

THE CHALLENGES IMPLEMENTING ESRF DATA POLICY



Andy Götz *on behalf of*
Data Implementation Working Group

THE CHALLENGES IMPLEMENTING ESRF DATA POLICY



THE CHALLENGES IMPLEMENTING ESRF DATA POLICY

- 1. Data Policy**
 - 2. Defining Metadata**
 - 3. Data Format**
 - 4. Metadata Catalogue**
 - 5. E-logbook**
 - 6. Finding Data**
 - 7. Long Term Archiving**
 - 8. Roadmap**
- ## **Conclusion**

WHO SAID THIS ?

Raw
Data
Now!

SIR TIM BERNERS LEE – INVENTOR OF THE WEB



ESRF DATA POLICY – MAIN POINTS

- ESRF is custodian of data and metadata
- ESRF to collect high quality metadata to facilitate reuse of data
- ESRF will keep metadata forever
- ESRF will keep raw (or reduced) data for 10 years
- Data will be registered in a data catalogue (ICAT)
- Data will be published with a Digital Object Identifier (DOI)
- The experimental team has exclusive access to data during the embargo period (3 years which can be extended on request)
- Data will be made public after the embargo period under licence CC-BY 4.0
- Data Policy will be implemented on all beamlines by 2020

The hard thing to do
and the
right thing to do
are usually
the same thing.



Attribution 4.0 International (cc BY 4.0)

This is a human-readable summary of (and not a substitute for) the [license](#).

[Disclaimer](#)



You are free to:

Share — copy and redistribute the material in any medium or format

Adapt — remix, transform, and build upon the material

for any purpose, even commercially.

The licensor cannot revoke these freedoms as long as you follow the license terms.

Under the following terms:



Attribution — You must give [appropriate credit](#), provide a link to the license, and [indicate if changes were made](#). You may do so in any reasonable manner, but not in any way that suggests the licensor endorses you or your use.

No additional restrictions — You may not apply legal terms or [technological measures](#) that legally restrict others from

« DATA is our core product – we must manage it correctly to ensure it is of high quality, traceable, reliable, curated, and reusable »

*Andy Götz (Workshop on Active DMP at CERN
June 2016)*

THE GOAL IS REUSE

« Good data management is not a goal in itself, but rather is the key conduit leading to knowledge discovery and innovation, and to subsequent data and knowledge integration and reuse by the community after the data publication process. »

*Mark D. Wilkinson et al. (March 2016 in Nature
www.nature.com/scientificdata)*

—

CHALLENGE #1 - DEFINING A DATA POLICY

- 2011 : PaNDa Europe FP7 work package 2 delivered a generic data policy
- 2011 : Proposed the ESRF management to adopt it but failed to convince
- 2011 to 2015 : rise of Open Science → Data Management Plans → Open Data
- 2015 : ESRF Data Policy become necessary + feasible, adopted by Council 1/12/2015
- 2020 : ESRF Data Policy implemented on all beamlines

« be patient, do not give up, now is the time ! »

« TIMES ARE A CHANGING » ... BOB DYLAN



DIE ZEIT
WOCHEZEITUNG FÜR POLITIK WIRTSCHAFT WISSEN UND KULTUR

Die Macht der Beleidigten



Politiker, Dozenten, aufgebrachte Bürger – wer heute Aufmerksamkeit erhalten will, muss sich gekränkt zeigen. Und das Verrückte ist: Es funktioniert JENS JESSEN IM FEUILLON

PSEUDONYM GELÜFTET

Elena Ferrante
schuldet uns nichts

Sie wurde verfolgt, ihre Privatsphäre verletzt. Warum nur? VON MARIAM LAU

Als am vergangenen Wochenende fünf internationale Medien das Pseudonym der italienischen Schriftstellerin Elena Ferrante entdeckten, dachten manche Leute erschrocken, die Autorin sei vielleicht etwas zu großes Geflecht. Welchen anderen Grund könnte es geben, die Frau, der Welt den nepotistischen Roman *Mafia grande* präsentierte, gegen ihres Willens Lügen der Öffentlichkeit zu eruren? Sie hat kein Verbrechen begangen. Sie hat keine Panama-Papiere. Ferrante findet, ihr Romanzug *Napolitanische Segnatur* ein eigenes Leben führen. Die Autorin habe sich zu verschwinden. Sie sieht ja, dass es im Feuilleton immer öfter umgedreht gehabt wird.

Ein Vierteljahrhundert lang ist es ihr gelungen, ihr Geheimnis einmal angelagert zu halten, sozusagen zu lagern. Damit sief sie den investigativen Wirtschaftsjournalisten Claudio Gatti auf den Plan, der finde, Ferrante habe damit ihr Recht auf Anonymität verwirkt. Sie habe Journalisten und Leser mit einer Menge herumförderter – ein Argument, das annehmen, ungeschönen Zusammensetzungen im Verhältnis zwischen Männern und Frauen bekannt ist. Verhältnisse übrigens, die Ferrante in ihrer Trilogie Schicht um Schicht freilegt. Monologe, die sie in der Umschau prangen galt, in Gedanken, Grundbauden, aufgewischisch die Lage ihrer Wohnung – in einer der schönsten Roms» umschlichen. Nein, das ging zu weit. Eine Übersetzung wie *Anie* von Ray Bradbury, die er im Verdruss hatte – mitsie sich so etwas niemals leisten können. Ferrante ist enttarnt.

