

Aprovechamiento de los **datos**

APRENDIZAJE, HERRAMIENTAS Y
EXPERIENCIAS PRÁCTICAS



ESCUELA DE DATOS

FORMACIÓN + INCIDENCIA = **IMPACTO**



13 FELLOWS

7 PAÍSES

PROYECTOS CON IMPACTO

COMUNIDADES LOCALES

EXPERIENCIAS PRÁCTICAS

RECURSOS EDUCATIVOS

COMUNIDADES



**Daniel
Villatoro**

Coordinador Escuela de
Datos y Fellow 2016

[@danyvillatoro](#)



**Pamela
Gonzales**

Fellow 2018
Bolivia

[@10PAMELA20](#)



**Sofía
Montenegro**

Fellow 2018
Guatemala

[@smontenegrom](#)

APRENDIENDO A USAR DATOS A TRAVÉS DE

el **DATA PIPELINE**

LA METODOLOGÍA DE ESCUELA DE DATOS





El “DataPipeline”

- Proyectos basados en datos de principio a fin
- Trabajo en proceso enfocado hacia un impacto
- Capacidades básicas para usar datos en todo el proceso
- Adaptado a “nuestro” contexto Latinoamericano

¿Por qué una tubería?

Las tuberías, como conjunto tienen un propósito: llevar un flujo común. En este caso, ese flujo son los datos, pero a lo largo de la tubería y a través de diferentes procesos, estos datos se van transformando para llegar a un punto en el que no estaban antes.

Un flujo común de datos. Es necesario tener un flujo común de datos para poder transformarlos y llevarlos a un punto en el que no estaban antes.

Definir.

Los proyectos guiados por datos deben empezar definiendo el problema que quieren resolver y sus acciones. Es en esta etapa te haces preguntas y llegas a los propósitos de tu proyecto. Definir tu problema implica pasar de un tema —contaminación ambiental, por ejemplo— a una o varias preguntas específicas — ¿El uso de bicicletas ha reducido la contaminación del aire?

Ser específico te fuerza a formular tu pregunta de tal manera que provea pistas hacia los tipos de datos que necesitarás. Lo que te ayuda a definir la ambición de tu proyecto: ¿Los datos que necesito son fáciles de obtener? ¿O algunos datos principales serán difíciles de encontrar?

Datos con propósito

¿Qué información necesitas?

- estadísticas
- información histórica
- información pública
- testimonios
- análisis
- evidencia gráfica
- información geolocalizada
-

¿Qué harás con la información?

- informar
- sensibilizar
- visibilizar
- denunciar
- involucrar
- posicionar
- vigilar
- movilizar
-

¿Qué quieres lograr?

- participación ciudadana
- conciencia social
- acción social o gubernamental
- políticas públicas
- rendición de cuentas
- educación cívica
- ...

Ejemplo: Informar a consumidores

RADIOGRAFÍA

PANDITAS - Gomitas de grenetina - DE RICOLINO

(115 g, 1 bolsita)



12 CUCHARADAS CAFETERAS DE AZÚCAR. Cubre **262% al 314%** del total de **azúcar máxima diaria** para un niño.



12 INGREDIENTES EN TOTAL. Primer ingrediente **jarabe de maíz** que puede contener **mayor cantidad de fructosa.**



El **alto consumo de azúcares** se asocia con **sobrepeso, obesidad, diabetes** y otras enfermedades.



Colorantes: rojo 40, azul 1, amarillo 5 y 6 **de-tonantes de hiperactividad y déficit de atención** agudos en niños.



VALORACIÓN

No recomendado para el consumo de niños por la presencia de colorantes.



Fuente: El poder del consumidor

Organizaciones de la sociedad civil nos congratulamos ante la aprobación de la propuesta para un etiquetado de advertencia en productos ultraprocesados

25 julio, 2019 | Etiketado de productos, En portada, Prensa, Salud nutricional



Buscar.

Al tener una definición del problema, llegas a una idea de qué datos necesitarás, buscar estos datos es otro paso, con mucha o poca dificultad dependiendo del problema. Hay muchas herramientas y técnicas para hacer eso: desde una simple pregunta en tus redes sociales, hasta usar herramientas como un buscador, portales de datos abiertos o una solicitud de acceso a la información pidiendo datos que están disponibles en esa institución del gobierno. Esta fase puede ser definitiva para el éxito de tu proyecto, ya que si no encuentras los datos, no podrás hacer mayor cosa. Pero esta es la fase en la que también se necesita creatividad para actuar diferente.



¿DÓNDE BUSCAR?

Gobierno + Organizaciones + Academia

¿portales de datos abiertos?

VS

¿acceso restringido?

A googlear!

filetype:XLS

filetype:CSV

filetype:SHP

filetype:MDB

filetype:SQL

filetype:DB

filetype:PDF

inurl:downloads

inurl:descargas

site:.gob

site:.gob.gt

Ejemplo: Femicidios en México



www.femicidios.mx

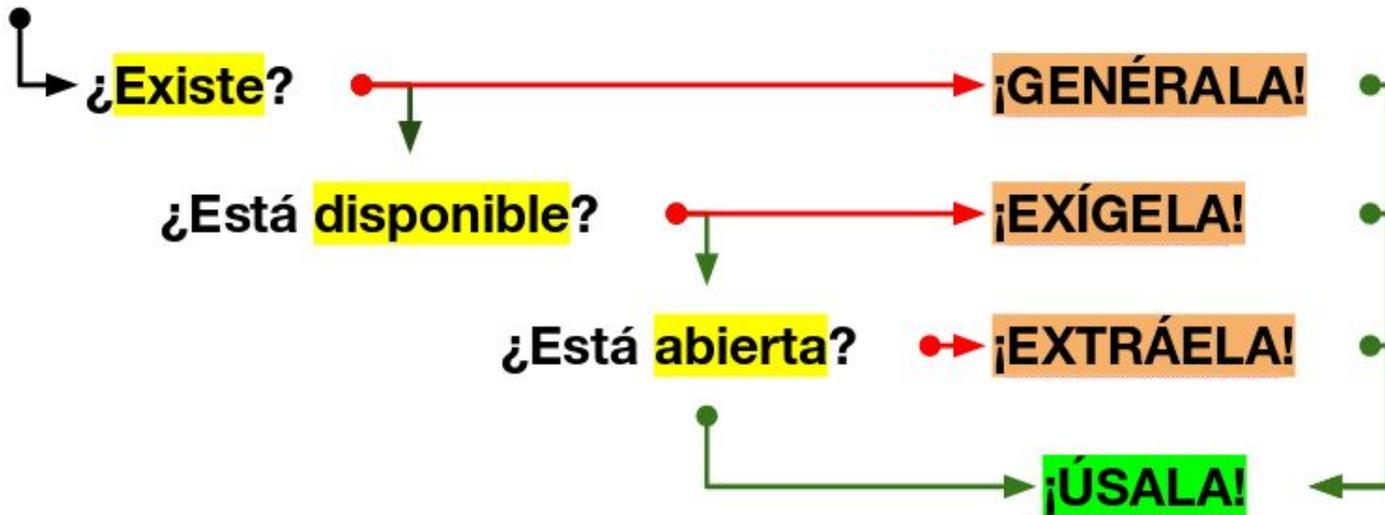
Recolectar.

