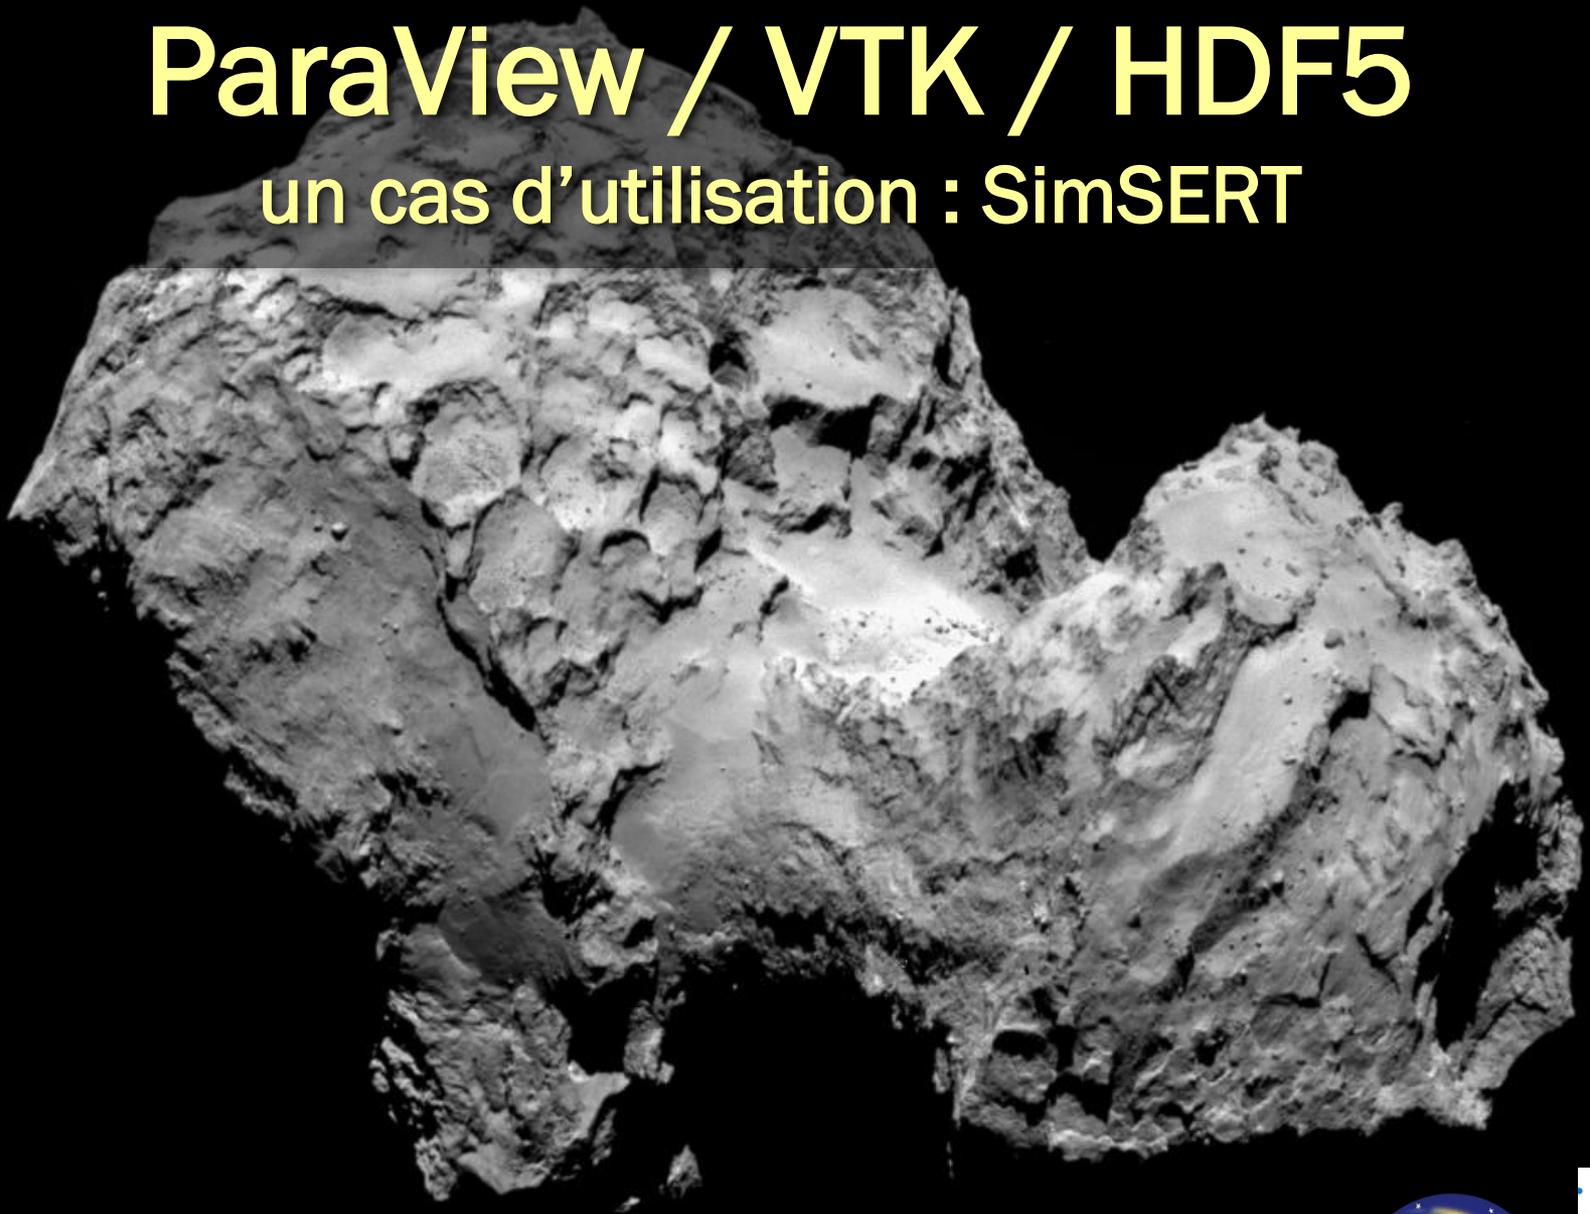


ParaView / VTK / HDF5

un cas d'utilisation : SimSERT



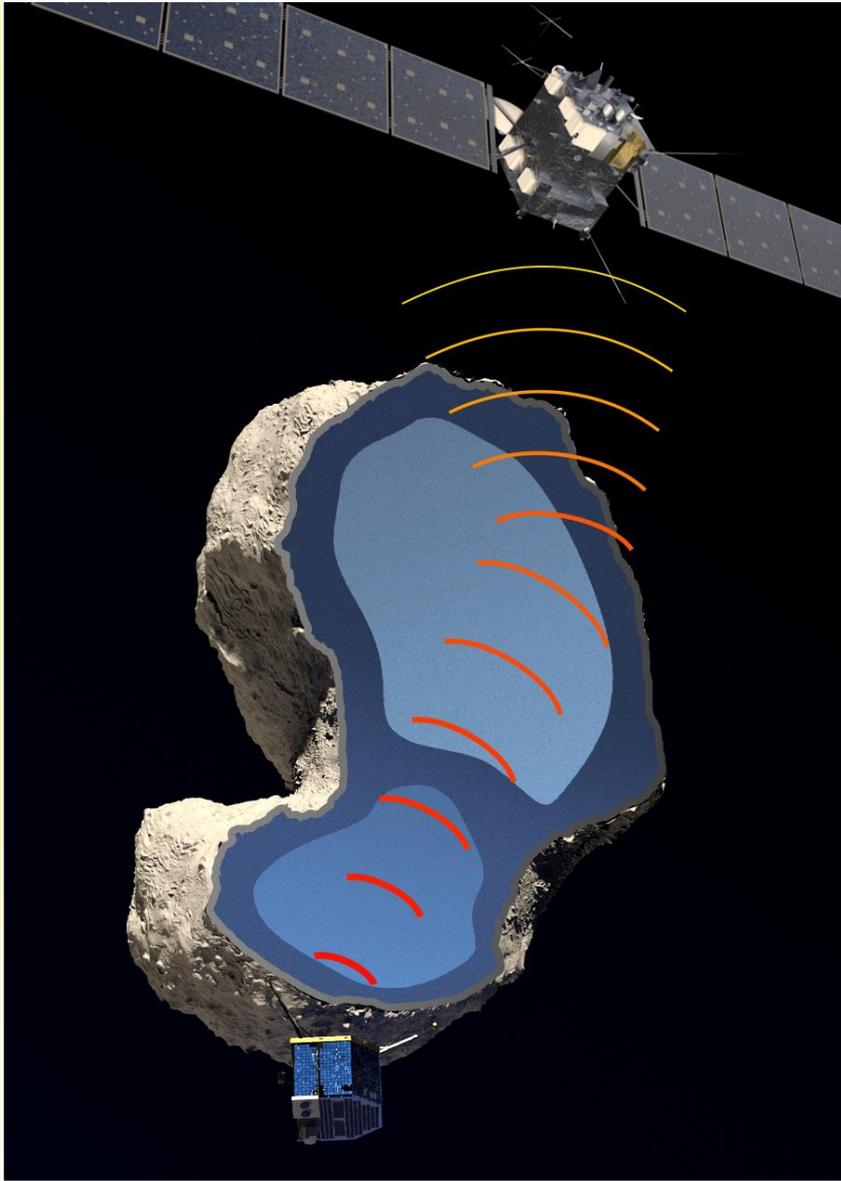
ParaView / VTK / HDF5

un cas d'utilisation : SimSERT

1. Contexte : CONSERT / ROSETTA
2. ParaView :
Fonctionnalités, pipeline VTK
Traitement et visualisation sur cluster
Retour d'expérience
3. Structures de données :
VTK et HDF5



