NII RCOS
Research Center for Open Science and Data Platform

分野横断的なオンライン分析システムの開発について

藤原 一毅
国立情報学研究所

2020/09/10

統計関連学会連合大会

オンライン分析システムとは

- NII は、人社データインフラ事業の一環として、オンライン分析システムの開発を進めています。
- 研究者は、オンライン分析システムにログインして、すぐに **R** や **Python** のプログラムを作成・実行することができます。
  - 手元のコンピュータに統計分析ソフトをインストールしたり、データを手元にダウンロードしたりする手間がかかりません。
- 共同研究者や学生は、汎用リポジトリに公開されている研究データとプログラムを**ボタンひとつで**オンライン分析システムに取り込み、すぐにデータ分析を始めることができます。
- 仕組みとしては、**Jupyter Notebook** の実行環境を NII がクラウド上で提供します。

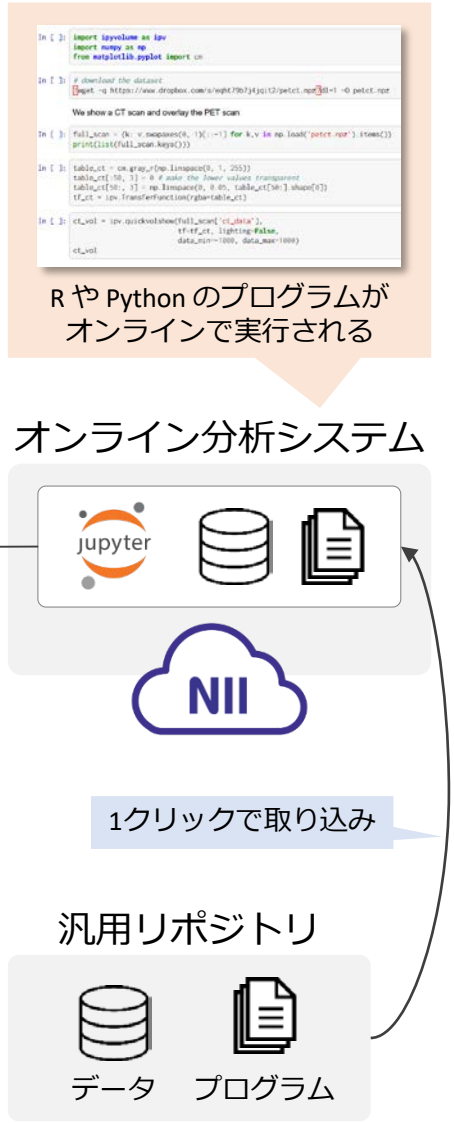

分野横断的な研究を簡単に始める

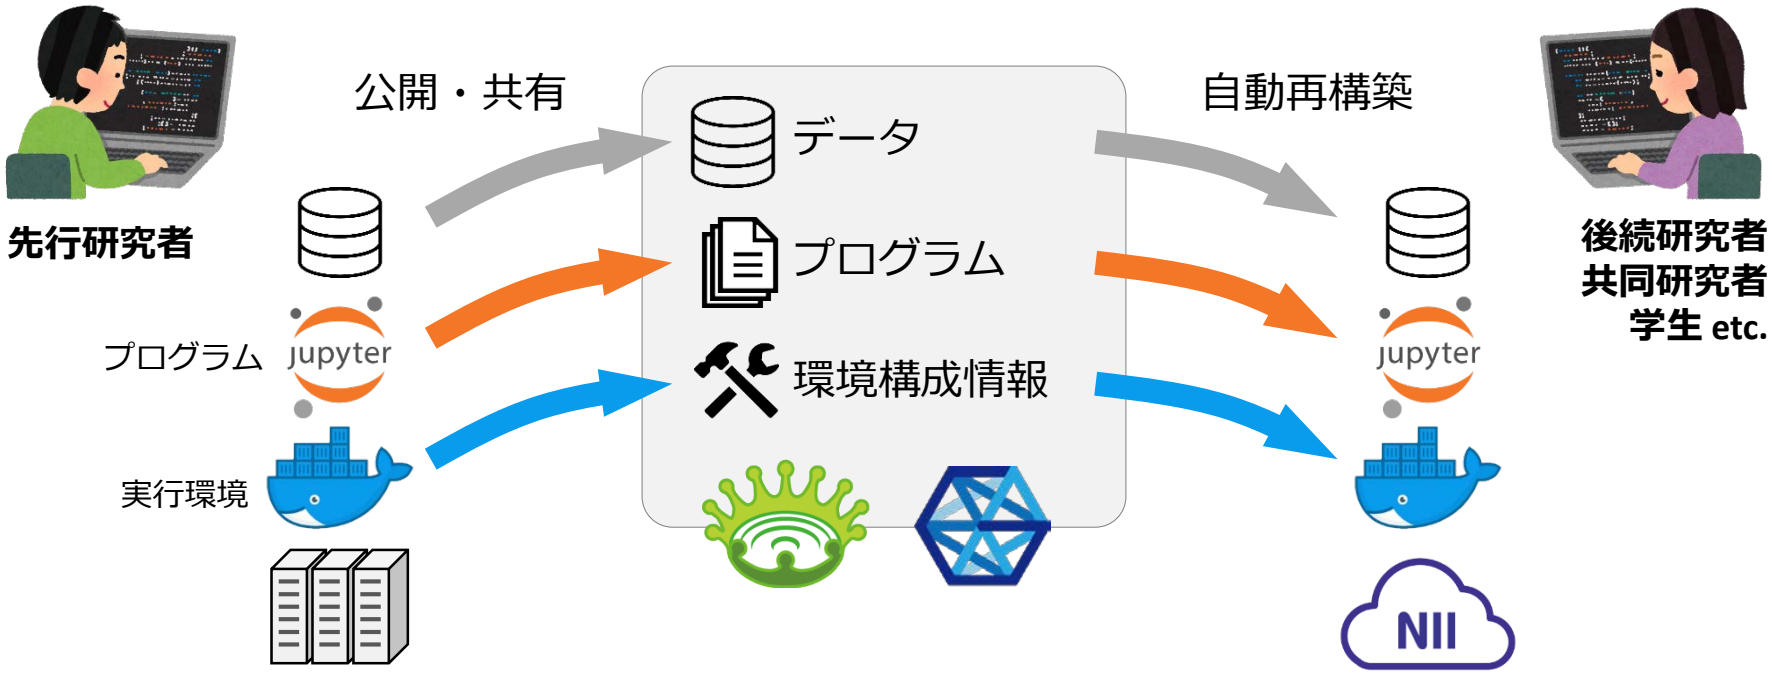

- 先行研究者は、データ・プログラム・環境構成情報をまとめてアップロードする
  - 一般公開なら WEKO / JAIRO Cloud へ、内部共有なら GakuNin RDM へ
- 後続研究者は、個人用のコンテナ環境上に実行環境を再構築し、プログラムを実行する
- 本サービスは、この**コンテナ再構築作業を自動化する**

