

DATA
TERRA



ODATIS

Offres de services du pôle (Infrastructures HPC & VRE)

Gwenaël CAËR, Cyril GERMINEAUD



contact@odatis-ocean.fr | www.odatis-ocean.fr

Les infrastructures HPC

Le pôle ODATIS mets à disposition l'accès aux infrastructures de calcul du CNES (*TREX*) et de l'Ifremer (*DATARMOR*).



Cluster du CNES (TREX)



Cluster de l'Ifremer (DATARMOR)

Les infrastructures HPC

Comment y accéder ? Une simple commande SSH, et vous voilà connecté au cluster.

```
DATARMOR

*****

Welcome to DATARMOR supercomputing center
You can use this shell for job scheduling via PBS, light editing/vizualisation of scripts and
data
Please, do NOT try to compute anything directly here, nor download large amounts of data.

Documentation : https://w3z.ifremer.fr/intraric/Mon-IntraRIC/Calcul-et-donnees-scientifiques
Any questions ? --> assistance@ifremer.fr

INFO : NEXT AUTUMN, modification of the way to connect to Datarmor :
'ssh datarmor' REPLACED by 'ssh datarmor-access'.
You can - and should - already use this hostname to get yourself accustomed

datahome/gcaer% █
```

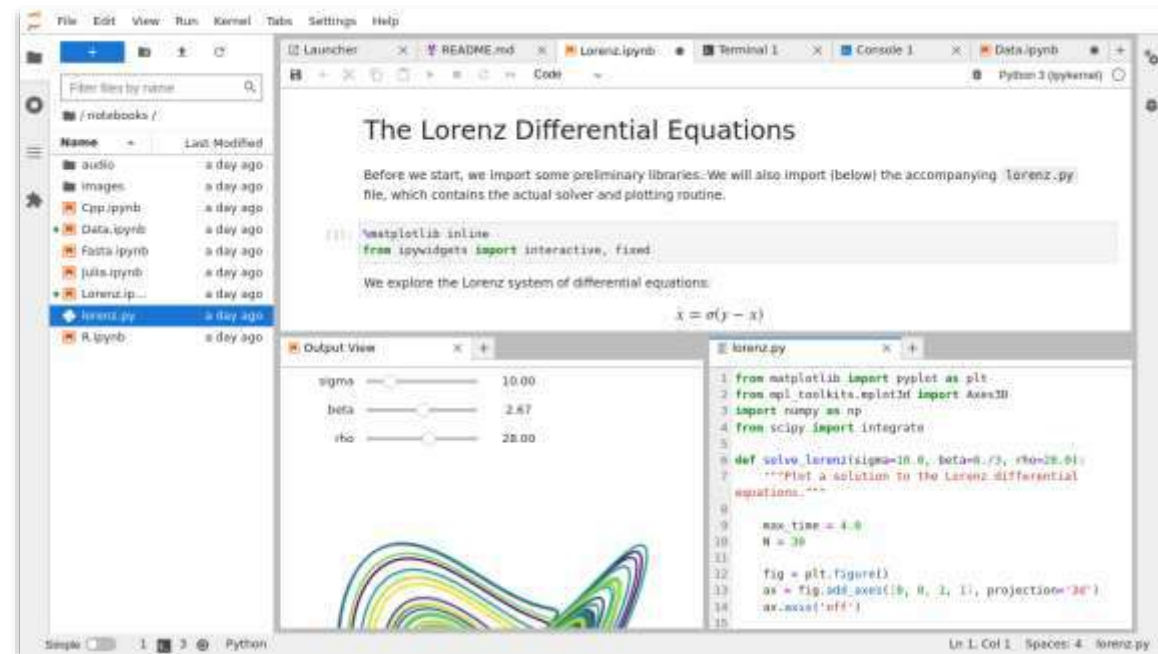

Les infrastructures HPC

Comment y accéder ? Une simple commande SSH, et vous voilà connecté au cluster.