CONSERT / ROSETTA - SimSERT

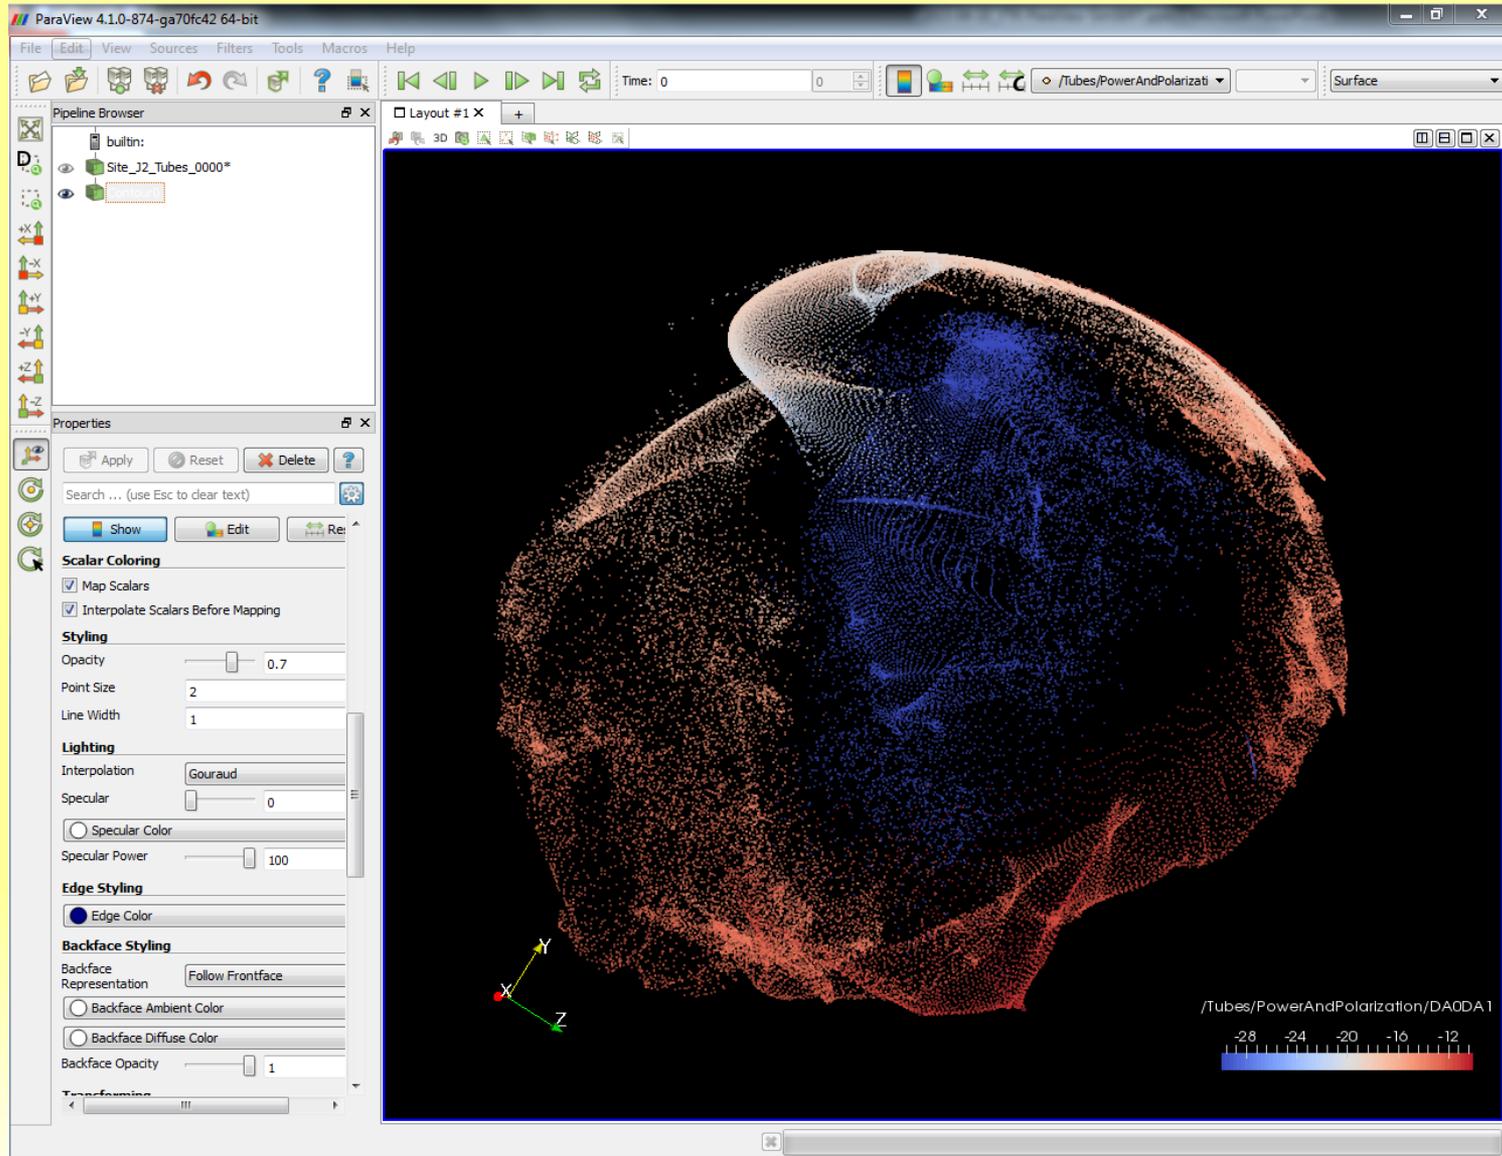


- COmet Nucleus Sounding by Radiowave Transmission
- SimSERT : Propagation radar en transmission sur un grand domaine
=> **ray-tracing**
- Besoin pour l'**analyse scientifique** et la préparation des **opérations**
- Visualisation et exploitation
HDF5/VTK/ParaView/Qt

