



Mirando al futuro, del acceso abierto a los datos abiertos de investigación



Fernando Ariel López
CAICYT – CONICET





Big Data: Volumen, Velocidad, Variedad y Veracidad
Explotación de Datos y Descubrimiento del Conocimiento
(Data Mining & Knowledge Discovery)



Openness → Open Science

**Open Access + Open Data + Open Source
+ Innovación + Colaboración Abierta**



**OPEN DATA
DATOS
ABIERTOS**

**Gobierno Abierto
Tercer Sector + Ciudadano
Periodismo de Datos**

¿Qué son los datos de investigación?

- *hechos, observaciones o experiencias (basado argumento, teoría o prueba)*
- *pueden ser numéricos, descriptivos o visuales.*
- *pueden ser en estado bruto o analizado,*
- *pueden ser experimentales u observacionales.*
- *pueden ser abiertos o cerrados*

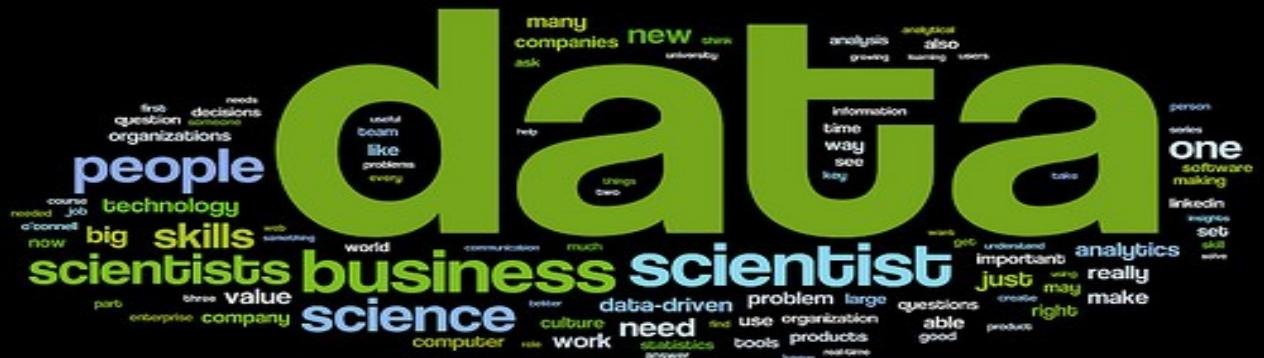


¿Qué son los datos de investigación?

Los datos incluyen: cuadernos de laboratorio, cuadernos de campo, datos de investigación primaria (incluidos los datos en papel o en soporte informático), cuestionarios, cintas de audio, videos, desarrollo de modelos, fotografías, películas, y las comprobaciones y las respuestas de la prueba.

Las colecciones datos para la investigación pueden incluir diapositivas; diseños y muestras.

En la información sobre la procedencia de los datos también se podría incluir: el cómo, cuándo, donde se recogió y con que (por ejemplo, instrumentos). El código de software utilizado para generar, comentar o analizar los datos también pueden ser considerados datos.”



Construcción de datos científicos: tipos

- **Experimentales:** datos provenientes de resultados experimentales
Ej: Aquellos que provienen de aparatos de medición en laboratorios, comúnmente reproducibles, pero caros.
- **Simulación:** datos generados de modelos de prueba donde el modelo y los metadatos pueden ser mas importantes que los datos de salida del modelo.
Ej: Modelos económicos o climáticos.
- **Desarrollados o compilados:** resultado de procesar y/o combinar datos “crudos”, comúnmente reproducibles pero caros.
Ej. Bases de datos compiladas, Resultados de text mining, Datos de censos consolidados.
- **Reference or canonical:** Una (estática u orgánica) conglomeración o colección de datasets mas pequeños (revisados por pares), la mayor parte de ellos publicados y “curados”
Ej. Bancos de datos genéticos, bases de datos cristalográficas.

DATASET

Es el objeto específico de control, organización, descripción y preservación de datos científicos

- Es una colección de datos reunidos durante la ejecución de un proyecto de investigación.
- Son objetos digitales compuestos y heterogéneos.
- Constituye la base de la investigación y va asociado a una publicación científica (resultado de la investigación).
- Se almacena y gestiona en Repositorios Interoperables conforme a estándares internacionales.

