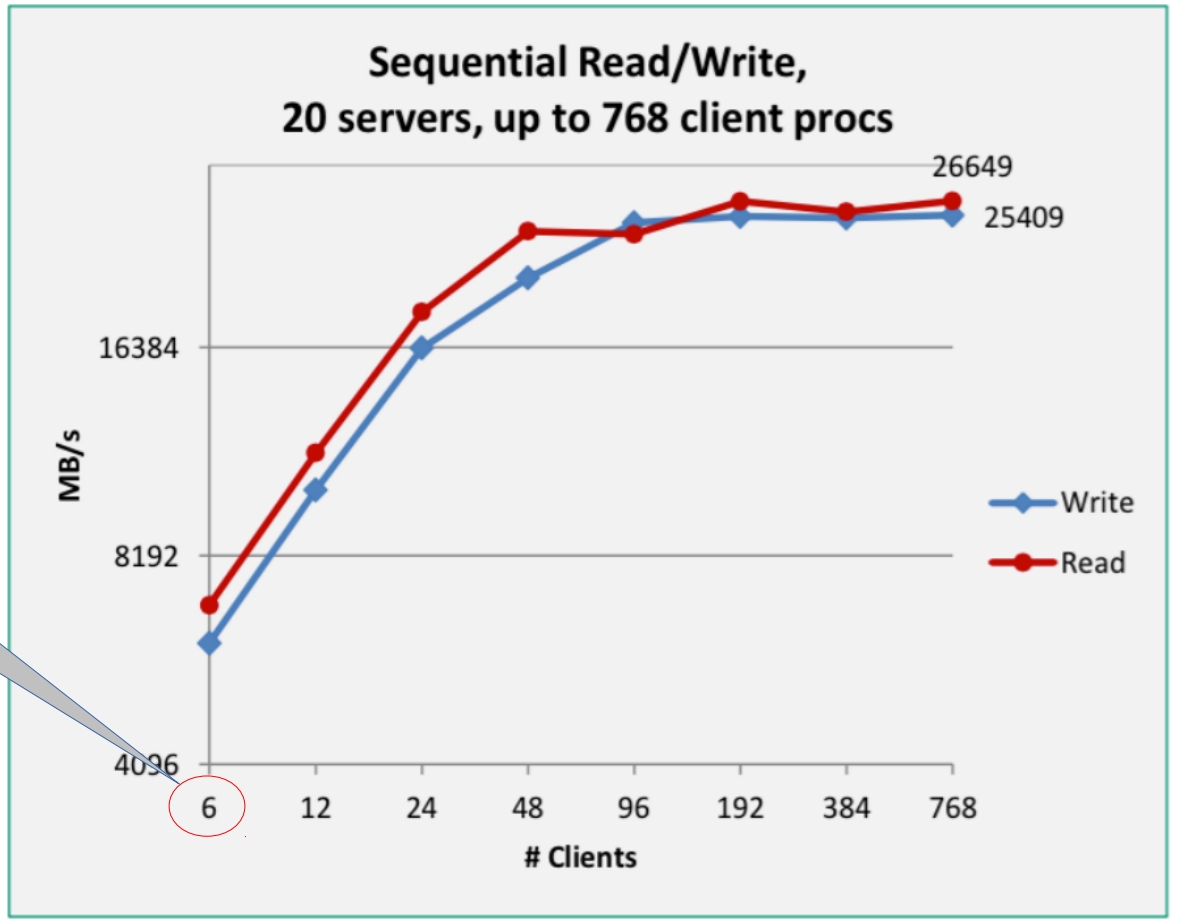

Et pour 2 ?

Slide by Christian Mohrbacher

Fraunhofer ITWM

Source : https://indico.cern.ch/event/346931/contributions/817830/attachments/684674/940478/beegfs-at-desy.pdf

Benchmarks...

Validation

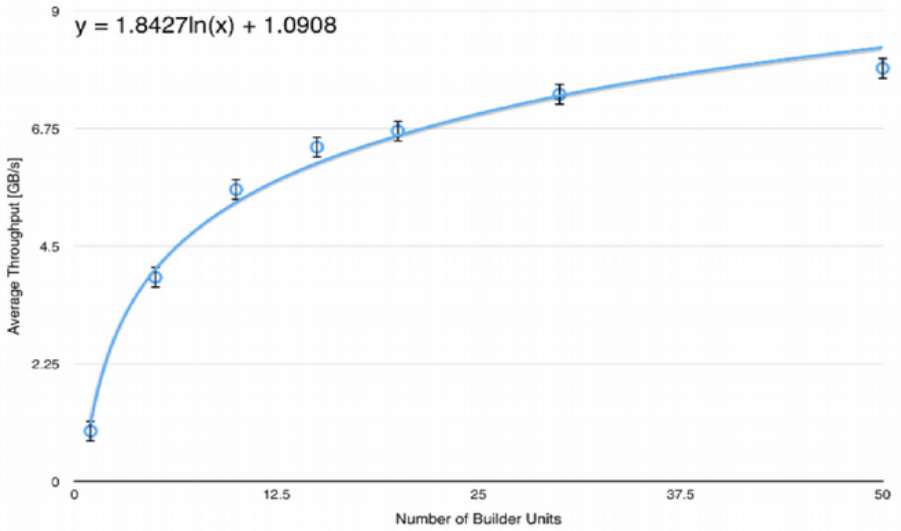

LFS bandwidth benchmarking

Emulation tests using the production computing cluster

- tests performed using different fractions of the available computing farm
- obvious non–linear behaviour with the number of BUs
- transfer system (read operations) were not considered during the tests
- saturation is expected around 8.5GB/s

Test de la chaine complète

- Benckmarks intégrés aux systèmes de fichiers distribués, exemple :

```
for size in 100M 1G 10G 20G 100G
do
  for threads in 1 6 8 10
  do
    for profile in write read
    do
      beegfs-ctl --storagebench --alltargets \
                 --cleanup
      beegfs-ctl --storagebench --alltargets \
                 --${profile} --blocksize=1M \
                 --size=${size} \
                 --threads=${threads} \
                 --verbose --wait
    done
  done
done
```

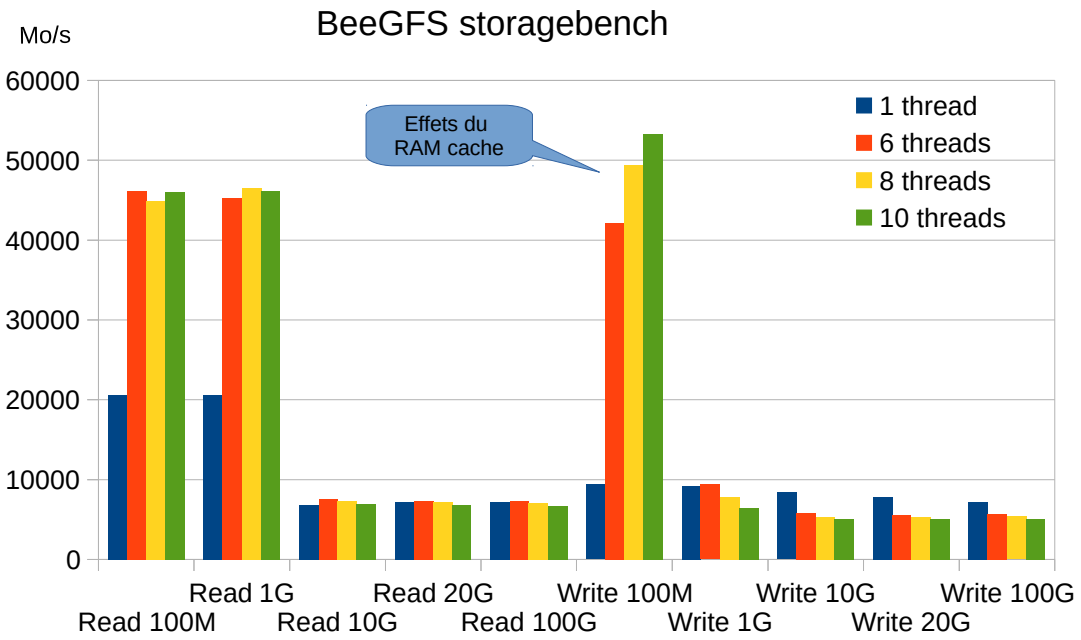

- Mais spécifique à chaque système de stockage → je ne les utilise pas
- Utilisation d'outils standards :
  - fio (read, write, readwrite, randread, rendwrite, randrw...), avec variation sur la taille et nb processus concurents
  - iozone (write, read, random-read/write, random_mix...) avec variation sur la taille et nb processus concurents
  - dd (sync, async, direct…)

3. Test des éléments de stockage

- Configuration du client : 1 seul client avec 2 * 40Gb/s + 2 * 10Gb/s
- Configuration du stockage : 9 éléments de stockage
  - 1 carte ethernet 10Gb/s Intel X520
  - 1 Raid 6 sur 12 disques de 2TB (10 Data + 2 Parity)
  - ~20 TB disponibles / serveur
  - Stripe size 1M
- Utilisation d'outils standards :
  - fio (read, write, readwrite, randread, rendwrite, randrw), avec variation sur la taille et nb processus concurents
  - iozone (write, read, random-read/write, random_mix) avec variation sur la taille et nb processus concurents
  - dd (sync, async, direct…)
- Le challenge est sur le débit d'écriture séquentielle sur les éléments de stockage
  - test dd (écriture séquentielle avec et sans buffer d'E/S) :

```
# dd if=/dev/zero of=test10G.dd bs=1M count=10000 oflag=sync
10485760000 bytes (10 GB) copied, 22,6967 s, 462 MB/s

# dd if=/dev/zero of=test10G.dd bs=1M count=10000 oflag=direct
10485760000 bytes (10 GB) copied, 9,91637 s, 1,1 GB/s
```

  - Test fio (écriture random) :

```
# fio --name=randwrite --ioengine=libaio --iodepth=1 --rw=randwrite --bs=4k
--direct=0 --size=512M --numjobs=8 –runtime=240 --group_reporting

bw=508339KB/s
```

À se rappeler pour la suite : 462 MB/s est le débit en écriture séquentielle qu'un serveur de ce type peut absorber

Systèmes de stockage testés

Rappel :

	Lustre	BeeGFS	GlusterFS	GPFS	MooseFS	XtreemFS	XRootD	EOS
Versions	v2.7.0-3	v2015.03.r10	3.7.8-4	v4.2.0-1	2.0.88-1	1.5.1	4.3.0-1	Citrine 4.0.12
POSIX	Oui	Oui	Oui	Oui	Oui	Oui	via FUSE	via FUSE
Open Source	Oui					Oui	Oui	Oui
MDS nécessaire	Oui				ata + er		Oui	Oui
Support RDMA / Infiniband	Oui	Oui	Oui	Oui	Non	Non	Non	Non
Striping	Oui	Oui	Oui	Oui	Non	Oui	Non	Non
Failover	M + D (1)	DR (1)	M + D (1)	M + D (1)	M + DR (1)	M + DR (1)	Non	M + D (1)
Quota	Oui	Oui	Oui	Oui	Oui	Non	Non	Oui
Snapshots	Non	Non	Oui	Oui	Oui	Oui	Non	Non
Outils de déplacement des données	Oui	Oui	Oui	Oui	Non	Oui	Non	Oui

Chaque fichier est divisé en « chunks » distribués vers tous les serveurs de stockage.