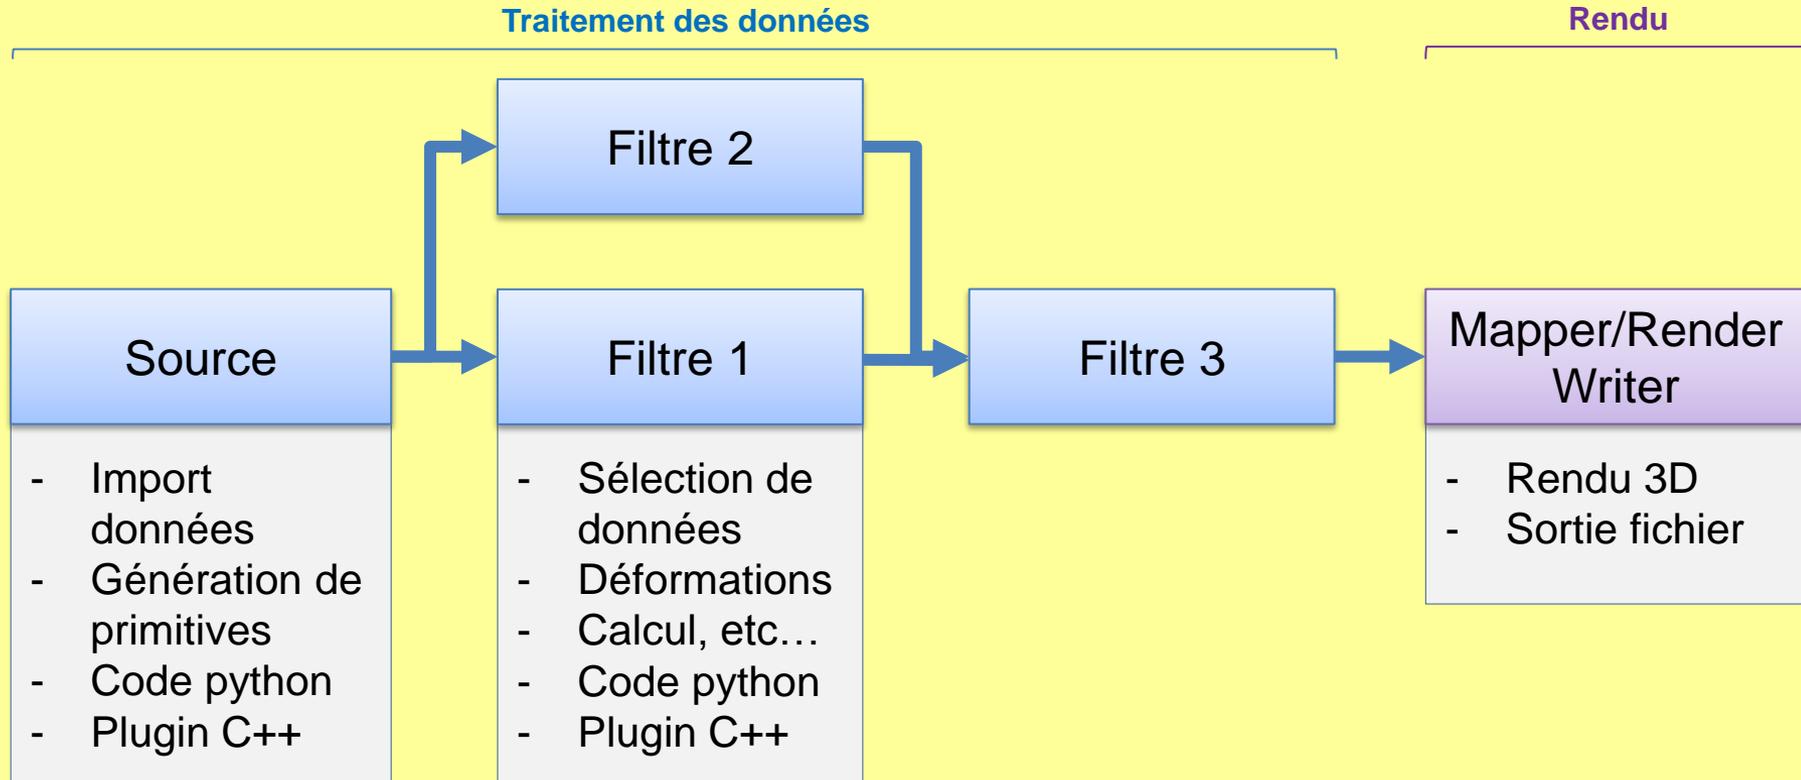
ParaView

- Visualisation de données 3D + temps :
points, lignes, surfaces, volumes
- Spreadsheets et graphs 2D en complément
- Stéréoscopie
- Gestion d'IHM avancées (VRPN)
- Outil de prototypage rapide
 - Import de données
 - Fonctions de traitement évoluées
 - Construction d'un pipeline interactif
 - Support de python (numpy & matplotlib)
- Vidéos, screenshots

ParaView

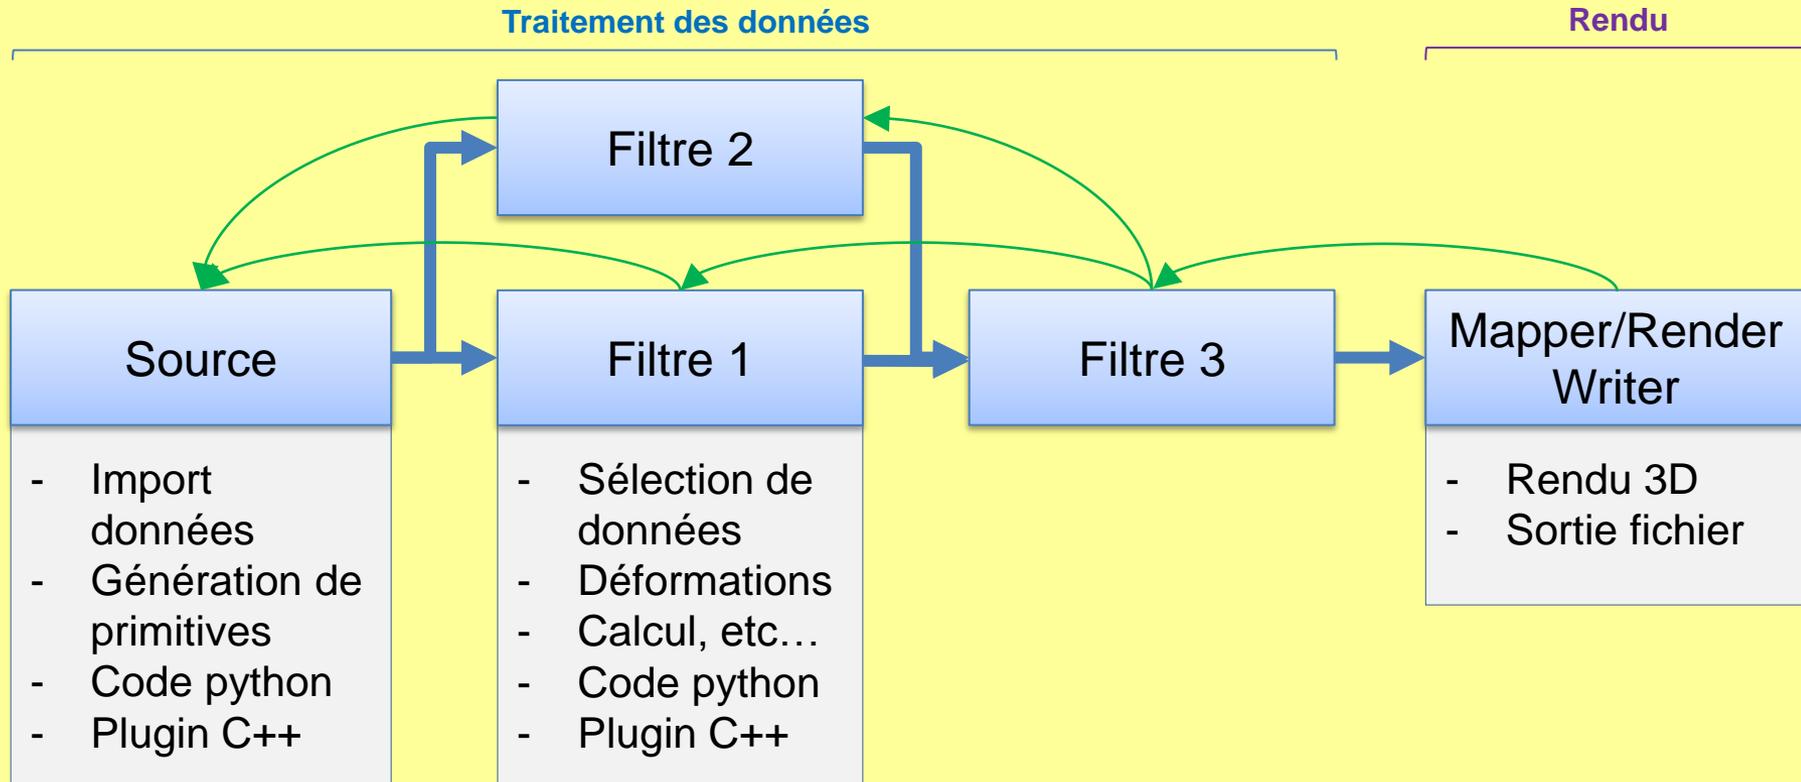


VTK: le pipeline



→ Flux des données : "downstream"

