Facilitando el acceso computacional a colecciones digitales

Universidad de Alicante
Gustavo Candela, Pilar Escobar, María Dolores Sáez

Facilitando el acceso computacional a colecciones digitales

With many thanks to:

Mahendra Mahey, Sally Chambers, Abbey Potter, Kristy Kokegei, Sarah Ames, Sophie Wagner, Thomas Padilla, Milena Dobreva-McPherson, Caleb Derven, Ditte Laursen, Armin Straube, Caleb Derven, Katrine Gasser, Aisha Al-Abdulla, Lotte Wilms, Paula Bray, Tim Sherratt, Juan Carlos García, Patricia Murrieta-Flores, Javier Pereda, David Abián, Wikimedia Spain and Deutschland

Facilitando el acceso computacional a colecciones digitales

- Parte 1
  - Introducción
  - Proyecto Jupyter
  - Conclusiones
- Parte 2
  - Ejecución de Jupyter Notebooks

Introducción

¿Quiénes somos?

- Dr. Gustavo Candela
- Dr. María Pilar Escobar
- MSC. María Dolores Sáez (Estudiante doctorado)
- Prof. Manuel Marco Such

Introducción

GLAM Lab: Reutilizando colecciones digitales de forma innovadora y creativa

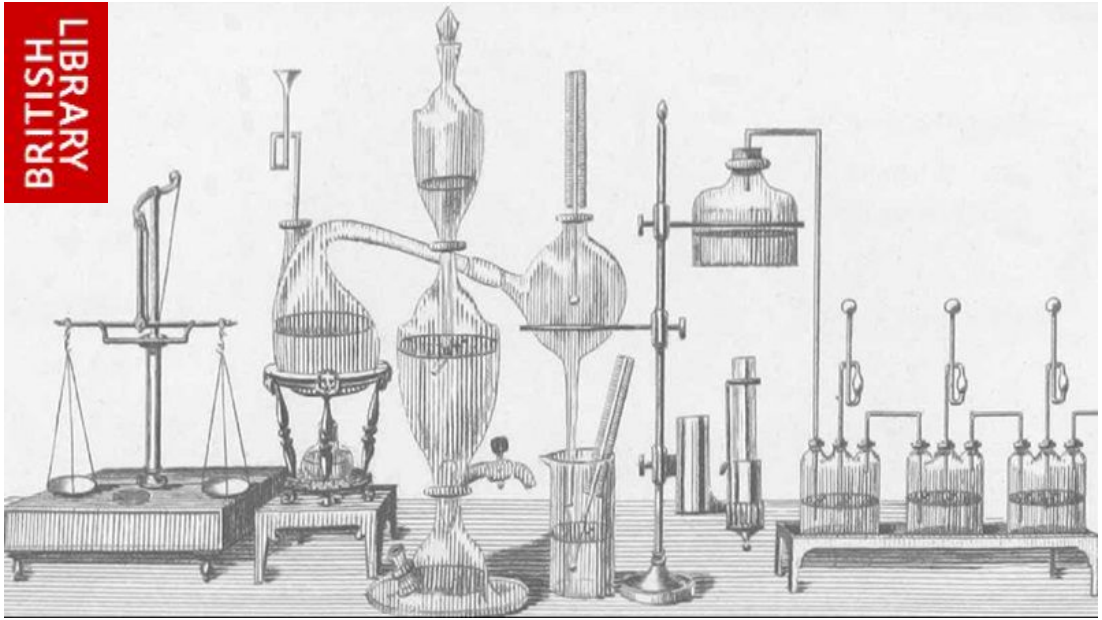

https://www.bl.uk/projects/british-library-labs

OPEN A GLAM LAB

https://glamlabs.io/books/
http://www.cervantesvirtual.com/obra/open-a-glam-lab-1066249/

Introducción

International GLAM Labs Community

¿Te interesan los GLAM labs?

https://glamlabs.io/

Introducción

GLAM Workbench

https://glam-workbench.net/

Sherratt, Tim, Wilms, Lotte, & Lingstadt, Kirsty. (2020, April). LIBER Webinar: Setting Up A GLAM Workbench In Your Library. Zenodo. http://doi.org/10.5281/zenodo.3743193