Gatti ist mit seiner Annahme nicht allein. Viele finden, Celebrities vermarkten der Öffentlichkeit ihren Ruf, aber schließlich ist es auch so. Bis jetzt im Prinzip noch griff die Vorstellung an, dass nur tolle Transparency sei noch mit dem Gedächtnis

KOLUMBIEN

Preis der Wahrheit

Die geplante Amnestie für die Farc-Rebellen empört die Opfer. Doch nur so kann das südamerikanische Land Frieden finden VON ANGELA KÖCKRITZ

Sie haben gemordet, vergewaltigt, gebrändschatzt, entführt. Haben sich an den sogenannten Einwohnern des Landes, die sie als bedrohlich bezeichneten, Millionen Kolumbianen das Leben zur Hölle gemacht. 52 Jahre lang wütete in Kolumbien der Bürgerkrieg zwischen linken Farc-Rebellen und rechten Paramilitärs. Er kostete 220 000 Menschen das Leben, sechs Millionen Menschen wurden vertrieben. Und ausgerechnet diesen Farc-Rebellen will man jetzt milde Strafen, Strafrechte, ja Privilegien gewähren? Wie muss sich das für jene anfühlen, die in diesem Krieg seit Jahren leben? Die Tiere für Tag mit dem Schmerz leben müssen, während sie da draußen der Mörder herumlaufen, vielleicht sogar Parlamentarier wird?

Die Kolombianer entschieden am Sonntag, Das darf es nicht mehr geben. Und dann hat Manuel Santos noch zum Referendum über das historische Friedensabkommen mit den Rebellen der Farc-Guerrilla gebeten. Die meisten Kolumbianen gaben nicht zur Abstimmung, der Rest stimmte für einen Vertrag, der 5000 bis 54 000 Stimmen unterschreibt. Der Partei selbst erklärt darüber: Der Waffenstillstand blieb in Kraft, es werde weiterverhandelt. Das Abkommen noch eine Chance.

Die Kolumbianen sind mit ihrem Risiko eingegangen. Den Gedanken oder Gedanktagebüchern schien viele Gedächtnisse auszuhandeln. Er hat die Deutschen 1945 genauso beschäftigt wie die Südafrikaner nach dem Ende des Zweiten Weltkriegs. Und jeden Tages Bericht schrieb die Syrer dem großen Hader – mitsie sich so etwas niemals leisten könnten. Ferrante ist enttarnt.

JÖBELPREISE

Einsame Helden? Das war gestern

Die Wissenschaft muss sich noch weiter öffnen VON ANDREAS SENTKER

Für so viel?, fragen sie. Denn im Gegengang dazu haben sie 25 Reiseziele im Osten der Welt und den Nord- und Südosten Asiens sowie (wieder) die Balkanländer und die Türkei von 2010 bis 2015 vergeben worden: an 870 Menschen und 23 Organisationen. Und niemand außer den Juroren wusste davon, teilt sich. Keiner wird dazu bestimmt, sich und die Seinen zu einer Leistung zu machen.

Die Inszenierung gelingt auch, weil Forschung hier ein Gesicht bekommt. Der Preis wird für – oft längst vergangene – Heldentaten Einzelner verliehen.

Bald jedoch soll die Wissenschaft anders aussehen. Nicht verborgen, nicht einsam, offen soll sie sein und kooperativ: Open Science. Forscher sollen nicht nur die Resultate, sondern auch die Daten ihrer Experimente zugänglich machen (Open Data). Sie sollen Bürger in ihre Arbeit einbeziehen (Participation). Ihre Publikationen sollen jedem zugänglich sein (Open Access).

Warum diese Wende?

Sie hat – zunächst – interne Gründe: Mehr Kooperation verspricht mehr Erkenntnis, Big Data gilt in der Forschung als der nächste große Treiber (siehe Ressort Wissen ab Seite 35). Mehr Transparenz ist zudem zur Qualitätssicherung erforderlich: Sie erschwert Fälschungen, macht Experimente nachvollziehbar und erleichtert so die Selbstkontrolle der Forschung.

Aber auch ein gesellschaftlicher Wandel lässt Forscher umdenken. Den Nobelpreisen zum



»Mitgefühl ist nicht mein Motiv«
Kurzwechsel? Von wegen! Die Kanzlerin bekräftigt ihre Flüchtlingspolitik

Seite 2/3



Guten Morgen!
Ein Heft über den letzten Rückzugsort – das Badezimmer ZEITmagazin

Im Totenwald
Drei Jahrzehnte nach der Tat: Auf der Spur eines mutmaßlichen Serienmörders
Recht & Unrecht, Seite 14



Umweltfreundlich

Bei den spektakulärsten Urteilen in der Kriminallawistik ist es fast immer ein Gangster oder Korsär, der aufgeflogen ist. Und Gangster, die an Montag die amerikanische Schauspielerin Kim Kardashian in einem Pariser Club attackiert haben, gefangen halten um Schmuck zu rauben, einkaufen auf Fabrikalen. Die Idee des umweltfreundlichen Radfahrens ist in der Unterwelt angekommen. Ihre Publikationen sind jedem zugänglich sein (Open Access).