ユースケース

研究公正

- 研究環境を別の研究者が再現し、成果を検証する

二次研究

- 研究環境を別の研究者が再現し、新たな研究を開始する

教育・学習

- 授業や研修の教材を受講者が各々再現し、学習する

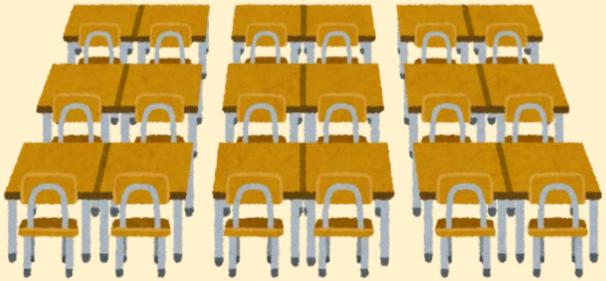

引き継ぎ

- 先輩の研究環境を後輩が再現し、研究を継続する

研究に使う例

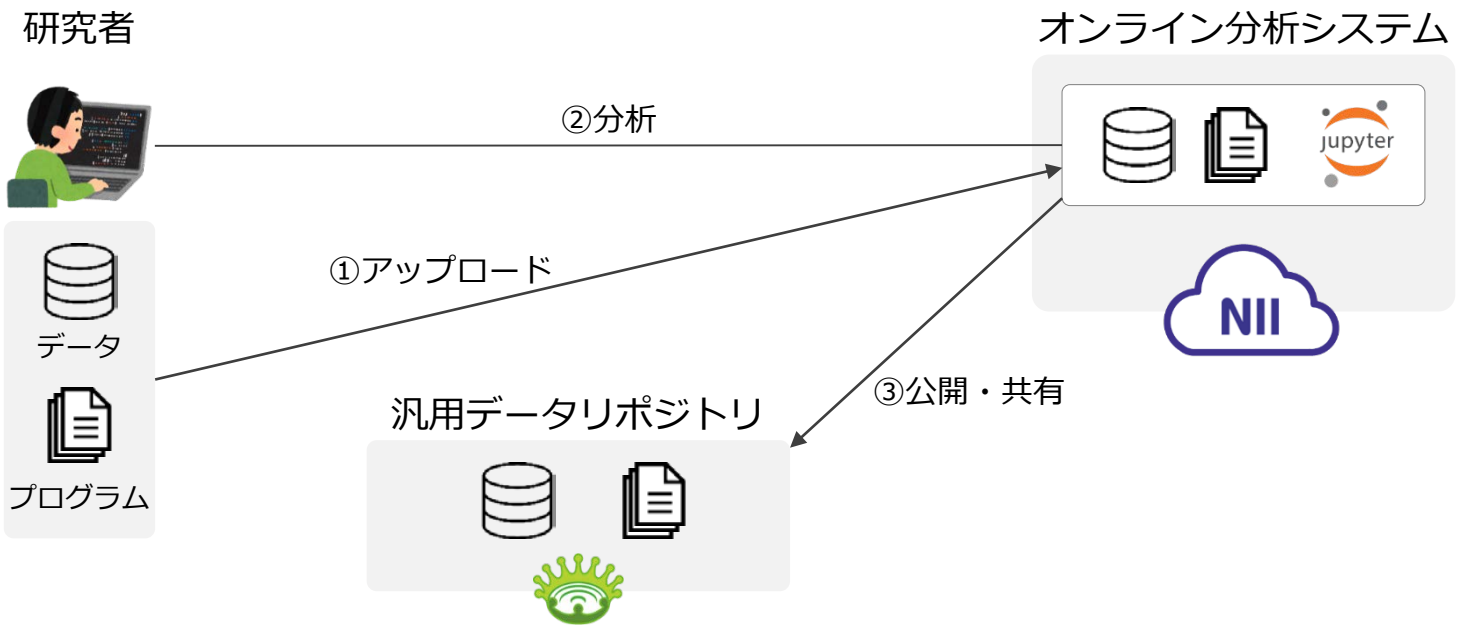