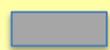
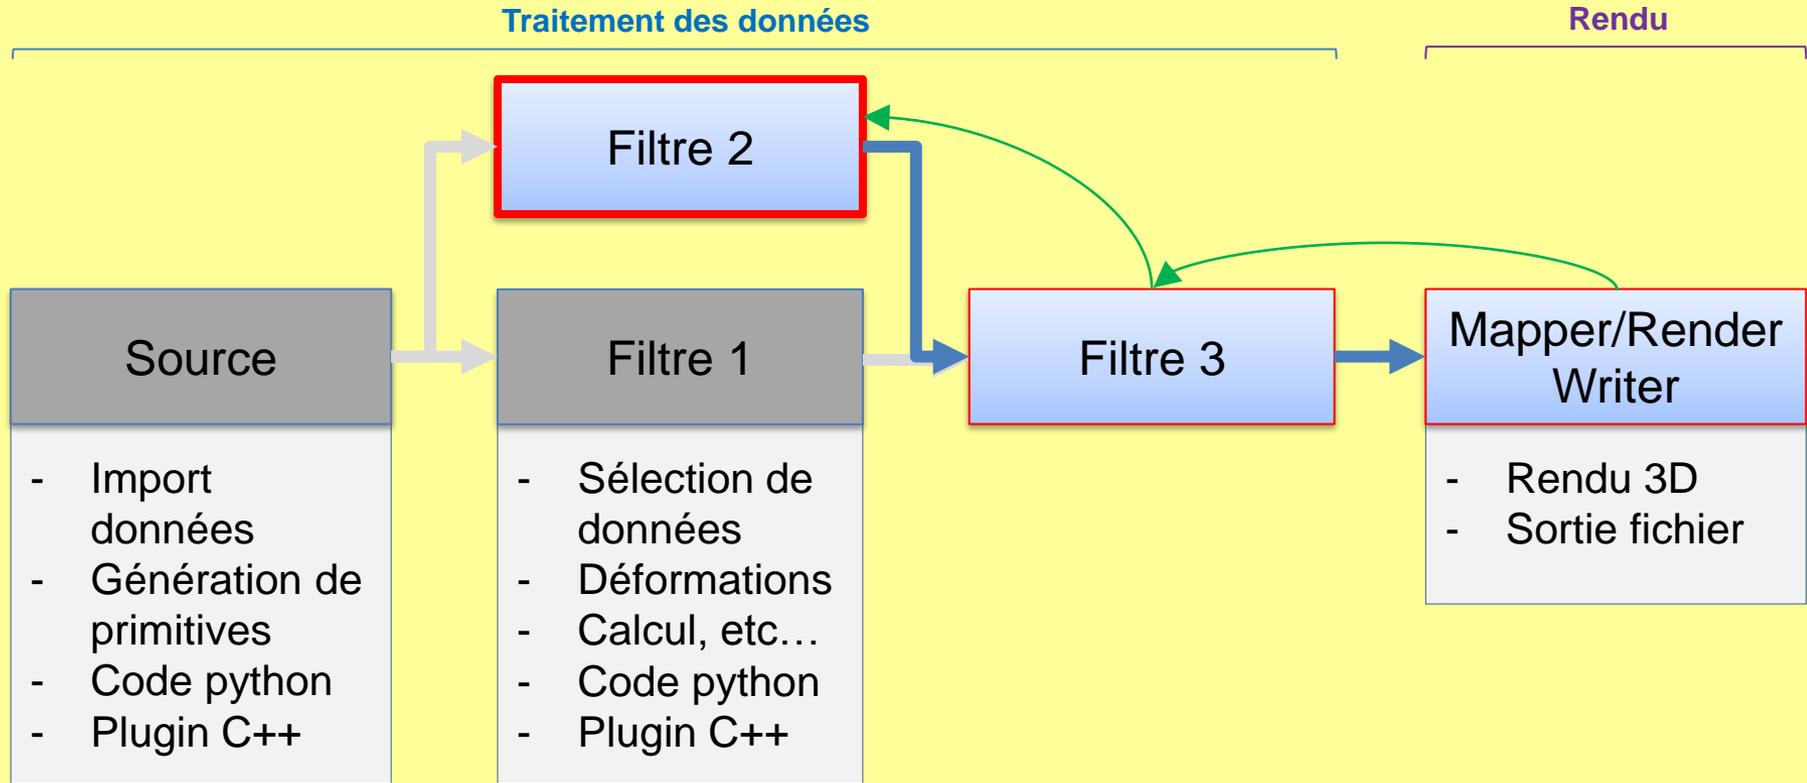
VTK: le pipeline



➔ Flux des données : “downstream”

← Flux des demandes de mise à jour : “upstream”

VTK: le pipeline



Propriétés inchangées



Flux des données : "downstream"



Flux des demandes de mise à jour : "upstream"

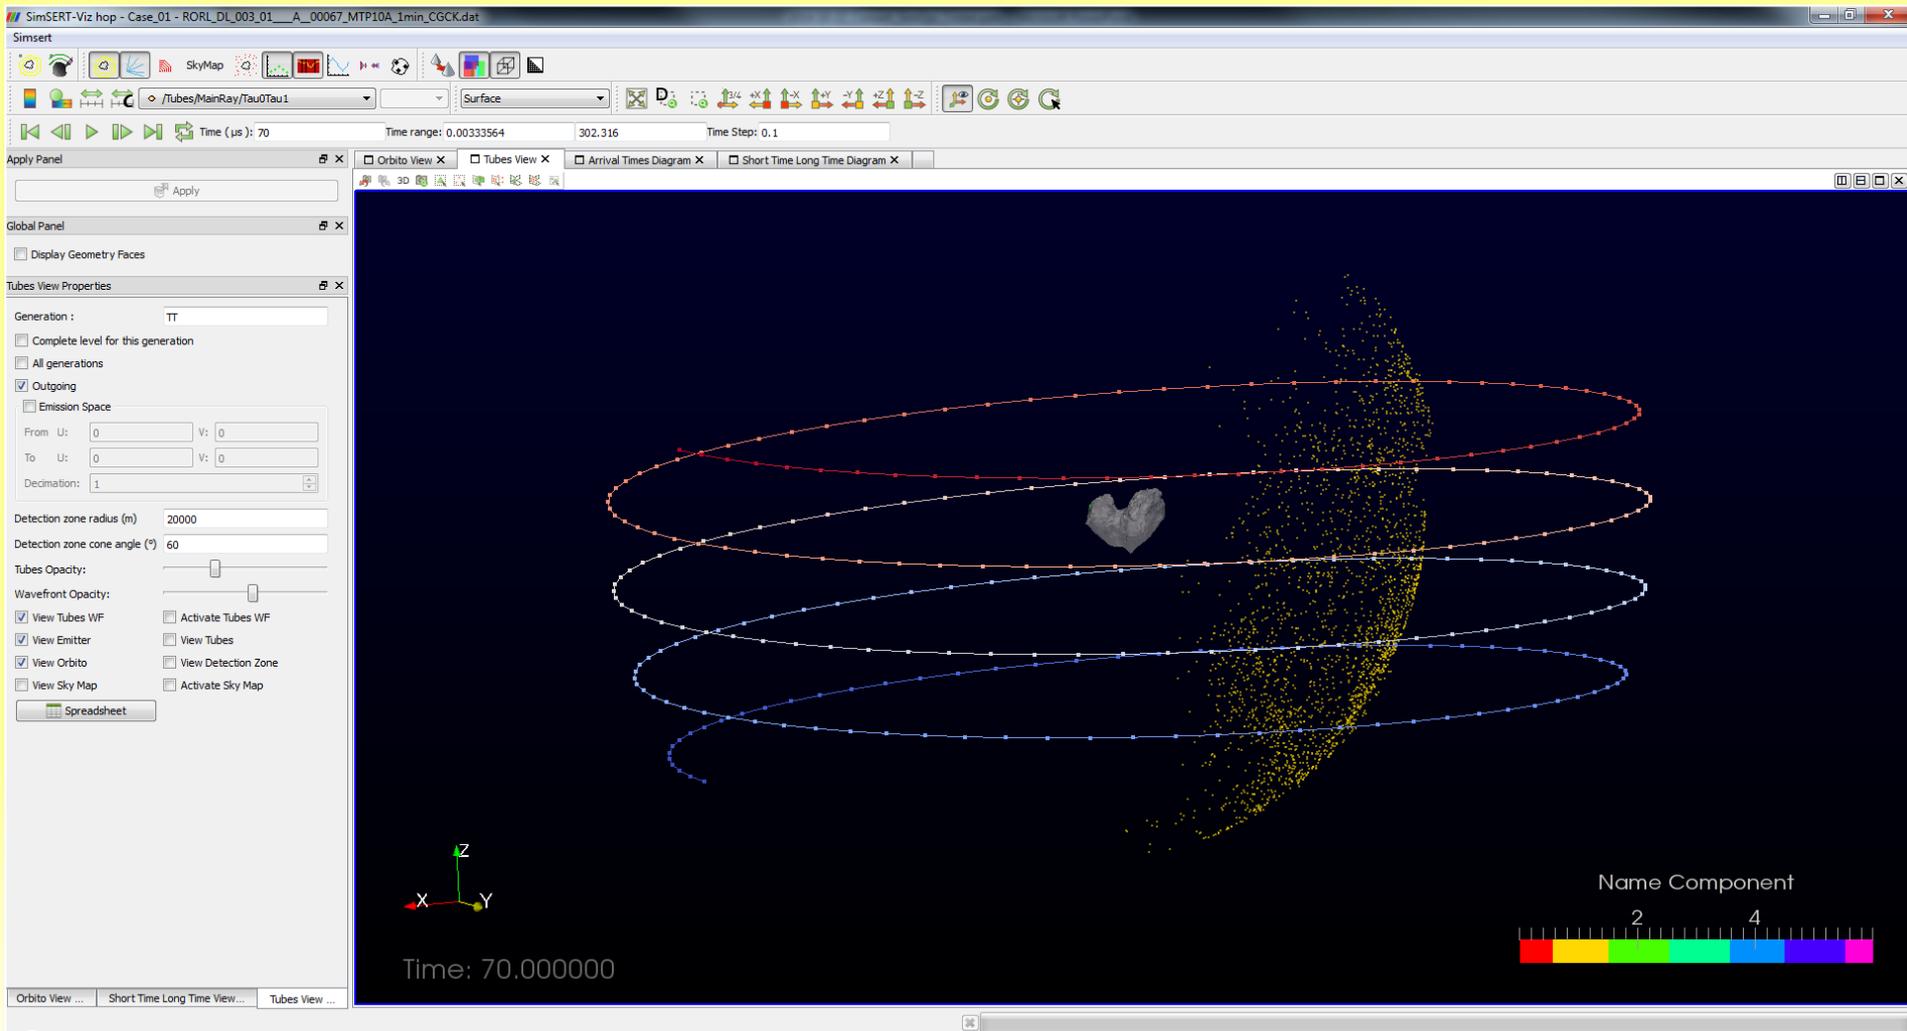
=> seuls les filtres nécessaires sont mis à jour