BENEFICIOS #DatosAbiertos

- Ayuda a verificar los resultados.
- Evitar la fabricación y falsificación de datos.
- Diferentes interpretaciones o enfoques aplicados a datos existentes contribuyen a los avances científicos.
- Optimización en el uso de recursos.
- Preservación a largo plazo bien gestionada, permite mantener la integridad de los datos.

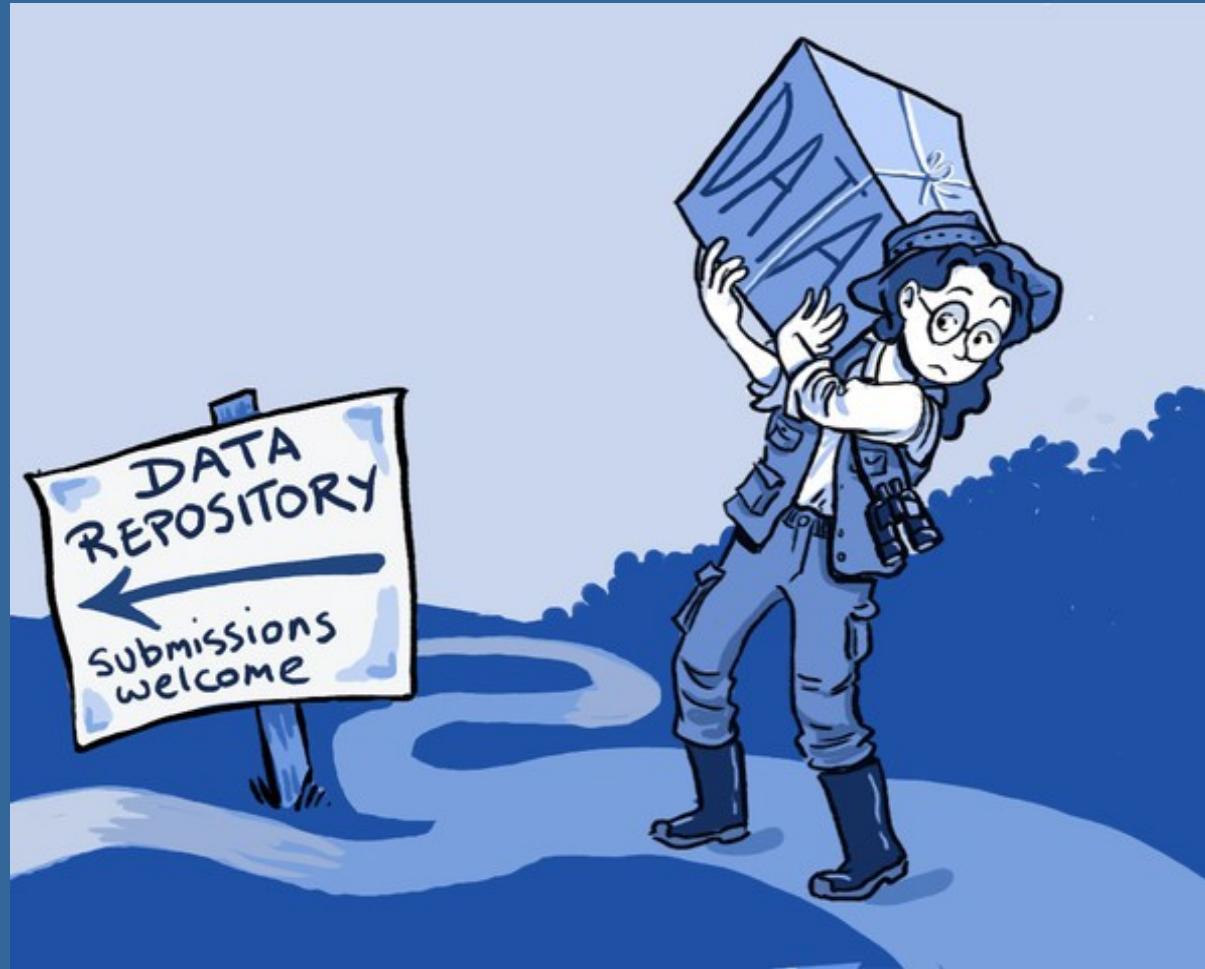
TenopirC, Allard S, Douglass K, AydinogluAU, et al. (2011) Data Sharing by Scientists: Practices and Perceptions. PLoS ONE 6(6): e21101. doi:10.1371/journal.pone.0021101
<http://www.plosone.org/article/info:doi/10.1371/journal.pone.0021101>