figshare zenodo The Dataverse Project GitHub GitLab

教育・学習に使う例

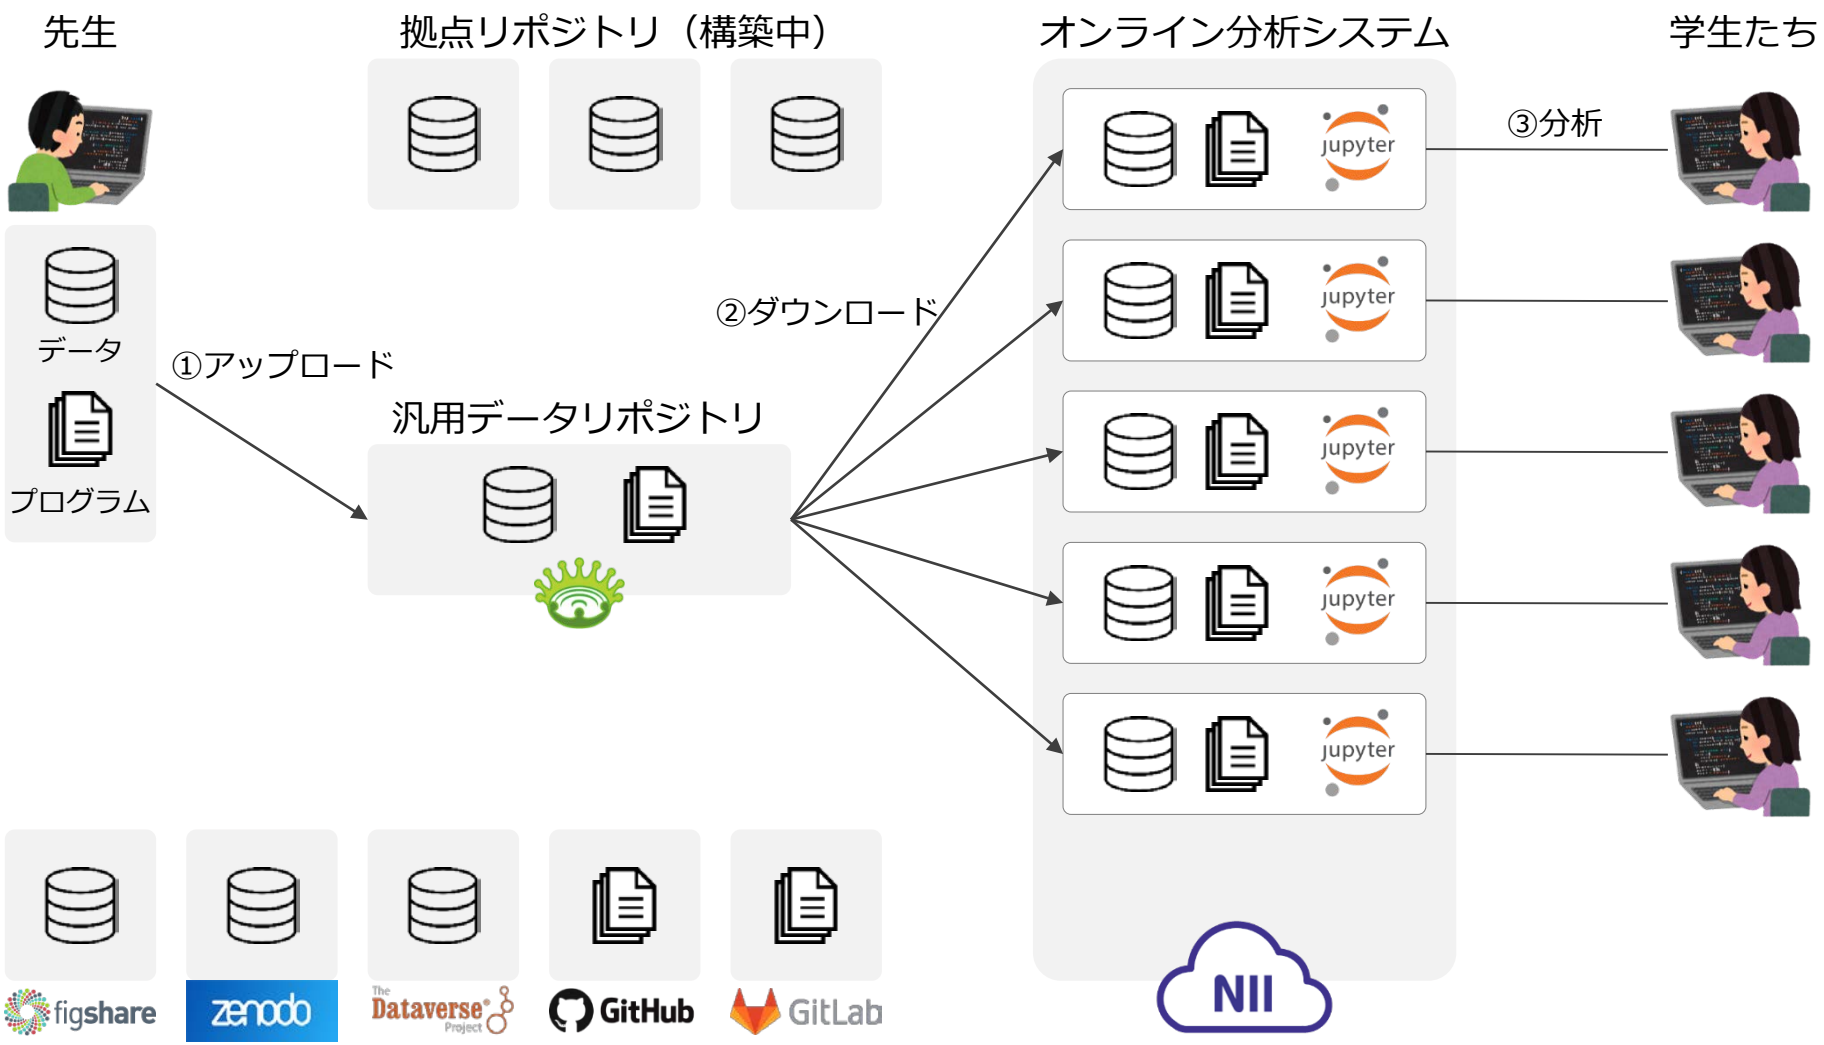
先生
拠点リポジトリ（構築中）
オンライン分析システム
学生たち
データ
プログラム
①アップロード
汎用データリポジトリ
②ダウンロード
③分析
jupyter
jupyter
jupyter
jupyter
jupyter
figshare
zenodo
The Dataverse Project
GitHub
GitLab
NII

