



Universitat Oberta
de Catalunya

Análisis predictivo de datos abiertos sobre el uso turístico del servicio de alquiler compartido de bicicletas de Nueva York

Una perspectiva desde la Ciencia de Datos

uoc.edu

Carlos E. Jiménez Gómez
Trabajo Final de Máster
Máster Universitario en Ciencia de Datos

Índice

Motivación
Objetivos y preguntas a responder
Metodología
Estado del arte
Técnicas utilizadas
Resultados
Conclusiones

Motivación

Motivación

- Problemáticas en el uso/demanda del servicio público de alquiler compartido de bicicletas
- El turismo como área estratégica en Nueva York: >60 millones visitantes en 2017
- En general, análisis predictivos en la literatura sin segmentación de usuario
- Aprovechamiento de datos abiertos
- Especial interés de las administraciones en *Smart Government*

Objetivos y preguntas a responder

Objetivos

- Análisis de datos abiertos sobre el uso del servicio público de alquiler de bicicletas de Nueva York (usuarios turistas)
- Análisis predictivo comparativo de modelos bajo un enfoque de *machine learning*. Especial interés en función de precipitaciones y eventos (festivos)
- Mostrar la necesidad estratégica de construir una organización pública orientada al dato e integrar la perspectiva de la ciencia de datos en su ecosistema organizacional

Preguntas a responder

- ¿Podemos considerar los eventos -identificados con días festivos y fines de semana- como variables sustanciales en la predicción de la demanda diaria de bicicletas por usuarios no suscritos al servicio público de alquiler de bicicletas?
- ¿El alquiler y la demanda de bicicletas por parte de los usuarios turistas (no suscritos o *Customer*), se rige por los mismos patrones que el de los usuarios suscritos (*Subscriber*)?
- ¿Qué algoritmo y, en base a éste, que modelo arroja mejores resultados en la predicción de la demanda diaria de bicicletas por parte de los usuarios no suscritos?
- ¿A partir de un análisis de uso de bicicletas segmentado por tipo de usuario y de la predicción sobre el mismo, que propuestas podrían aportar valor a la gestión de recursos de la ciudad, la planificación y al diseño de políticas públicas en las áreas de transporte y turismo?

Metodología

Metodología

Seguimiento de las fases propias de un proyecto de Ciencia de Datos

1. Análisis del ámbito, problemáticas y preguntas a responder
2. Identificación, recogida y almacenamiento de conjuntos de datos
3. Preprocesado, preparación de datos y análisis inicial, incluyendo visualización preliminar
4. Visualizaciones y análisis visual
5. *Machine learning*:
 - Entrenamiento y test de modelos clasificación
 - Predicción de los modelos y análisis comparativo
6. Análisis de resultados
7. Conclusiones y respuestas a las preguntas planteadas

Estado del arte

Estado del arte

Análisis - Machine Learning

- Martins et al., (2015); Feng y Wang (2017). Random Forest
- Thu et al., (2017); Liu et al. (2015). Red Neuronal Artificial
- Datta (2014). AdaBoost
- Nekkanti (2017). J48
- Nekkanti (2017); Martins et al. (2015). Utilizan Naive Bayes y Red Bayesiana
- No se profundiza en la segmentación por tipo de usuario
- Detalles generales sobre la preparación de datos

Organizacional - estratégico:

- Kaplan et al. (2014). Ante un hipotético escenario de vacaciones, interés de los potenciales turistas en estos servicios
- Vogel et al. (2011). Patrones de comportamiento en los sistemas de uso de bicicleta para mejora de planificación estratégica y operativa.