VRE (Environnement Virtuel de Recherche)

Un VRE pour Environnement Virtuel de Recherche, correspond à une plateforme interactive, permettant de faciliter l'accès aux données et aux ressources des infrastructures (*calculs, logiciels, documentations ...*).



VRE (Concrètement, comment ça fonctionne ?)

Travailler à distance ... comme si vous étiez en local.

1 Accéder à l'URL
(et se connecter)

<https://jupyterhub.cnes.fr> (ou ifremer.fr)

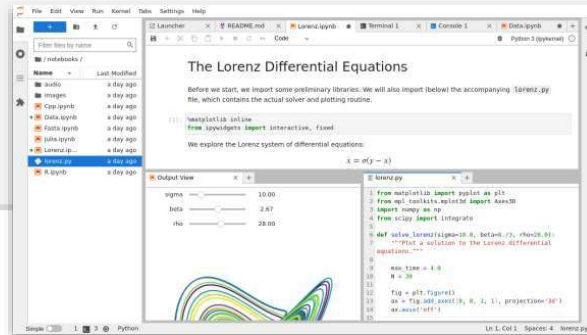
connexion

2 Sélectionner les
ressources (CPU,
RAM, Durée, ..)

Sélection des ressources

1 coeur, 4gb, 8 heures
8 coeurs, 32gb, 8 heures
28 coeurs, 115gb, 8 heures

3 Commencer à
l'utiliser la VRE
(Données, Analyse,
Visualisation, ...)



VRE (Concrètement, comment ça fonctionne ?)

Travailler à distance ... comme si vous étiez en local.

1 Accéder à l'URL (et se connecter)

<https://jupyterhub.cnes.fr> (ou ifremer.fr)

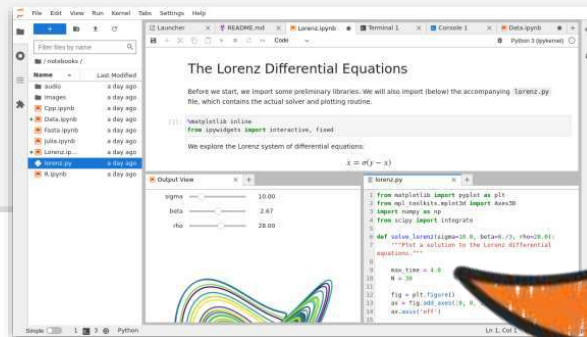
connexion

2 Sélectionner les ressources (CPU, RAM, Durée, ..)

Sélection des ressources

1 coeur, 4gb, 8 heures
8 coeurs, 32gb, 8 heures
28 coeurs, 115gb, 8 heures

3 Commencer à l'utiliser la VRE (Données, Analyse, Visualisation, ...)



Les données

- Accès au catalogue 
- Accès distant (via S3, HTTPS, OPeNDAP, FTP, ...)

VRE (Concrètement, comment ça fonctionne ?)

Travailler à distance ... comme si vous étiez en local.

1 Accéder à l'URL (et se connecter)

<https://jupyterhub.cnes.fr> (ou ifremer.fr)

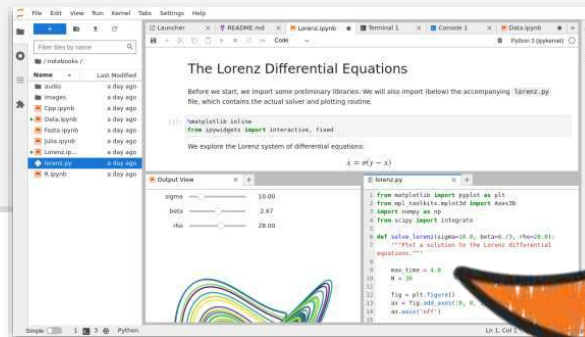
connexion

2 Sélectionner les ressources (CPU, RAM, Durée, ..)

Sélection des ressources

1 coeur, 4gb, 8 heures
8 coeurs, 32gb, 8 heures
28 coeurs, 115gb, 8 heures

3 Commencer à l'utiliser la VRE (Données, Analyse, Visualisation, ...)



Les données

- Accès au catalogue 
- Accès distant (via S3, HTTPS, OPeNDAP, FTP, ...)