再構築手順

1. フォルダを選んで Launch を押す
2. 3分待つ※
3. 起動した Jupyter 環境でプログラムを実行する

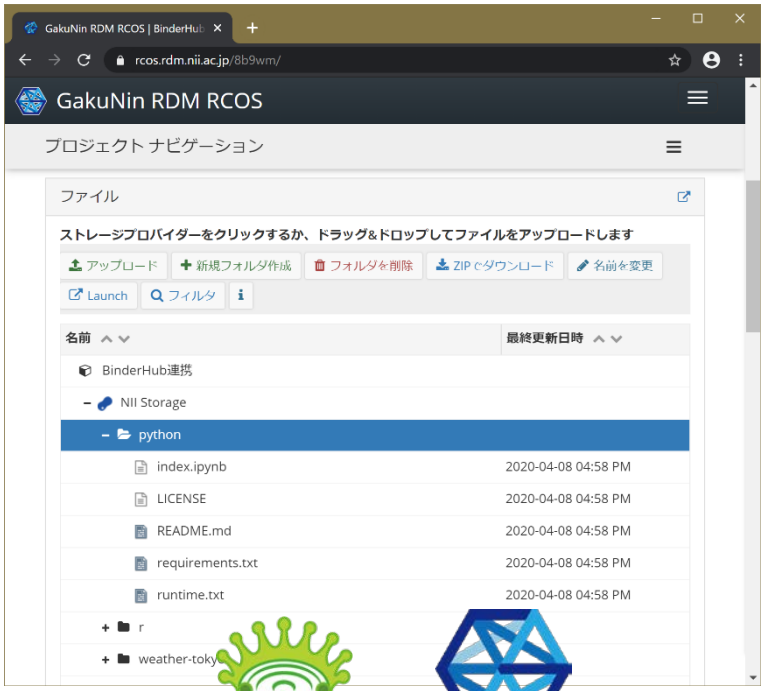

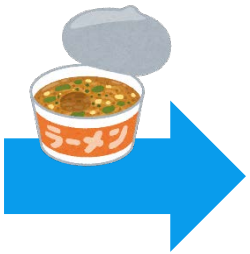

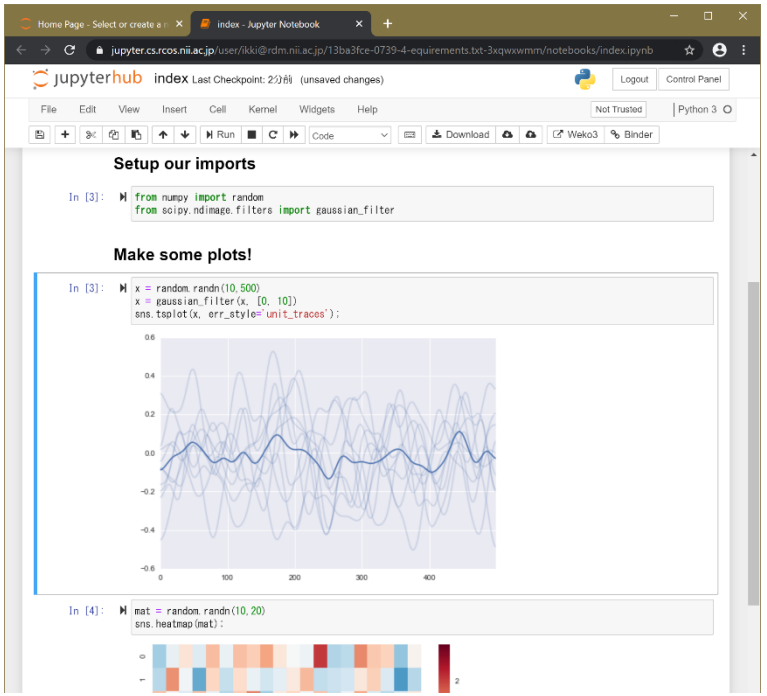

figshare zenodo The Dataverse Project

GitHub GitLab

NII

※待ち時間は再構築内容により前後します。初回はOAuth認証が必要です

環境構成情報

- 例: environment.yml

```
name: ipyvolume
channels:
 - conda-forge
dependencies:
 - nodejs
 - pip:
   - traittypes
   - traitlets
   - ipywidgets>=7.4
   - Pillow
   - scipy
   - numpy
   - scikit-image>=0.13
   - requests
   - ipywebrtc>=0.4
   - pythreejs>=1.0
   - matplotlib
   - jupyterlab>=0.34
   - notebook>=5.3
```

https://github.com/maartenbreddels/ipyvolume/blob/master/binder/environment.yml

- 例: Dockerfile

```
FROM jupyter/scipy-notebook:latest

# Install TF libraries
RUN wget
  https://storage.googleapis.com/tensorflow/libtensorflow/libtensorflow-
  cpu-linux-x86_64-1.14.0.tar.gz
RUN tar -C /usr/local -xzf libtensorflow-cpu-linux-x86_64-1.14.0.tar.gz
RUN rm libtensorflow-cpu-linux-x86_64-1.14.0.tar.gz
