

Devolución general del Ej 2

Eduardo Fernández

2023


Etapas

1. Averiguar la estructura de los datos.
2. Realizar sanity check.
 - Realizar preguntas iniciales que sirvan para explorar los datos.
3. Realizar más preguntas.

Datos

- World-Development-Indicators <https://databank.worldbank.org/reports.aspx?source=world-development-indicators> Indicadores de países según el Banco Mundial.
- <https://datasf.org> Datos de crímenes en San Francisco.
- <https://courses.cs.washington.edu/courses/cse512/21sp/data/weather.csv.gz> estaciones meteorológicas en EEUU.
- <https://catalogodatos.gub.uy/dataset/intendencia-montevideo-viajes-realizados-en-los-omnibus-del-stm> líneas de bus en Montevideo.
- <https://capitalbikeshare.com/system-data> alquiler de bicicletas en Washington DC.
- <https://www.kaggle.com/datasets/shivamb/netflix-shows> Netflix

Mapa de calor para buscar densidad de ausencias de datos



Matriz de correlación de indicadores




Podría aportar el uso de dendogramas para ordenar indicadores por similitud.

Mapa de Calor


. Colores complementados con números.

- El color da la impresión general.
- La precisión la da el número.




Bar plots

- **Quizá que falten datos es razonable, y no invalida la tupla o fila de datos.**
- En Hawaii nadie pone la nieve que NO hay.
- En estaciones precarias o automáticas quizá no se calcula el viento/temperatura promedio del día.



Múltiples mapas de calor para comparar datos




Box-plot para analizar distribuciones.

¿Los colores aportan?

A veces la densidad de puntos ocultan la forma del box plot.

¿Alternativas?: Violín, histogramas, Ridgeline





Box-plot para analizar distribuciones.

Outlier no significa que esté mal el dato.

Puede estar correcto, o no.


También puede haber datos que no sean outliers pero estén mal.



Scatter plots

Correlaciones no del todo claras.


Quizá conviene acompañarlas con una línea que señale la correlación.




Bar plots

- No todos los crímenes se realizan por igual en todos los vecindarios.
- Agrupar los crímenes por categorías según su peligrosidad y condena, y luego comparar vecindarios, normalizando valores.
- Los números en ratios de la población total.

Crimes by Category (without Larceny Theft) in San Francisco from 2018 –




Crimes by Neighborhood in San Francisco from 2018 – 2022




Bar plots

- No todos los crímenes se realizan por igual en todos los vecindarios.
- Agrupar los crímenes por categorías según su peligrosidad y condena, y luego comparar vecindarios, normalizando valores.
- Los números en ratios de la población total.

Crimes by Category (without Larceny Theft) in San Francisco from 2018 –




Crimes by Neighborhood in San Francisco from 2018 – 2022



Bar plots


- **No todos los crímenes se realizan por igual en todos los meses.**
- **Agrupar los crímenes por categorías según su peligrosidad y condena, y luego comparar meses, normalizando valores.**




Bar plots

- **Escala logarítmica en el eje Y?**
- ¿Separarlos por su frecuencia y analizarlos aparte?

Velocidad del viento diaria promedio




Crimes by Category in San Francisco from 2018 – 2022



Bar plots

- ¿Escala logarítmica en el eje Y?
- ¿Separarlos por su frecuencia y analizarlos aparte?


Cantidad de viajes en STM en Junio 2023 por línea




Interpolar

- **Mostrar tendencias.**
 - Los crímenes vuelven a los números pre-pandemia, pero la policía aun no vuelve al número de arrestos.
- **Ojo, la interpolación no deja de ser una interpretación.**
 - Hay que hacer análisis más finos.
 - Quizá hubo un cambio en el tipo de crimen, o cambiaron los procedimientos policiales. En consecuencia, varían los arrestos.

Daily Crimes in San Francisco from 2018 – 2022





Daily Police Arrests in San Francisco from 2018 – 2022



Interpolar

La interpolación no reemplaza a los datos.



- **Las interpolaciones pueden obviar los picos.**
 - Los picos hay que analizarlos aparte.
- **Puede dar continuidad a la discontinuidad.**
 - El cambio de régimen requiere de análisis particulares.
- **La interpolación puede inventar valores donde no hay.**
 - Ver donde es pertinente aplicarla.
- **El ruido (la varianza) también es dato importante.**



Dot plots e interpolación


Acotar las escalas.

- Intervalo en Y es el doble de lo necesario ([-50 140]).
- Quizá haya que quitar outliers para ver mejor las tendencias.
- Las tendencias quedan más horizontales.



Dot plot para mostrar densidad

- **Cuando se superponen muchos puntos, hay áreas con color uniforme, pero eso no significa que la densidad sea uniforme.**
- Quizá poner transparencia a los puntos (Alpha=0.1), entonces cuando los puntos se superponen, se oscurece la zona.




Colores

- Los colores significan diferentes cosas según el gráfico.


- Colores que no se utilizan.

Cantidad de viajes en STM en Junio 2023 por línea
5 líneas con mayor cantidad de viajes




Colores

- **Gama de colores secuencial sin significado.**
 - Quizá poner paleta cualitativa como set 1



- **Apreciar los límites de la percepción.**
 - Muchos datos dificultan la percepción.




Colores

. El color jerarquiza los datos.

- Importa la interpolación, pero también los datos.
- Colores fuertes para las línea interpolada y pastel para los datos/líneas individuales, donde importa más la distribución global y no cada valor individual.

Daily Crimes in San Francisco from 2018 – 2022



. Colores complementados con números.

- El color da la impresión general.
- La precisión la da cada número.