C'est toujours à la charge de la CPU du client (DAQ back-end)

(1) : M=Metadata, D=Data, M+D=Metadata+Data, DR=Data Replication

Tests communs à l'ensemble des systèmes

- Écriture de données en fonction de différents paramètres :
  - **Taille des fichiers à écrire** (pour déterminer quelle est la taille optimale, détermination du coût du traitement des meta-données) :
    => **choix = 100Mo**, **1Go**, **10Go** et **20Go**
  - **Nombre de flux** / nombre de threads / nombre de processus en parallèle écrivant les données :
    => choix = 1, 6, 8
    1 = pour connaître le débit d'un flux individuel
    6 = nombre de flux reçus par un « Event Builder »
    8 = nombre de coeurs hyper-threadés de mon client
  - Nombre de **chunks** (nombre de blocs de données pour chaque fichier écrits sur plusieurs éléments de stockage :
    => pour connaître l'effet de la répartition des données sur plusieurs serveurs de stockage
    => choix = 1, 2, 4, 8
  - **Nombre de targets** : Nombre de serveurs de données utilisés pour l'enregistrement des données

=> 4*3*4 = 48 combinaisons à tester

=> 48 combinaisons * 8 FS = 384 tests

Différences dans les tests

- Différences dans les tests entre les systèmes POSIX et Non POSIX : Dans les graphiques suivants :
  - Systèmes de fichiers POSIX : iozone

```
iozone -e -+u -r 1m -s ${size} -i 0 -t ${threads}
```

  - XrootD et EOS : xrdcp (client XrootD)
    - Méthode :
      - Création d'un RAMDISK de 21Go (et montage sur `/test-ramdisk`)
      - Création du fichier de la taille souhaitée dans le RAMDISK
    - Copie du fichier avec xrdcp :

```
xrdcp /test-ramdisk/fichier root://${server}/${repertoire}/f_${i}_t_${thread}
```

    - Tests xrdcp :
      - Copie de 300 fois le même fichier de 100Mo vers le système de stockage
      - Copie de 300 fois le même fichier de 1Go vers le système de stockage
      - Copie de 30 fois le même fichier de 10Go vers le système de stockage
      - Copie de 15 fois le même fichier de 20Go vers le système de stockage

Différences dans les configurations

- Ça se complique :
  - Les systèmes de fichiers locaux sur les éléments de stockage ne sont pas toujours les mêmes (XFS, EXT4, formats propriétaire...)
  - Les paramètres de tuning des systèmes de stockage sont nombreux
  - Le fonctionnement n'est pas toujours comparable d'un produit à l'autre :
    - Lustre permet de créer des fichiers stripés sur 1 à n OSTs (parmi 9 serveurs), la taille du stripe est ajustable (ici 1MB)
    - BeeGFS permet de créer des fichiers stripés sur 1 à n OSTs (parmi 9 serveurs), la taille du stripe est ajustable (ici 1MB)
    - GlusterFS permet de créer des volumes stripés sur n targets (parmi 9 bricks), des volumes distribués (/9 bricks), ou des volumes EC (8+1)
    - GPFS découpe les fichiers en stripes de la taille d'un block (1M), par défaut il stocke les stripes sur tous les NSD (ici 9 NSD). Dans les tests suivants, le nombre de « targets » GPFS corresponds au nombre de serveurs mis en production pour réaliser le test (contrairement à Luste, BeeGFS, Gluster et XtreemFS où c'est le nombre de « chunks » qui sont paramétrables).
    - MooseFS stripe les fichiers en chuncks de 64MB
    - XtreemFS permet de créer des fichiers stripés sur 1 à n OSDs (parmi 9 serveurs), la taille du stripe est ajustable (ici 1MB)
    - XrootD ne stripe pas les fichiers
    - EOS ne stripe pas les fichiers

- Choix de paramètres communs :
  - Block size = 1M
  - Pas de réplication (ni donnée, ni meta-donnée, ni serveur de méta-donnée), pas de quota, pas de snapshot

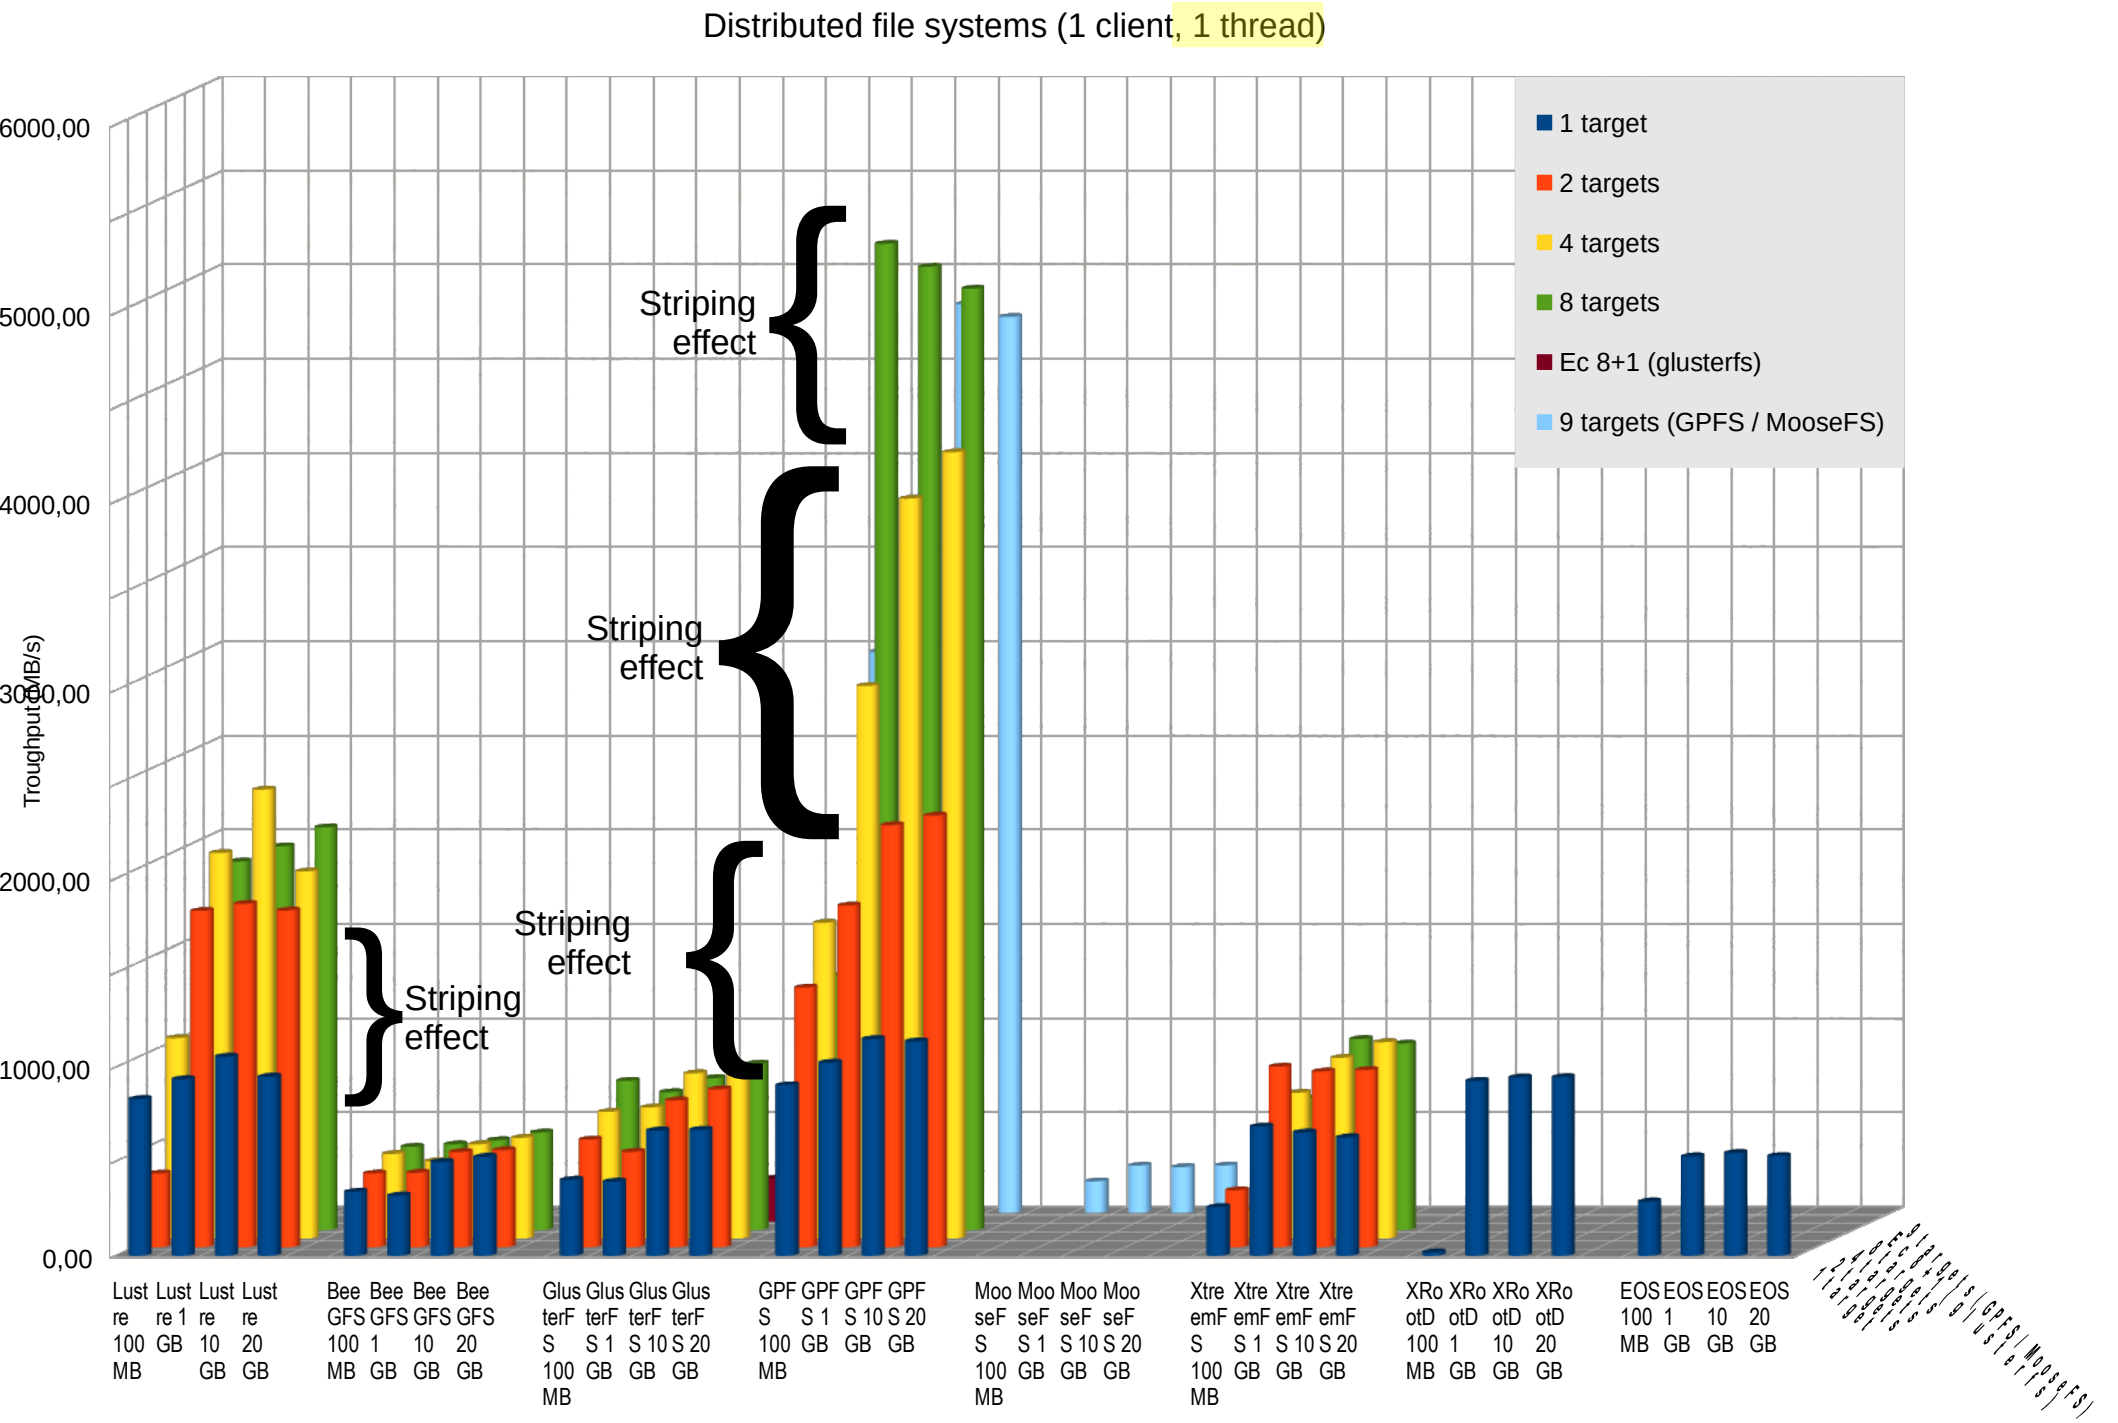
Distributed file systems (1 client, 1 thread)
Troughput (MB/s)
6000,00
5000,00
4000,00
3000,00
2000,00
1000,00
0,00
1 target
2 targets
4 targets
8 targets
Ec 8+1 (glusterfs)
9 targets (GPFS / MooseFS)
Striping effect
Striping effect
Striping effect
Striping effect
Lustre 100 MB
Lustre 1 GB
Lustre 10 GB
Lustre 20 GB
BeeGFS 100 MB
BeeGFS 1 GB
BeeGFS 10 GB
BeeGFS 20 GB
GlusterFS 100 MB
GlusterFS 1 GB
GlusterFS 10 GB
GlusterFS 20 GB
GPFS 100 MB
GPFS 1 GB
GPFS 10 GB
GPFS 20 GB
MooseFS 100 MB
MooseFS 1 GB
MooseFS 10 GB
MooseFS 20 GB
XtreemFS 100 MB
XtreemFS 1 GB
XtreemFS 10 GB
XtreemFS 20 GB
XRootD 100 MB
XRootD 1 GB
XRootD 10 GB
XRootD 20 GB
EOS 100 MB
EOS 1 GB
EOS 10 GB
EOS 20 GB
1 target
2 targets
4 targets
8 targets
Ec 8+1 (glusterfs)
9 targets (GPFS / MooseFS)