RUN ldconfig
# Install .NET Core SDK
ENV DOTNET_SDK_VERSION 3.1.101
RUN curl -SL --output dotnet.tar.gz
  https://dotnetcli.blob.core.windows.net/dotnet/Sdk/$DOTNET_SDK_VERSION/d
  otnet-sdk-$DOTNET_SDK_VERSION-linux-x64.tar.gz && mkdir -p
  /usr/share/dotnet && tar -zxf dotnet.tar.gz -C /usr/share/dotnet && rm
  dotnet.tar.gz && ln -s /usr/share/dotnet/dotnet /usr/bin/dotnet
# Enable detection of running in a container
ENV DOTNET_RUNNING_IN_CONTAINER=true
ENV DOTNET_USE_POLLING_FILE_WATCHER=true
ENV NUGET_XMLDOC_MODE=skip
ENV DOTNET_TRY_CLI_TELEMETRY_OPTOUT=true

# Install Microsoft.DotNet.Interactive
RUN dotnet tool install -g dotnet-interactive --add-source
  "https://dotnet.myget.org/F/dotnet-try/api/v3/index.json"
ENV PATH="${PATH}:${HOME}/.dotnet/tools"
RUN echo "$PATH"
# Install kernel specs
RUN dotnet interactive jupyter install
# Enable telemetry once we install jupyter for the image
ENV DOTNET_TRY_CLI_TELEMETRY_OPTOUT=false
# Set root to notebooks
WORKDIR ${HOME}/notebooks/
```