Zentrale Gerd Bucerius GmbH & Co KG,
20090 Hamburg, Telefon 040 / 32 80 - E-Mail:
DieZeitung.de, Leserbriefe@die.de
ZEIT ONLINE GmbH: www.zeit.de
ZEIT-Stellennachrufe: www.zeitjobs.de

ABONNENTENSERVICE:
Tel. 040 / 21 70 76,
Fax 040 / 21 70 79,
E-Mail: abo@zeit.de
PREISE IM AUFLAND:
DK 49,00/PIF 7,50/N 66,00/E 6,10/
CAN 6,00/A 10,70/
A 2,00/GB 10,00/C 6,70/
B 5,00/S 6,00, 5,00/1 209,00

TO 42

NOBELPREISE

Einsame Helden? Das war gestern

Die Wissenschaft muss sich noch weiter öffnen VON ANDREAS SENTKER

ur wenige Jurys nehmen es mit der Geheimhaltung so genau wie jene, die über die Nobelpreise befinden. 573-mal sind die Preise von 1901 bis 2015 vergeben worden, an 870 Menschen und 23 Organisationen. Und niemand außer den Juroren wusste zuvor, wer sie erhalten würde. Das macht die alljährliche Bekanntgabe so aufregend.

Die Inszenierung gelingt auch, weil Forschung hier ein Gesicht bekommt. Der Preis wird für – oft längst vergangene – Heldentaten Einzelner verliehen.

Bald jedoch soll die Wissenschaft anders aussehen. Nicht verborgen, nicht einsam, offen soll sie sein und kooperativ: Open Science. Forscher sollen nicht nur die Resultate, sondern auch die Daten ihrer Experimente zugänglich machen (Open Data). Sie sollen Bürger in ihre Arbeit einbeziehen (Participation). Ihre Publikationen sollen jedem zugänglich sein (Open Access).



