Pangeo

A community platform
for Big Data geoscience

Sommaire

Pangeo

- Qu'est-ce?
- Architecture

Pile logicielle

- Jupyter
- Xarray
- Dask

Atelier

Pangeo – Qu'est-ce?

A community platform for Big Data geoscience

- Un écosystème logiciels "big data geosciences"
- Une communauté internationale de développeurs
- Une infrastructure partagée sur le cloud

Mission : entretenir un écosystème dans lequel la prochaine génération d'outils, d'analyse « open source » pour les géosciences appliquée à de gros volumes de données peut être développée, distribuée et maintenue.

Vision:

- Développement ouvert et collaboratif.
- Outils de mise à l'échelle des calculs pour des ensembles de données de petite à très grande taille.
- Structures pour intégrer l'analyse scientifique aux données.
- Encourager une culture du développement accueillante et participative.

Présentation: ESIP Tech Dive (01/2018) par Ryan Abernathy & Matthew Rocklin

Site web: http://pangeo.io/

Github: https://github.com/pangeo-data

Blog: https://medium.com/pangeo

Gitter: https://gitter.im/pangeo-data

Pangeo - Architecture

Données, prêtes à l'analyse, stockées et cataloguées sur un système de stockage distribué accessible à l'échelle globale (p. ex. S3, GCS)

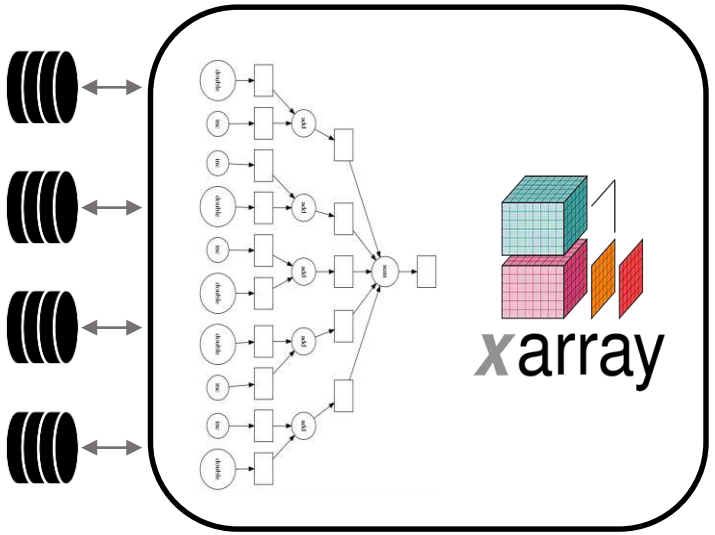

Système de calcul parallèle construit sur Kubernetes ou HPC.
Dask dit aux nœuds ce qu'ils doivent faire.

Jupyter pour un accès interactif sur des systèmes distants.

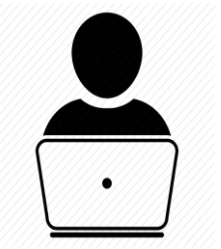

xarray fournit des structures de données et une interface intuitive pour interagir avec les ensembles de données.