VTK: le pipeline

- Contrôle des flux de données et d'informations
- Modules de traitements indépendants, réutilisables et paramétrables interactivement
- “Lazy update”
- “Streaming” (découpage des données en pièces ou blocs structurés) si la capacité mémoire n'est pas suffisante
- Aisément extensible en C++ (écriture de nouveaux filtres)

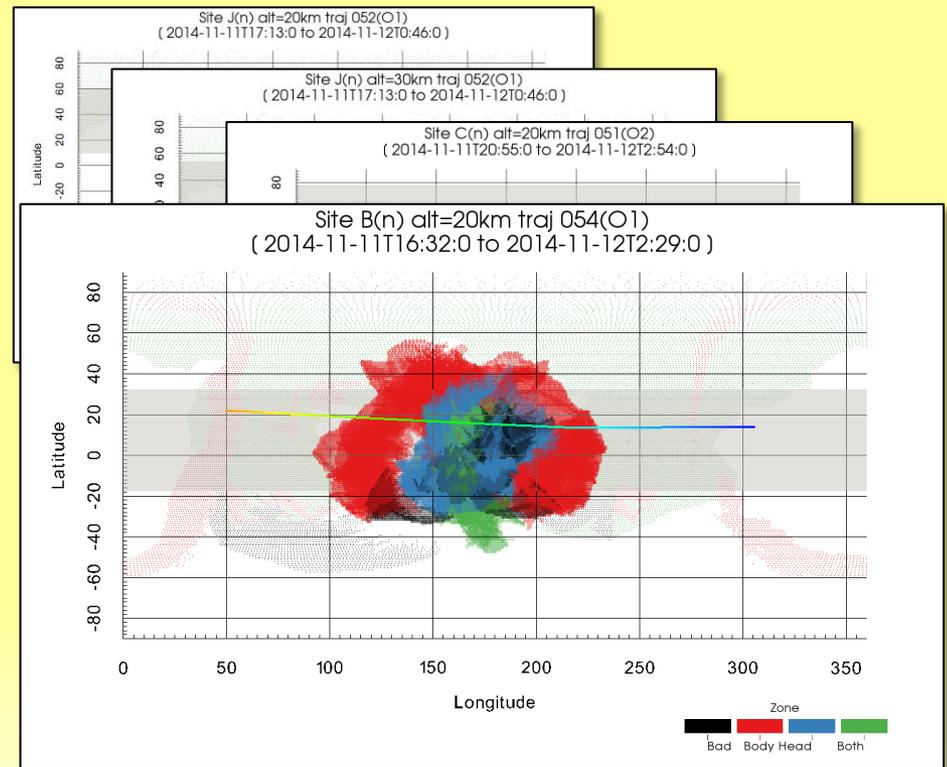
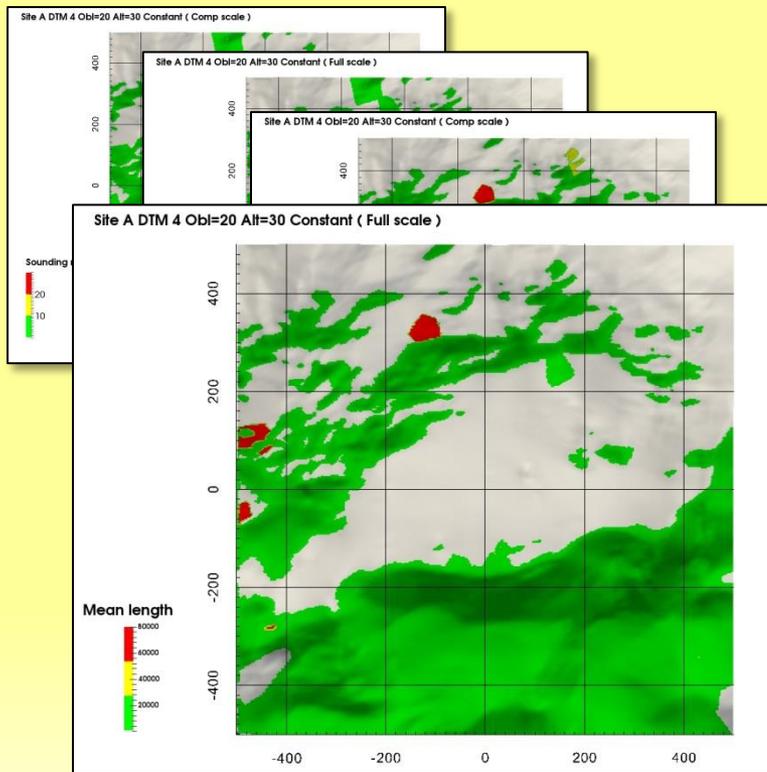
SimSERT

- Extension de la GUI de ParaView (Qt)



ParaView

- Process complètement automatisables via python pour générer des visualisations, des statistiques, etc...