CHALLENGE #2 - DEFINING METADATA

- One of the biggest challenges – why ?
- « *Metadata is the data you don't need for your data analysis* » Armando Solé
- → Hard to find people motivated to work on this
- ESRF lucky to have Armando+Alex+Roberto and some motivated scientists (Peter+Wout+...)
- Nexus is our baseline but we add local definitions as we go along (not using Nexus Applications)
- Goal is to produce a complete set of metadata for experiment logging, debugging and data analysis

If it's broken - Fix it

If you don't like it - Change it

If you want something - Take it

Nexus

**Don't complain about it
Just do something about it.**



CHALLENGE #3 – DATA FORMAT

- **Ingredients :**
HDF5,Nexus



- **A single master file / experiment**
- **Master file stores metadata (copy of database)**
- **Links to data file(s) with multiple datasets**
- **Easier to analyse, backup + transfer**
- → **Need to convert data analysis programs**
- **ESRF developing SILX library with HDF5 support**
- → **See poster on SILX (A.Solé) today**



The European Synchrotron



CHALLENGE #4 – CHOOSING A METADATA CATALOGUE

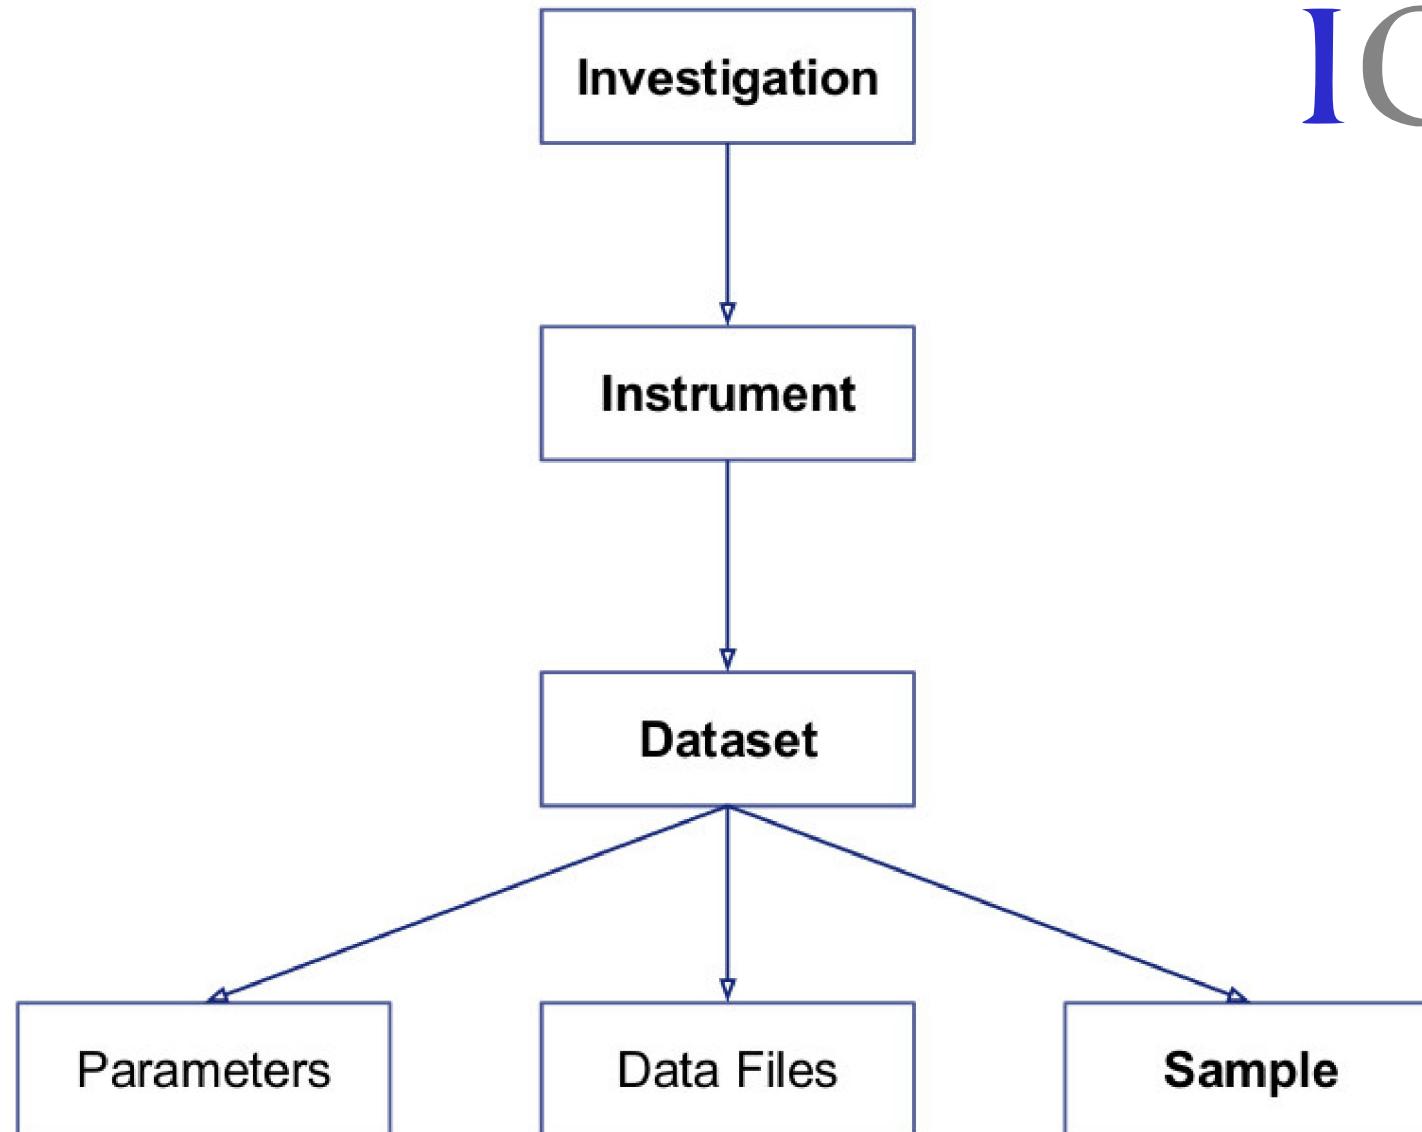
- Many Metadata catalogues
- CRISP project compared 20 metadata catalogues