Introducción

Collections as Data

- Documentos de texto
- Imágenes
- Metadatos
- Application Programming Interface (APIs)
- Datos enlazados (Linked Open Data)

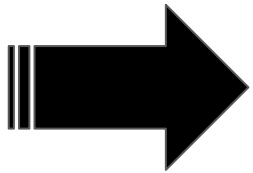

https://doi.org/10.5281/zenodo.3152935

https://collectionsasdata.github.io/fiftythings/

Introducción

Candela, G., Sáez, M. D., Escobar Esteban, Mp., & Marco-Such, M. (2020). Reusing digital collections from GLAM institutions. *Journal of Information Science*. https://doi.org/10.1177/0165551520950246

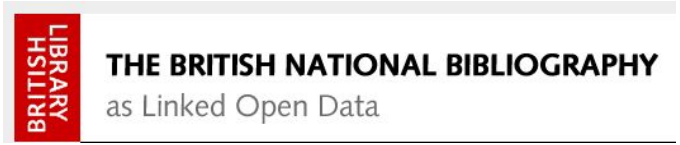

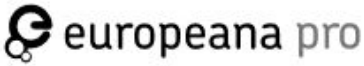

Introducción

Creando Collections as Data

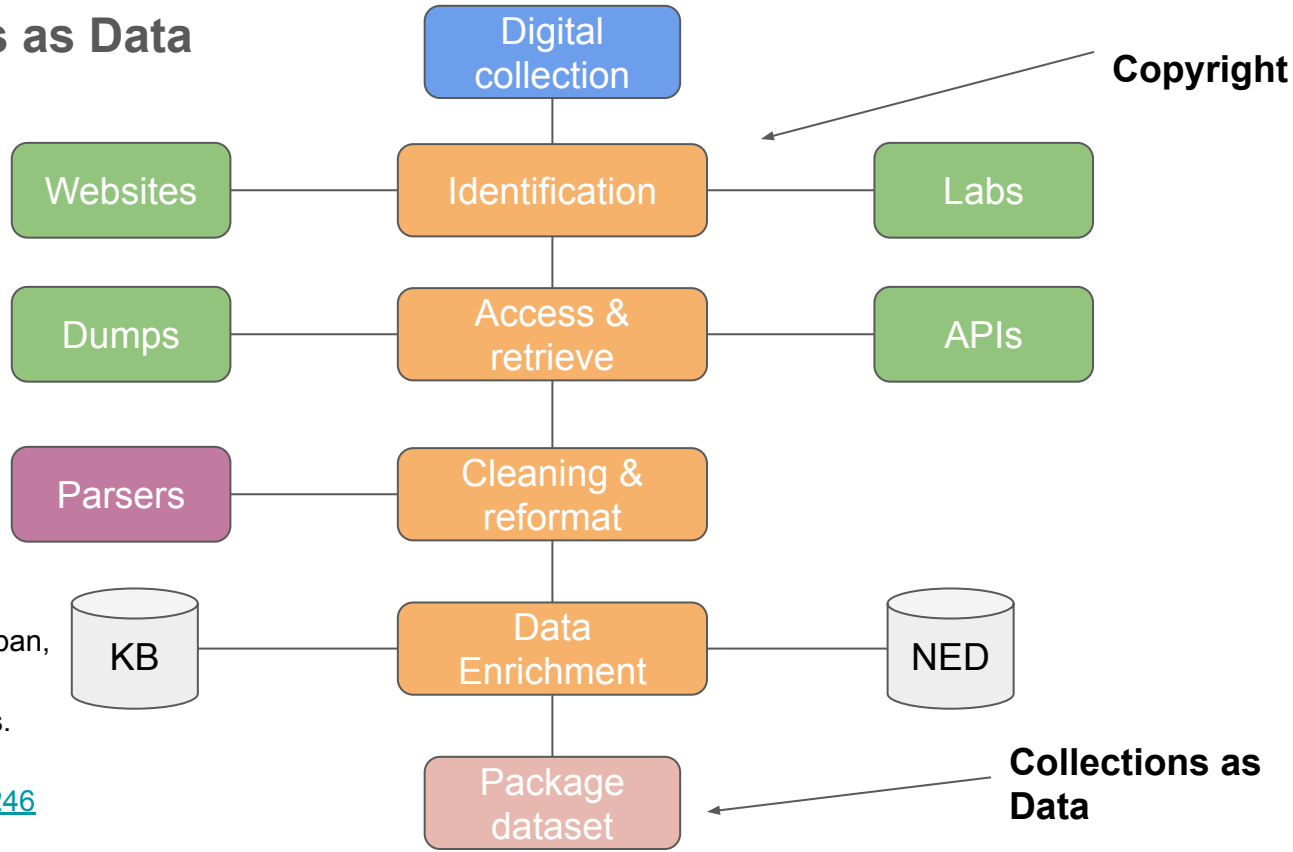

Candela, G., Sáez, M. D., Escobar Esteban, Mp., & Marco-Such, M. (2020). Reusing digital collections from GLAM institutions. *Journal of Information Science*. https://doi.org/10.1177/0165551520950246

Jupyter Notebooks

Proyecto Jupyter

- Software de **código abierto**
- Facilita un **interfaz** sencillo de edición y ejecución
- Combina **documentación textual con código ejecutable**
- Herramienta **colaborativa, reproducible** y reutilizable
- Permite el uso de **lenguajes de programación** como Python y Java