Una gestión adecuada de los datos requiere al menos los siguientes aspectos:

- **Políticas** a nivel de agencias de financiación e institucionales. Definición de roles/responsabilidades de los distintos actores.
- **Recursos financieros** a largo plazo ya que los datos son acumulativos y se preservan.
- **Recursos humanos** especializados (para generación de datos, normalización, explotación y preservación).
- **Infraestructuras** coordinadas para garantizar su interoperabilidad. Entre los requisitos de las infraestructuras destacar: *preservación, acceso, data curation, data processing, distribución*.

Para dar respuesta a estos aspectos es necesaria una formación adecuada, equipamientos, sistemas de almacenamiento masivo de datos y redes de alta capacidad.

Mayor resistencia: Cambio Cultural



Los investigadores pueden ser reacios a compartir sus datos públicamente debido a los costos individuales reales y / o percibidos.

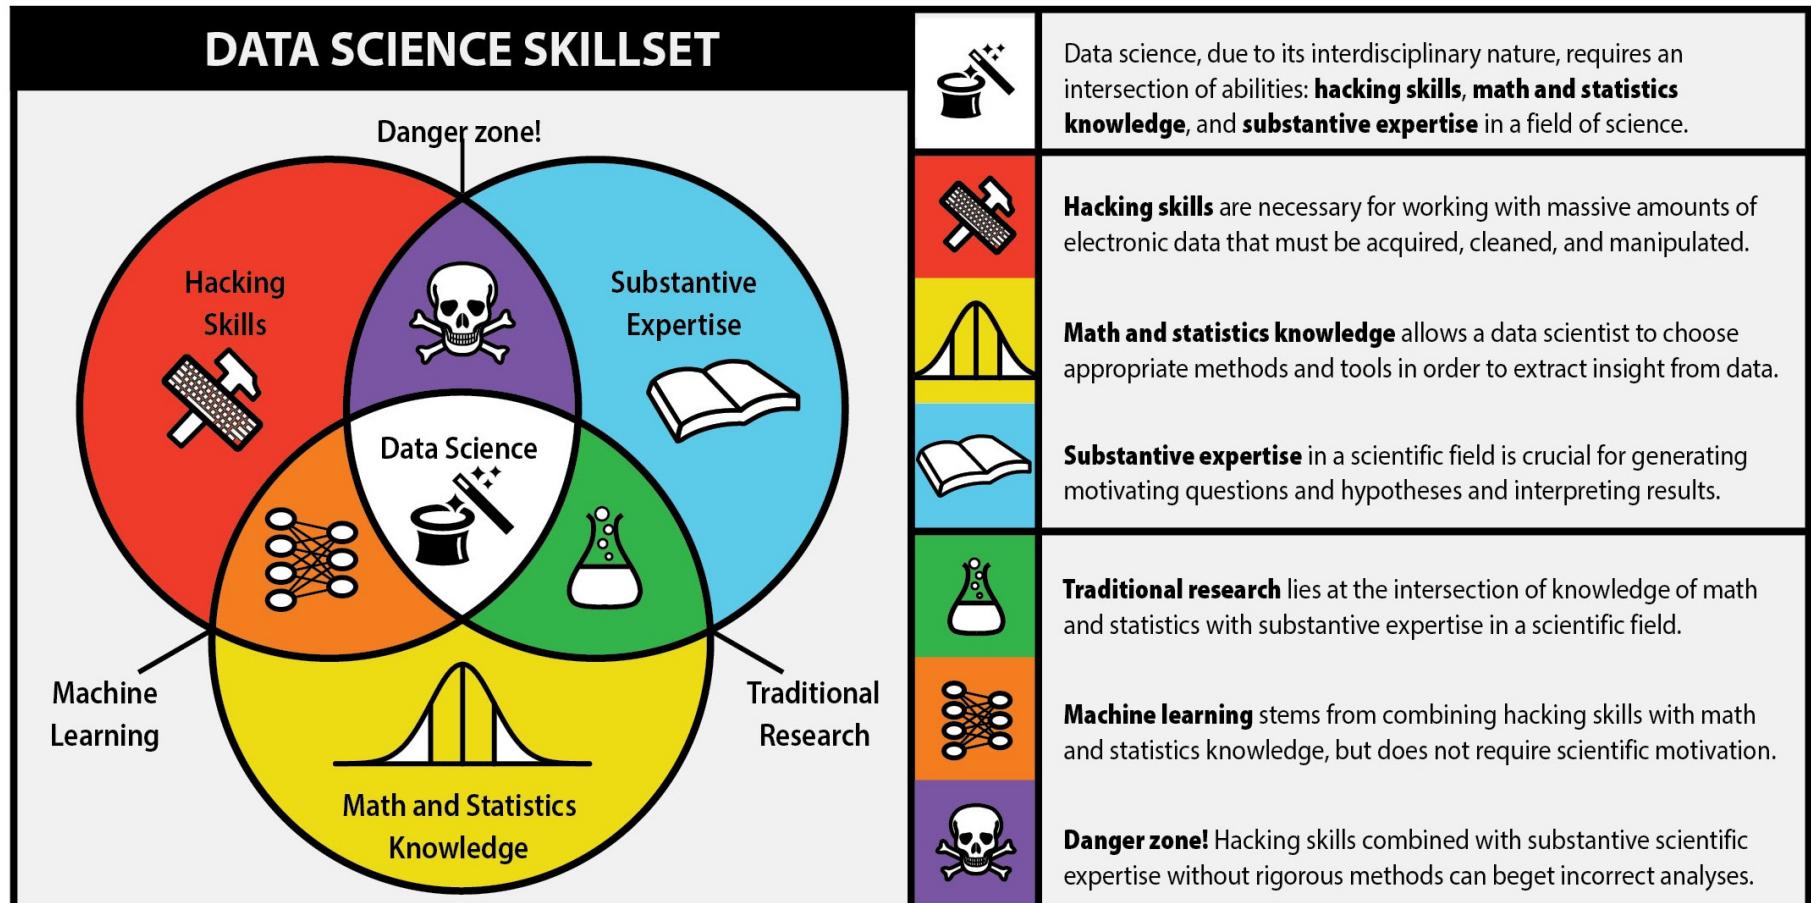