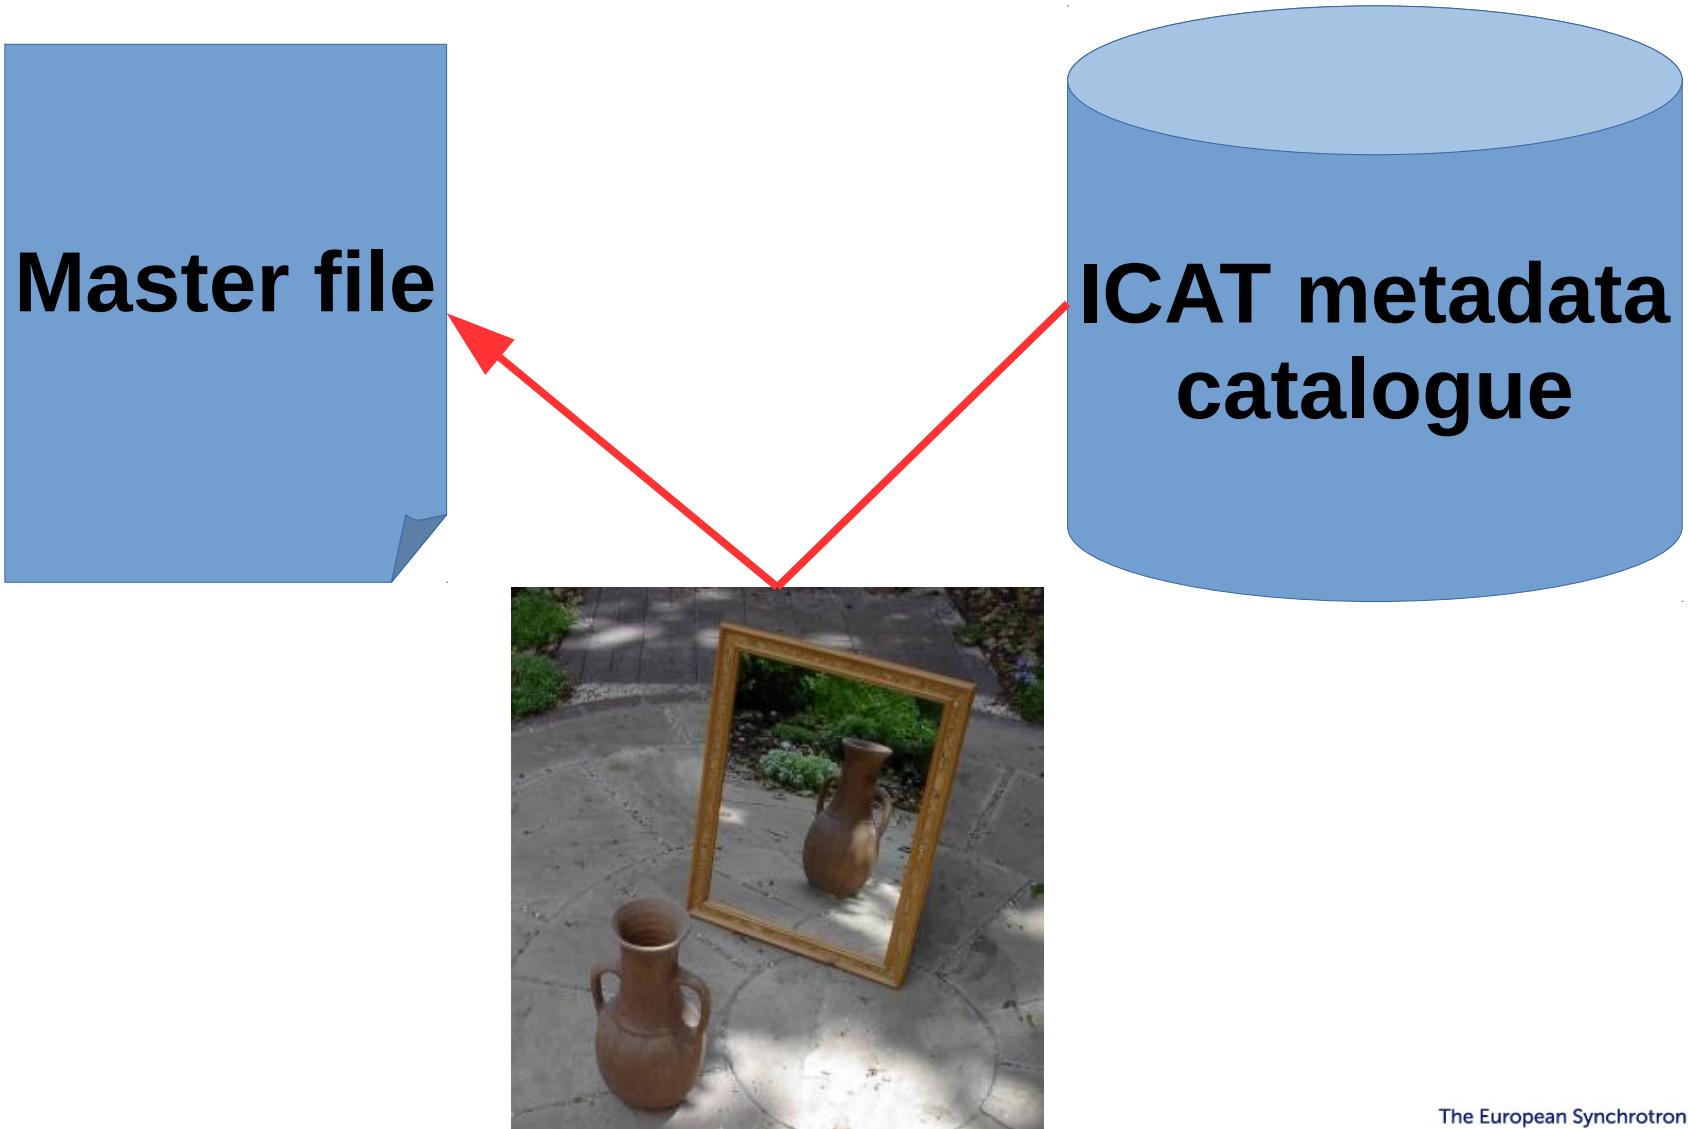
- **ICAT was chosen for its generic data model which captures the scientific experiment**
- **ICAT not invented at here (ESRF)**
- **ISPyB (for MX) was close second**
- **ICAT community is collaborating to address all steps of data management**
- → **See next two talks (Steve+Frazer)**

