

# Analyse mehrdimensionaler Arrays auf Hochleistungsrechnern

xarray und dask

Aaron Spring

Max-Planck-Institut für Meteorologie

2019-07-01

# Ökosystem des wissenschaftlichen Rechnens mit Python




Abbildung: Python Visualization Landscape

# Agenda

- 1 Herausforderung
- 2 xarray
- 3 dask
- 4 Zusammenfassung

# Herausforderung

- Analyse mehrdimensionaler Daten
  - Wettervorhersage, Satellitendaten, Klimamodeloutput
  - (Börsendaten)
- Aufbereiten der Daten zu einer schlüssigen Story
- $\leftrightarrow$  technisch möglichst einfach und intuitiv




Abbildung: Januar 2014 Ozeanoberflächentemperatur

# Live-Demo 1

- nur mit `numpy` und `netcdf`
- mit `xarray`

## xarray package



- Analyse mehrdimensionaler Daten
- selbstbeschreibende Daten (`netcdf`, `hdf5`, ...)
- simpel: inspiriert durch `pandas`
- effizient: basiert auf `numpy` und `dask`
- Teil des Scientific Python Ecosystems
- Hoyer und Hamman, 2017: "Xarray: N-D Labeled Arrays and Datasets in Python"

## xarray Datentypen




Abbildung: xarray Datenmodell [Xarray Documentation]

## Live-Demo 2

- xarray Anwendung: SST inter-annual variability
- Herausforderung: Satelliten-Daten MODIS-SST

## dask package



- Dynamischer Task Scheduler
- nutzt multiprocessing, threading und concurrent
- Chunking von "Big Data" für Parallelisierung
- intuitiv: bekannte API
- skaliert: vom Laptop zum Supercomputer
- Teil des Scientific Python Ecosystems
- Rocklin, 2015: "Dask: Parallel Computation with Blocked Algorithms and Task Scheduling"

## dask Datenmodell

- `dask.array` → `numpy.ndarray`
- `dask.bag` → `iterable`
- `dask.dataframe` → `pandas.DataFrame`




Abbildung: [Dask Documentation]

## Live-Demo 3: dask

- chunking of lazy data
- dask task graphs
- (optional) Benchmark
- SST inter-annual variability
- dask.distributed: MODIS-SST inter-annual variability

## Nützliche Projekte und Erweiterungen

- `scipy` : (fast) alle Funktionen anwendbar mit `xr.apply_ufunc`
- `cartopy` : Kartenprojektionen
- `seaborn` : Visualisierung von statistischen Graphiken
- `bokeh` : Dynamische Visualisierung von statistischen Graphiken
- `geoviews` : Dynamische Visualisierung von Kartenprojektionen
- `intake` : Laden von ähnlichen `.csv`-Dateien durch Kataloge
- `intake-xarray` : `intake` für `netcdf`
- `intake-esm` : `intake` für Erdsystemmodeloutput (CMIP auf `mistral`)
- `climpred` : Vorhersage-Verifikation
- ... <http://xarray.pydata.org/en/stable/related-projects.html>

# Datentyp-Kompatibilität

- `ds.to_dataframe()` : xarray → pandas
- `ds.from_dataframe(df)` : pandas.df → xarray
- `ds['var'].values` : xarray → numpy.ndarray
- `ds.to_netcdf()` : xarray → netcdf
- `ds.to_zarr()` : xarray → zarr (Cloudspeicherformat)
- `intake.cat.item.to_dask()` : Katalogisierte netcdf → xarray.dask
- `cdo.operator(input=ifile, returnXDataset=True)` : cdo-py Output → xarray.dataset
- ... <http://xarray.pydata.org/en/stable/api.html#io-conversion>

# Zusammenfassung




Abbildung: Python Visualization Landscape

- Read the fucking manual (RTFM).
- Ökosystem ausnutzen.
- High-level nutzer-freundlicher als low-level.
- Chunking bei Big Data.
- Parallelisierung ist nicht automatisch schneller.

## Literatur

*Dask Documentation*. URL: <https://docs.dask.org/en/latest/> (besucht am 04.06.2019).

Hoyer, Stephan und Joe Hamman (2017). “Xarray: N-D Labeled Arrays and Datasets in Python”. In: *Journal of Open Research Software* 5.1. DOI: 10/gdqdmw.

*Python Visualization Landscape*. Jake VanderPlas *The Python Visualization Landscape PyCon 2017*. URL: <https://www.youtube.com/watch?v=FytuB8nFHPQ> (besucht am 04.06.2019).

Rocklin, Matthew (2015). “Dask: Parallel Computation with Blocked Algorithms and Task Scheduling”. In: *Python in Science Conference*. Austin, Texas, S. 126–132. DOI: 10/gfz6s5.

*Xarray Documentation*. URL: <http://xarray.pydata.org/en/stable/index.html> (besucht am 04.06.2019).