

Qserv

base de données distribuée pour LSST

Fabrice Jammes (LPC Clermont)

Emmanuel Medernach (LPC Clermont)

LSST

Télescope « grand champ » destiné à la recherche de l'énergie noire et à l'étude des supernovae.

Ce télescope, doté d'une CCD de 1m², réalise un film de l'univers.


60 PB d'images => 5 PB de données de type catalogue.





en une slide



- Expérience de cosmologie de 4ème génération :
 - Télescope de 8,4 m
 - Cerro Pachon (Chili)
 - Astronomie très grand champ : caméra $9,6^\circ$, Résolution $0,7''$
 - A partir de 2020



- Tout le ciel visible en 6 bandes (ugrizy) ($20\,000^\circ$)
- Poses de 15 s, 1 visite / 3 jours
- 10 ans, 60 Pbytes de données

Simulation des données :

~ 1/1 000 000 000 des données LSST !



LSST Headquarters Site
System Operations Center
Location TBD

Stand-alone U.S.
Data Access Center

Archive Site
Archive Center
Data Access Centers*


Stand-alone
Data Access Center
In Europe, Australia, Asia...

Site Roles and their Functions

- **Base Facility**
Real-time Processing and Alert Generation,
Long-term storage (copy 1)
- **Archive Center**
Nightly Reprocessing, Data Release
Processing, Long-term Storage (copy 2)
- **Data Access Centers (DACs)**
Data Access and User Services
- **System Operations Center (SOC)**
System Supervisory Monitoring Control
& End User Support/Help Desk


* Co-located DAC: shares
infrastructure with Archive Center

** Co-located DAC: shares
infrastructure with Base Facility




Couche applicative

Application Layer - framework-based pipelines process raw data to products



Qserv: objectifs



Object
Source

...



Qserv : exigences fonctionnelles

SGBD relationnel, car les chercheurs connaissent bien le SQL.

<https://dev.lsstcorp.org/trac/wiki/db/queries>


Optimisé pour pouvoir comparer des observations voisines.

La syntaxe SQL n'est pas entièrement supportée et les requêtes sont classées de 'simple' à 'impossible'.


<https://dev.lsstcorp.org/trac/wiki/db/queries/difficulty>

Qserv : exigences techniques

- Données distribuées en mode « Shared-nothing »
- Moteur d'exécution parallèle
- Disques locaux sur les esclaves
- Shared scans
- Open Source



Worker Qserv



WORKER

XRootD CMSD Server

QSERV-OFS



Chunk 3

Object_4
Source_4


Chunk 4

Object_3
Source_3


Chunk 16

Object_16
Source_16

Master Qserv




Au dessus de MySQL et xrootd



Réécriture de requêtes

MASTER

```
SELECT count(*)  
FROM Object  
WHERE qserv_areaspec_box(1,3,2,4)  
      AND scisql_fluxToAbMag(zFlux_PS) BETWEEN 21 AND  
21.5;
```



WORKER

```
SELECT count(*)  
FROM Object_456  
WHERE scisql_s2PtInBox(...)  
      AND scisql_fluxToAbMag(zFlux_PS) BETWEEN 21 AND  
21.5;
```



Avantages d'une solution ad-hoc

- Code bien adapté au besoin métier :
 - géométrie sphérique
 - recherche sur les proches voisins
- Maîtrise du code
- Contact étroit avec les développeurs Xrootd et MySQL (MariaDB)



Inconvénients

- => Les méthodes génériques implémentées dans les outils Map-Reduce sont à re-écrire :**
- Partitionnement et chargement des données
 - Supervision et gestion des pannes
 - Répartition de charge et haute-disponibilité



En France : Petasky

Réponse à l'appel d'offre du défi de la MI du CNRS sur les BigData
2012 : Mastodons

*La disponibilité de très **grandes masses de données** et la **capacité de les traiter de manière efficace** est en train de modifier la manière dont nous faisons de la science.*

Consortium pluridisciplinaire :

- IN2P3 : LPC, APC, LAL, CC
 - INS2I : LIMOS (Clermont-Ferrand), LIRIS (Lyon)
- => Expertise + Financement (Infrastructure, missions)



Activités réalisées au LPC

Procédure d'installation automatique validée par SLAC

<https://dev.lsstcorp.org/trac/wiki/db/Qserv/InstallAuto>

Intégration continue (install, tests) au NCSA

Benchmarking (tuning MariaDB, jeux de données, requêtes SQL)

<https://dev.lsstcorp.org/trac/wiki/mysqlLargeTablesAtIn2p3>

Contribution à l'installation des 300 nœuds au CC-IN2P3 (3TB)

Passage à l'échelle

Machine de dév :

- 1 noeud, 20 MB (PT1.1, 1.2, W13)

Plate-forme de dév :

- 30 noeuds, 200GB

Plate-forme de benchmark :

- 300 noeuds, 3TB




Lecons apprises

Difficulté de manipuler des données (via le réseau ou sur disque)

Adopter une démarche itérative :

- expérimenter sur 1 seul nœud
- travailler avec des petits jeux de données
- planifier une montée en charge très progressive (nœuds et données)



Questions/réponses



Remerciements à Emmanuel Gangler, Christian Arnaud, Dominique Boutigny et au service informatique du LPC.