Hacer que los datos lleguen a tu computadora puede ser una tarea corta y fácil, o una larga y dolorosa. Hay muchas maneras de lograrlo. Se puede hacer crowdsourcing usando formularios en línea o encuestas, una recolección offline, scrapear una página web o simplemente descargar conjuntos de datos de los sitios del gobierno -usando portales de datos o a través de una solicitud de acceso a información-.



Ir por los datos

¿Qué información necesito?



Generación de datos

Construir mis propios datos

Tú administras una encuesta, haces llamadas, vas llenando una base de datos, vas obteniendo datos manualmente

Puedes utilizar:

- Formularios online y offline
- Aplicaciones para levantar datos: preguntas, imágenes, audio, video y geolocalización

Ejemplo: Reconstrucción post-sismo



Datos desde las expresiones en línea

Crowdsourcing

Las personas van dando sus datos en plataformas públicas, redes sociales o mecanismos de obtención de datos

Mecanismos comunes para crowdsourcing:

- Apps y formularios de reporte o denuncia
- Acceso a datos de redes sociales
- Extracción de datos de plataformas y espacios de comentarios y expresión ciudadana

Ejemplo: Reportes ciudadanos

¿Qué hace el CIC con tus reportes?

Con el objetivo de que conozcas mejor tu comunidad, y que la autoridad conozca los problemas que la aquejan, el CIC recibe, valida, canaliza, da seguimiento y publica los reportes ciudadanos.

Los resultados en tiempo real se muestran a continuación. Te recomendamos ver el **CIVIX** para su mejor entendimiento. ¡Súmate reportando y sé parte de la solución!



<http://www.cic.mx/>

Solicitar datos públicos

Solicitudes de información pública

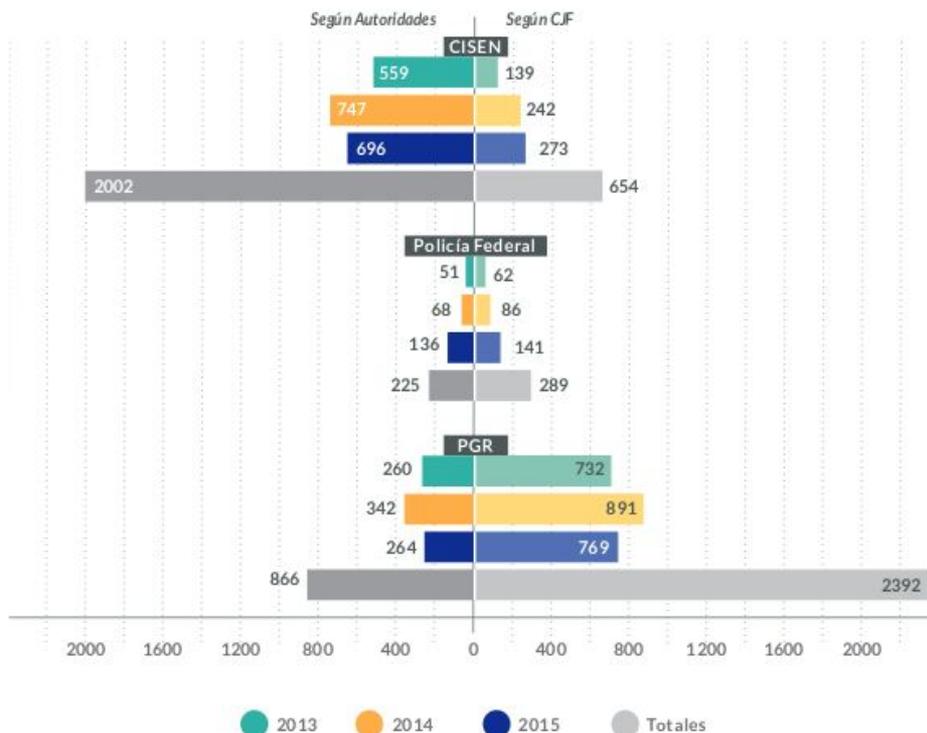
La Ley te faculta para pedirle información a entes públicos y cualquier privado que administre fondos públicos

Recomendaciones:

- Identificar área exacta de gobierno que la genera
- Solicitar información puntual de acuerdo a la nomenclatura identificada en contexto de gobierno
- Solicitar formatos abiertos para entrega
- Apalancar en información otorgada o abierta

Ejemplo: Vigilancia Estatal en México

INTERVENCIÓN DE COMUNICACIONES PRIVADAS
SOLICITUDES DE AUTORIZACIÓN JUDICIAL SEGÚN AUTORIDADES VS DATOS DEL CJF
2013-2015 · SAI - CJF