https://github.com/javiercp/BinderTF.NET/blob/master/Dockerfile

- コンテナに pip や Conda で任意のパッケージをインストールする
- コンテナ構築時に任意のコマンドを実行することもできる

プログラム

- 例: Jupyter Notebook

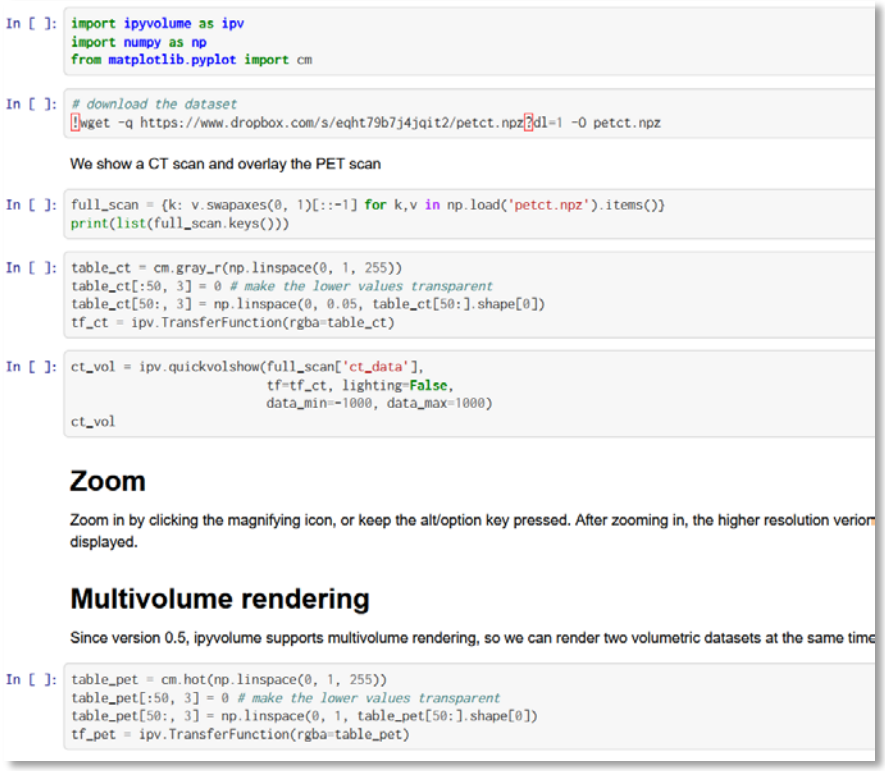

```
In [ ]: import ipyvolume as ipv
        import numpy as np
        from matplotlib.pyplot import cm

In [ ]: # download the dataset
        !wget -q https://www.dropbox.com/s/eqht79b7j4jqit2/petct.npz?dl=1 -O petct.npz
```

We show a CT scan and overlay the PET scan

```
In [ ]: full_scan = {k: v.swapaxes(0, 1)[::-1] for k,v in np.load('petct.npz').items()}
        print(list(full_scan.keys()))

In [ ]: table_ct = cm.gray_r(np.linspace(0, 1, 255))
        table_ct[:50, 3] = 0 # make the lower values transparent
        table_ct[50:, 3] = np.linspace(0, 0.05, table_ct[50:].shape[0])
        tf_ct = ipv.TransferFunction(rgba=table_ct)

In [ ]: ct_vol = ipv.quickvolshow(full_scan['ct_data'],
                               tf=tf_ct, lighting=False,
                               data_min=-1000, data_max=1000)
        ct_vol
```

Zoom

Zoom in by clicking the magnifying icon, or keep the alt/option key pressed. After zooming in, the higher resolution verior displayed.

Multivolume rendering

Since version 0.5, ipyvolume supports multivolume rendering, so we can render two volumetric datasets at the same time

```
In [ ]: table_pet = cm.hot(np.linspace(0, 1, 255))
        table_pet[:50, 3] = 0 # make the lower values transparent
        table_pet[50:, 3] = np.linspace(0, 1, table_pet[50:].shape[0])
        tf_pet = ipv.TransferFunction(rgba=table_pet)
```

https://github.com/maartenbreddels/ipyvolume/blob/master/notebooks/multi-volume.ipynb