→ Par rapport a seulement 1 thread : Parallelisation des écriture sur des serveurs différents

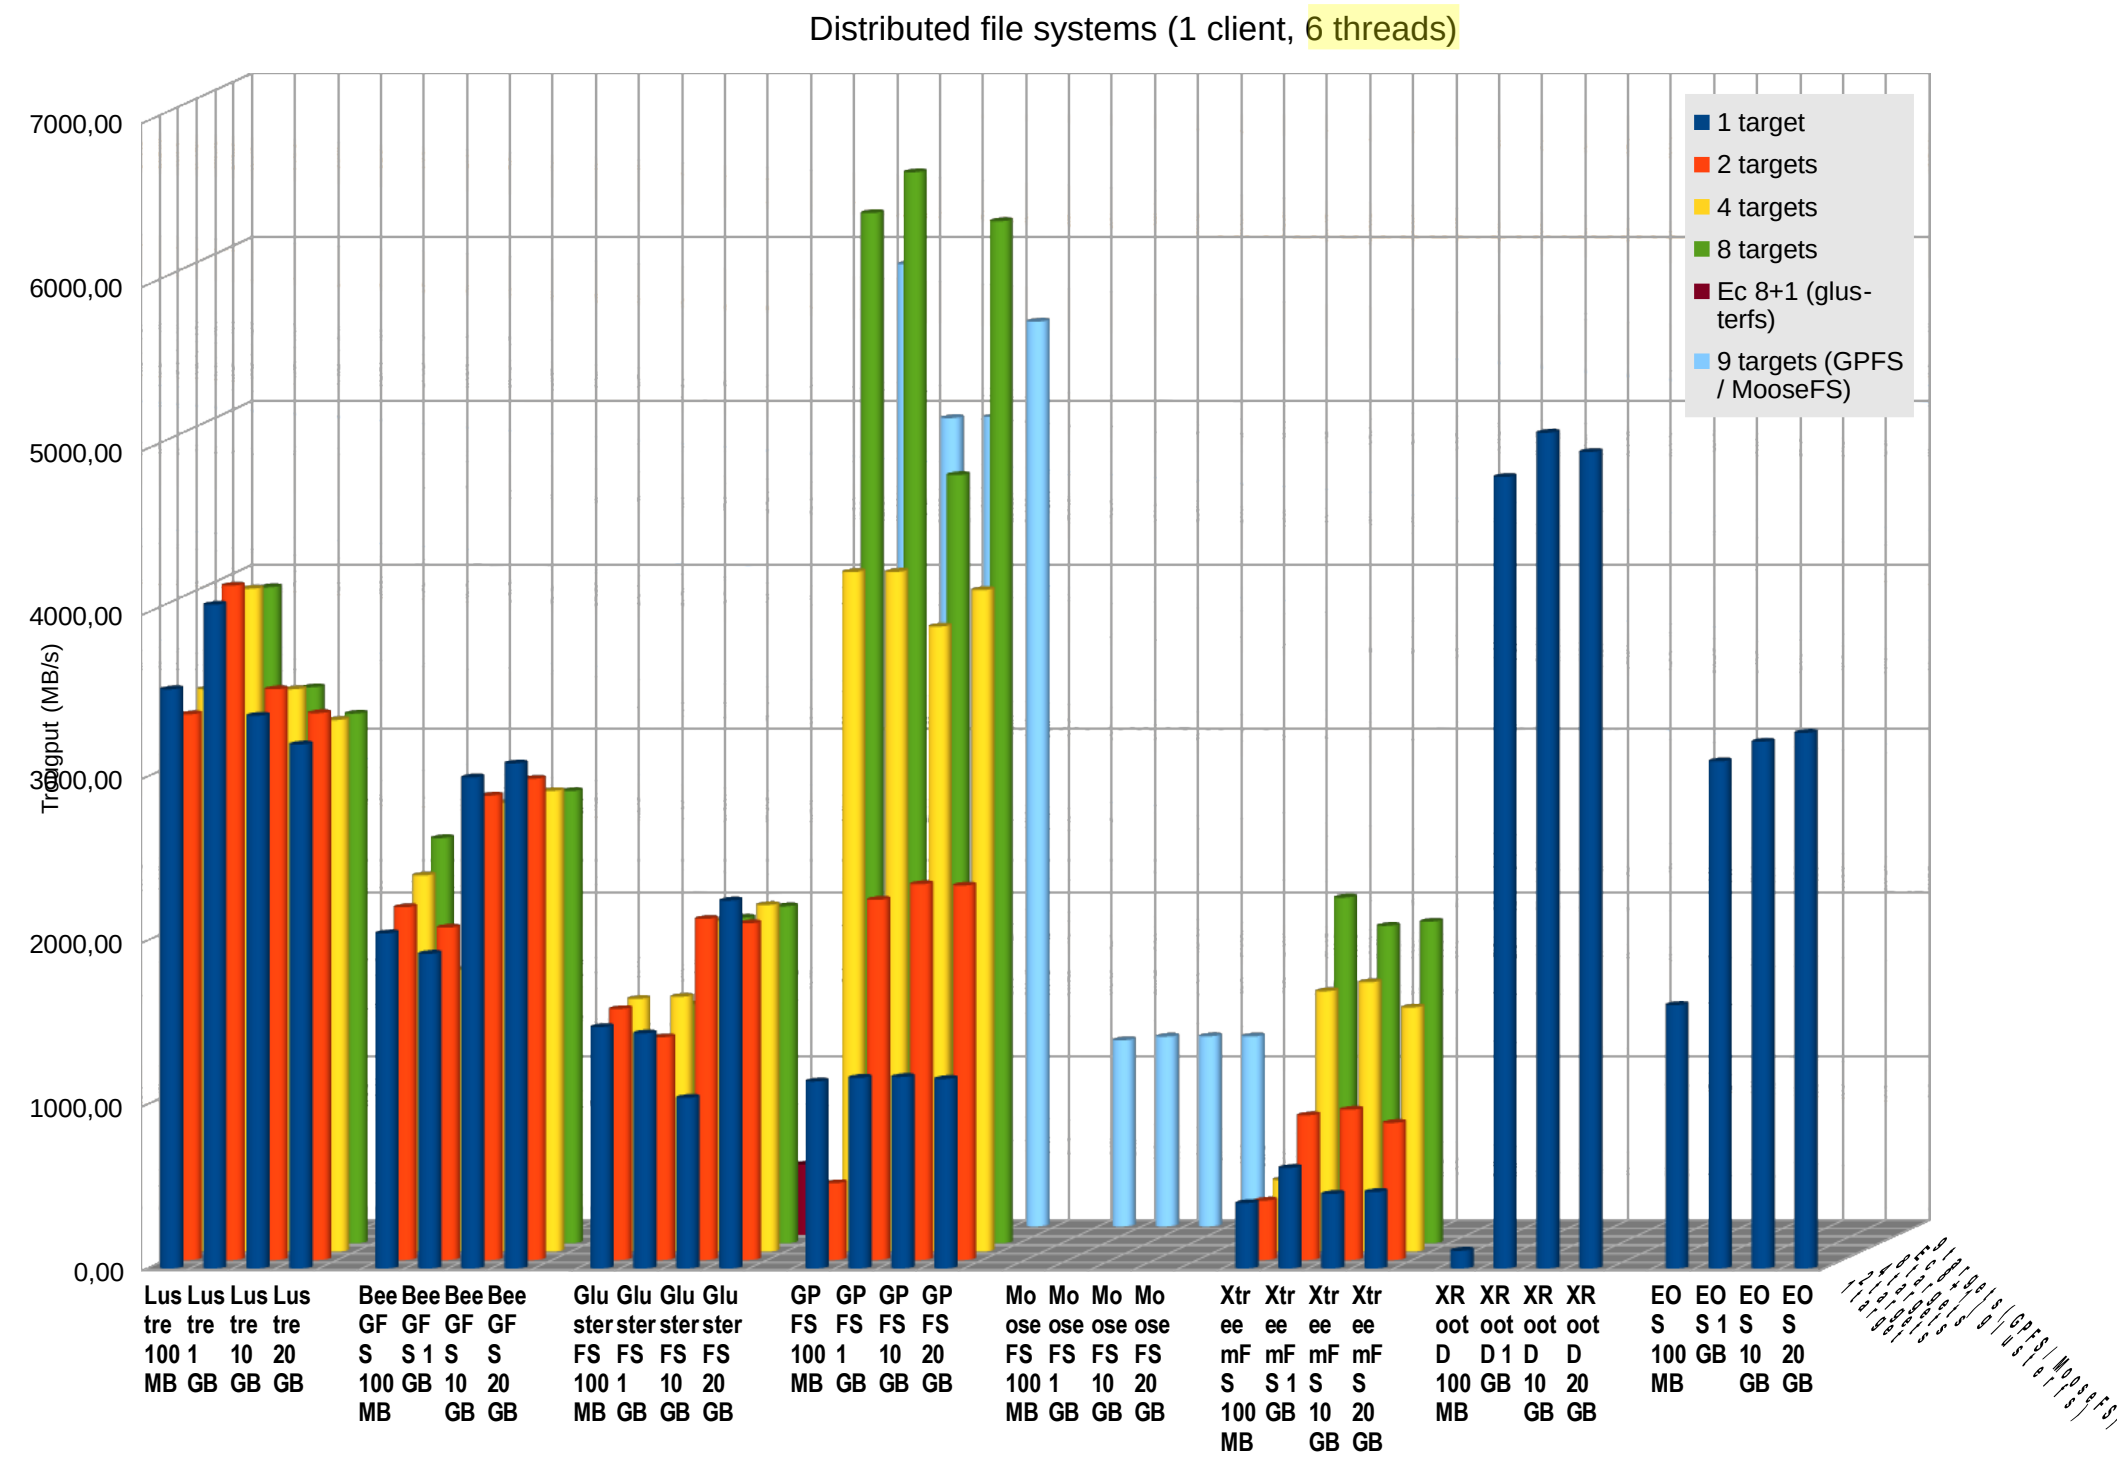

→ tous les coeurs du client sont utilisés

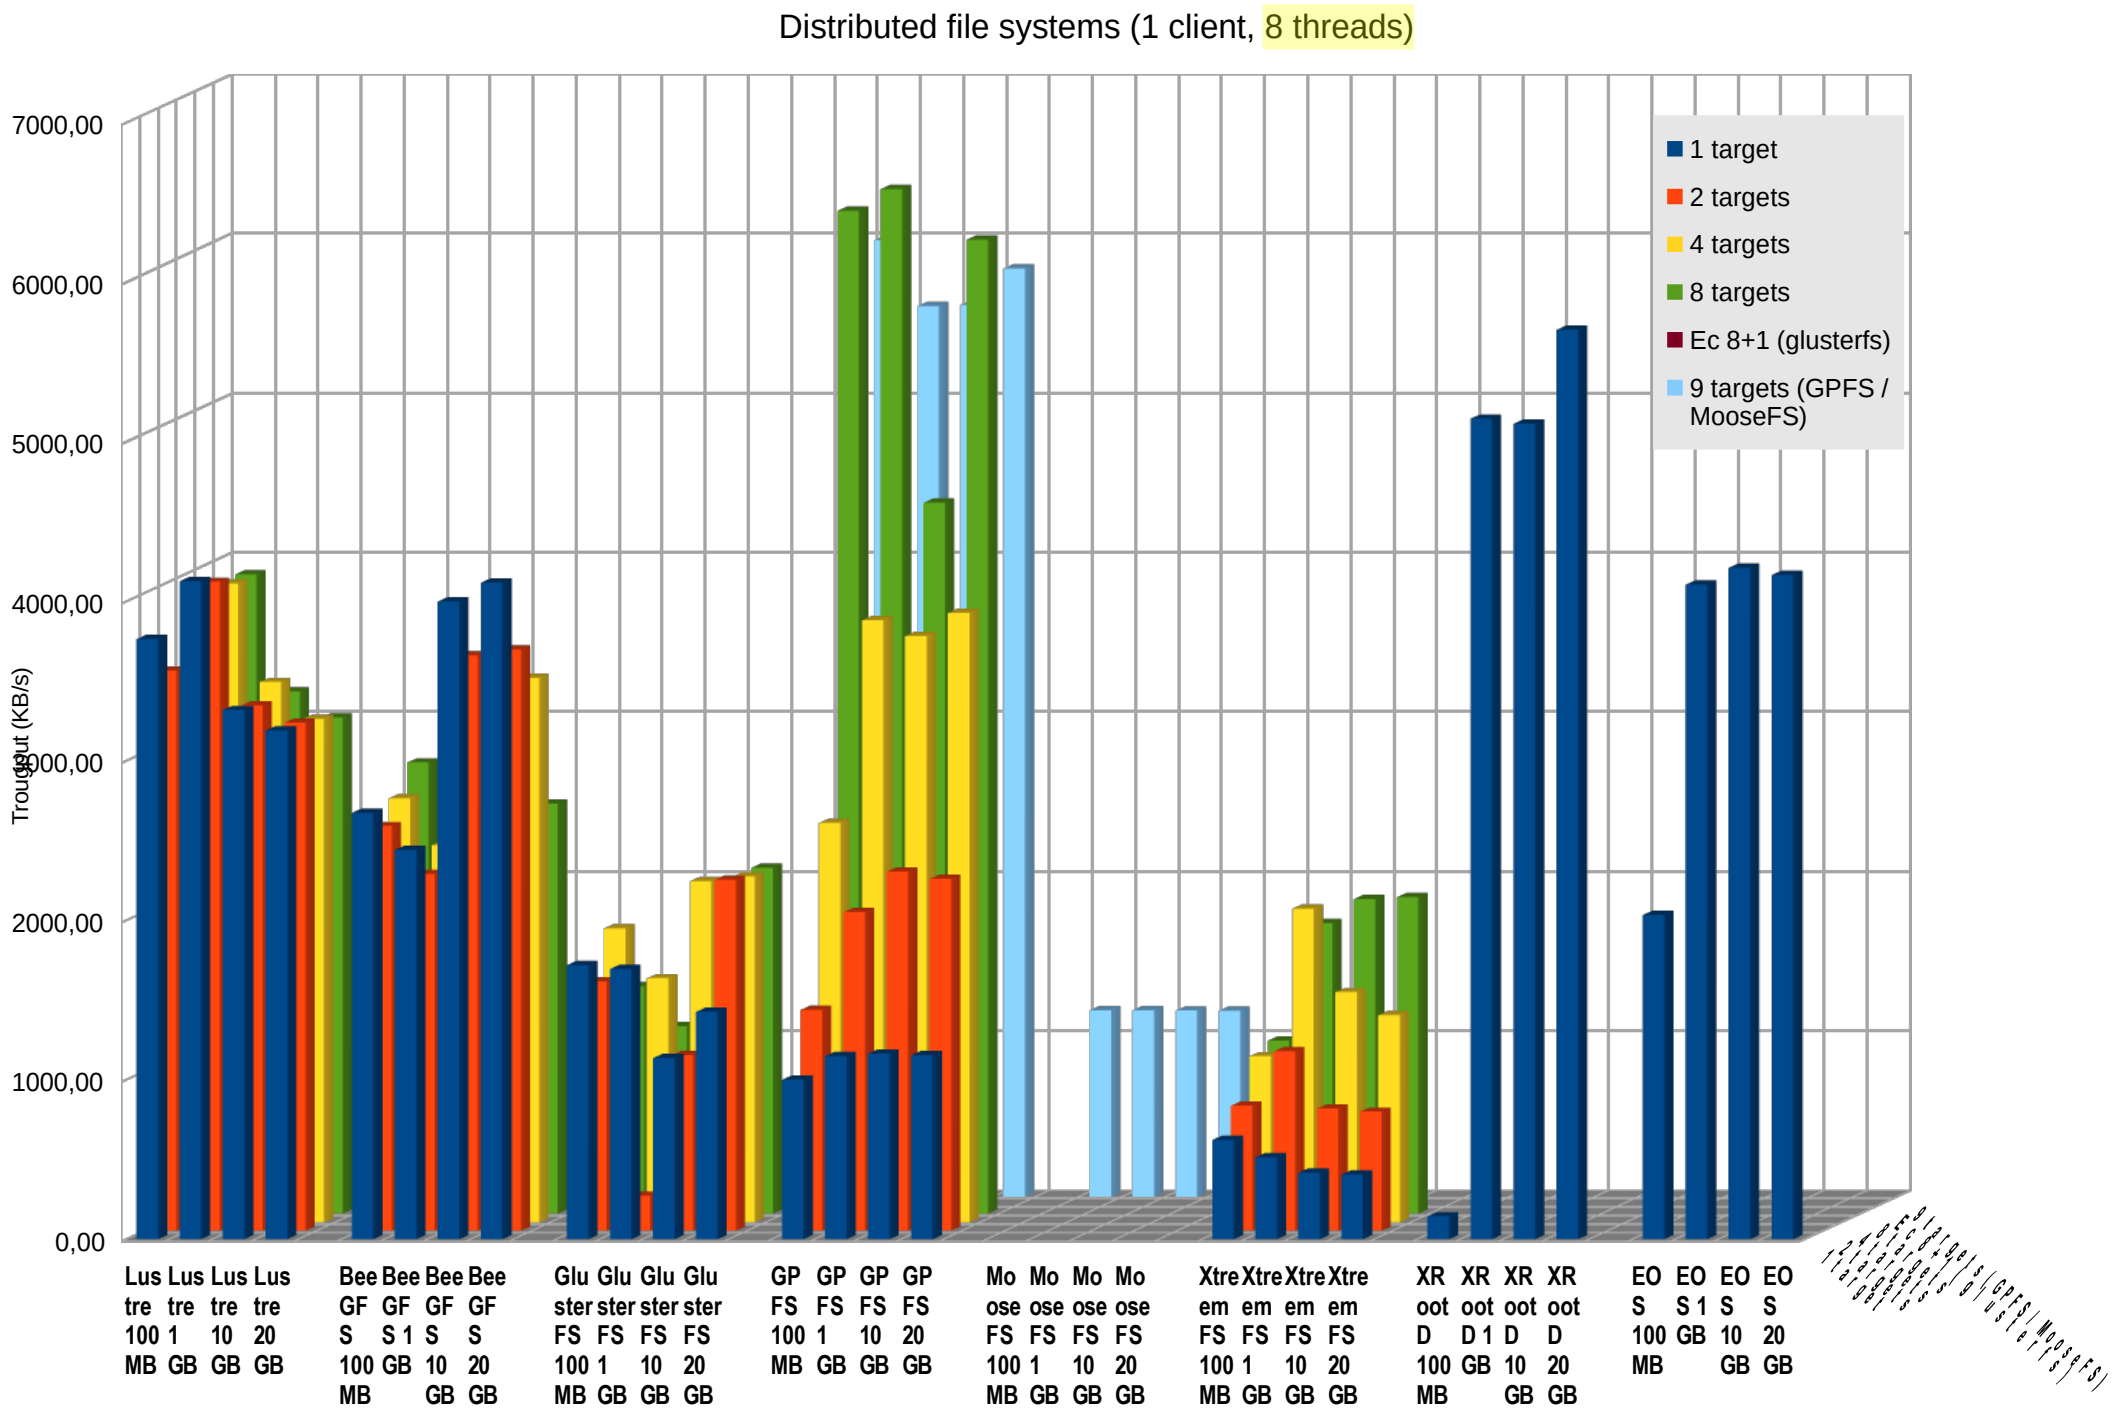

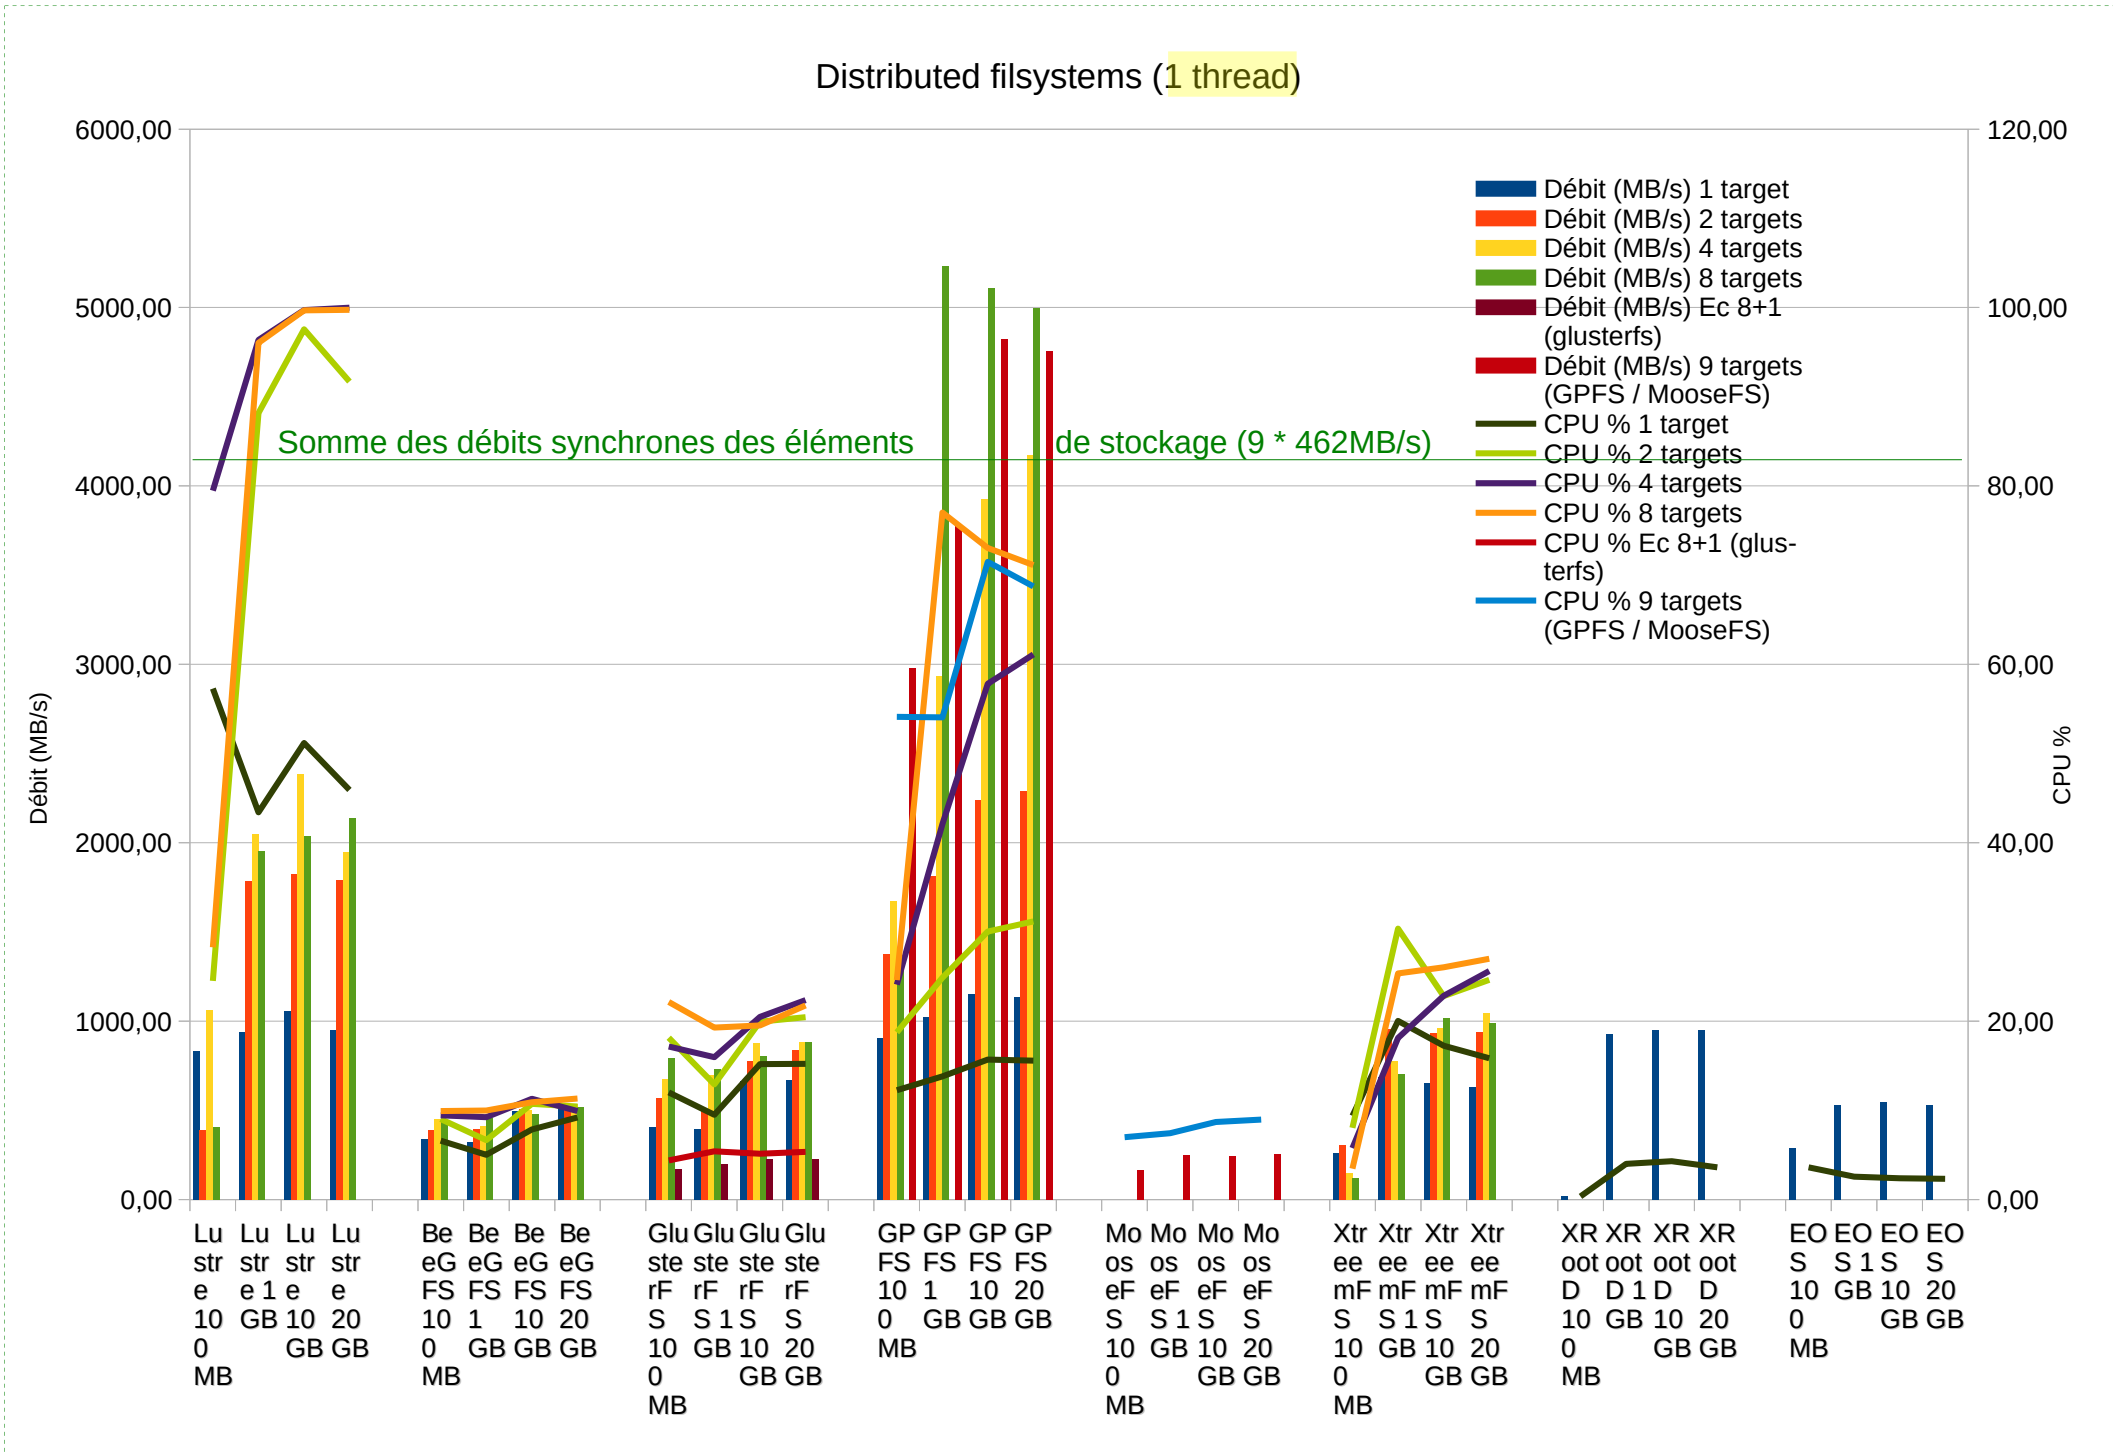
Distributed filsystems (1 thread)
Somme des débits synchrones des éléments de stockage (9 * 462MB/s)
Débit (MB/s)
CPU %
6000,00