Técnicas utilizadas

Técnicas utilizadas (I)

Preprocesado, preparación y almacenamiento de datos (R, PostgreSQL)

Conjunto de datos para visualización:

- Julio 2017: 1.735.599 observaciones de 21 variables
- Segmentación/granularidad:
 - 2 tipos de usuarios
 - Diaria
 - Semanal
 - Mensual

Técnicas utilizadas (II)

Preprocesado, preparación y almacenamiento de datos (R, PostgreSQL)

Conjunto de datos para machine learning (I):

- Abril a septiembre 2017: más de 10 millones de observaciones de 21 variables
 - Agrupadas por día en 183 observaciones y 6 variables:
 - Demanda diaria (clase a predecir, con 3 niveles: Baja, Media, Alta por método K-medias)
 - Día (del año)
 - Precipitación
 - Laborable/festivo
 - Mes
 - Día de la semana

Técnicas utilizadas (III)

Preprocesado, preparación y almacenamiento de datos (R, PostgreSQL)

Conjunto de datos para machine learning (II):

- Segmentación para usuario *Customer*
- 3 conjuntos para entrenamiento y test (variación tipo variable día)
- 1 conjunto con nuevos datos para predicción
- Validación cruzada con 10 particiones

Técnicas utilizadas (IV)

Análisis georreferenciado, mapas y visualización de características (Carto)

Análisis comparativo machine learning y predicción (Weka)

- J48
- Random Forest
- AdaBoostM1
- Red Neuronal Artificial
- Naive Bayes
- Red Bayesiana

Búsqueda hiperparámetros y mejor clasificador (AutoWeka)

- JRip

Evaluación de clasificación correcta (Weka)

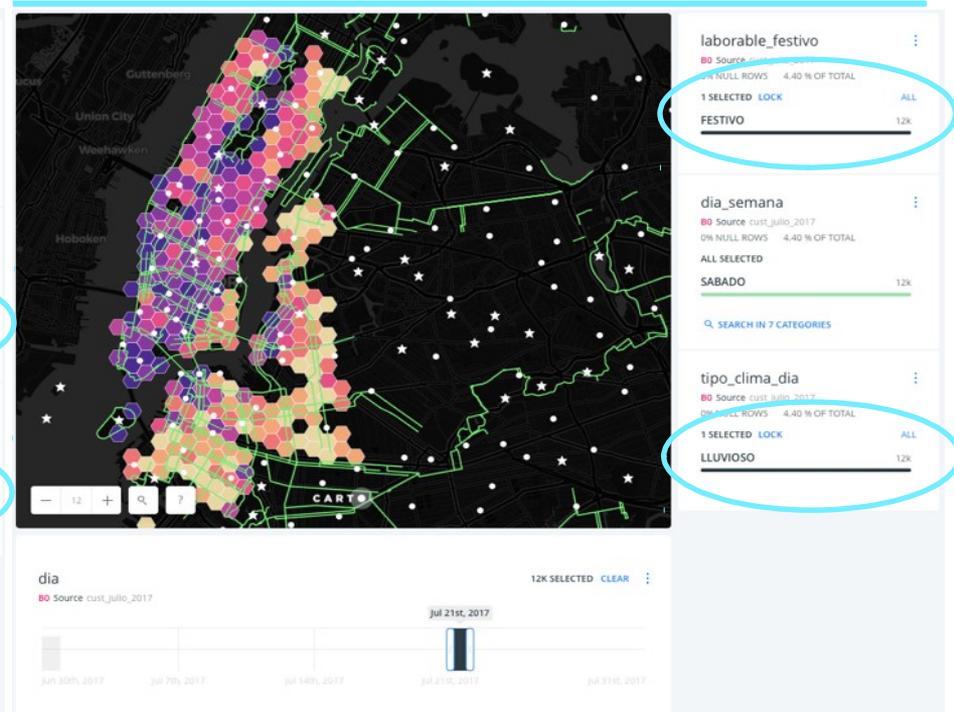
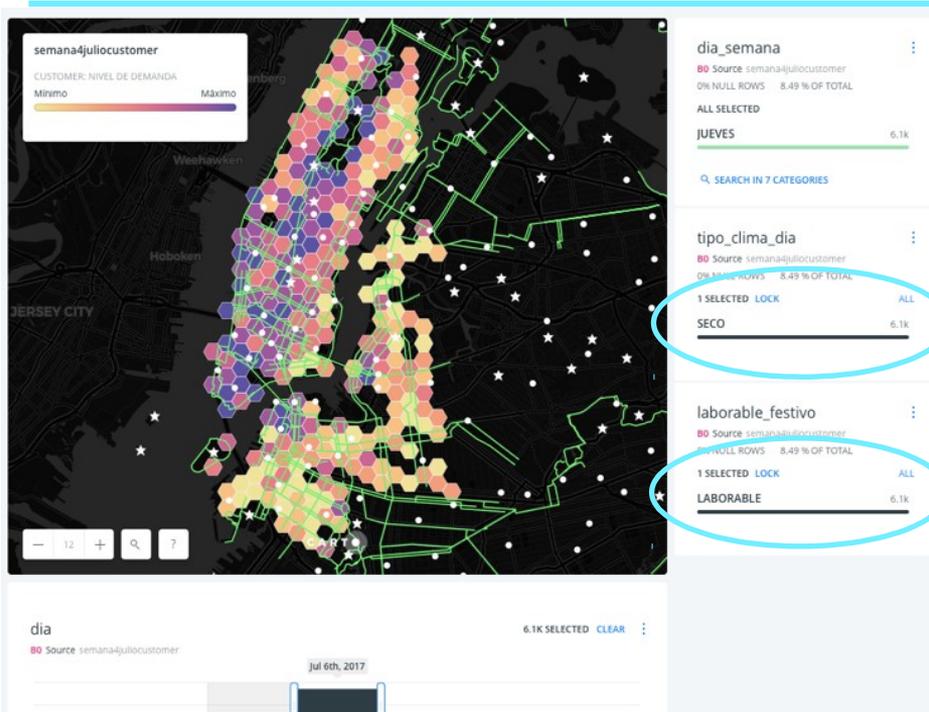
- AUC ROC
- *F measure*