ACTORES IMPLICADOS

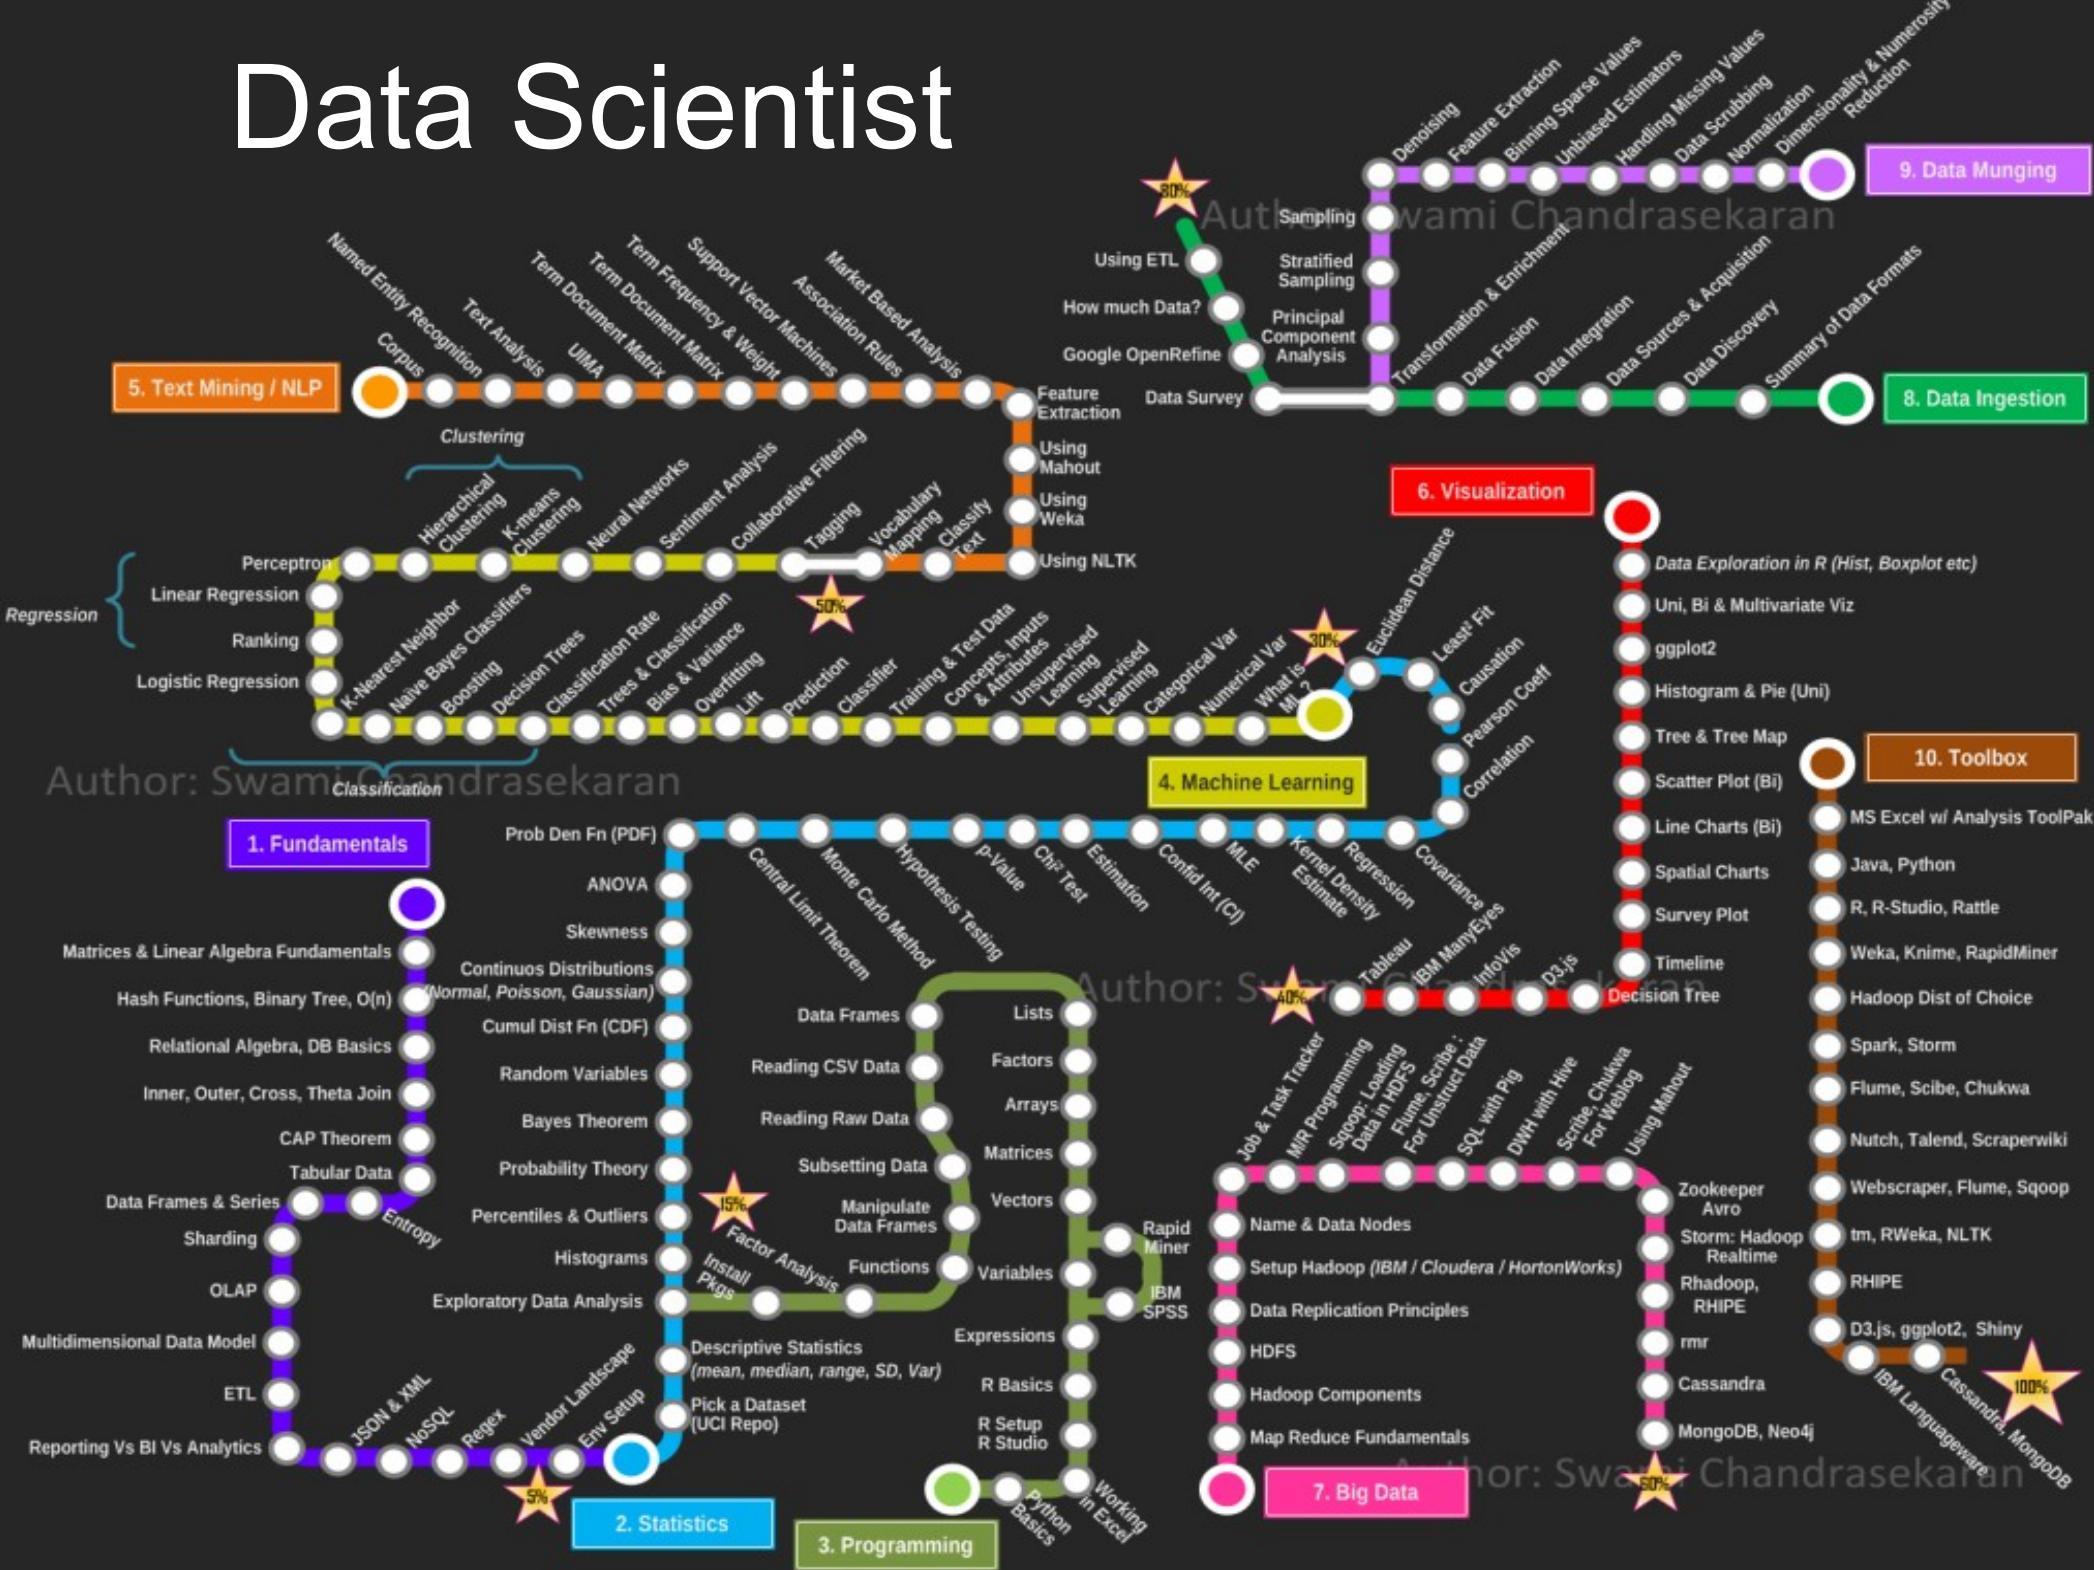
- Investigadores / productores de datos
- Universidades y Centros de Investigación
- Repositorios Institucionales (corto-mediano plazo)
- Centro de Datos (largo plazo)
- Gestores de datos
- Usuarios que reutilizan los datos
- Agencias de financiación