- 例: Python

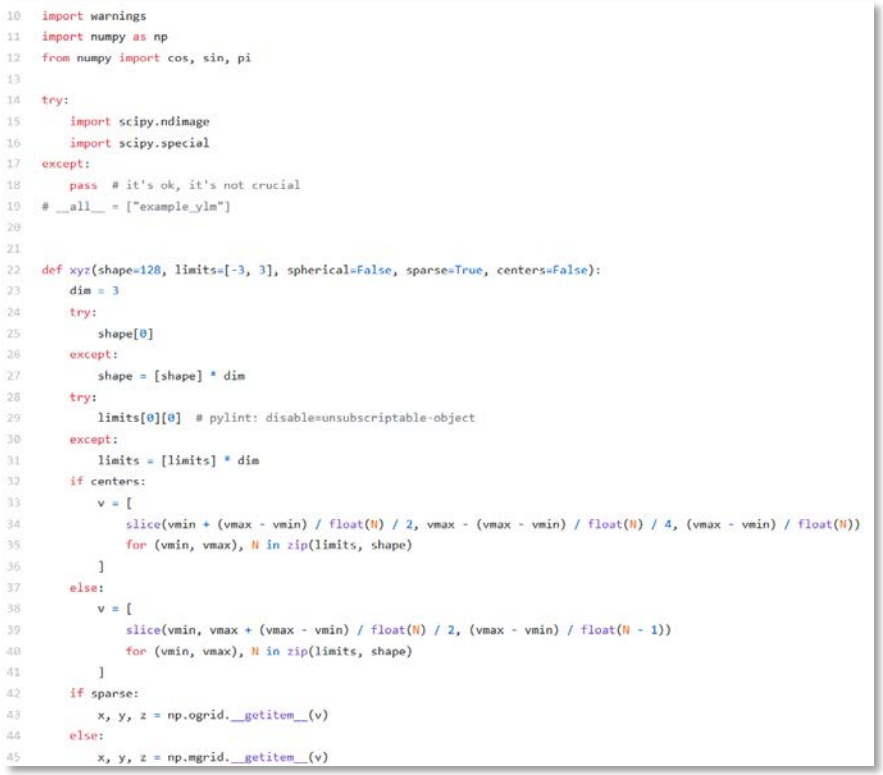

```
import warnings
import numpy as np
from numpy import cos, sin, pi

try:
    import scipy.ndimage
    import scipy.special
except:
    pass  # it's ok, it's not crucial
# __all__ = ["example_ylm"]


def xyz(shape=128, limits=[-3, 3], spherical=False, sparse=True, centers=False):
    dim = 3
    try:
        shape[0]
    except:
        shape = [shape] * dim
    try:
        limits[0][0]  # pylint: disable=unsubscriptable-object
    except:
        limits = [limits] * dim
    if centers:
        v = [
            slice(vmin + (vmax - vmin) / float(N) / 2, vmax - (vmax - vmin) / float(N) / 4, (vmax - vmin) / float(N))
            for (vmin, vmax), N in zip(limits, shape)
        ]
    else:
        v = [
            slice(vmin, vmax + (vmax - vmin) / float(N) / 2, (vmax - vmin) / float(N - 1))
            for (vmin, vmax), N in zip(limits, shape)
        ]
    if sparse:
        x, y, z = np.ogrid.__getitem__(v)
    else:
        x, y, z = np.mgrid.__getitem__(v)
```

https://github.com/maartenbreddels/ipyvolume/blob/master/ipyvolume/examples.py

- 基本は Jupyter Notebook
- 構築されたコンテナ上で実行可能な任意の言語を使える

類似サービスとの比較

	本サービス（構想中）	Google Colab	mybinder.org	GESIS Notebooks	Pangeo's BinderHub	Codalab Worksheets
対象分野	汎用	主に深層学習	汎用	社会科学	地球科学	深層学習
提供元	NII （日・学術機関）	Google （米・民間企業）	Project Jupyter （任意団体）	GESIS （独・学術機関）	Pangeo （米・学術団体）	Microsoft （米・民間企業）
アカウント	**学認**	Google	不要	GESIS	GitHub	Codalab
対応言語	Python, R, Julia （需要により追加）	Python, R, Julia, Swift	Python, R, Julia	Python, R, Julia	Python	Python
対応リポジトリ	**WEKO3, GakuNin RDM,** GitHub, Gist, GitLab, Zenodo, Figshare, Hydroshare, Dataverse	Google Drive, GitHub	GitHub, Gist, GitLab, Zenodo, Figshare, Hydroshare, Dataverse	GitHub, Gist, GitLab, Zenodo, Figshare, Hydroshare, Dataverse	GitHub, Gist, GitLab, Zenodo	?
メモリ **CPU** **ストレージ**	（これから決める）	13GB 2コア 40GB	2GB 1コア ?	32GB 2コア 10GB	8GB 4コア ?	?
タイムアウト	（これから決める）	90分 / 12時間	10分	40分	11分 / 3時間	?
インフラ	オンプレ	Google	Google, OVH, Turing Institute	オンプレ	Google	Microsoft

オープンサイエンスの環をつなげよう

- NII では、分野横断的な研究をサポートするため、オンライン分析システムの開発を進めています。
- 先行研究者が開発したプログラムとその実行環境を後続研究者が容易に再構築できるようになります。
- 2020年10月から実証実験を開始します。ご興味のある方はご連絡ください。