Resultados

Visualizaciones (I)

6.100

12.000



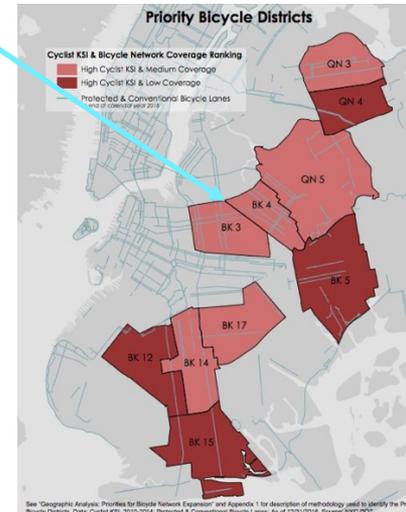
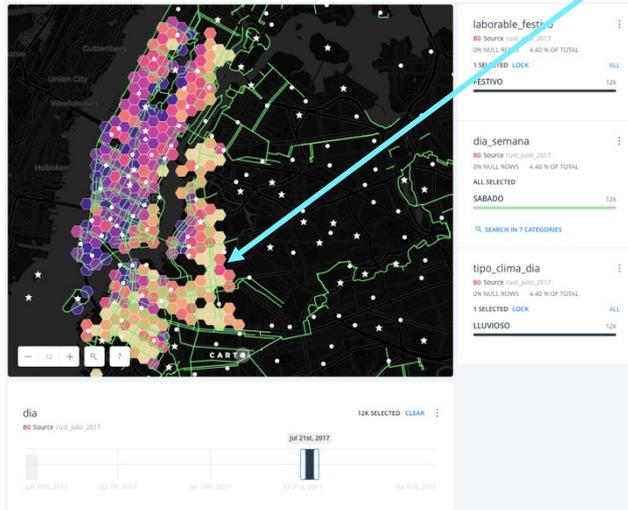
Visualizaciones (II)

- Diferentes densidades (misma zona) y preferencia días festivos (*Customer*) vs. laborables (*Subscriber*)



Visualizaciones (III)

- Identificación de puntos de mayor afluencia turística: valor para decisiones en la priorización de estrategias y planificación