CIMENT et Parallélisation

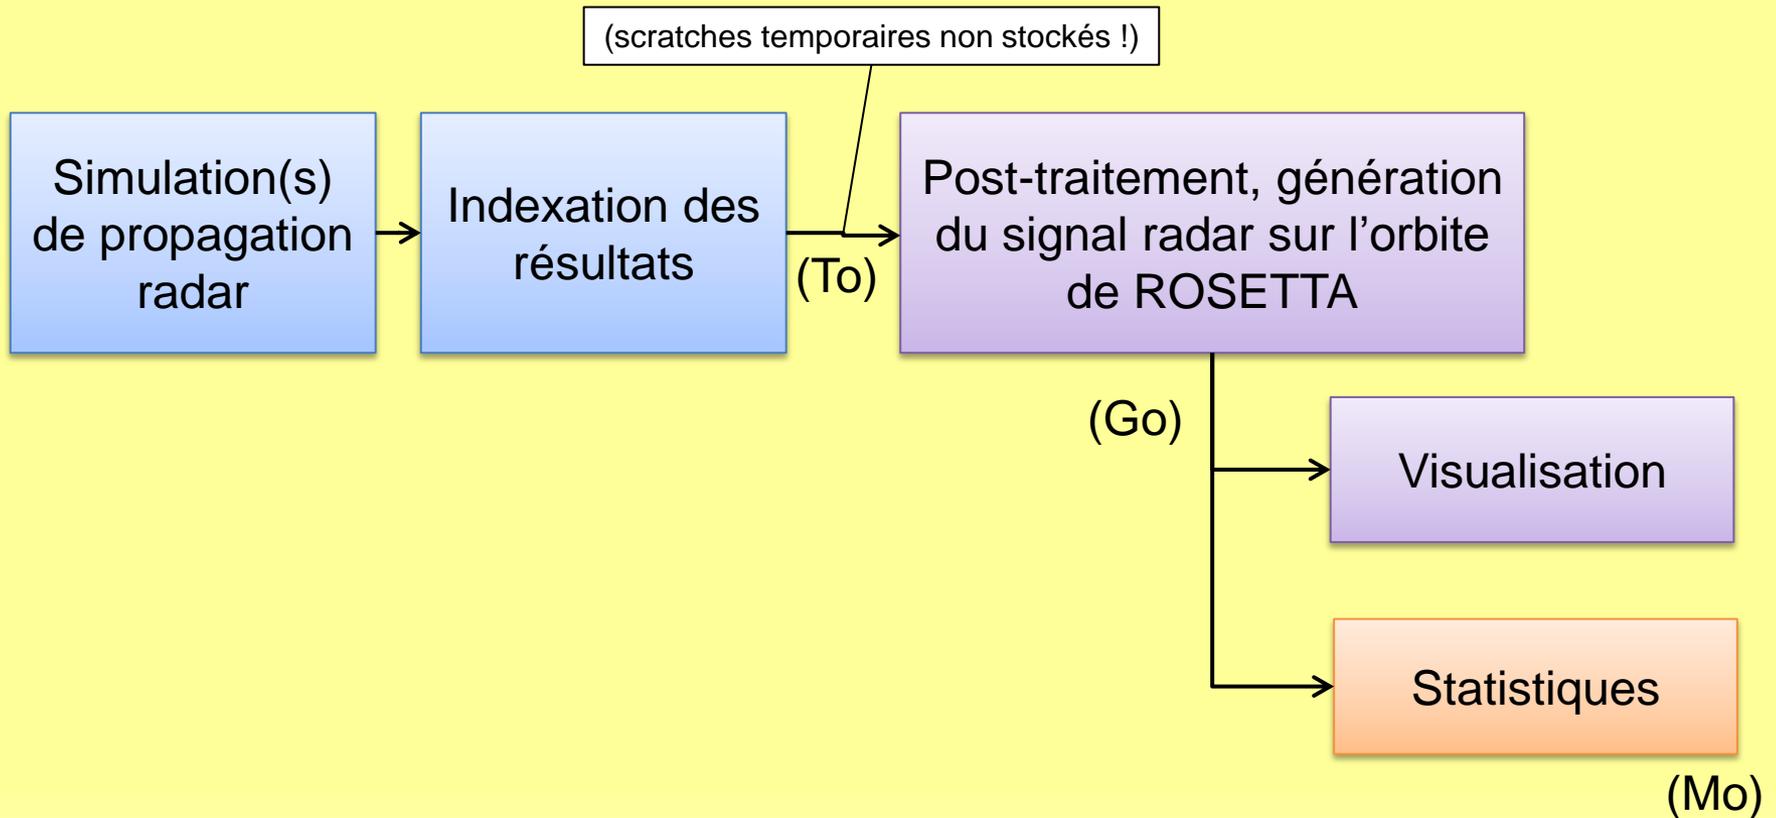
- Distribution de job : “embarrassingly parallel”
 - Aucune communication entre les process
 - On ne parle pas ici de parallélisation
 - Typique de l’utilisation **grille** (CiGri)
- Parallélisation en mémoire distribuée
 - Communication minimisée entre les process (MPI)
 - Typique de l’utilisation **cluster** (OAR) ou noeud
- Parallélisation en mémoire partagée
 - La RAM est complètement partagée entre les threads
 - Typique de l’utilisation **noeud** ou CPU (OpenMP, pthreads)

CIMENT et Parallélisation

- Distribution de job : “embarrassingly parallel”
 - Aucune communication entre les process
 - On ne parle pas ici de parallélisation
 - Typique de l’utilisation **grille** (CiGri)
- Parallélisation en mémoire distribuée
 - Communication minimisée entre les process (MPI)
 - Typique de l’utilisation **cluster** (OAR) ou **noeud**
- Parallélisation en mémoire partagée
 - La RAM est complètement partagée entre les threads
 - Typique de l’utilisation **noeud** ou CPU (OpenMP, pthreads)

**ParaView se
situe à ce niveau**

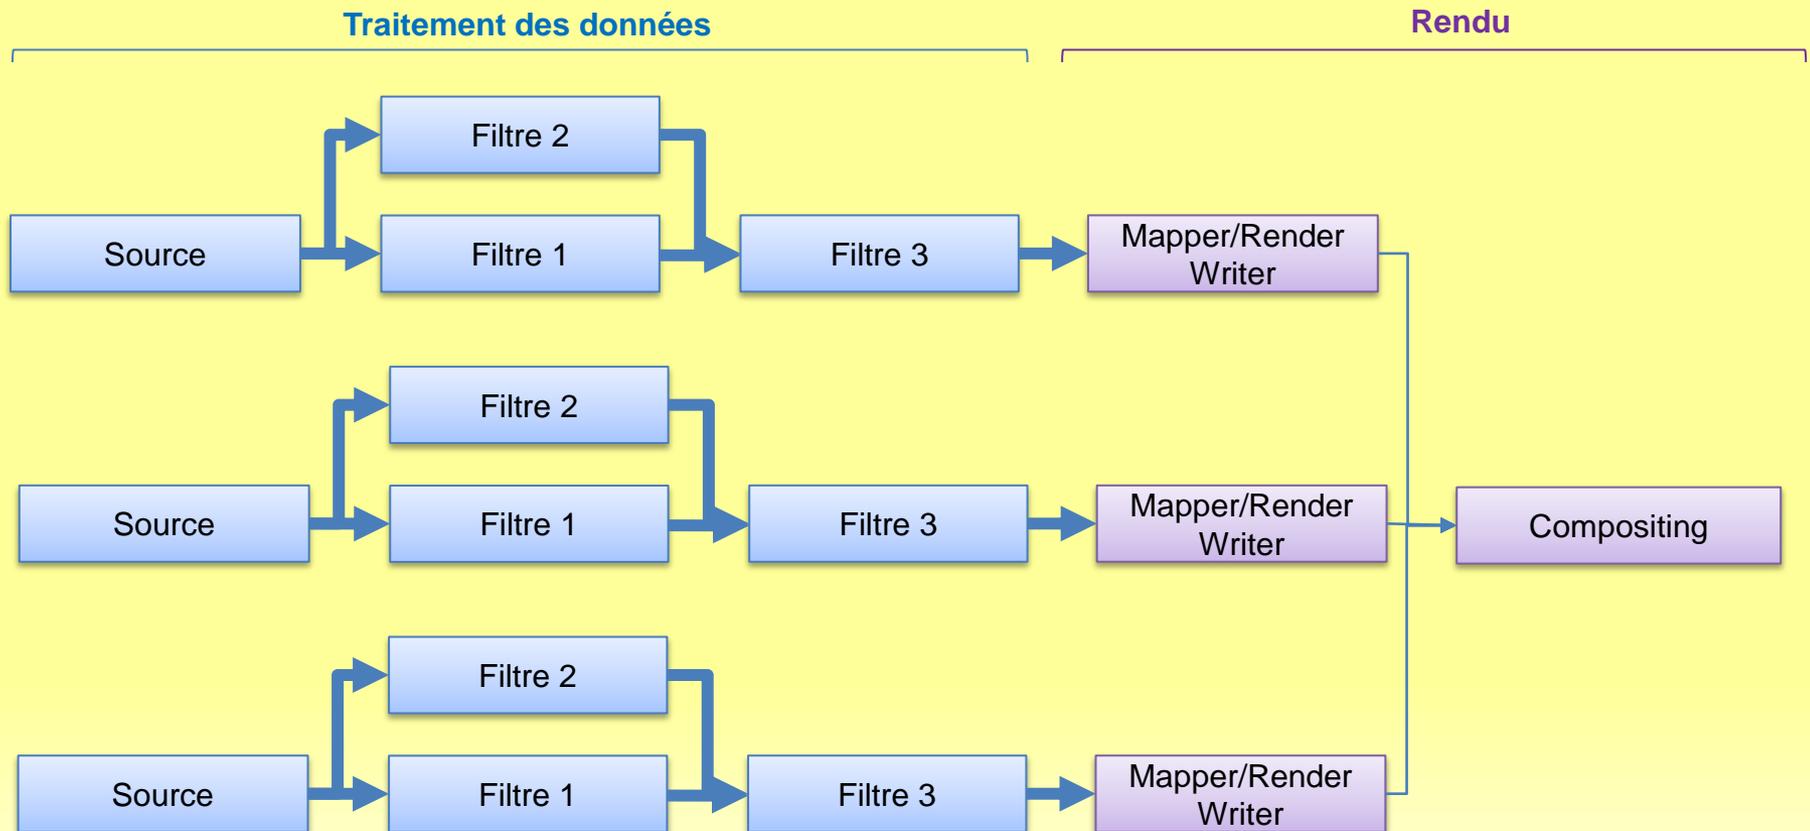
SimSERT et Parallélisation



- Grille** Distribution de jobs indépendants (pthread) sur la grille en mode best-effort
- Cluster** Exécution sur poste local (SimSERT-Viz), ou cluster (MPI) + OpenMP
- Noeud** Noeud simple, serveur de calcul dédié (pvpython + numpy)