Jupyter Notebooks

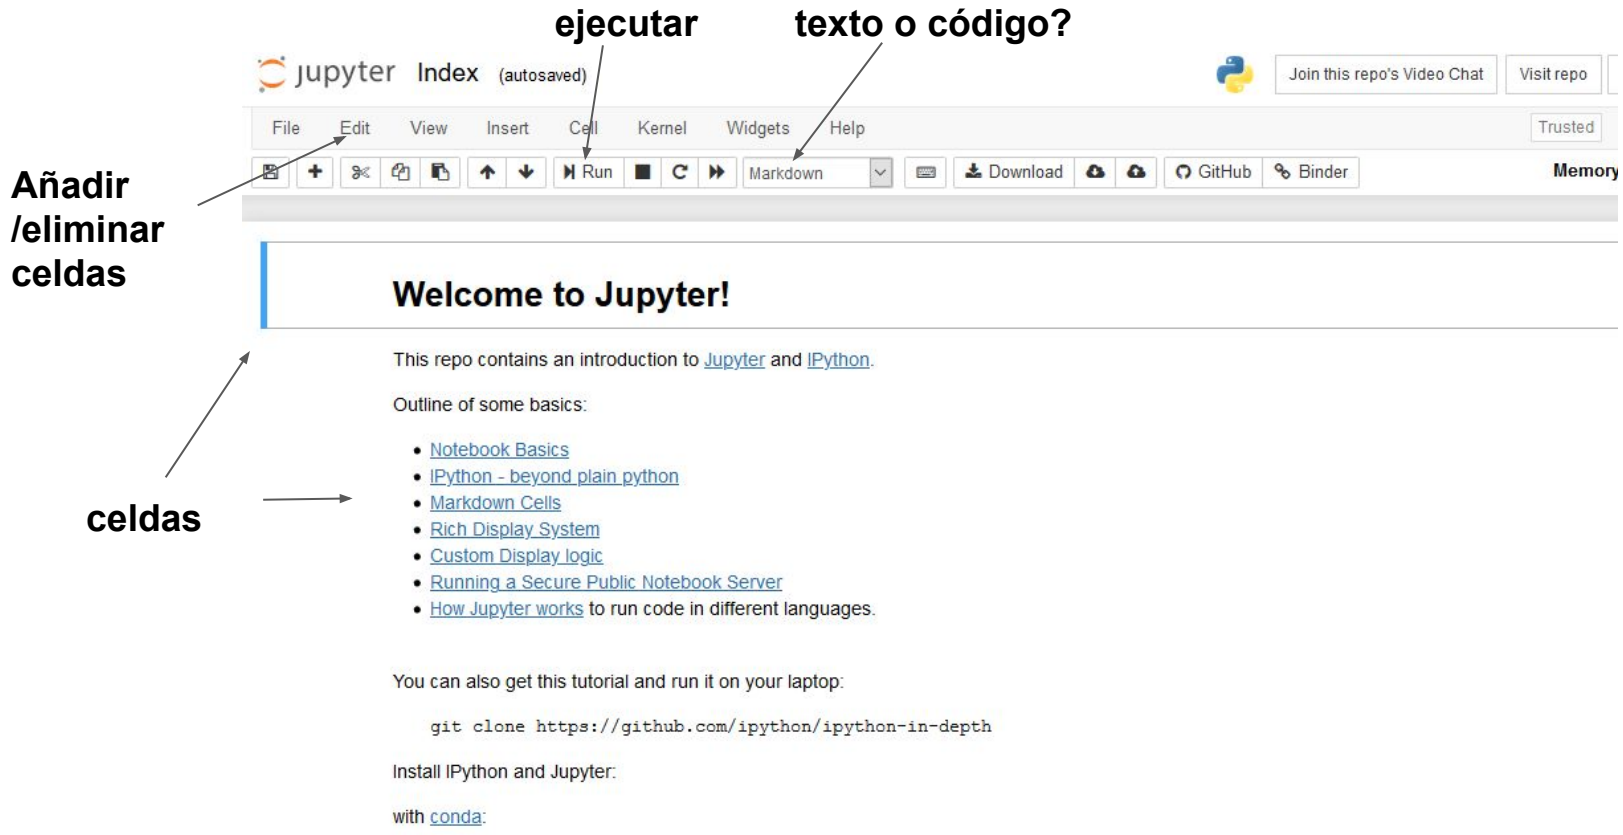

Jupyter Notebooks

[GLAM WorkBench]

[LC Maps for Robots]

[BL Labs]

[Archives Unleashed Notebooks]

[LC - Newspapers navigator]

[National Library of Scotland]

[ONB Labs]

[BVMC]

Reproducible

Popular en la comunidad

Código

Ejecutable en la nube

Herramienta pedagógica

Fácil de utilizar

No es necesario escribir código

Documentación

Jupyter Notebooks

Estructura general

- Introducción (colección, licencia, etc.)
- Importación de librerías de software
- Descarga de la colección digital
- Preprocesamiento de datos
- Análisis

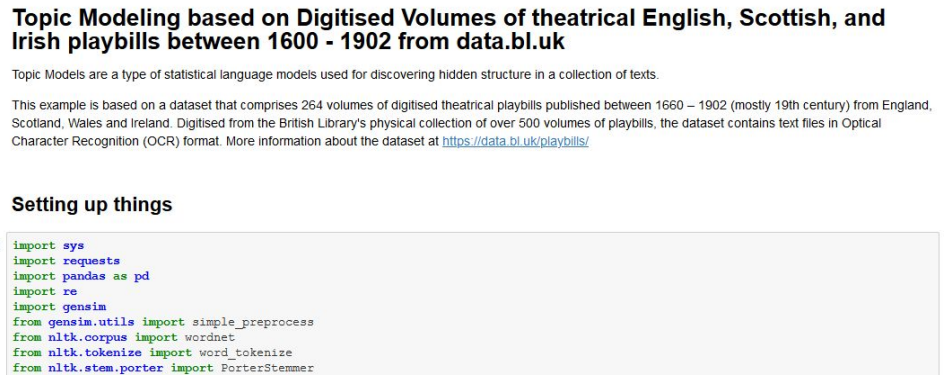

Topic Modeling based on Digitised Volumes of theatrical English, Scottish, and Irish playbills between 1600 - 1902 from data.bl.uk

Topic Models are a type of statistical language models used for discovering hidden structure in a collection of texts.