Pangeo – Pile logicielle

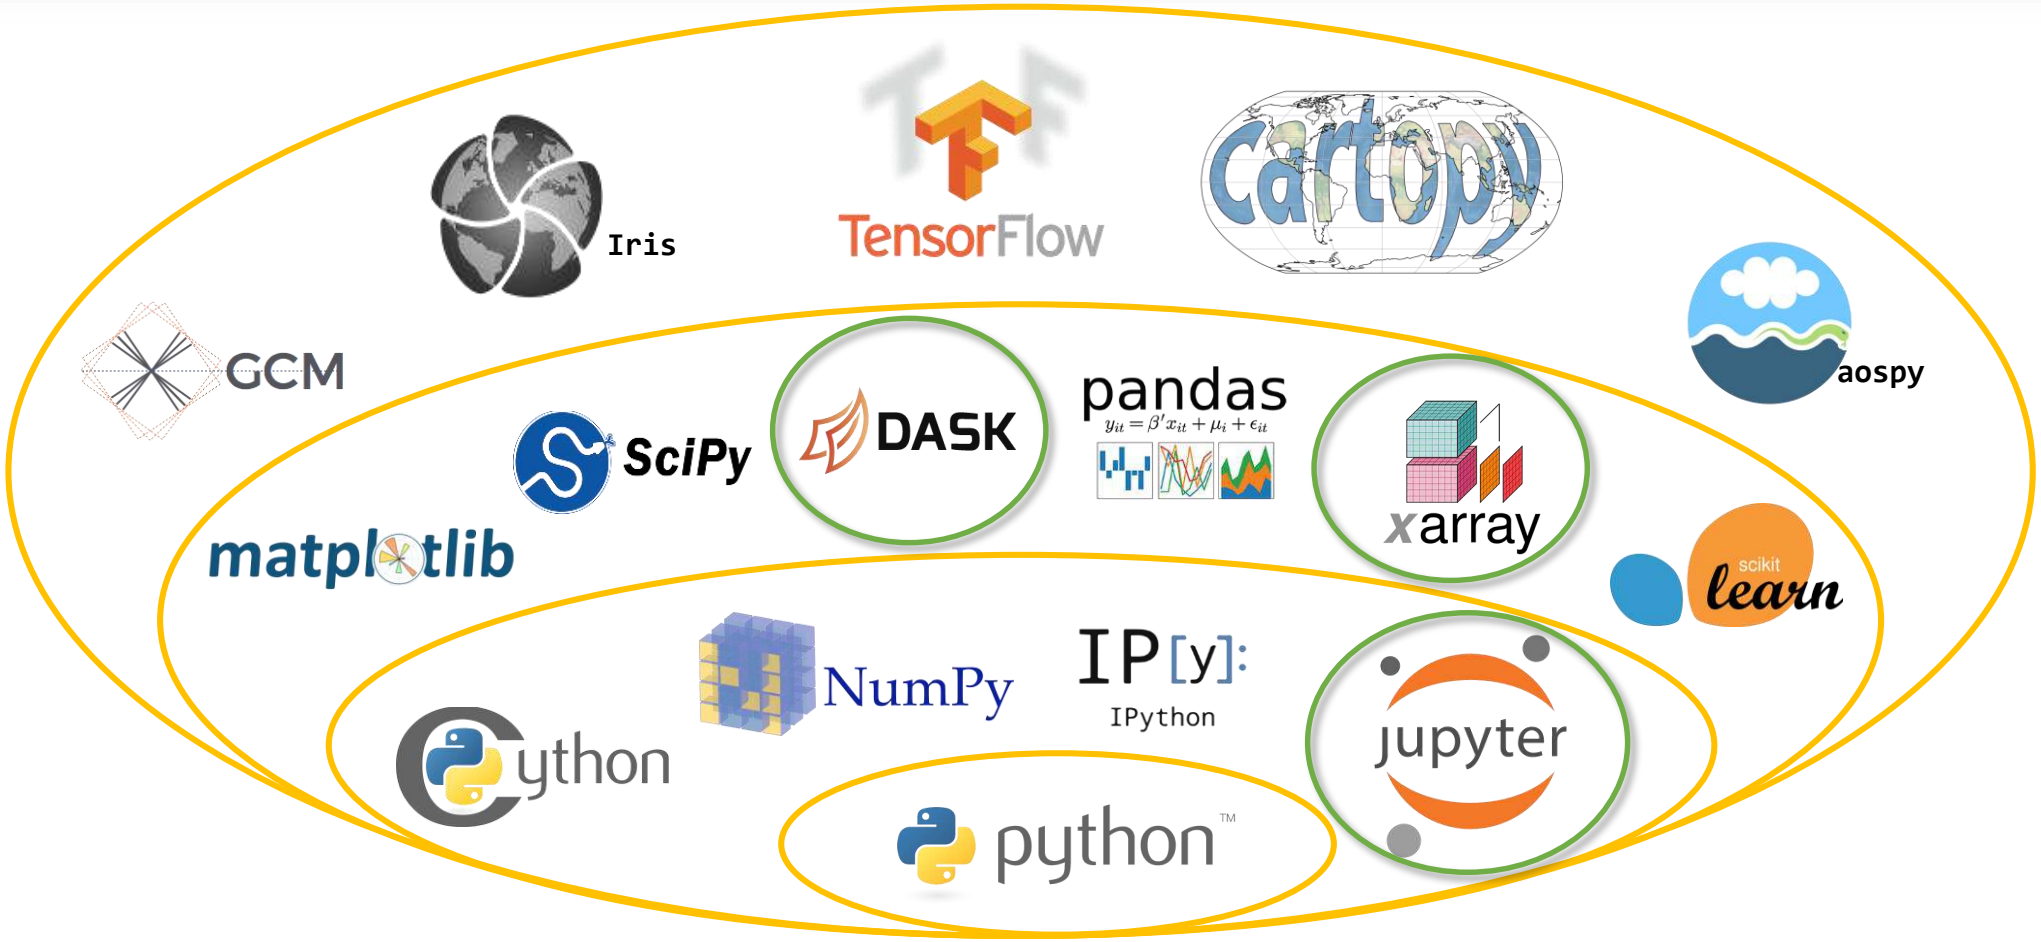

Un environnement de calcul interactif

Un format de document reproductible :