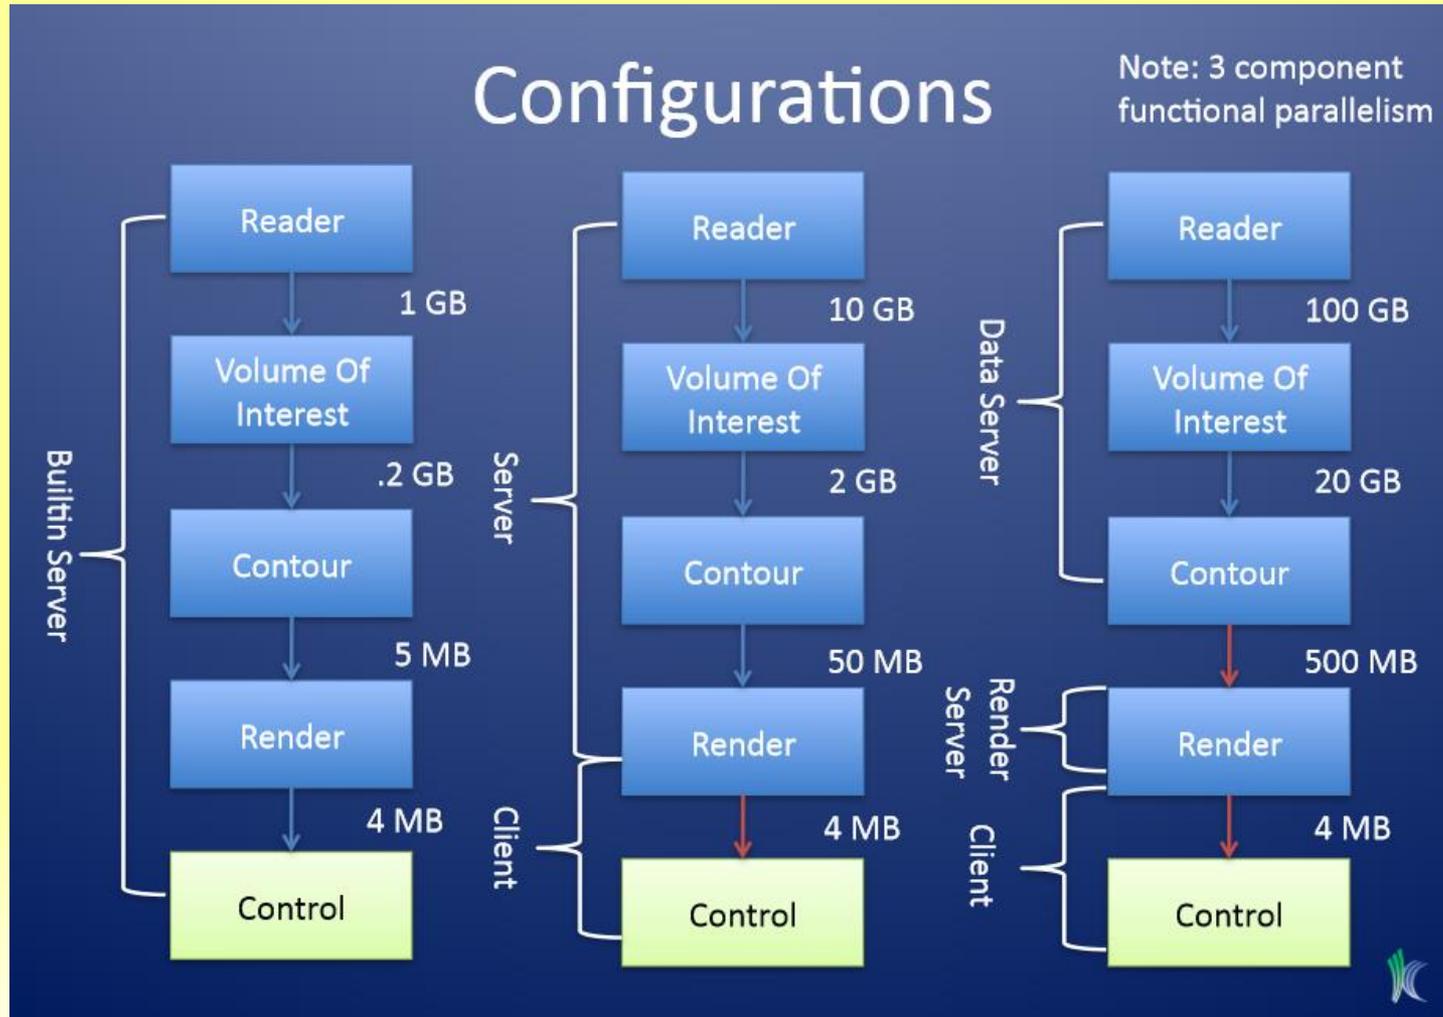
ParaView : le “Para”

- Exécution parralèle : pipeline dupliqué, données découpées



ParaView : le “Para”

- Répartition data / render / control



ParaView : le “Para”

- Architecture de parallélisation modulable

Architecture	Taille des données sources	Taille des données visualisées	Résolution d’affichage	Contraintes matérielles
(1) pvserver mode data + client paraview*	++ (le traitement doit réduire les données)	=	=	La machine client paraview doit avoir un GPU** puissant et une très bonne connexion réseau : Les données arrivent toutes sur un même noeud
(2) pvdataserver + pvrenderserver + client paraview*	++	+	=	Serveurs de data et render exactement couplés (même nombre), sinon on se retrouve dans la situation (1)
(3) client paraview* seul	=	=	=	Une machine avec CPU + GPU** puissants
(4) pvserver + client paraview*	+	+	=	Tous les noeuds doivent être équipés de GPU** mais aussi de CPU puissants si les données modifiables sont importantes
(5) mode “tiling” + Client paraview*			+	Plus de noeud avec GPU** sont nécessaires (jamais testé en fait, vraiment utile pour les très hautes résolutions, multi-surfaces)

* Le client paraview peut être la GUI de ParaView ou pvpython

** GPU = carte graphique, ne s’applique pas pour les GPGPU dédiés (type Tesla)

ParaView : le “Para”

- Architecture de parallélisation modulable

Architecture	Taille des données sources	Taille des données visualisées	Résolution d’affichage	Contraintes matérielles
(1) pvserver mode data + client paraview*	++ (le traitement doit réduire les données)	=	=	La machine client paraview doit avoir un GPU** puissant et une très bonne connexion réseau : Les données arrivent toutes sur un même noeud
(2) pvdataserver + pvrenderserver + client paraview*	++	+	=	Serveurs de data et render exactement couplés (même nombre), sinon on se retrouve dans la situation (1)
(3) client paraview* seul	=	=	=	Une machine avec CPU + GPU** puissants
(4) pvserver + client paraview*	+	+	=	Tous les noeuds doivent être équipés de GPU** mais aussi de CPU puissants si les données modifiables sont importantes
(5) mode “tiling” + Client paraview*			+	Plus de noeud avec GPU** sont nécessaires (jamais testé en fait, vraiment utile pour les très hautes résolutions, multi-surfaces)