This example is based on a dataset that comprises 264 volumes of digitised theatrical playbills published between 1660 – 1902 (mostly 19th century) from England, Scotland, Wales and Ireland. Digitised from the British Library's physical collection of over 500 volumes of playbills, the dataset contains text files in Optical Character Recognition (OCR) format. More information about the dataset at https://data.bl.uk/playbills/

Setting up things

```
]: import sys
   import requests
   import pandas as pd
   import re
   import gensim
   from gensim.utils import simple_preprocess
   from nltk.corpus import wordnet
   from nltk.tokenize import word_tokenize
   from nltk.stem.porter import PorterStemmer
```

Jupyter Notebooks

¿Qué necesitamos para su ejecución?

- Un navegador

Usuarios avanzados

- Repositorio de software: GitHub
- Plataforma de ejecución en la nube: MyBinder
- Proyecto Jupyter
- Google Colab vs MyBinder
- Zenodo, figshare

GitHub

Jupyter Notebooks

The notebooks are available in GitHub classified by type of project: images, Linked Open Data, and metadata and text. Additional notebooks provided by ONB Labs and developed by Stefan Karner, have been integrated into the collection.

They are also citable (in Zenodo) and have been assigned a DOI.

DOI 10.5281/zenodo.3765188
DOI 10.5281/zenodo.3765186
DOI 10.5281/zenodo.3765184

In order to launch the notebooks in the cloud, click on the Binder button. Each notebook is based on a dataset provided by a GLAM institution.

Have fun!