- Code
- Texte
- Equations (LaTeX)
- Visualisations

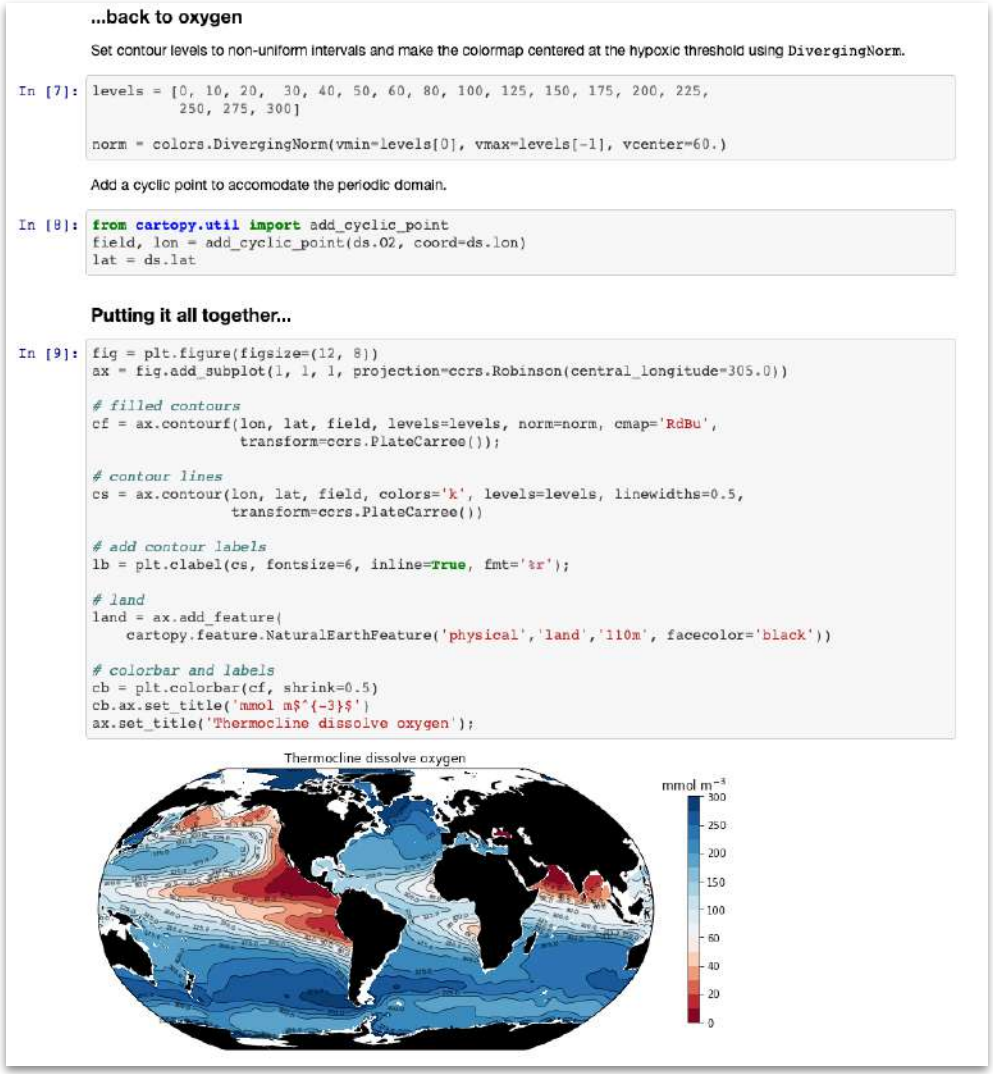

...back to oxygen

Set contour levels to non-uniform intervals and make the colormap centered at the hypoxic threshold using `DivergingNorm`.

```
In [7]: levels = [0, 10, 20,  30, 40, 50, 60, 80, 100, 125, 150, 175, 200, 225,
                  250, 275, 300]

        norm = colors.DivergingNorm(vmin=levels[0], vmax=levels[-1], vcenter=60.)
```