5000,00
4000,00
3000,00
2000,00
1000,00
0,00
120,00
100,00
80,00
60,00
40,00
20,00
0,00
Débit (MB/s) 1 target
Débit (MB/s) 2 targets
Débit (MB/s) 4 targets
Débit (MB/s) 8 targets
Débit (MB/s) Ec 8+1 (glusterfs)
Débit (MB/s) 9 targets (GPFS / MooseFS)
CPU % 1 target
CPU % 2 targets
CPU % 4 targets
CPU % 8 targets
CPU % Ec 8+1 (glus-terfs)
CPU % 9 targets (GPFS / MooseFS)
Lustre 100 MB
Lustre 1 GB
Lustre 10 GB
Lustre 20 GB
BeeGFS 100 MB
BeeGFS 1 GB
BeeGFS 10 GB
BeeGFS 20 GB
GlusterFS 100 MB
GlusterFS 1 GB
GlusterFS 10 GB
GlusterFS 20 GB
GPFS 100 MB
GPFS 1 GB
GPFS 10 GB
GPFS 20 GB
MooseFS 100 MB
MooseFS 1 GB
MooseFS 10 GB
MooseFS 20 GB
XtreemFS 100 MB
XtreemFS 1 GB
XtreemFS 10 GB
XtreemFS 20 GB
XRootD 100 MB
XRootD 1 GB
XRootD 10 GB
XRootD 20 GB
EOS 100 MB
EOS 1 GB
EOS 10 GB
EOS 20 GB