Tercer sector / Sociedad Civil

Científico de Datos: nuevos conocimientos y competencias



Data Scientist

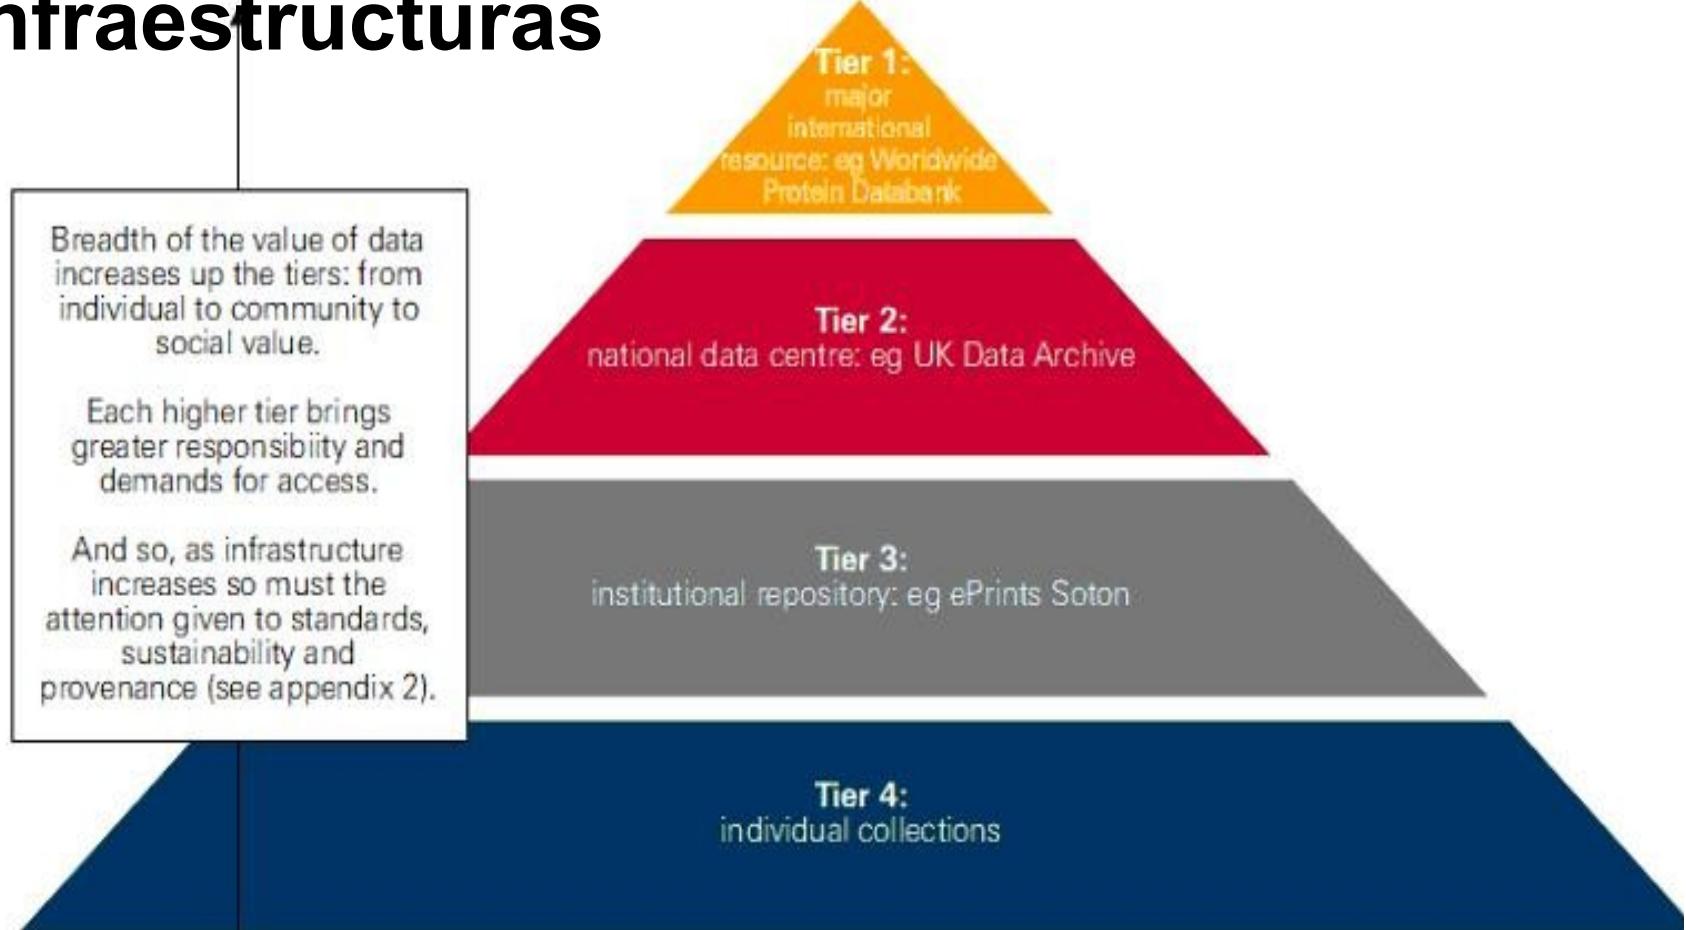


Antecedentes Políticas en las Agencias de Financiamiento

- **Estados Unidos:** National Science Foundation (NSF), National Aeronautics and Space Administration (NASA), National Oceanographic Data Center (NODC) y National Institutes of Health (NIH).
- **Europa:** Horizon2020
- **Reino Unido:** AHRC, BBSRC, Cancer Research UK, EPSRC, ESRC, MRC, NERC, STFC, WellcomeTrust.
- **Regional:** OCDE
- **Argentina:**
 - Iniciativas Nacionales de Datos
<http://sistemasnacionales.mincyt.gob.ar/>
 - **Ley Nacional 26.899.** Datos primarios en 5 años disponibles. Excepciones

Líneas de Trabajo

- **Plan de Gestión de Datos / Data Management Plan (DMP)**
- **e-Infraestructuras**



Plan de Gestión de Datos (DMP)

- **Referencia y nombre del set de datos**
- **Descripción del set de datos**
- **Estándares y metadatos**
- **Datos compartidos**
- **Archivo y preservación**