Add a cyclic point to accomodate the periodic domain.

```
In [8]: from cartopy.util import add_cyclic_point
        field, lon = add_cyclic_point(ds.o2, coord=ds.lon)
        lat = ds.lat
```

Putting it all together...

```
In [9]: fig = plt.figure(figsize=(12, 8))
        ax = fig.add_subplot(1, 1, 1, projection=ccrs.Robinson(central_longitude=305.0))

        # filled contours
        cf = ax.contourf(lon, lat, field, levels=levels, norm=norm, cmap='RdBu',
                         transform=ccrs.PlateCarree());

        # contour lines
        cs = ax.contour(lon, lat, field, colors='k', levels=levels, linewidths=0.5,
                        transform=ccrs.PlateCarree())

        # add contour labels
        lb = plt.clabel(cs, fontsize=6, inline=True, fmt='%r');

        # land
        land = ax.add_feature(
            cartopy.feature.NaturalEarthFeature('physical','land','110m', facecolor='black'))

        # colorbar and labels
        cb = plt.colorbar(cf, shrink=0.5)
        cb.ax.set_title('mmol m$^{-3}$')
        ax.set_title('Thermocline dissolve oxygen');
```

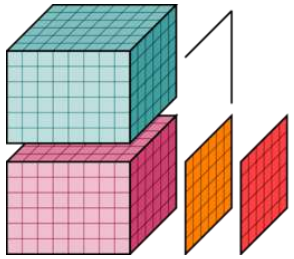

xarray

- Structures de données pour tableaux N-D
- Une API inspirée de pandas
- Interopérable avec les outils standards pydata

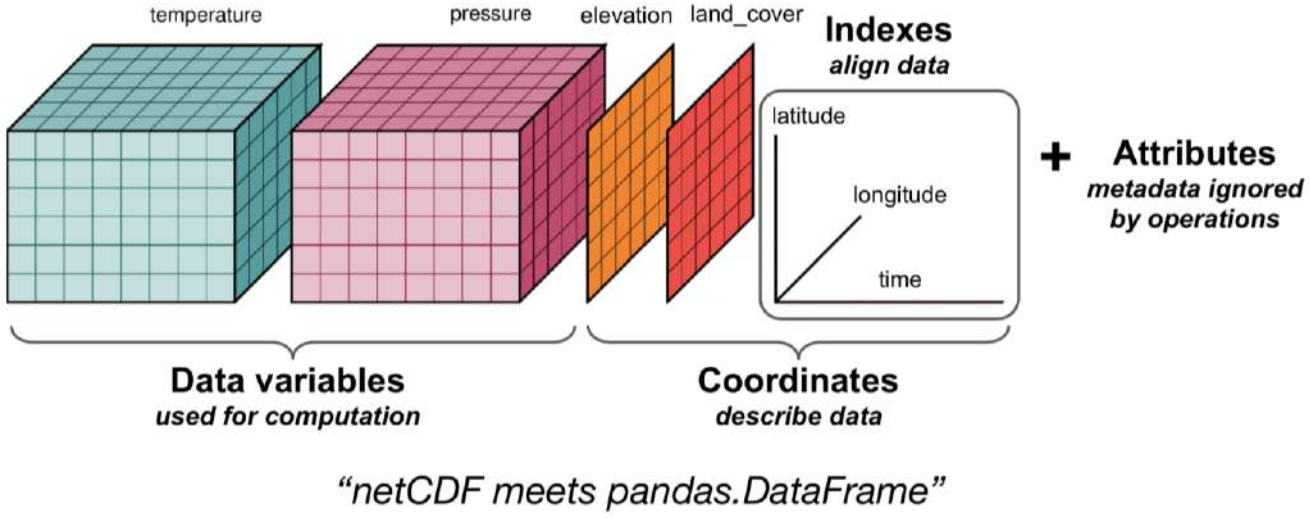

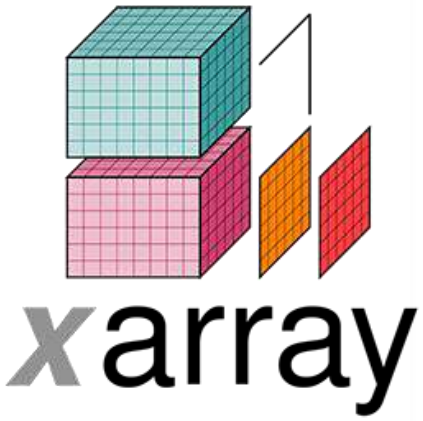


```
sst_clim = sst.groupby('time.month').mean(dim='time')
sst_anom = sst.groupby('time.month') - sst_clim
nino34_index = (sst_anom.sel(lat=slice(-5, 5), lon=slice(190, 240))
                        .mean(dim=('lon', 'lat'))
                        .rolling(time=3).mean(dim='time'))
nino34_index.plot()
```