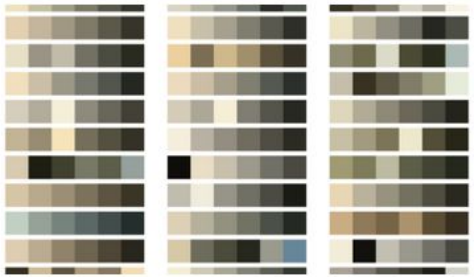

Binder

Binder

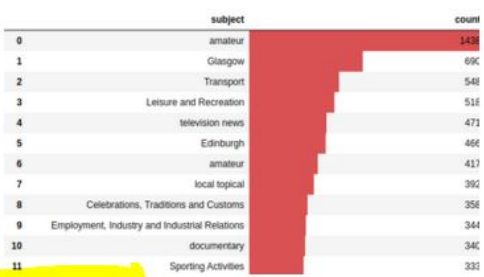

Binder

http://data.cervantesvirtual.com/blog/notebooks/

Jupyter Notebooks

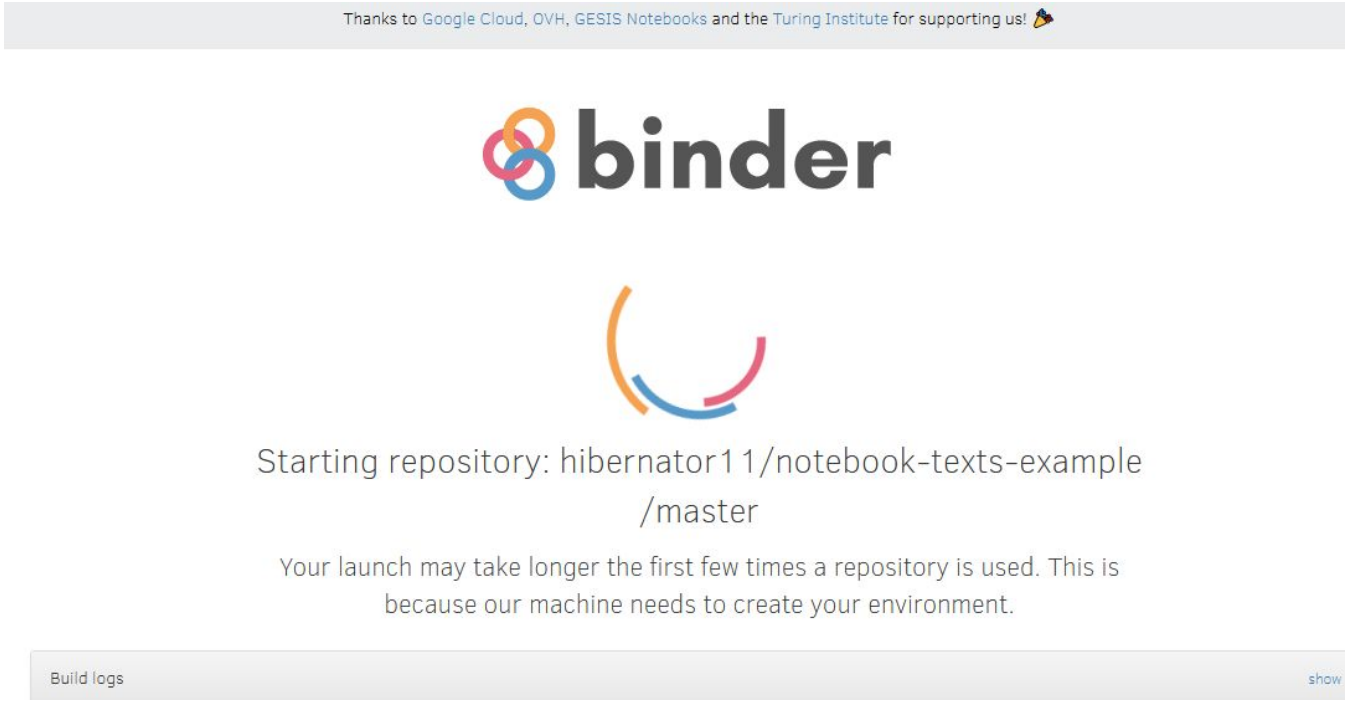

http://data.cervantesvirtual.com/blog/notebooks/

Jupyter Notebooks

http://data.cervantesvirtual.com/blog/notebooks/

Jupyter Notebooks

Topic modeling

Map visualization

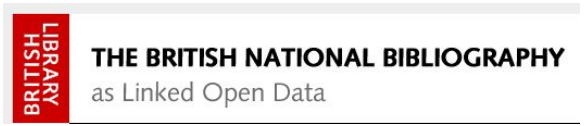

MARC extraction

	subject	count
0	amateur	1436
1	Glasgow	690
2	Transport	548
3	Leisure and Recreation	518
4	television news	471
5	Edinburgh	466
6	amateur	417
7	local topical	392
8	Celebrations, Traditions and Customs	358
9	Employment, Industry and Industrial Relations	344
10	documentary	340
11	Sporting Activities	333

Jupyter Notebooks

Ventajas

- Facilita el tratamiento de las **colecciones publicadas** por instituciones GLAM
- Elimina **barreras de entrada** para los usuarios con menos formación en el uso de la tecnología

- Permite la aplicación de **métodos de investigación**
- **Guía a los usuarios** y permite la edición y ejecución del código

Jupyter Notebooks

¿Dónde encontrar colecciones de datos?

Institución	Colección	URL
Bibliothèque nationale de France	BnF API et jeux de données	http://api.bnf.fr/