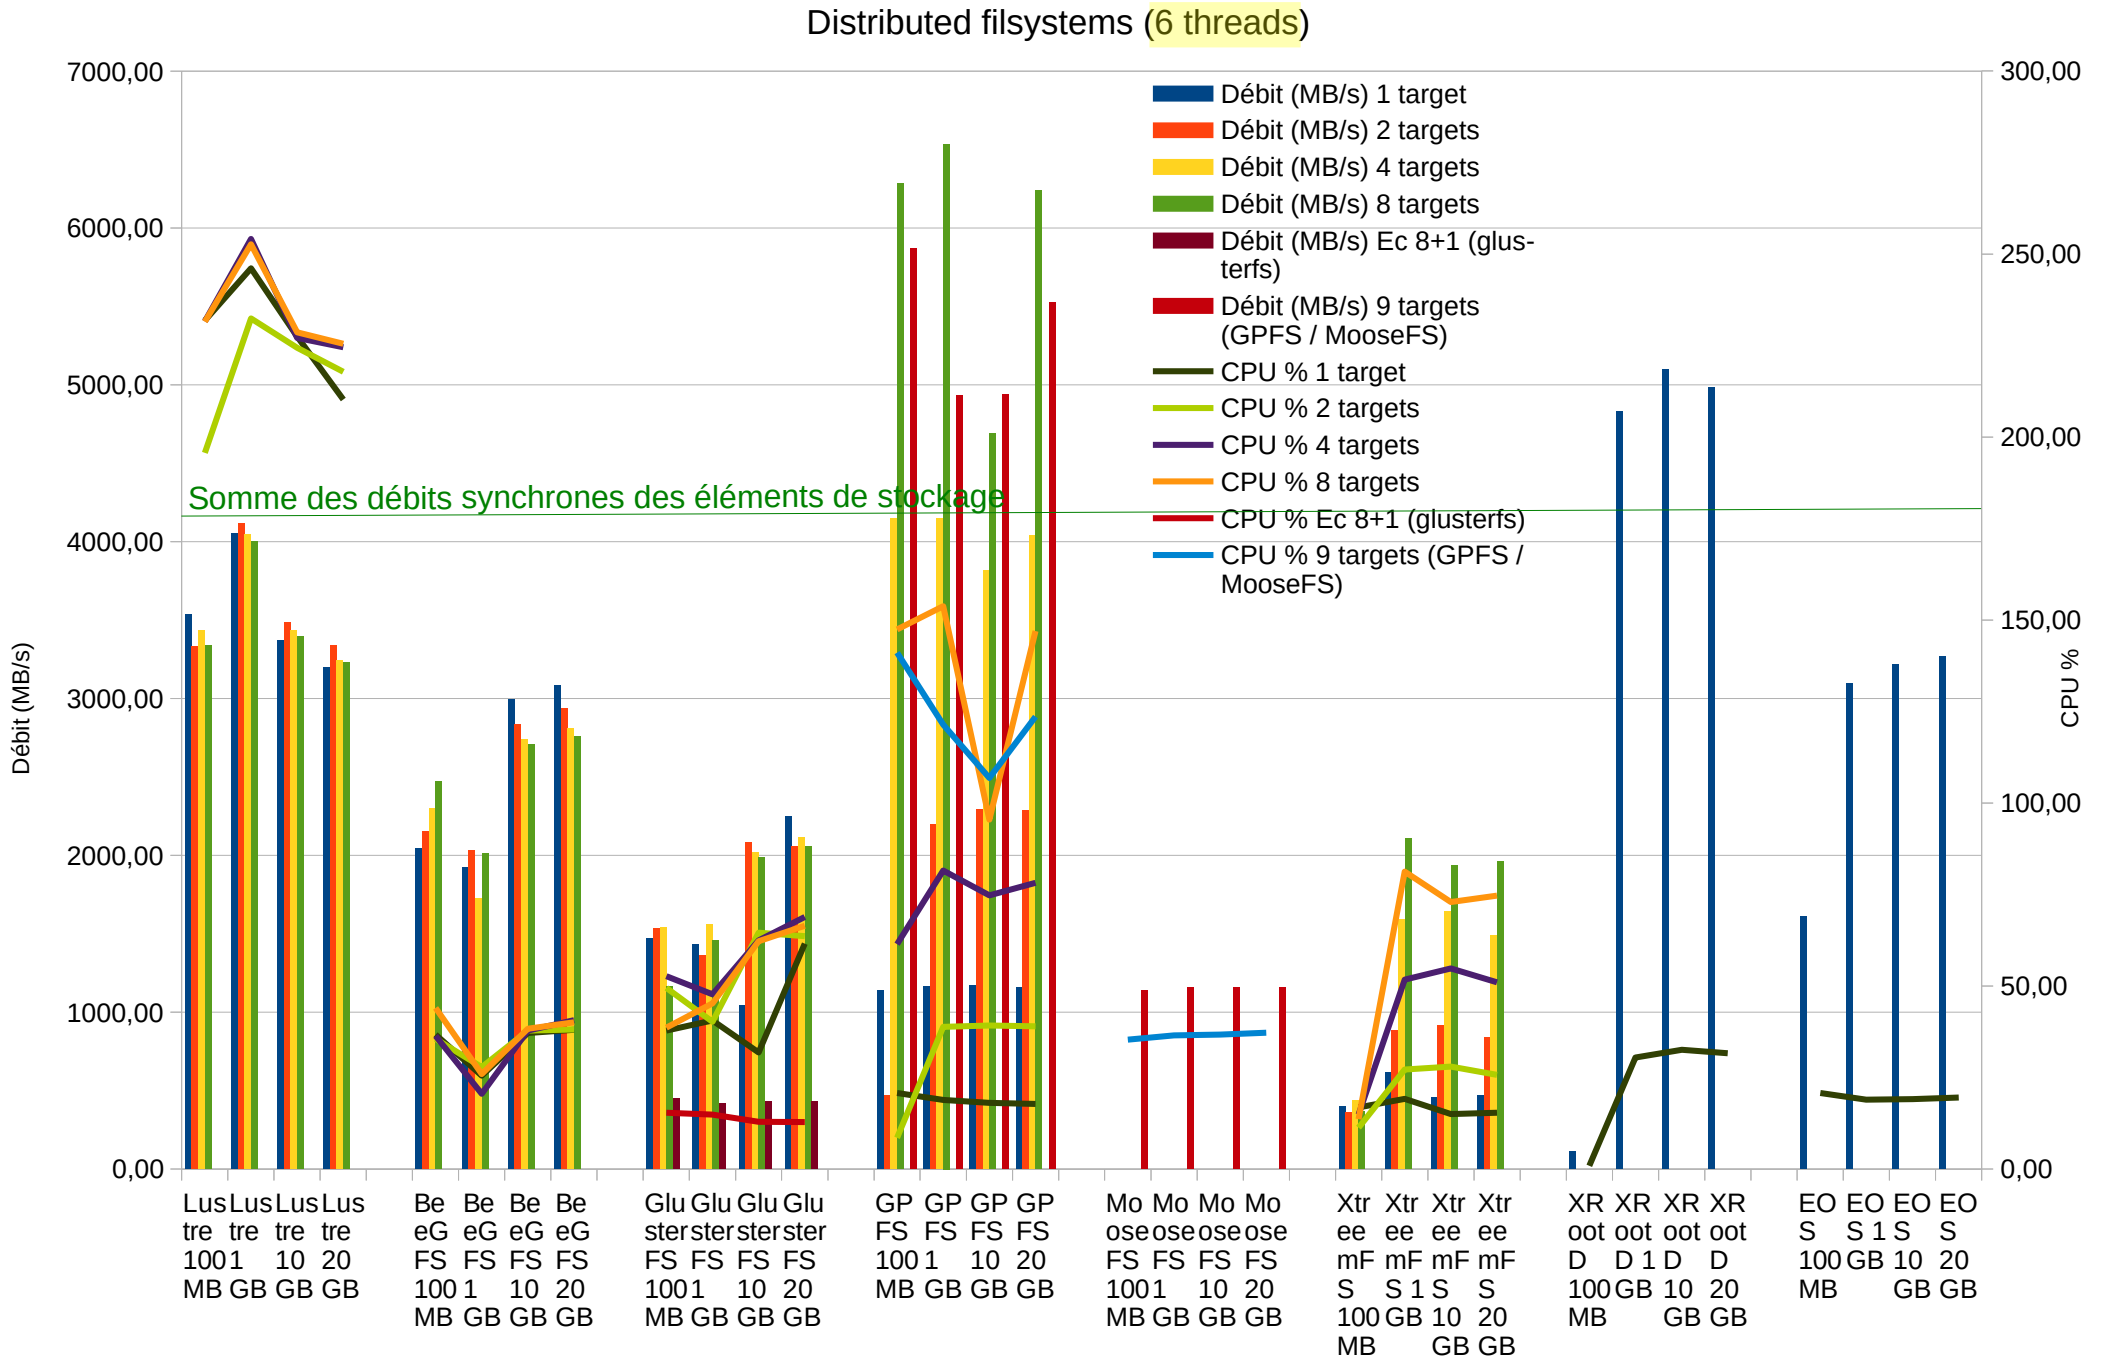
Distributed filsystems (6 threads)
Débit (MB/s)
CPU %
Somme des débits synchrones des éléments de stockage
Débit (MB/s) 1 target
Débit (MB/s) 2 targets
Débit (MB/s) 4 targets
Débit (MB/s) 8 targets
Débit (MB/s) Ec 8+1 (glus-terfs)
Débit (MB/s) 9 targets (GPFS / MooseFS)
CPU % 1 target
CPU % 2 targets
CPU % 4 targets
CPU % 8 targets
CPU % Ec 8+1 (glusterfs)
CPU % 9 targets (GPFS / MooseFS)
7000,00
6000,00
5000,00
4000,00
3000,00
2000,00
1000,00
0,00
300,00
250,00
200,00
150,00
100,00
50,00
0,00
Lustre 100 MB
Lustre 1 GB
Lustre 10 GB
Lustre 20 GB
BeeGFS 100 MB
BeeGFS 1 GB
BeeGFS 10 GB
BeeGFS 20 GB
Glusterfs 100 MB
Glusterfs 1 GB
Glusterfs 10 GB
Glusterfs 20 GB
GPFS 100 MB
GPFS 1 GB
GPFS 10 GB
GPFS 20 GB
MooseFS 100 MB
MooseFS 1 GB
MooseFS 10 GB
MooseFS 20 GB
XtreemFS 100 MB
XtreemFS 1 GB
XtreemFS 10 GB
XtreemFS 20 GB
XRootD 100 MB
XRootD 1 GB
XRootD 10 GB
XRootD 20 GB
EOS 100 MB
EOS 1 GB
EOS 10 GB
EOS 20 GB