ICAT METADATA DATA MODEL



METADATA DEFINITION IN ICAT

- **HDF/Nexus Metadata master file is a mirror image of the Metadata stored in ICAT**



METADATA DEFINITION IN ICAT

- **Follow the Nexus conventions when defining Dataset Parameters :**

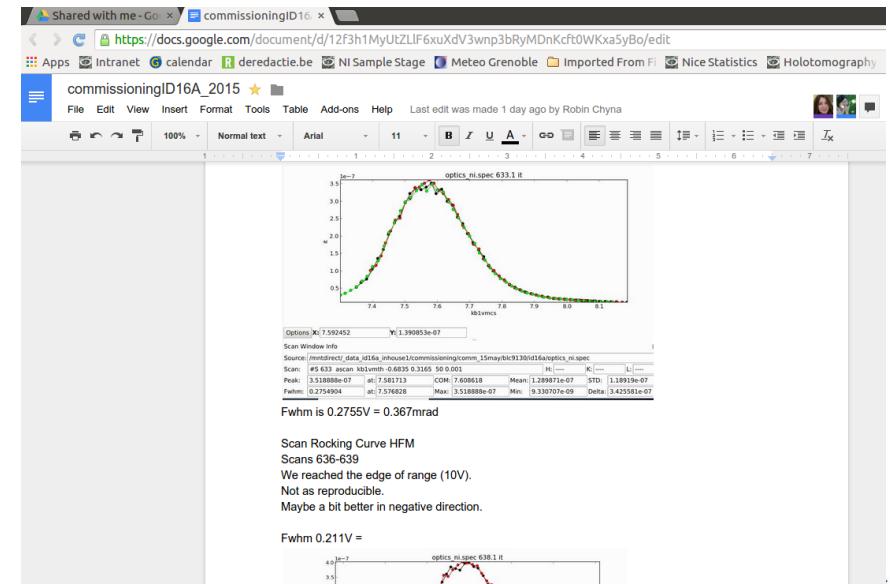
InstrumentPositioners_name InstrumentPositioners_value
InstrumentMonochromator_energy InstrumentMonochromator_wavelength
InstrumentMonochromatorCrystal_usage InstrumentMonochromatorCrystal_d_spacing
InstrumentMonochromatorCrystal_type InstrumentMonochromatorCrystal_reflection
InstrumentSource_mode InstrumentSource_current InstrumentSlitPrimary_name
InstrumentSlitPrimary_vertical_gap InstrumentSlitPrimary_vertical_offset
InstrumentSlitPrimary_horizontal_gap InstrumentSlitPrimary_horizontal_offset
InstrumentSlitPrimary_blade_up InstrumentSlitPrimary_blade_down
InstrumentSlitPrimary_blade_front InstrumentSlitPrimary_blade_back
InstrumentSlitSecondary_name InstrumentSlits_name InstrumentSlits_vertical_gap
InstrumentSlits_vertical_offset InstrumentSlits_horizontal_gap
InstrumentSlits_horizontal_offset InstrumentSlits_blade_up
InstrumentSlits_blade_down InstrumentSlits_blade_front InstrumentSlits_blade_back
InstrumentAttenuatorPositioners_name InstrumentAttenuatorPositioners_value
InstrumentInsertionDevice_gap_name InstrumentInsertionDevice_gap_value
InstrumentInsertionDevice_taper_name InstrumentInsertionDevice_taper_value
InstrumentOpticsPositioners_name InstrumentOpticsPositioners_value
InstrumentDetector01_name InstrumentDetector01Positioners_name
InstrumentDetector01Positioners_value InstrumentDetector02_name
InstrumentDetector02Positioners_name InstrumentDetector02Positioners_value
.....

CHALLENGE #5 – E-LOGBOOK

- **Get rid of paper logbooks !**
- **No solution for now – we will work on this in the future.**



- **Some beamlines using Wikimedia, Google doc ...**



CHALLENGE #6 – FINDING DATA

- Data must be FAIR i.e. Findable, Accessible, Inter-Operable, Re-Usable (<http://www.nature.com/articles/sdata201618>)
- Latest version of TopCat (ICAT web UI) offers searching by Investigation, Sample, Dataset
- Parameter/metadata searching still needs work
- Publish data DOIs, link to public repositories
- Idea : implement the Open Archives Initiative Protocol for Metadata Harvesting (OAI-PMH)
- Dream (?) : Link data to Wikipedia ...

FINDING DATASETS VIA WIKIPEDIA

Visit the main page 

AndyGotz 2 Talk Sandbox Preferences Beta Watchlist Contributions Log out

Article Talk Research Read Edit View history More Search

Herschel Space Observatory

Datasets in relation

- **HESIOD** : The Herschel IdOc Database is delivering photometric maps and spectral cubes from the PACS and SPIRE Instruments (IR domain), reprocessed at IAS with the latest ESA pipelines and with high level customized pipelines. Virtual Observatory compatible. ([source](#))

From Wikipedia, the free encyclopedia

This article is about the space telescope. For the ground-based telescope, see [William Herschel Telescope](#).

The **Herschel Space Observatory** was a space observatory built and operated by the European Space Agency (ESA). It was active from 2009 to 2013, and was the largest infrared telescope ever launched,^[5] carrying a single 3.5-metre (11.5 ft) mirror^{[5][6][7][8]} and instruments sensitive to the far infrared and submillimetre wavebands (55–672 μm). *Herschel* was the fourth cornerstone mission in the ESA science programme, along with *Rosetta*, *Planck*, and *Gaia*. NASA is a partner in the *Herschel* mission, with US