* Le client paraview peut être la GUI de ParaView ou pvpython

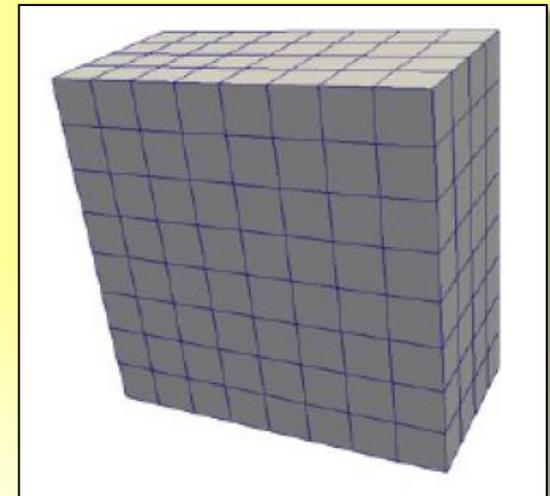
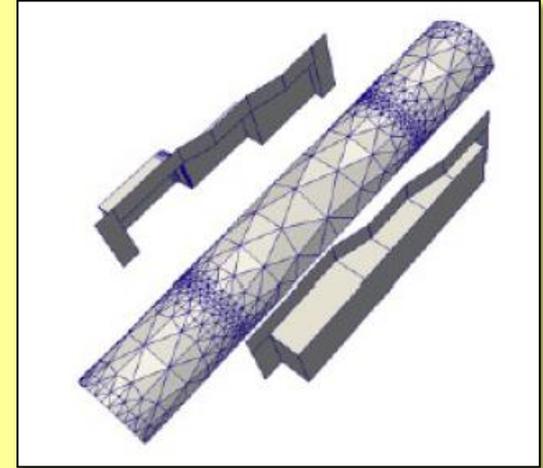
** GPU = carte graphique, ne s’applique pas pour les GPGPU dédiés (type Tesla)

ParaView : retour d'expérience

- Les plus
 - Parallélisation sans connaître MPI
 - Flexibilité / évolutivité, bien adapté au projet scientifique
 - Multi-plateforme
 - Communauté très (ré)active
 - VTK repose sur une architecture mature et efficace
- Les moins
 - Instabilité (très peu de contrôle d'erreur dans ParaView)
 - Quelques points de détail pénibles dans l'ergonomie
 - Architecture logicielle de ParaView complexe (problèmes rencontrés en dérivant la GUI)
 - Difficultés à la compilation (dépendances)
 - Parfois très gourmand en RAM, avec les filtres de base

Structures de données : VTK

- Structures de données dédiées à la visualisation
- S'avère très efficace en traitement également
- Structures
 - Géométrie : points
 - Topologie : cellules
 - Données structurées / non structurées
 - Série temporelles
- Données attachées
 - “vtkArrays” assurent la coalescence des données
 - Lecture à la demande
- Points faibles
 - matrices creuses
 - accès aléatoires partiels

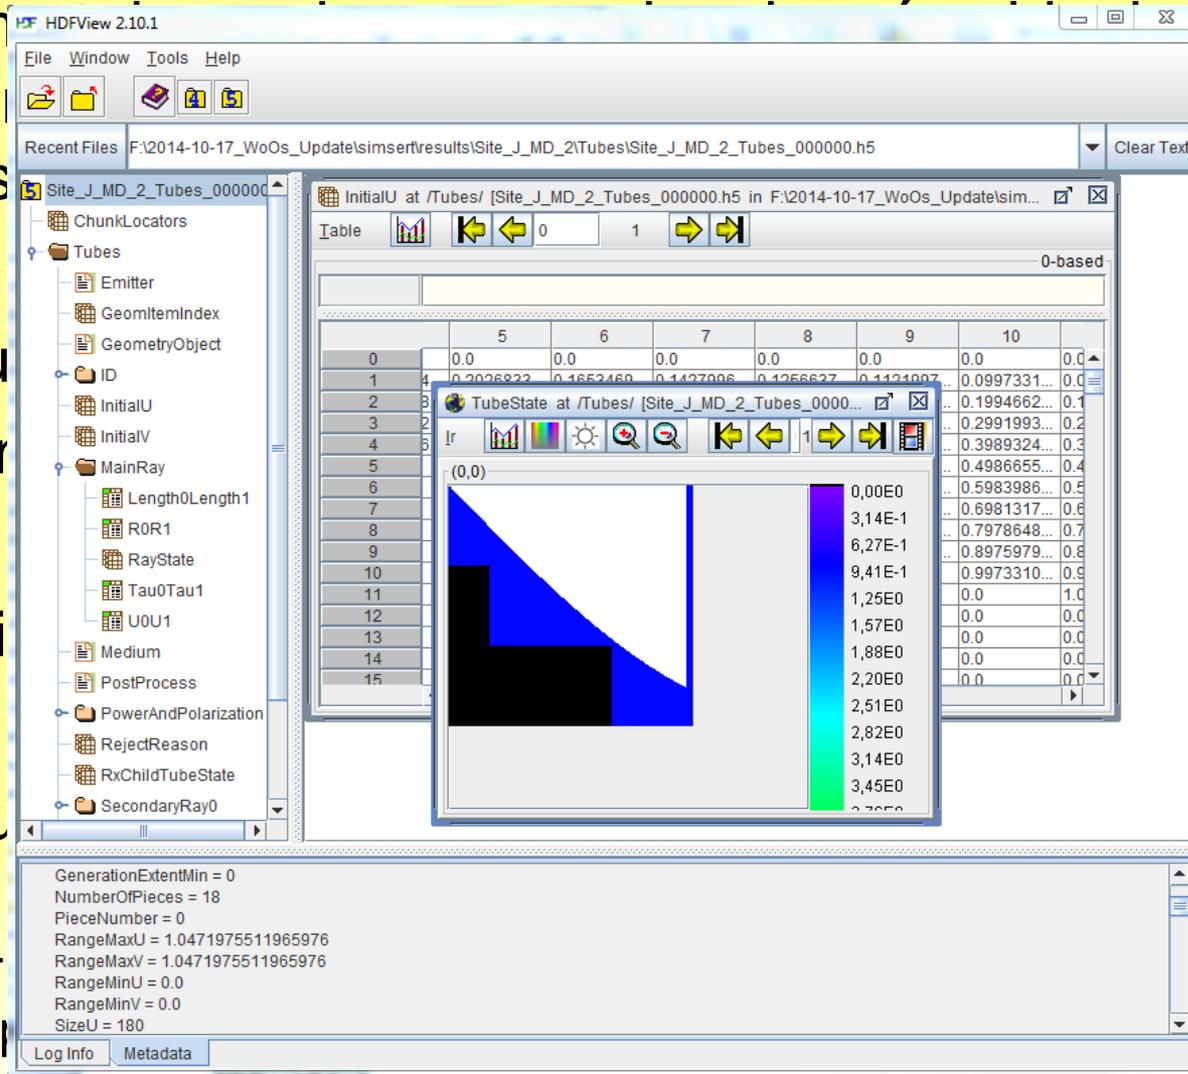


HDF5

- Un format de stockage pour des données binaires structurées, notamment pour les matrices à plusieurs dimensions
- Structuration arborescente auto-décrite (group, dataset)
- Gestion native d'un système de méta-données (attributs)
- Outil bien pratique : HDFView
- API multiplateforme à plusieurs niveaux
 - Haut niveau : portée dans de nombreux langages (C++, Java, python, IDL, matlab(?))
 - Complète : C uniquement

HDF5

- Un format de données multidimensionnelles
- Structure de données
- Gestion des attributs
- Outil de visualisation
- API multi-plateformes
 - Haut niveau (C++)
 - Compilé



s

eurs

tributs)

HDF5

- Stockage et mapping mémoire (dataspaces)
- Accès aléatoires optimisés
- Stockage de matrices creuses
 - Découpage des datasets en chunks
 - Compression par chunk
- Gestion de “familles” de fichiers (découpage)
- API parallèle (MPI)

- Avec SimSERT
 - Besoin de nombreux modes de lectures partielles et aléatoires
 - Optimisation des paramètres de chunk :
compromis taille des paquets / taille des fichiers

HDF5 & VTK

- Remarque : même approche de la structuration “array” plutôt que “objet”
- On peut donc directement lire un fichier HDF5 dans une structure VTK
- → On optimise l’utilisation et les allocations mémoire jusqu’au rendu 3D

Quelques liens pour aller plus loin...

- **Présentations CED 2015**
(Caroline Bligny, Bruno Bzeznik, Franck Pérignon - LJK/CIMENT)
- **Site Kitware VTK + ParaView :**
<http://www.kitware.com/opensource/paraview.html>
<http://www.kitware.com/opensource/vtk.html>
- **Mise en place cluster ParaView:**
http://www.vtk.org/Wiki/images/a/a1/Cluster09_PV_Tut_Setup.pdf
- **Site HDF5:** <http://www.hdfgroup.org/HDF5/>
- **Site CIMENT :** <https://ciment.ujf-grenoble.fr/wiki-pub/index.php>
- **Site Visit :** <https://wci.llnl.gov/simulation/computer-codes/visit/>
- **G-SCOP (INPG) – Projet Visionnaire :** [http://www.infra-visionair.eu./](http://www.infra-visionair.eu/)
- **Blog rosetta ☺ :** <http://blogs.esa.int/rosetta/>