Les ressources

- Calcul (CPU/GPU, RAM, ...)
- Langages (Python, R, Julia)
- Environnements (de base (pangeo) ou personnalisés)
- Outils (QGIS, Git, ...)

VRE (Concrètement, comment ça fonctionne ?)

Travailler à distance ... comme si vous étiez en local.

1 Accéder à l'URL (et se connecter)

<https://jupyterhub.cnes.fr> (ou ifremer.fr)

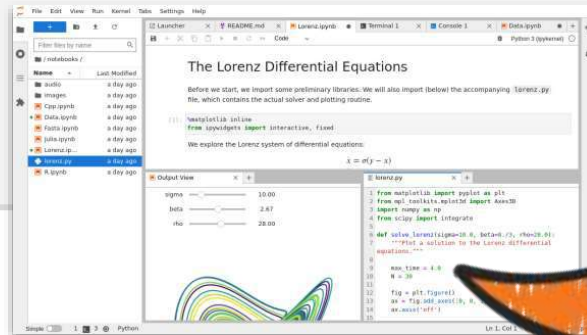
connexion

2 Sélectionner les ressources (CPU, RAM, Durée, ..)

Sélection des ressources

1 coeur, 4gb, 8 heures
8 coeurs, 32gb, 8 heures
28 coeurs, 115gb, 8 heures

3 Commencer à l'utiliser la VRE (Données, Analyse, Visualisation, ...)



Les données

- Accès au catalogue 
- Accès distant (via S3, HTTPS, OPeNDAP, FTP, ...)

Les ressources

- Calcul (CPU/GPU, RAM, ...)
- Langages (Python, R, Julia)
- Environnements (de base (pangeo) ou personnalisés)
- Outils (QGIS, Git, ...)

Les services (Helpdesk)


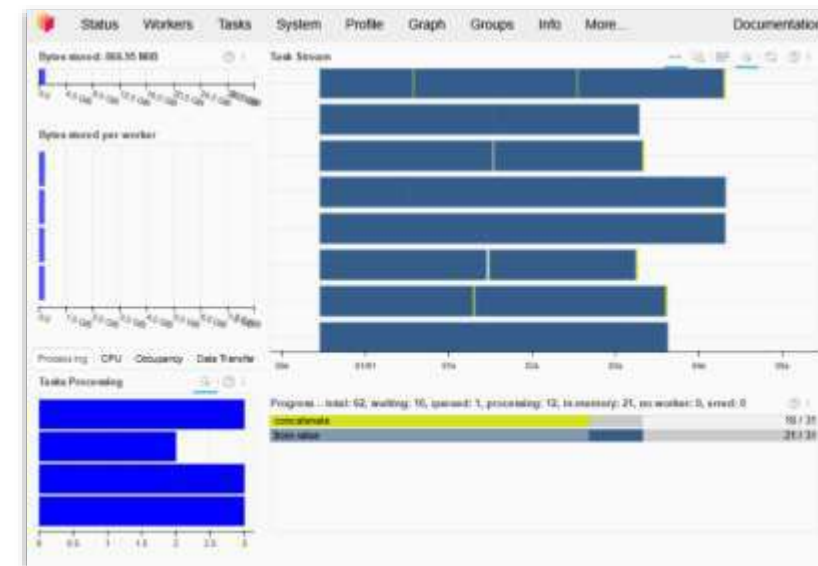
- Documentation (Premiers pas, FAQ, Tutoriels ...) <https://odatis-public.gitlab-pages.ifremer.fr/vre/documentation>
- Cas d'usages (Illustration de l'utilisation de la VRE pour traiter des problématiques scientifiques.)