Extracción (“scraping”) de datos

Scraping, rascado o extracción automática

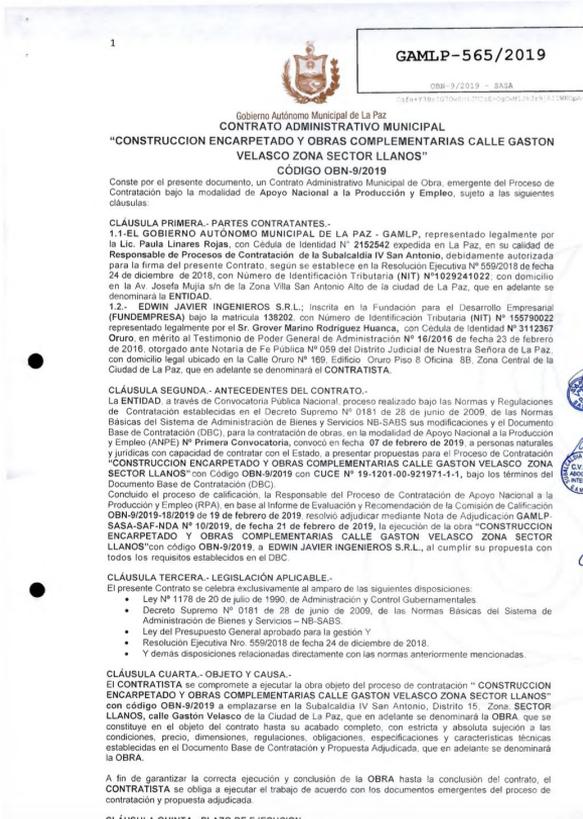
La información está en la web, pero no está junta ni sistematizada. Con herramientas y código la extraes para tu uso.

Puedes extraer datos desde:

- Papel ... con personas voluntarias :S
- Imágenes utilizando OCR
- PDFs
- Sitios web / HTML

Ejemplo: Extracción desde imagen

Result



Images

Text

Fonts

Metadata

Only the first 100 lines of extracted text are shown. Use the download button to download the full document.

Download result as a file

EL PRESENTE CONTRATO ADMINISTRATIVO MUNICIPAL N° 565/2019, DE EDWIN JAVIER INGENIEROS S.R.L., A CUMPLIR SU PROPOSITO DE LOS REQUISITOS ESTABLECIDOS EN EL DBC.

CLÁUSULA TERCERA.- LEGISLACIÓN APLICABLE. El presente Contrato se celebra exclusivamente de acuerdo con los requisitos establecidos en el DBC.

• Ley N° 1178 de 20 de julio de 1990, de Administración y Control Gubernamentales.

• Decreto Supremo N° 0181 de 28 de junio de 2009, de las Normas Básicas del Sistema de Administración de Bienes y Servicios - NB-SABS.

• Ley del Presupuesto General aprobado para la gestión Y

• Resolución Ejecutiva Nro. 559/2018 de fecha 24 de diciembre de 2018.

• Y demás disposiciones relacionadas directamente con las normas anteriormente mencionadas.
CLÁUSULA CUARTA.- OBJETO Y CAUSA. El CONTRATISTA se compromete a ejecutar la obra ENCARPETADO Y OBRAS COMPLEMENTARIAS CALLE GASTON VELASCO ZONA SECTOR LLANOS, calle Gaston Velasco de la ciudad de La Paz, que en adelante se denominará la OBRA.

Back to start

<https://www.extractpdf.com/>

Ejemplo: Extracción desde PDF

Import one or more PDFs

Browse...

Import

Imported PDFs

File Name	Size	Pages	Date Added	Remove	Process
NuevoSim.pdf	136 kB	6	01 Aug 2019 01:26	×	Extract Data
110.pdf	1024 kB	12	01 Aug 2019 01:25	×	Extract Data

judging-rubric.pdf

Templates

Clear All Selections

Autodetect Tables

Technovation
Judging Rubric

Please see each on a scale of 5 pts:

- 5 pts - Outstanding. The work is cutting edge.
- 4 pts - Well-Implemented. The work meets major requirements.
- 3 pts - Good. The work shows promise.
- 2 pts - Fair. The work is of good quality.
- 1 pts - Satisfactory. The work is of average quality.

Ideation (20 points)	Score
How do the team members describe their idea, and describe why?	
2.0 pts The team clearly shows how their idea fits the stage with questions that connect.	
1.0 pts The team provides evidence of the problem they are solving through facts and statistics.	
0.0 pts The team fails to address the problem well.	
Ideation Total Score	
Technical (20 points)	Score
How do the team describe, demonstrate, and describe their?	
2.0 pts The app appears to be fully functional and has no noticeable bugs.	
1.0 pts The app is easy to use and the features are well thought out.	
0.0 pts The app is not fully complete. The team does not explain their solution. Do not award any points until the 2.0 score is given on the Technical section of the judging rubric.	
Technical Total Score	
Pitch (20 points)	Score
How do the team describe their pitch?	
2.0 pts The team clearly states the problem they are solving.	
1.0 pts The team presents a convincing argument to support their solution.	
0.0 pts The team fails to clearly explain what is well thought out.	
0.0 pts The pitch is weak and not the team's.	
Pitch Total Score	

1

Technovation
Judging Rubric

Please see each on a scale of 5 pts:

- 5 pts - Outstanding. The work is cutting edge.
- 4 pts - Well-Implemented. The work meets major requirements.
- 3 pts - Good. The work shows promise.
- 2 pts - Fair. The work is of good quality.
- 1 pts - Satisfactory. The work is of average quality.

Entrepreneurship (20 points)	Score
Does the team clearly state the business plan, describe their idea, and explain why?	
2.0 pts The team has a strategy for being the best in their field.	
1.0 pts The team research shows they have identified the competition and ways to stand out from them.	
0.0 pts The team has no research on the market or their competition. The goals are unrealistic and unclear.	
0.0 pts The team's business has no identity through branding and assets.	
Entrepreneurship Total Score	
Overall Impression (20 points)	Score
How do the entire submission.	
2.0 pts The submission stands out from others.	
1.0 pts Each component of the team submission is well thought out.	
0.0 pts The team is using repetitive and generic ideas, and the presentation is not creative.	
0.0 pts The way the team approaches and solves the problem is unique.	
0.0 pts The submission stands out from others.	
Overall Impression Total Score	

Total Score
Ideation Total Score
Technical Total Score
Entrepreneurship Total Score*
Pitch Total Score
Overall Impression Total Score
Team Submission Total Score

2

5 pts	Each component of the team submission is well thought out.
5 pts	The team's strong dedication and work ethic is clear, even if the submission is not complete.
5 pts	The way the team approaches and solves the problem is unique.
5 pts	The submission stands out from others.
Overall Impression Total Score:	

Total Score	
Ideation Total Score	
Technical Total Score	
Entrepreneurship Total Score*	
Pitch Total Score	
Overall Impression Total Score	
Team Submission Total Score	
*Senior Division only	

Is the extracted data incorrect?