Herschel Space Observatory



https://en.wikipedia.org/wiki/Main_Page

Refer to → <https://io.datascience-paris-saclay.fr/map.php>

CHALLENGE #7 – LONG TERM ARCHIVING

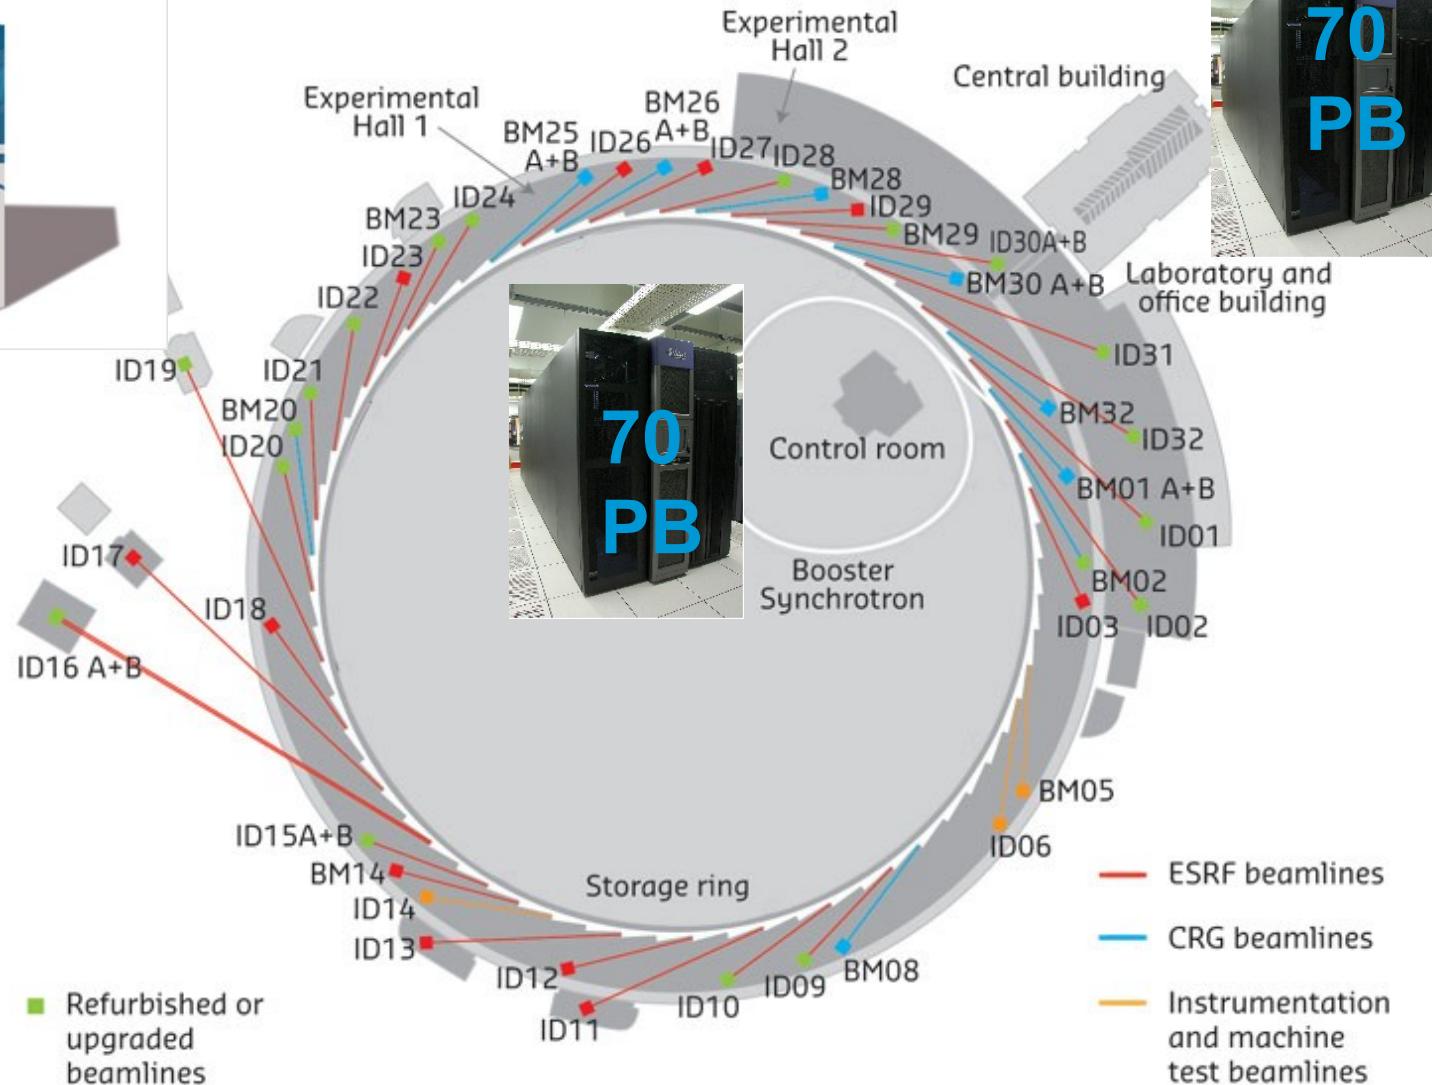
- **What raw data to curate and archive ?**
- **Only data which have been produced at the ESRF by a well defined process**
- **In a well defined format which ESRF provides tools for reading and writing**
- **What if there is too much raw data ?**
 - Store the reduced data only
 - Limit the amount of data
 - Store the metadata