British Library	data.bl.uk	https://data.bl.uk/
Det Kgl. Bibliotek	KB Labs	https://labs.kb.dk/
National Library of Netherlands	KB Lab	https://lab.kb.nl/
National Library of Scotland	Data Foundry	https://data.nls.uk/
Library of Congress	LC for Robots	https://labs.loc.gov/lc-for-robots/

Conclusiones

Impacto

- British Library Labs Public Awards 2020
- Presentación en Research Libraries UK
- Artículo Journal of Information Science http://rua.ua.es/dspace/handle/10045/109460
- Tutorial Programming Historian sobre GLAM Labs
- Colaboración con Lancaster University Digital Humanities Hub

Conclusiones

- Notebooks pueden servir como herramienta pedagógica
- La instituciones GLAM están comenzando a adoptar **Collections as Data**
- Existen multitud de formas de hacer públicas las colecciones digitales
- **GLAM Labs** son el espacio ideal para recolectar colecciones digitales
- **Copyright** debe ser claro (Creative Commons Public Domain)
- ¿Estamos reutilizando las colecciones digitales de forma eficiente? ¿Investigadores externos las usan?

Facilitando el acceso computacional a colecciones digitales

Muchas gracias

gcandela@ua.es, mpilar.escobar@ua.es, md.saez@ua.es