You can revise your selected cells or try an alternate extraction method.

Revise Selected Cells

Data has been extracted from the cells you selected in the previous step. You can revise your selection(s) to add or remove cells.

[← Revise selection\(s\)](#)

Choose Alternate Extraction Method

The current preview uses the **Stream** extraction method. If the data is not mapped to the correct cells, try the **Lattice** method instead.

judging-rubric.pdf

Export Format

✓ CSV

TSV

JSON (dimensions)

JSON (data)

zip of CSVs

Script

Export

Copy to Clipboard

Preview of Extracted Table Data

Total S

Ideation Total Score

Technical Total Score

Entrepreneurship Total Score*

18 Pitch Total Score

Overall Impression Total Score

Team Submission Total Score

Verificar.

Obtener los datos no significa que el problema está resuelto. Es necesario verificar si su información es válida, así como revisar los metadatos y la metodología con la que se recolectó este conjunto de información. Es importante también conocer quién organizó este conjunto de datos y si es una fuente con credibilidad en el tema y en la técnica de recolección.



¿Esta información es la que necesito?

¿Tengo la información completa?

¿En qué contexto están estos datos?

¿Están en un formato que me permita analizarlos?

¿Estos datos responden a mis preguntas iniciales?

¿Son datos oficiales?

¿La fuente es confiable?

¿Cuál fue la metodología para producirlos?

Ejemplo: Verificación de noticias

verificad 

2018



<https://es.schoolofdata.org/tag/fact-checking-la-fiebre-que-se-contagia-por-toda-latinoamerica/>

MÉTODO DE VERIFICACIÓN DEL DEBATE PÚBLICO

Ocho pasos para un buen chequeo:

- 1- Seleccionar una frase del ámbito público
- 2- Ponderar su relevancia
- 3- Consultar a la fuente original
- 4- Consultar a la fuente oficial
- 5- Consultar a fuentes alternativas
- 6- Ubicar en contexto
- 7- Confirmar, relativizar o desmentir la afirmación
- 8- Calificar



ConPruebas es un ejercicio periodístico de verificación del discurso público



En efecto, los datos respaldan el enunciado.



Todos los datos e información indican que el enunciado no es real.



Algunos datos son verdaderos, pero no todos.



No hay documentos que prueben que el enunciado es correcto.

Limpiar.

Es muy común que los datos que se obtienen y validan estén en desorden y tengan problemas de formato: filas duplicadas, nombres de columna que no combinan con los registros, valores que contienen caracteres raros o que impiden el procesamiento de la computadora y otros más. En este paso, necesitamos habilidades y herramientas que nos permitan tener los datos en un formato legible para analizarlo por computadora. Herramientas como OpenRefine, LibreOffice Calc o Excel y conceptos como bases de datos relacionales son útiles en esta etapa.



¿Porqué hay que limpiar datos?

País	1996	2000	2004
 Estados Unidos	122	394	281
 Estados Unidos de America	500	200	300
 Estados Unidos,	400	200	124
 Unión Soviética	280	39	76
 Union Soviética	110	230	140
 Union Sovietica	5	50	80



País	1996	2000	2004
 Estados Unidos	1022	794	705
 Unión Soviética	395	319	296

¿Cuándo hay que limpiar datos?

La ortografía es inconsistente

Los dedazos o errores “de dedo” en palabras o números

Espacios o caracteres inconsistentes

Formatos de fecha inconsistentes

Texto que fue convertido a números

Números que fueron guardados como texto

Extracción (“scraping”) de datos

Limpieza sencilla desde hojas de cálculo

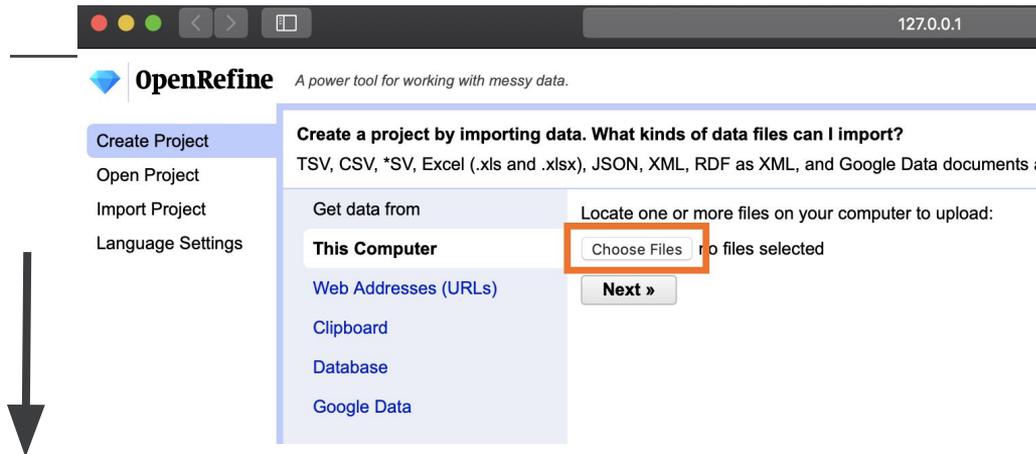
> Funciones básica tales como buscar, reemplazar, filtros y formatos de celdas

Limpieza de grandes volúmenes de datos



DataWrangler^{alpha}

Ejemplo:



1236 records

Extensions: Wikidata ▾

Show as: rows records

Show: 5 10 25 50 records

« first < previous 1 - 10 next > last »