(incluyendo almacenamiento y copias de seguridad)

- **Formatos**
- **Metadatos**
- **Identificador digital de datos**
- **Marco legal relacionado con la gestión y divulgación de datos de investigación**
 - Acceso y datos
 - Privacidad y confidencialidad
 - Propiedad Intelectual y datos
 - Depósito de los datos
 - Licencias alternativas copyright
- **Preservación**

Horizon2020 (UE)

FECYT (España)

e-Infraestructura

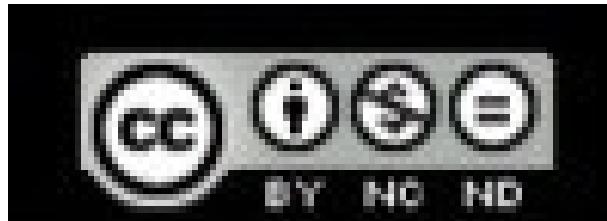
- **Repositorio Interoperable de Datos**
 - Datos Públicos Argentina (CKAN, OKF),
 - Zenodo (Invenio, CERN)
 - DRYAD, PLICSS, LAGOS (DSpace, MIT & HP),
 - Harvard DATAVERSE (Eprints)
- **Plataforma de Trabajo para Investigadores**
 - OSF, HubZero, MyExperiment.org, etc.
- **Cluster de Almacenamiento y/o Procesamiento**

COMPARTE TUS IDEAS, ARTÍCULOS y DATOS!!



¿Preguntas, Dudas o Consultas?

Muchas Gracias



Fernando Ariel López
CAICYT – CONICET

flopez@caicyt.gov.ar

[@fernando_lopez](https://twitter.com/fernando_lopez)