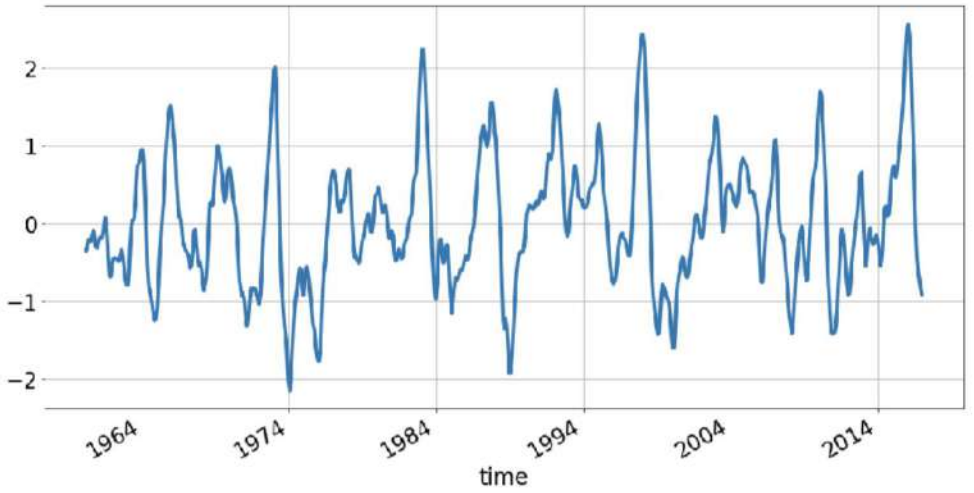

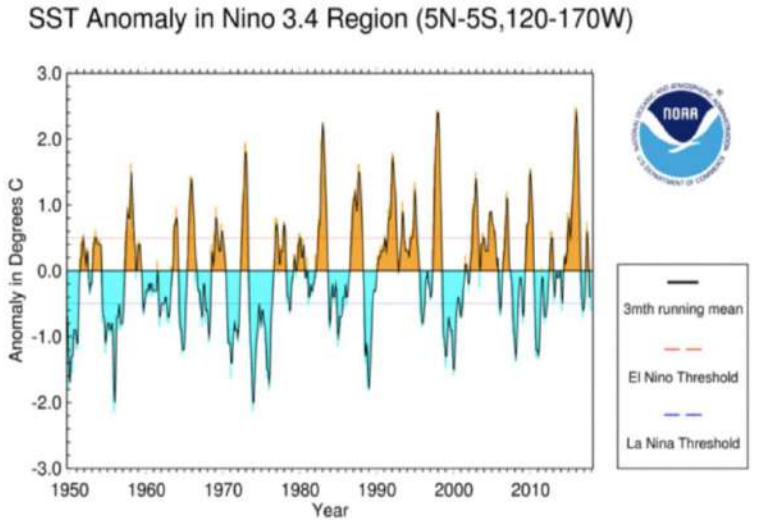

DASK

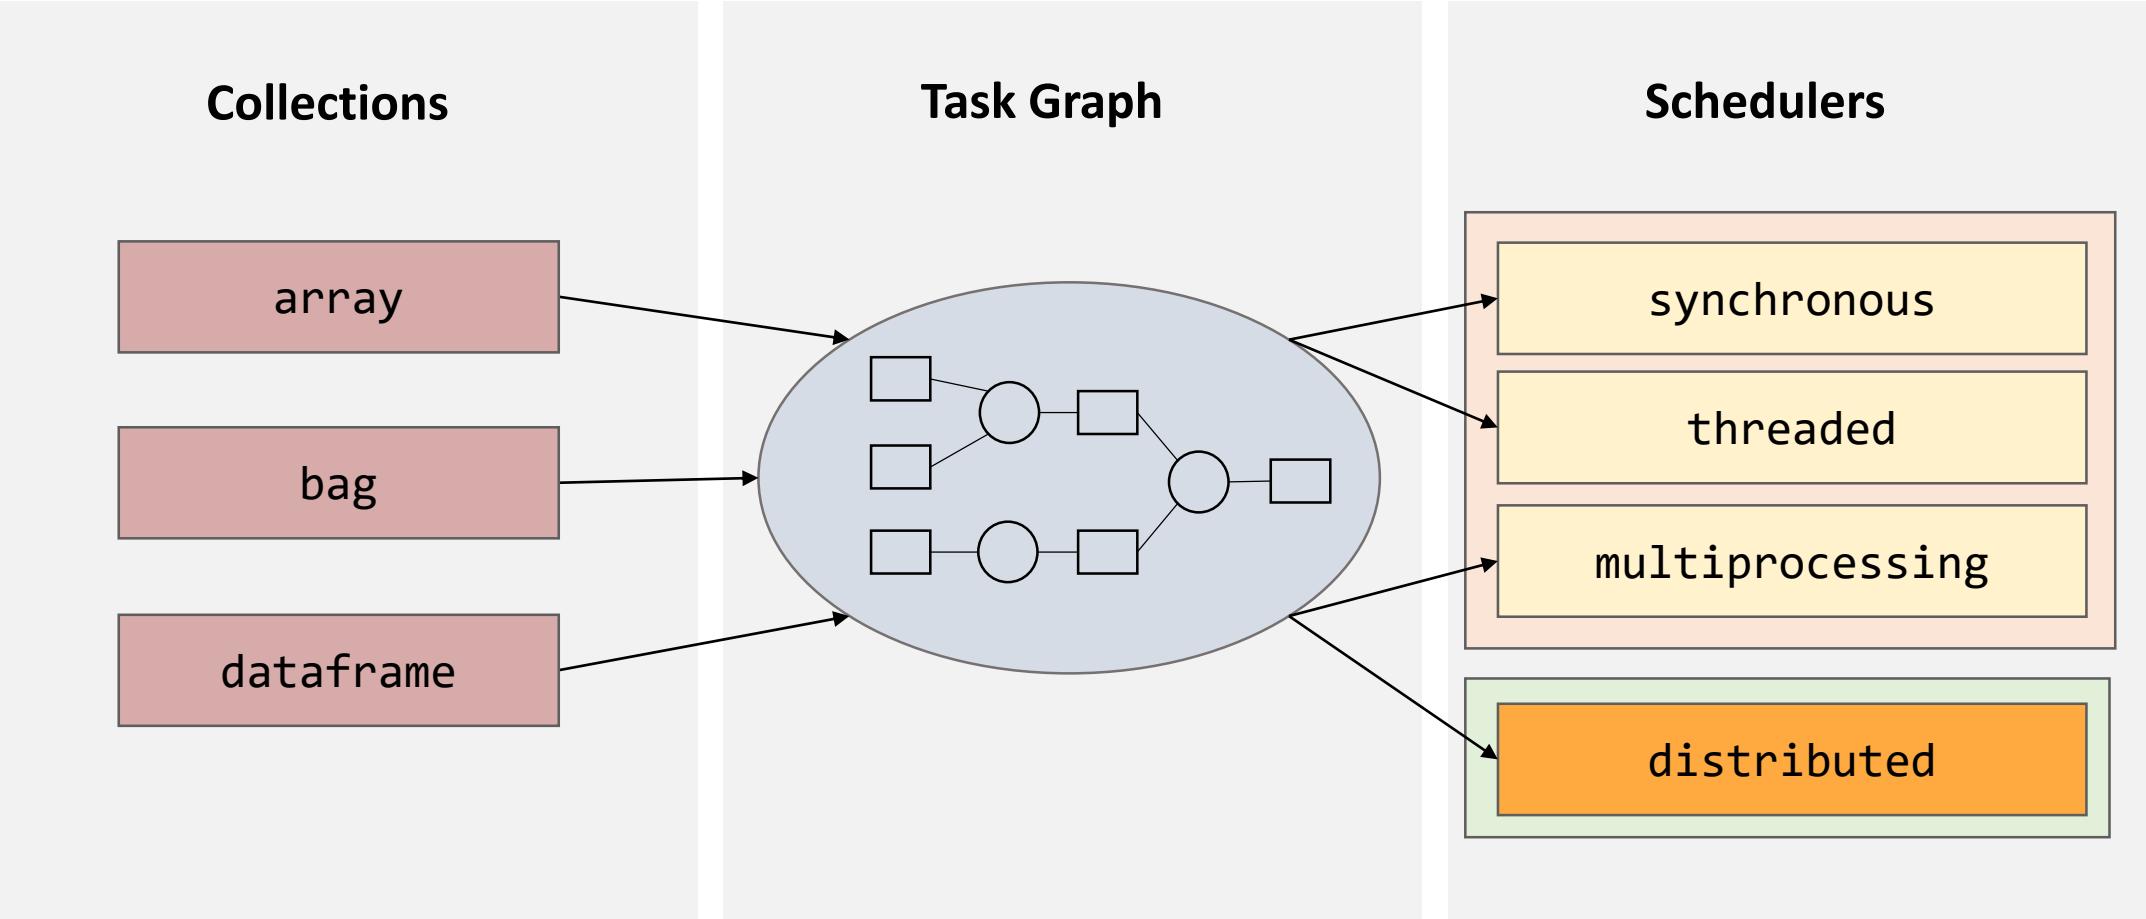
Collections
Task Graph
Schedulers
array
bag
dataframe
synchronous
threaded
multiprocessing
distributed