▼ All	▼ «iOJ	▼ NOMBRE	▼ NIT / DPI	▼ AFILIADO	▼ SIMPATIZANTE	▼ CUENTA BANCA	▼ No. DE RECIBO	▼ fecha1	▼ fecha2
☆	🔊	1.							
☆	🔊	2. 1	Ileana Guadalupe Calles Domínguez	X	■ f:		327	0.00	50.00
☆	🔊	3. 2	Milton Francisco Sánchez Cuellar	X			320/325	200,00	200.00
☆	🔊	4. 3	Verónica Liseth del Alba Crispin M,	X			328	100,00	0.00
☆	🔊	5. 4	Maria Eugenia Sarrios Robles	x			329	: 0,00	100.00
☆	🔊	6. 1	Egar Justino Ovalle Maído nado	x	1 323		800.00	0,00	0.00
☆	🔊	7. 2	Jaime Antonio de la Peña	X	336		0.00	100.00	0.00
☆	🔊	8. 3	Sergio Raúl Franco Sagastume	X	321		100.00	0.00	0.00
☆	🔊	9. 4	Gregorio Augusto López	X	326		100.00	0.00	0.00
☆	🔊	10. 5	Milton Francisco Sánchez Cuellar j	X	335		0.00	0.00	200.00

Fingerprint

Quita todos los espacios en blanco, cambia todos los caracteres a minúsculas, remueve toda la puntuación y normaliza cualquier carácter especial a una versión estándar. Luego, parte el texto y aplica espacios en blanco. Así encuentra las coincidencias.

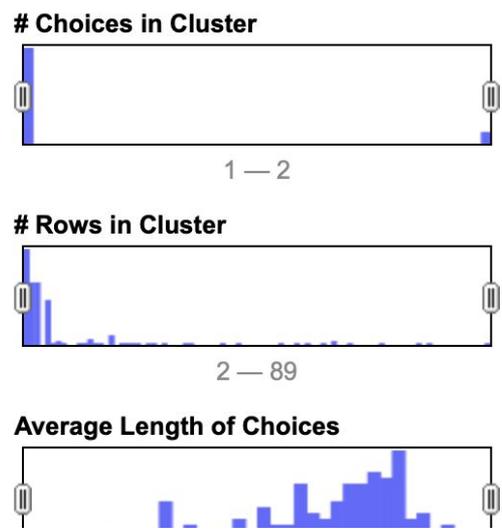
Method 

Keying Function

- ✓ fingerprint
- ngram-fingerprint
- metaphone3
- cologne-phonetic
- Daitch-Mokotoff
- Beider-Morse

166 clusters found

Cluster Size	Row Count	Values in Cluster	Row Cell Value
2	18	<ul style="list-style-type: none">Alex Ortiz (12 rows)Alex Ortíz (6 rows)	Alex Ortiz
2	14	<ul style="list-style-type: none">Juan Carlos Ovaile (10 rows)Juan Carlos Ovaile ' (4 rows)	Juan Carlos Ovaile
2	76	<ul style="list-style-type: none">Gregorio Augusto López (74 rows)Gregorio Augusto López . (2 rows)	Gregorio Augusto López
2	4	<ul style="list-style-type: none">María Eugenia Barrios Robles (2 rows)María Eugenia Barrios Robles (2 rows)	María Eugenia Barrios Robles



<https://es.schoolofdata.org/2018/05/03/algoritmos-y-clusters-encuentra-errores-y-limpialos-de-manera-facil-con-openrefine/>

Analizar.

Esta es la parte en la que obtenemos conocimiento sobre el problema que definimos al principio. Al poner en práctica nuestras habilidades estadísticas y matemáticas, podemos entrevistar un conjunto de datos como cualquier periodista entrevista a sus fuentes. Solo que en vez de usar una grabadora y una libreta, analizamos con muchas herramientas y habilidades. Podemos generar visualizaciones que nos muestren la distribución de diferentes variables o podemos usar paquetes de lenguajes de programación como Pandas (Python) o R. También podemos usar hojas de cálculo como LibreOfficeCalc y Excel, o programas estadísticos como SPSS.