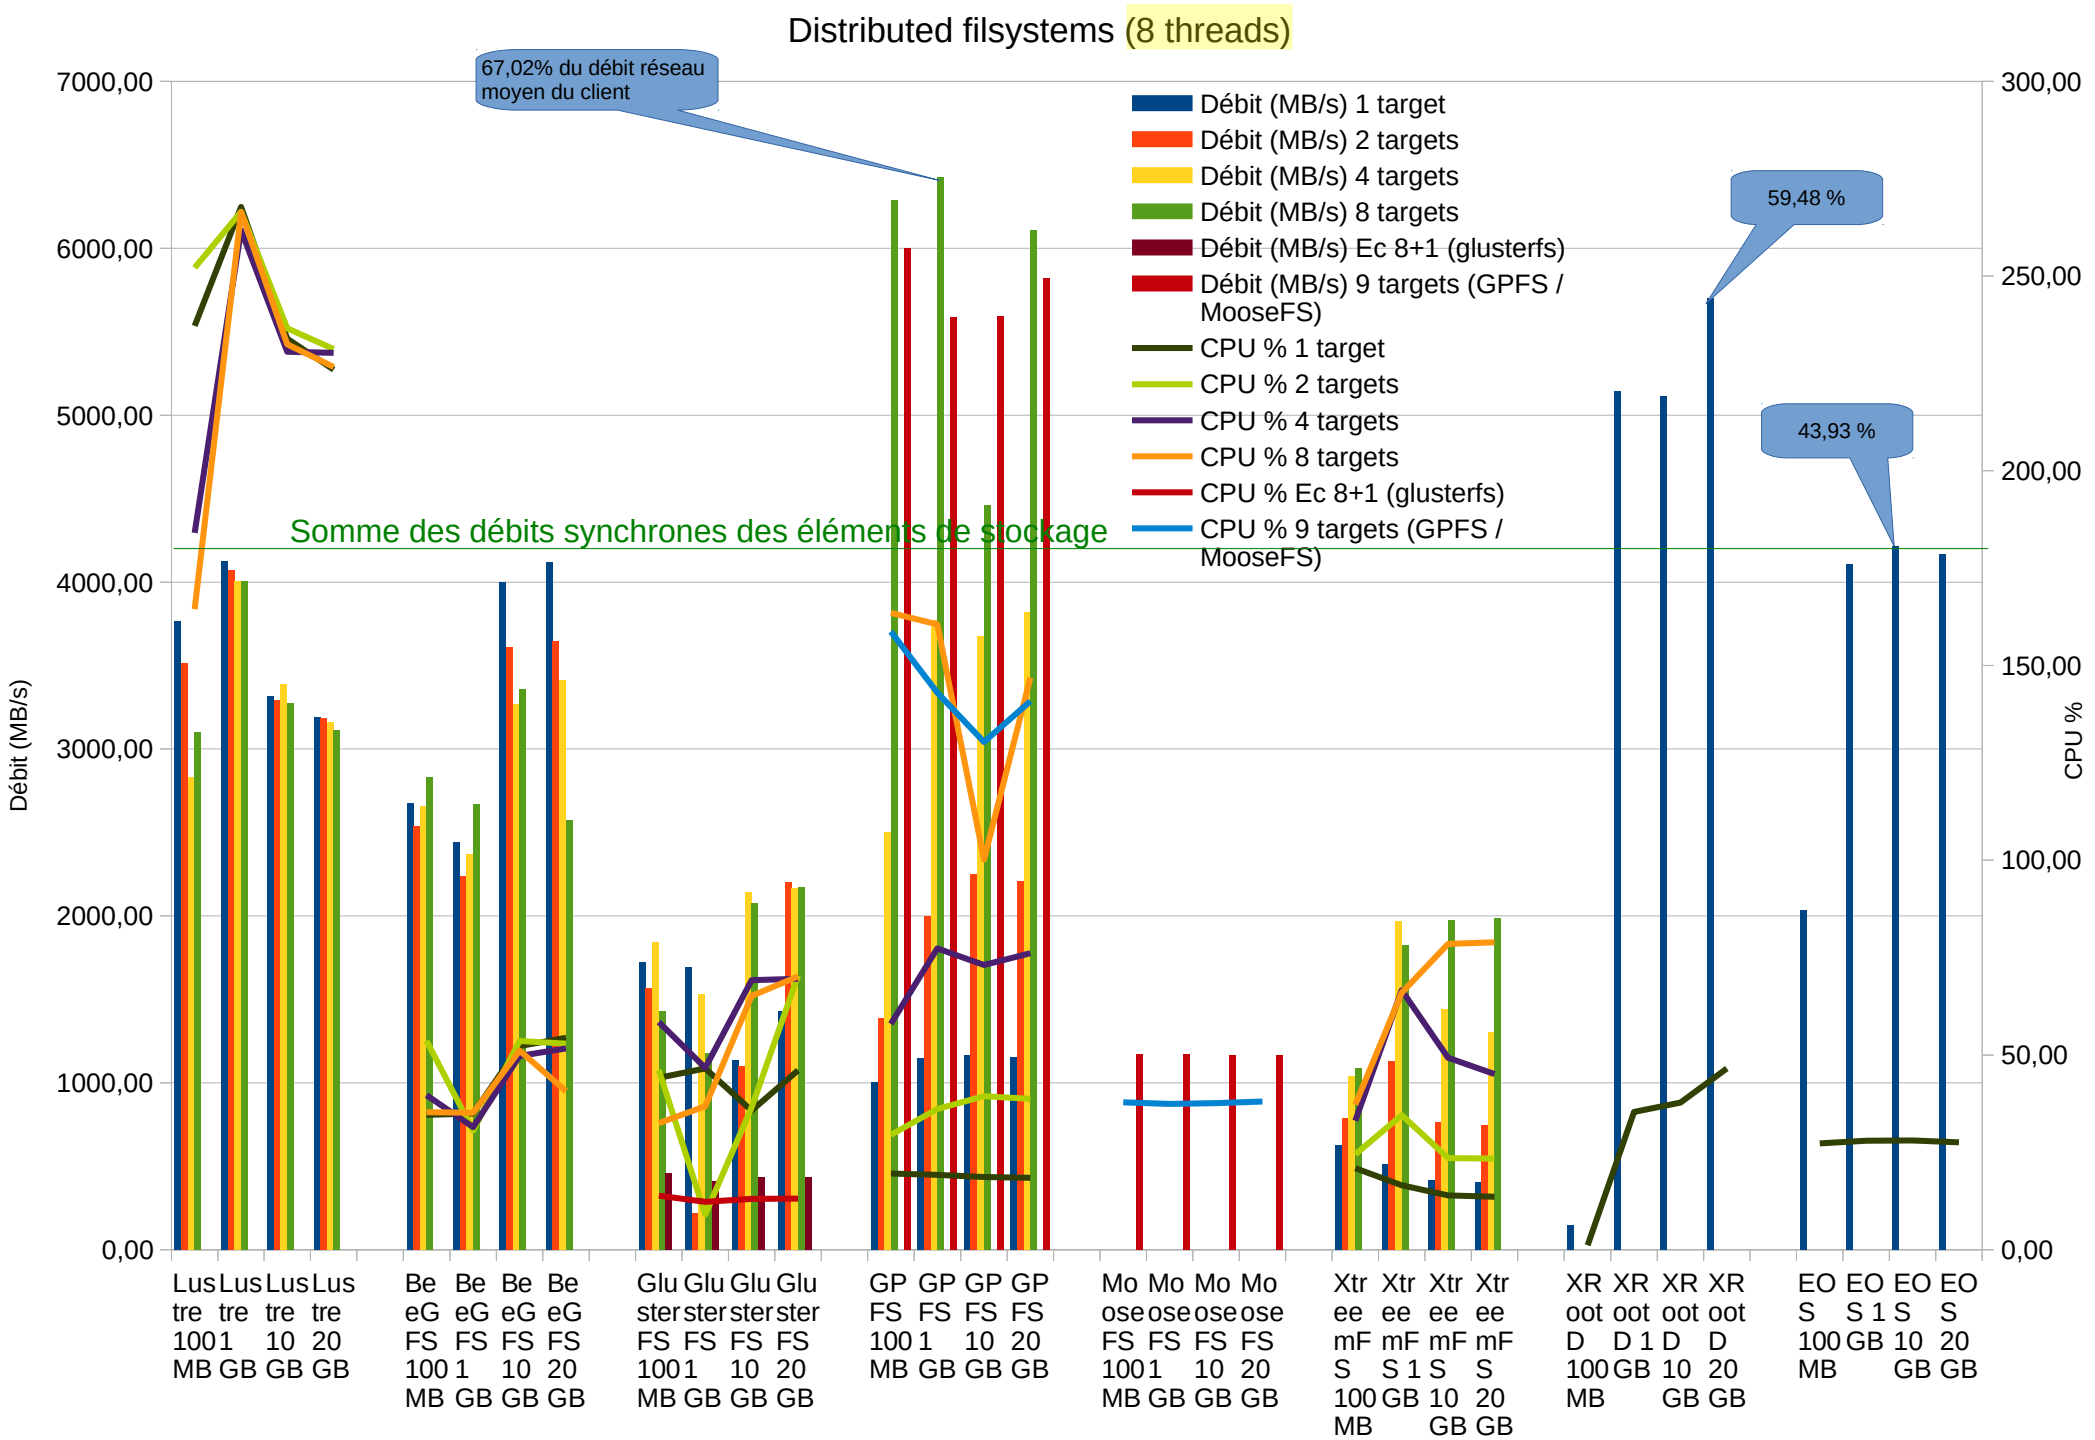
Distributed filsystems (8 threads)
67,02% du débit réseau moyen du client
59,48 %
43,93 %
Somme des débits synchrones des éléments de stockage
Débit (MB/s) 1 target
Débit (MB/s) 2 targets
Débit (MB/s) 4 targets
Débit (MB/s) 8 targets
Débit (MB/s) Ec 8+1 (glusterfs)
Débit (MB/s) 9 targets (GPFS / MooseFS)
CPU % 1 target
CPU % 2 targets
CPU % 4 targets
CPU % 8 targets
CPU % Ec 8+1 (glusterfs)
CPU % 9 targets (GPFS / MooseFS)
Débit (MB/s)
CPU %
7000,00
6000,00
5000,00
4000,00
3000,00
2000,00
1000,00
0,00
300,00
250,00
200,00
150,00
100,00
50,00
0,00
Lustre 100 MB
Lustre 1 GB
Lustre 10 GB
Lustre 20 GB
BeeGFS 100 MB
BeeGFS 1 GB
BeeGFS 10 GB
BeeGFS 20 GB
Gluster FS 100 MB
Gluster FS 1 GB
Gluster FS 10 GB
Gluster FS 20 GB
GPFS 100 MB
GPFS 1 GB
GPFS 10 GB
GPFS 20 GB
Moose FS 100 MB
Moose FS 1 GB
Moose FS 10 GB
Moose FS 20 GB
XtreemFS 100 MB
XtreemFS 1 GB
XtreemFS 10 GB
XtreemFS 20 GB
XRootD 100 MB
XRootD 1 GB
XRootD 10 GB
XRootD 20 GB
EOS 100 MB
EOS 1 GB
EOS 10 GB
EOS 20 GB