Dask – Connexion des utilisateurs de Python au HPC

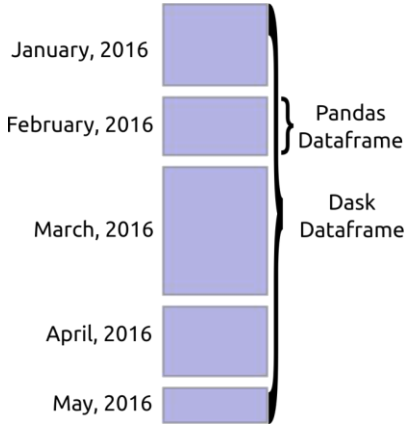

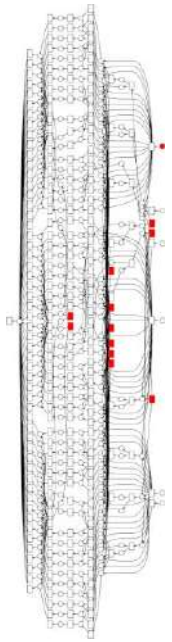

Utilisateur → Ecrit un code de haut niveau (NumPy/Pandas/Scikit-Learn) → Se transforme en graphe → S'exécute sur le HPC

Dask – Ecosystème

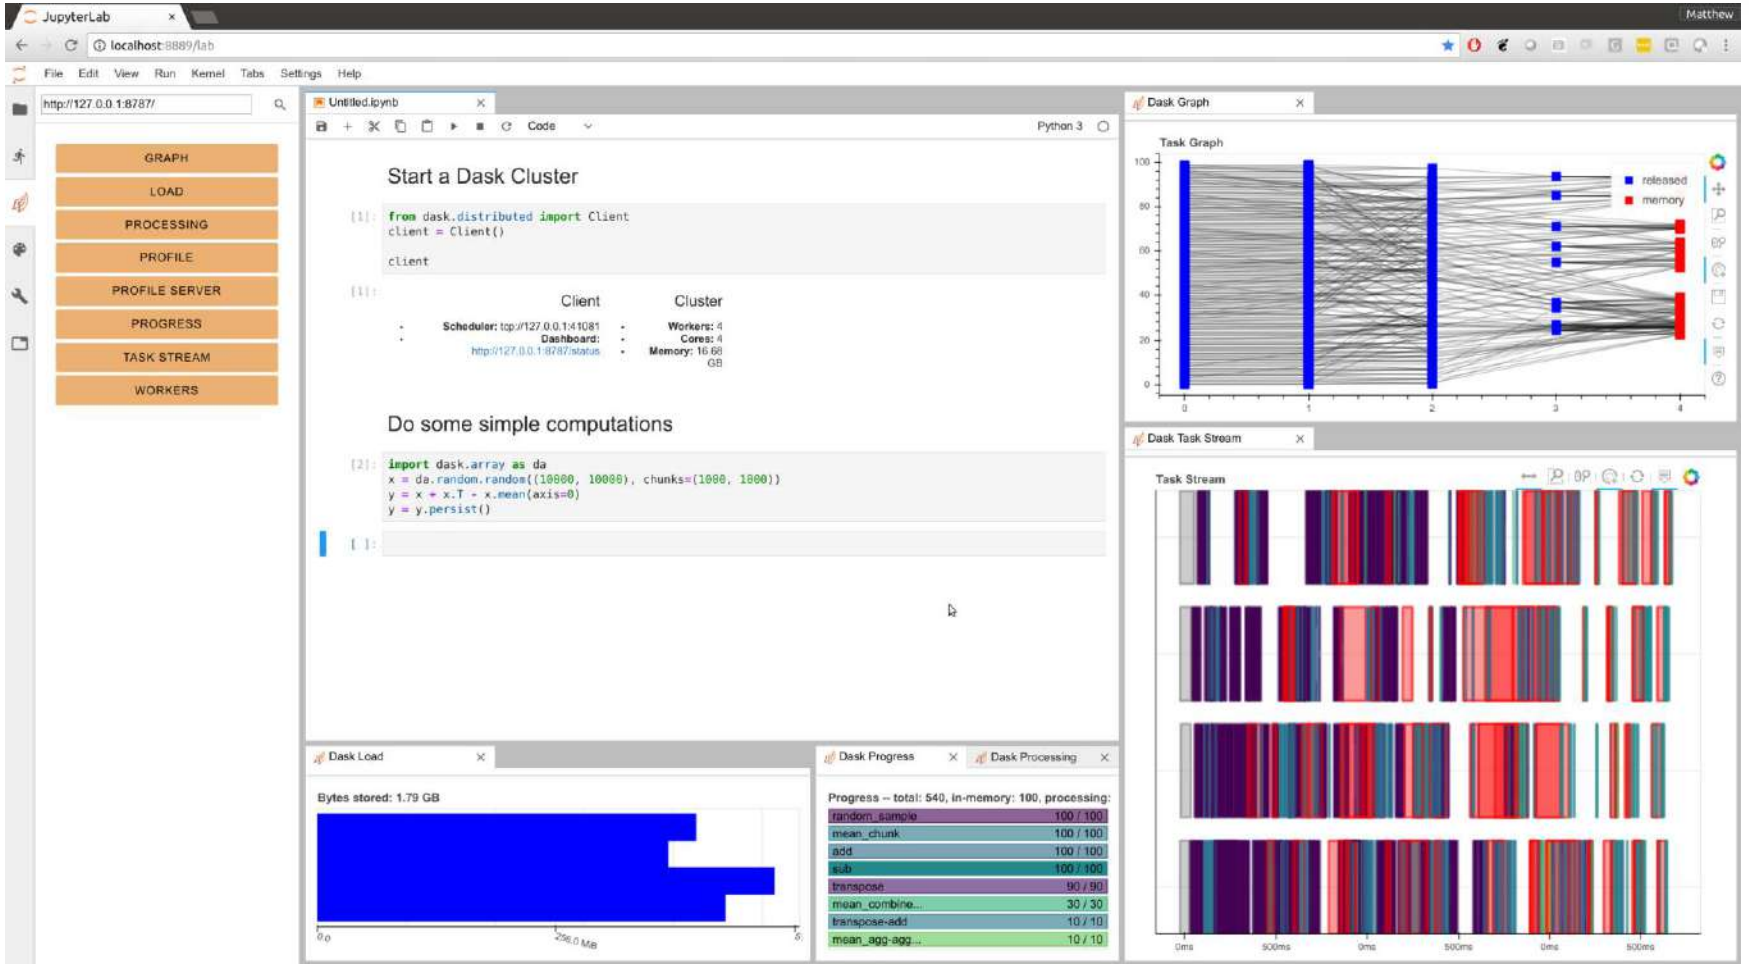

Atelier sur HAL

Ces différents notebooks permettent de découvrir les concepts présentés plus haut. Les différentes cellules présentées doivent juste être exécutées. Ouvert à tous publics : débutant ou non.

Présentation des concepts de Dask

- pangeo_01_dask.ipynb

Analyse des grilles DUACS

- pangeo_02_duacs_l4.ipynb

xarray

- pangeo_03_xarray.ipynb

Atelier sur HAL

Ces différents notebooks permettent de découvrir et d'approfondir les concepts manipulés par dask: graphes, tableaux, scheduler. Les différentes cellules présentées doivent juste être exécutées, et il y a quelques exercices. Demande une connaissance plus approfondie de Python. Mais tout le monde peut les faire.

Les graphes de calcul

- 01_dask_delayed.ipynb

Les ordonnanceurs

- 02_distributed.ipynb

Les tableaux

- 03_array.ipynb

Analyse des collections

- 04_bag.ipynb

Autres aspects

Interpolation des données

Co-localisation

D'autres besoins ?