Tipos de análisis de datos

Análisis descriptivo

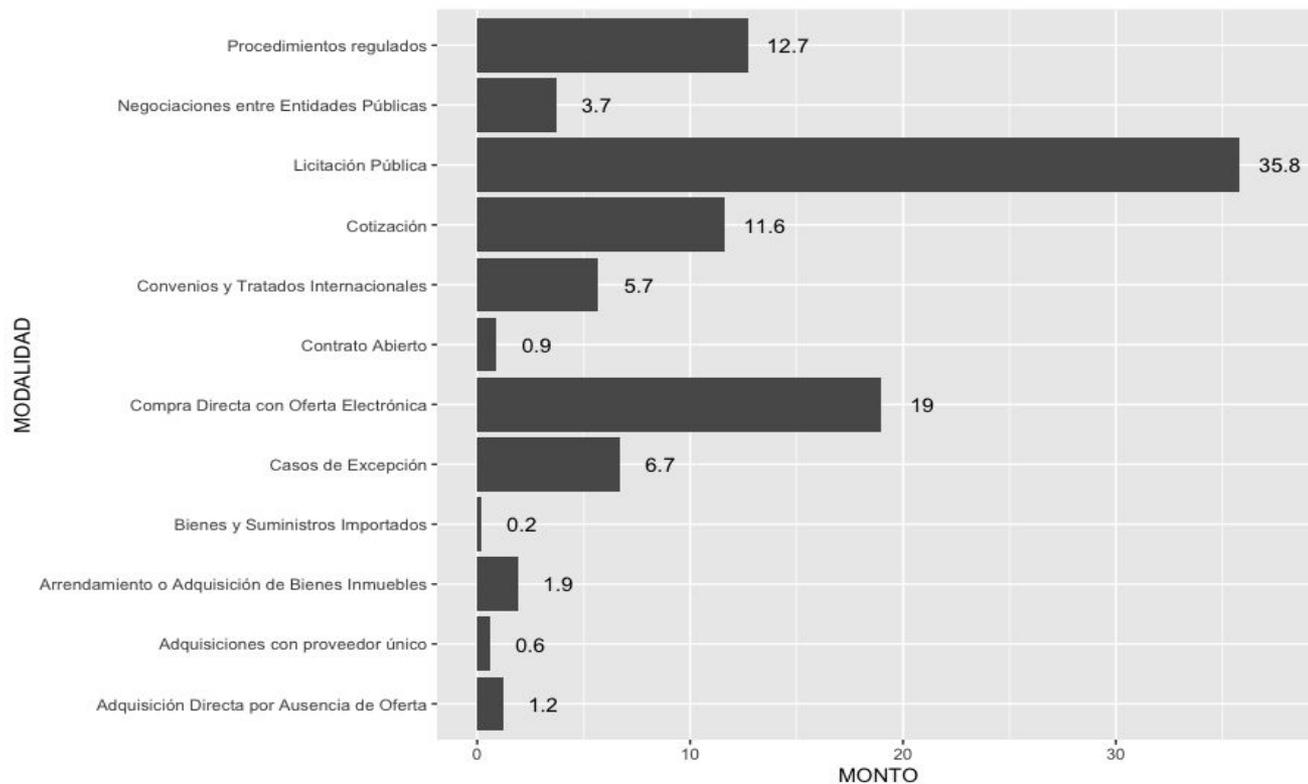
Medidas de tendencia central

- Promedio
- Moda
- Mediana
- Desviación estándar

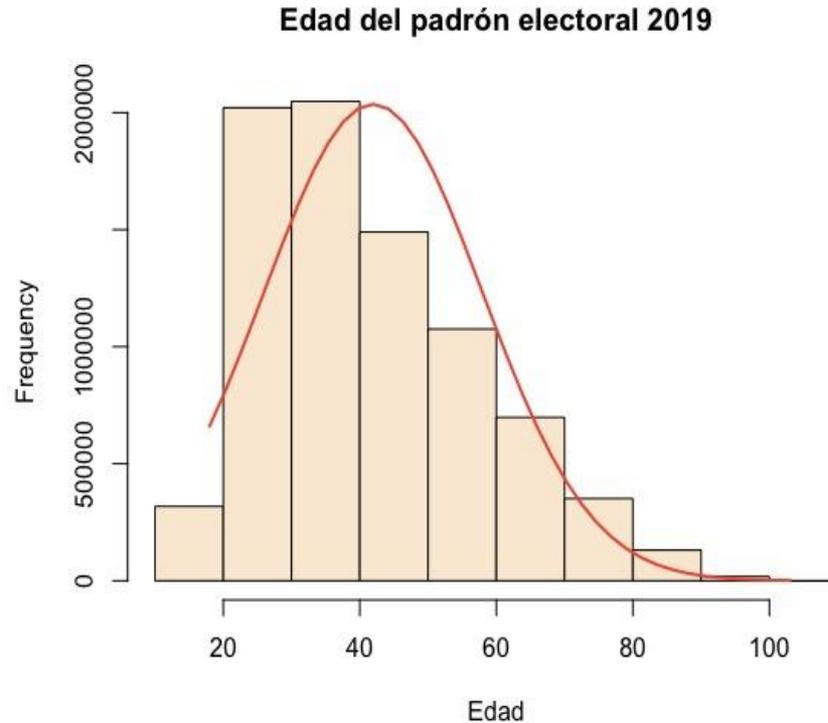
Análisis inferencial

- Prueba de hipótesis
- Intervalos de confianza
- Correlación y causalidad
- Intro a probabilidad
- Outlayers

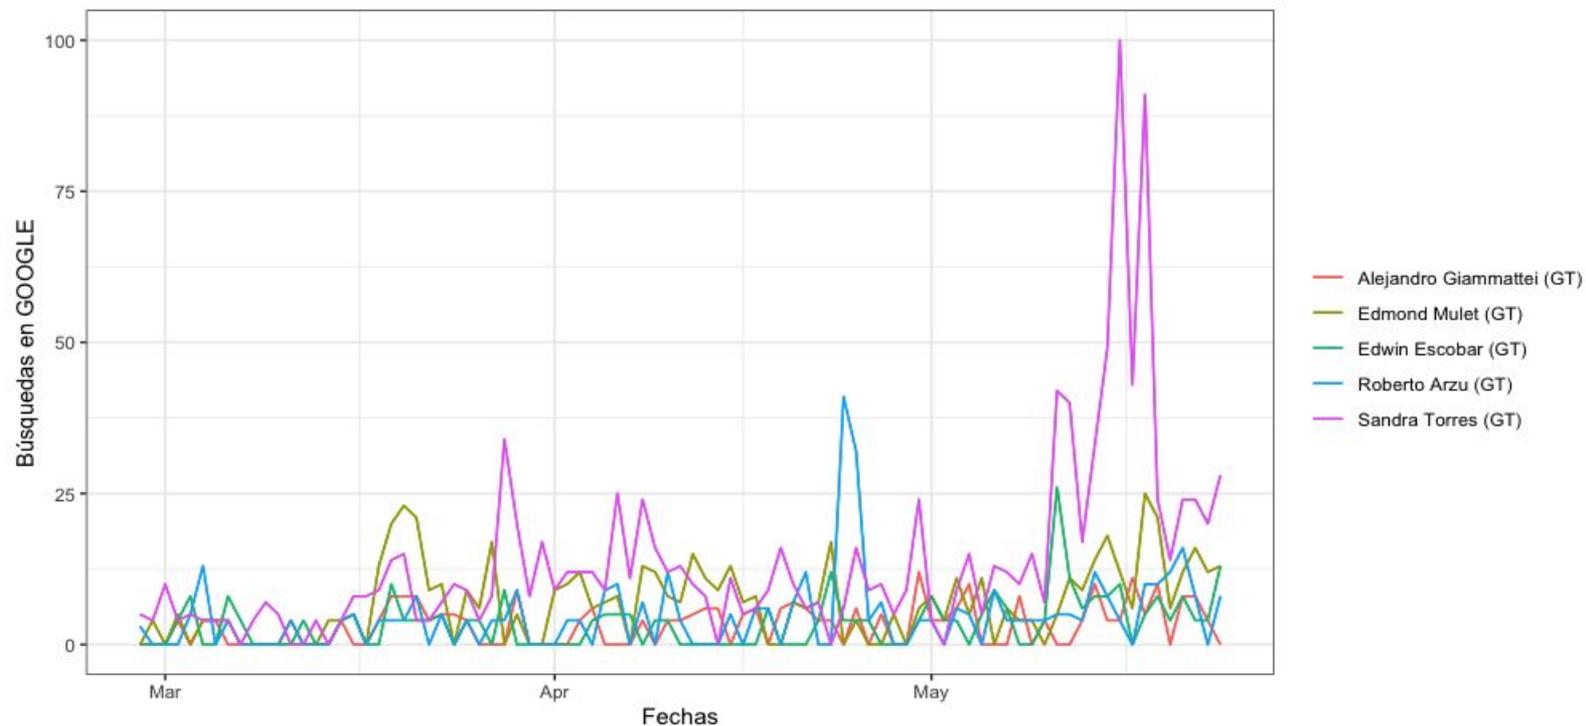
¿Cómo se ve el análisis de datos?