Conclusion

- Classification grossière :
  - Haute performance : GPFS, Lustre, BeeGFS
  - PRA : XtreemFS, MooseFS
  - Pour tous usages : GlusterFS
  - Pour le stockage massif de données : XRootD et EOS sont bien adaptés

- Acquisition :
  - Pour améliorer le débit du client => répartir le traitement des flux d'acquisition sur plusieurs processus : Distribuer les flux d'acquisition sur différents processus indépendants (ideal ratio : 1 flux d'acquisition / CPU core)
  - Pour distribuer les E/S sur le système de stockage, créer autant de flux réseau indépendants que possible (ideal ratio : 1 flux réseau par serveur de stockage)

- Tests réseaux :
  - 40gb/s vers 10gb/s : source d'inefficacité : retransmissions TCP et drops UDP
  - Utiliser de préférence le même débit d'interfaces sur tous les systèmes: 10Gb/s → 10Gb/s, 40gb/s -> 40gb/s, 56gb/s -> 56gb/s…
  - Algorithme de bonding :
    - Balance-tlb et balance-alb : forte variation des débits dans le temps
    - LACP (IEEE 802.3ad) plus efficace que les autres algorithmes de bonding quand les interfaces ont le même débit

Conclusion

La parallelisation des I/O (chuncks répartis sur les serveurs de stockage) :

- apporte un gain seulement pour un nombre faible de clients (1, 2, 3..?)
- N'a aucun effet pour 6 ou 8 flux indépendants

- Systèmes de stockage distribués POSIX
  - La couche POSIX a un coût CPU important coté client
  - Grosses différences dans les performances : Impact négatif de fuse (inutilisable dans notre cas), piles logicielles ± optimisée
  - GPFS très efficace dans l'utilisation des capacités matérielles, mais problème du coût de la licence (€€€)
  - Lustre et BeeGFS sont performants, mais Lustre utilise beaucoup la CPU du client (dans la version 2,7,0)

- Pour les systèmes de stockage non POSIX :
  - Avantages pour XrootD et EOS: ne fournissent pas la couche POSIX, donc n'utilisent que très peu de CPU (ouverture de sockets réseau)
  - Avantage de performance pour XrootD (pour des fichiers > 1Go) : mais problème de performance des métadonnées pour les petits fichiers (100Mo)
  - EOS a été moins performant que XrootD, mais dispose de fonctionnalités plus intéressantes pour la production (cycle de vie des données et des serveurs de stockage)

- Taille des fichiers stockés dans le système de fichiers :
  - Ne pas créer des fichiers trop petits (impact négatif du traitement des metadonnées) : créer des fichiers > 1GB
  - Ne pas créer des fichiers trop gros : Tenir compte des contraintes de traitement des données sur les worker nodes dans les phases d'analyse online ou offline (< 20GB / file ?)

Remerciements

- **Telindus / SFR pour le prêt du switch**
- R. Barbier (IPNL/EBCMOS), B. Carlus (IPNL/WA105) et J. Marteau (IPNL/WA105) pour le prêt des cartes Mellanox 40gb/s
- L’équipe CMS de l’IPNL pour l’utilisation temporaire des 9 Dell R510 avant le début de la prise de données du RUN 2 du LHC
- L-M Dansac (Univ-Lyon 1/CRAL) pour l'utilisation temporaire d'un Dell R630
- Pour l’aide : C. Perra (Univ-lyon 1/FLCHP), Y. Calas (CC-IN2P3), L. Tortay (CC-IN2P3), B. Delaunay (CC-IN2P3), J-M. Barbet (SUBATECH), A-J. Peters (CERN)

Quelques commandes de configuration

FS	Client	Serveurs de données
Lustre	mount -t lustre 10.3.3.3:/lustre /lustre lfs setstripe --size $stripe_size --count $nb_targets /lustre/nt$nb_targets The default stripe_size is 1 MB	mkfs.lustre --reformat --fsname=lustre --mgsnode=10.3.3.3@tcp --ost --index=$i /dev/sdb
BeeGFS	beegfs-ctl --setpattern --numtargets=$nb_targets --chunksize=1m /mnt/beegfs/test3	/etc/beegfs/*.conf : tuneNumWorkers = 8
GlusterFS	gluster volume set vol-$i cluster.stripe-block-size 1MB	
GPFS	mmcrfs /dev/d1 "st17;st18;st19;st20;st21;st22;st23;st24;st25" -A yes -B 1M -D posix -j cluster -T /gpfs mmmount /dev/d1 /gpfs	1 NSD / serveur, bs=1M, pas de quota, pas de réplication Data ni Metadata usage=dataAndMetadata pour chaque NSD
XtreemFS	mount.xtreemfs 10.3.3.5/test2 /xtreemfs --enable-async-writes xtfsutil --set-dsp -p RAID0 -w $nb_targets -s 1024 /xtreemfs/nt4 xtfsutil /xtreemfs --set-drp --replication-policy none # OSD selection policy : roundrobin xtfsutil --set-osp roundrobin /xtreemfs xtfsutil --disable-snapshots /xtreemfs	
EOS		mkfs.ext4 -E stride=10,stripe-width=1024 /dev/sdb mount /dev/sdb -o defaults,user_xattr /gridcms1

Links / bibliography

- Storage systems :
  - GPFS : https://www.ibm.com/support/knowledgecenter/SSFKCN/gpfs_welcome.html
  - Lustre : http://lustre.org/
  - BeeGFS :
    - http://www.beegfs.com/content
    - http://www.beegfs.com/docs/Introduction_to_BeeGFS_by_ThinkParQ.pdf
  - GlusterFS : https://www.gluster.org
  - MooseFS : https://moosefs.com
  - XtreemFS :
    - http://www.xtreemfs.org
    - http://www.xtreemfs.org/xtfs-guide-1.5.1.pdf
  - XrootD : http://xrootd.org
  - EOS : http://eos.readthedocs.io/en/latest
- Bonding : https://www.kernel.org/doc/Documentation/networking/bonding.txt
- System, network and Mellanox tuning :
  - http://www.mellanox.com/related-docs/prod_software/MLNX_EN_Linux_README.txt
  - http://supercomputing.caltech.edu/docs/Chep2012_40GEKit_azher.pdf
  - http://www.nas.nasa.gov/assets/pdf/papers/40_Gig_Whitepaper_11-2013.pdf
  - https://access.redhat.com/sites/default/files/attachments/20150325_network_performance_tuning.pdf
  - https://fasterdata.es.net/host-tuning/40g-tuning/
- The new CMS DAQ system for LHC operation after 2014 (DAQ2) :
  - http://iopscience.iop.org/article/10.1088/1742-6596/513/1/012014/pdf