Cas d'usages

Traitement des données de fibre optique (DAS)

Dans le cadre d'une campagne menée en Sicile par une équipe de [Geo-Ocean](#), un volume très important de données a été acquis (environ 20To). L'idée de ce cas d'usages est d'étudier comment optimiser la lecture, le traitement et la visualisation d'un tel volume de données ?

- Les notions abordées:
 - Comment paralléliser la lecture de milliers de fichiers ?
 - Comment appliquer des traitements en parallèle ?
 - Comment visualiser les données de manière interactive et optimisée ?
- Développement d'une librairie en cours.



Cas d'usages

Traitement des données d'imagerie benthique

Dans le cadre du projet [DeepSeaSpy](#) mené par le LEP, un grand nombre d'annotation d'espèce provenant de la science participative sont disponible. L'idée de ce cas d'usage est d'étudier comment utiliser des données citoyennes pour entraîner un modèle d'IA, afin d'annoter de futures images de manière automatique ?


- Les notions abordées:
 - Comment accéder aux données sur le HPC ?
 - Comment nettoyer les données ?
 - Comment utiliser les ressources GPU pour entraîner un modèle d'IA ?
 - Comment utiliser le modèle pour annoter de nouvelles images ?




Cas d'usages

Colocalisation des données in situ et satellitaires

Dans le cadre de nombreux travaux de recherche, une étape importante est la colocalisation des données. L'idée de ce cas d'usage est d'étudier comment utiliser des outils communs aux géosciences ([Xarray](#), [Kerchunk](#), [Dask](#)), pour optimiser la colocalisation d'un grand nombre de données ?



- Les notions abordées:
 - Comment utiliser Kerchunk pour émuler un fichier zarr à partir de milliers de fichiers unitaire ?
 - Comment utiliser Xarray pour ouvrir un datacube ?
 - Comment utiliser et optimiser dask pour la lecture et l'extraction des données ?
- Développement d'une librairie de colocalisation : [PytCube](#)




 PytCube

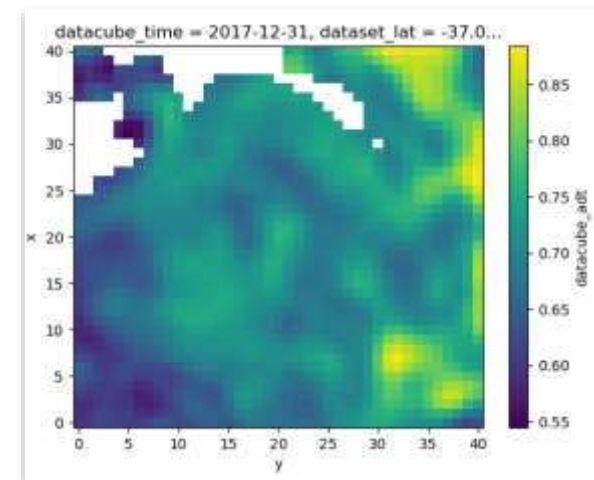
Cas d'usages

Colocalisation des données in situ et satellitaires

Dans le cadre de nombreux travaux de recherche, une étape importante est la colocalisation des données. L'idée de ce cas d'usage est d'étudier comment utiliser des outils communs aux géosciences ([Xarray](#), [Kerchunk](#), [Dask](#)), pour optimiser la colocalisation d'un grand nombre de données ?



- Les notions abordées:
 - Comment utiliser Kerchunk pour émuler un fichier zarr à partir de milliers de fichiers unitaire ?
 - Comment utiliser Xarray pour ouvrir un datacube ?
 - Comment utiliser et optimiser dask pour la lecture et l'extraction des données ?
- Développement d'une librairie de colocalisation : [PytCube](#)



Vous avez une idée de cas d'usages ? N'hésitez pas à nous contacter.

 **PytCube**

Perspectives

L'offre de service VRE du pôle ODATIS se concentre pour l'instant sur la solution JupyterLab, mais elle a vocation à s'élargir à l'avenir en incluant d'autres solutions, telles que **Galaxy**.