¿Cómo se ve el análisis de datos?

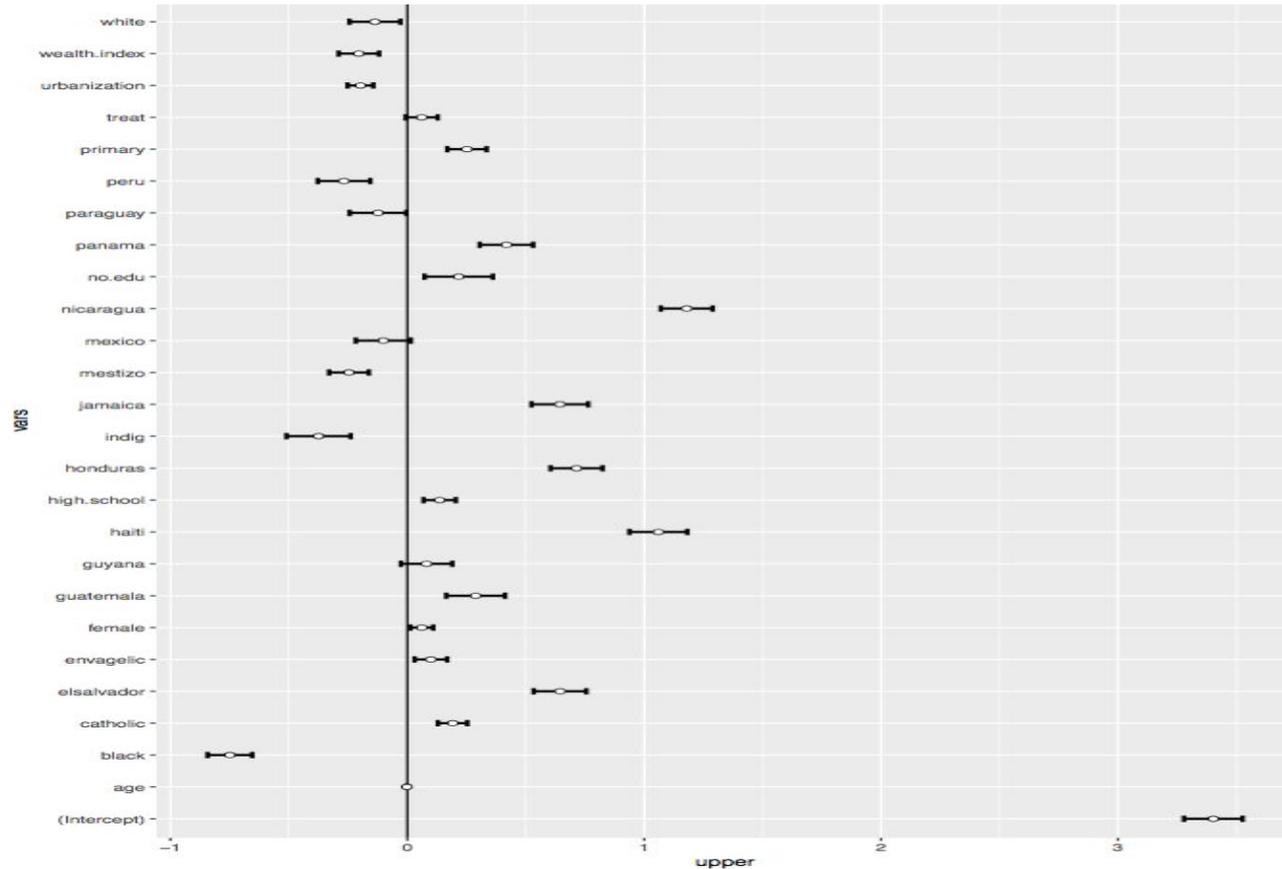


¿Cómo se ve el análisis de datos?



Elaborado por @smontenegrom con datos de Google Trends

¿Cómo se ve el análisis de datos?



Presentar.

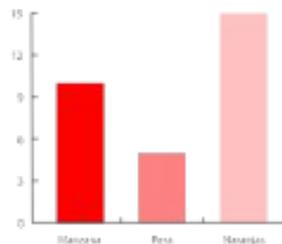
Es necesario presentar los datos: hablar con tu audiencia para que conozca las preguntas que buscabas responder y el medio que te ha permitido llegar a ciertas conclusiones o iniciar una conversación. En esta etapa debemos enfocarnos en entender buenas prácticas para presentar los datos de manera visual y sabernos dar a entender.