CHALLENGE #7 – LONG TERM ARCHIVING

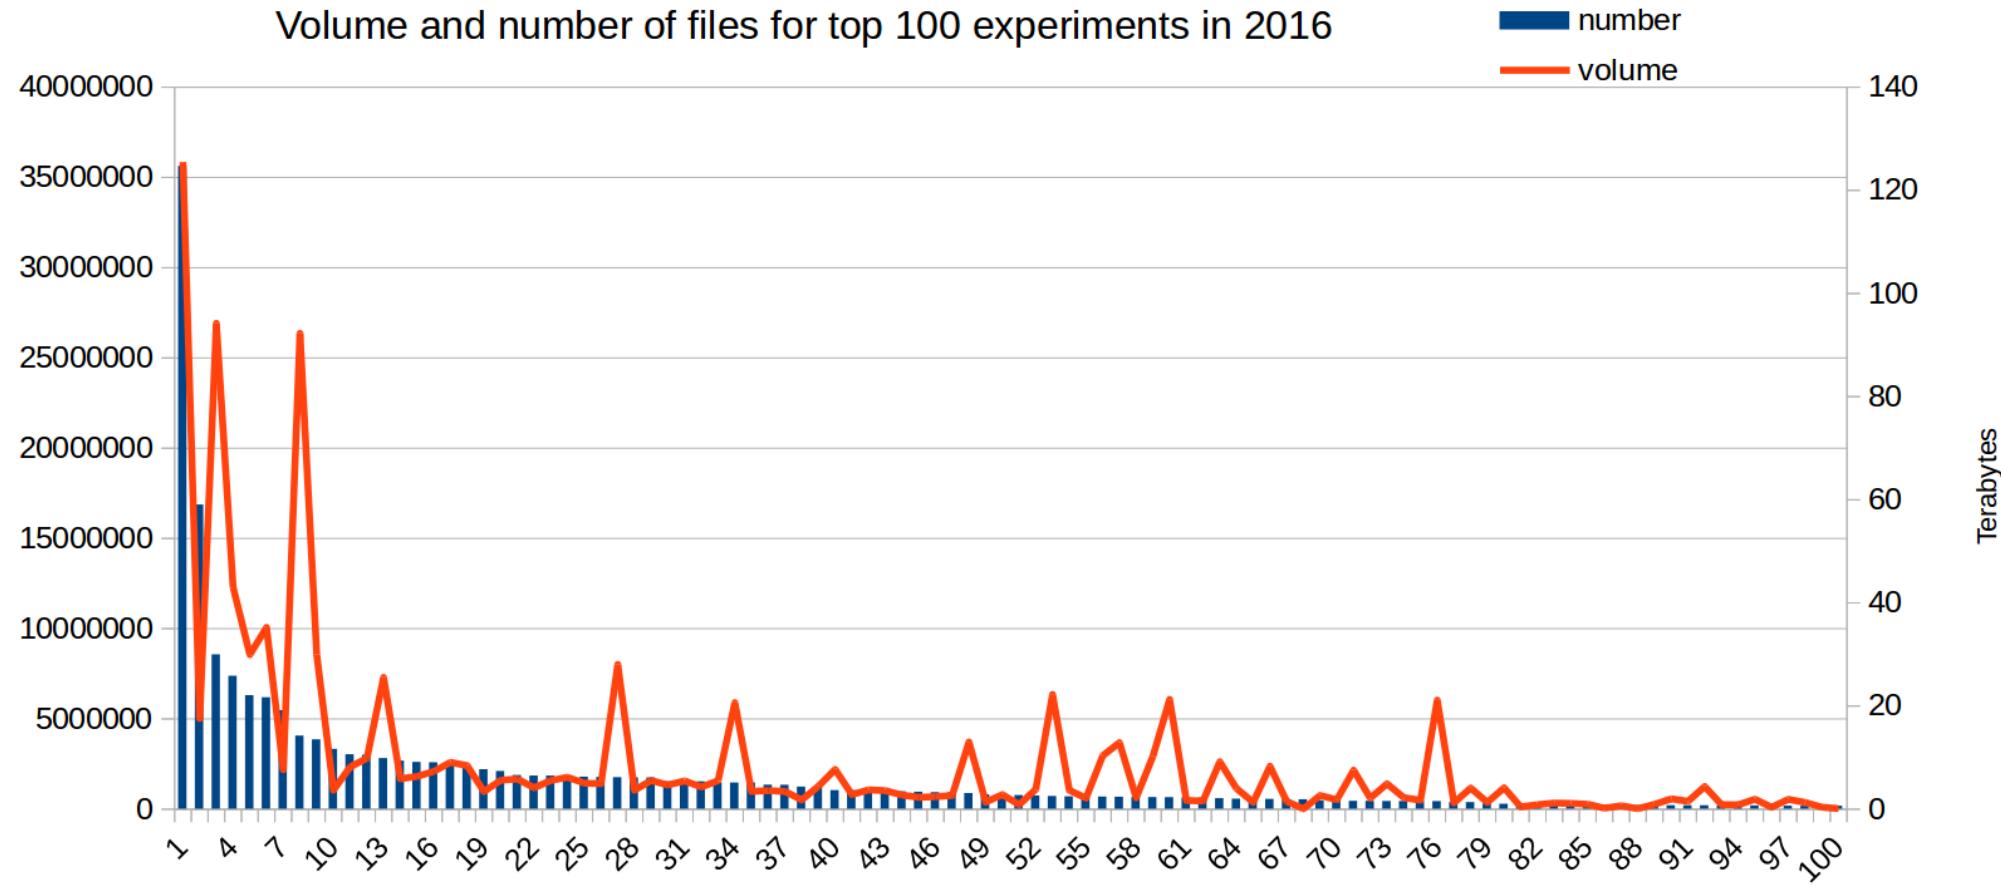
- How much does it cost ?
- Additional costs are :
 - Tape drives + tapes = 100 000 euros / year
 - Human resources = 2.5 FTEs / yr over 4 years
 - 1 data manager, 1 metadata, 0.5 for archiving
- ESRF has 2 tape libraries on site
- Upgraded tape drives to T1000 drives and T2 tapes with 8.5 TB capacity and 300 MB/s read/write
- Data Policy restricted to data and not compute resources for data analysis

LONG TERM ARCHIVING (LTA) – 2 COPIES

Time Navigator(TiNa)



TOO MANY FILES - CHALLENGE IS TO REDUCE THEM !



→ Limit for LTA is 1000 files / 8 hours / experiment
i.e. roughly 20000 per experiment / week ...

CHALLENGE #8 – ROADMAP

- ALL beamlines to implement Data Policy by 2020
- Corresponds to 10 beamlines / yr over 4 years
- So far we are on track for 2016 (10 beamlines) !



CONCLUSION

- **A Data Policy is (1) necessary in today's scientific and political landscape and (2) feasible**
- **Users are the main winners because they get better managed data (Data Management Plans)**
- **Open Data Policy opens up new possibilities e.g. implementing Data as a Service and Open Data**
- **Data is our core product, the goal is to ensure its re-use as much as possible !**

Kun døde fisk
svømmer med
strømmen

Only dead fish
swim with the
current