Visualización vs. Narrativas

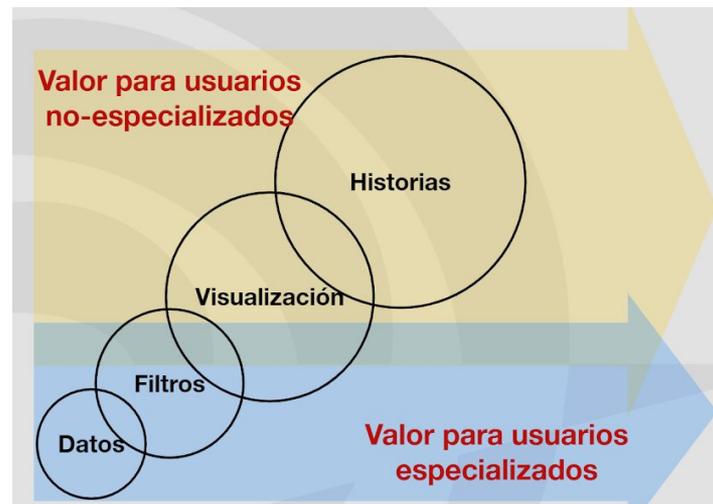
Visualización

Una gráfica, un diagrama

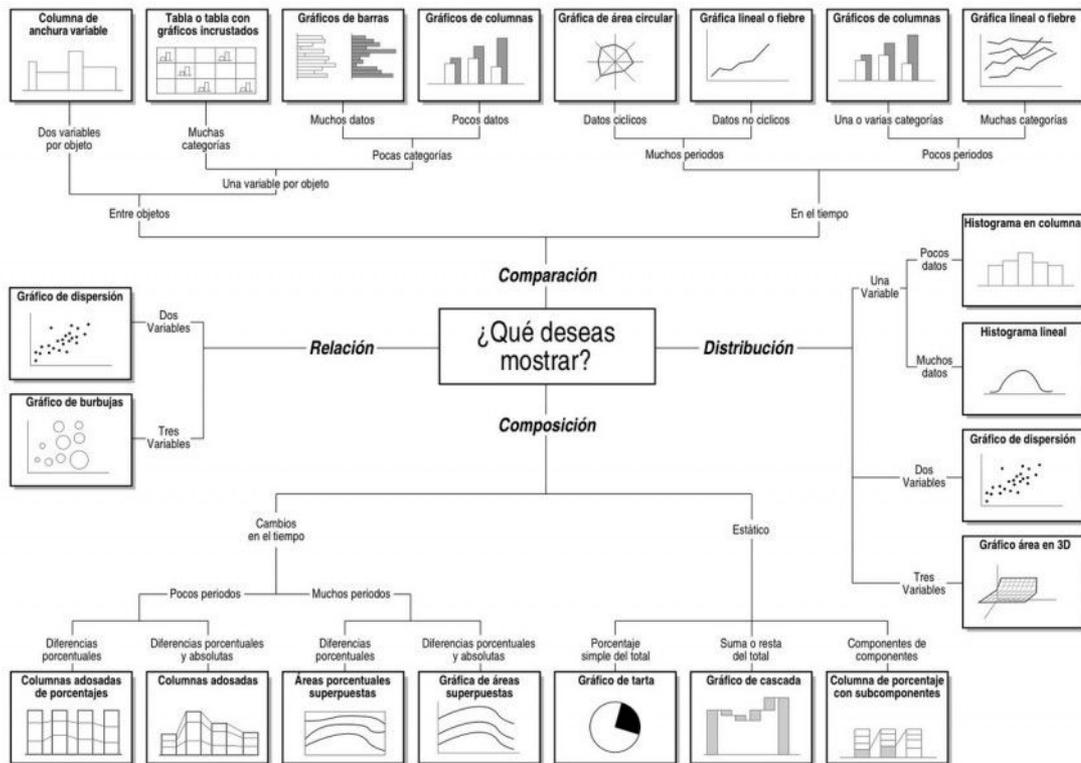


Narrativas

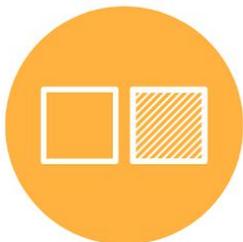
Contar una historia
Hacer evidente un mensaje
Contextualizar
Llevar de lo general a lo particular



¿Qué gráfica usar?



¿Qué se desea mostrar?



Comparaciones



Dimensiones



Relaciones



Jerarquía



Como Funcionan las
Cosas



Procesos y Métodos



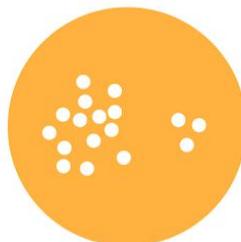
Conceptos



Ubicación



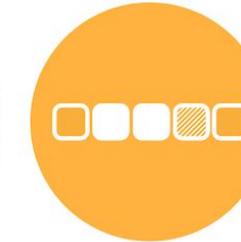
Parte a la Totalidad



Distribución



Movimiento o Flujo

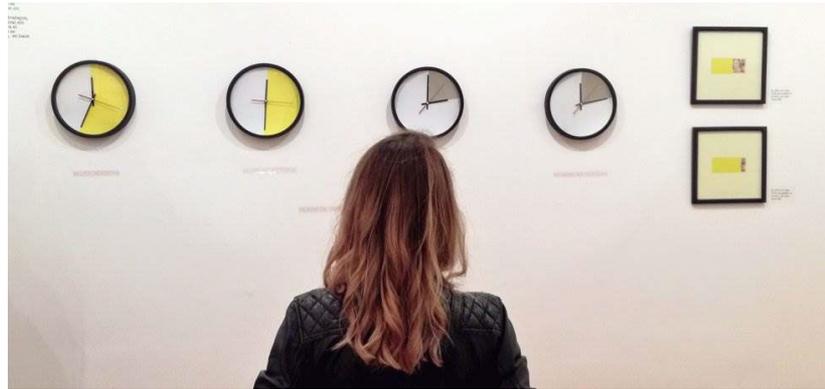


Patrones

Ejemplo: Data Art

brecha

Un proyecto para visibilizar la desigualdad entre sexos



<https://www.behance.net/gallery/55950059/brecha-instalacion-y-visualizacion-de-datos>

Herramientas para visualizar datos

Tableau - <https://www.tableau.com/es-es>

Flourish - <https://flourish.studio>

Infogr.am - <https://infogram.com>

Piktochart - <https://piktochart.com>

Plot.ly - <https://plot.ly>

KnightLab - <https://knightlab.northwestern.edu/projects>

Cómo elegir la mejor gráfica - <https://datavizcatalogue.com/>

Elementos a considerar



Que lo que digo esté
fundamentado



Que las personas
puedan leerlo



Que conecte con ellos
en una dimension
emocional

¡Gracias!

@EscuelaDeDatos