Influencia del preprocesado y preparación de datos: tipo de datos entrenamiento y test (% correcto)

- Variación en el tipo de un atributo (tipo de la variable "día")

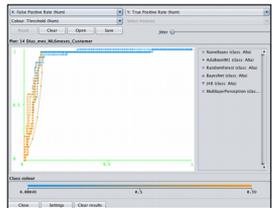
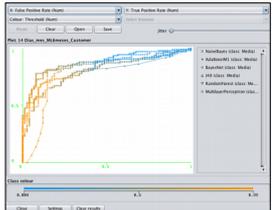
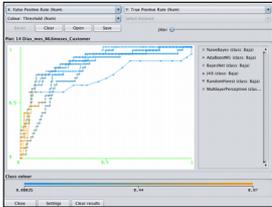
A partir de hiperparámetros y clasificador óptimos →

| | J48 | AdaBoostM1 | Random Forest | Red Neuronal | Red Bayesiana | Naive Bayes | JRip(*) |
|--|-------|------------|---------------|--------------|---------------|-------------|---------|
| Conjunto datos variable "día" incluye tipo fecha | 80.3 | 77.11 | 75.76 | 77.62 | --- | --- | --- |
| Conjunto datos variable "día" nominal (solo formato fecha) | 80.6 | 80.46 | 66.36 * | 77.67 | 78.35 | 78.56 | --- |
| Conjunto datos variable "día" agrupada (rango 1 a 31) | 82.21 | 75.6 | 71.13 * | 75.77 * | 77.74 | 79.32 | 84.153 |

Dataset para la predicción

Impacto de preparación y preprocesado de datos

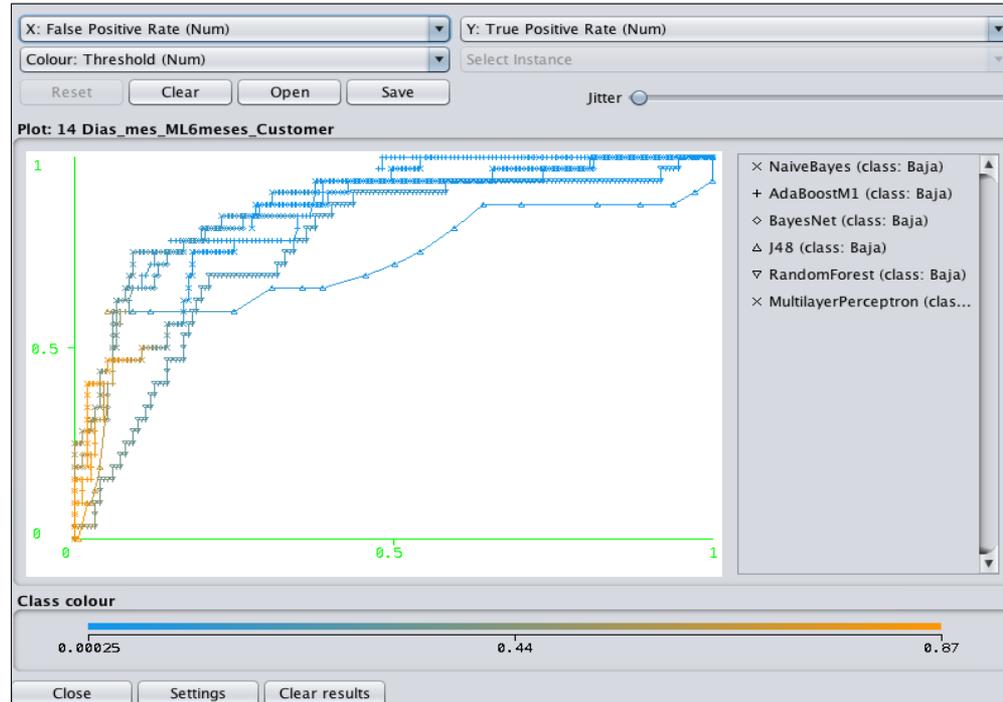
Modelos: clasificación (*F measure* y AUC ROC media ponderada)



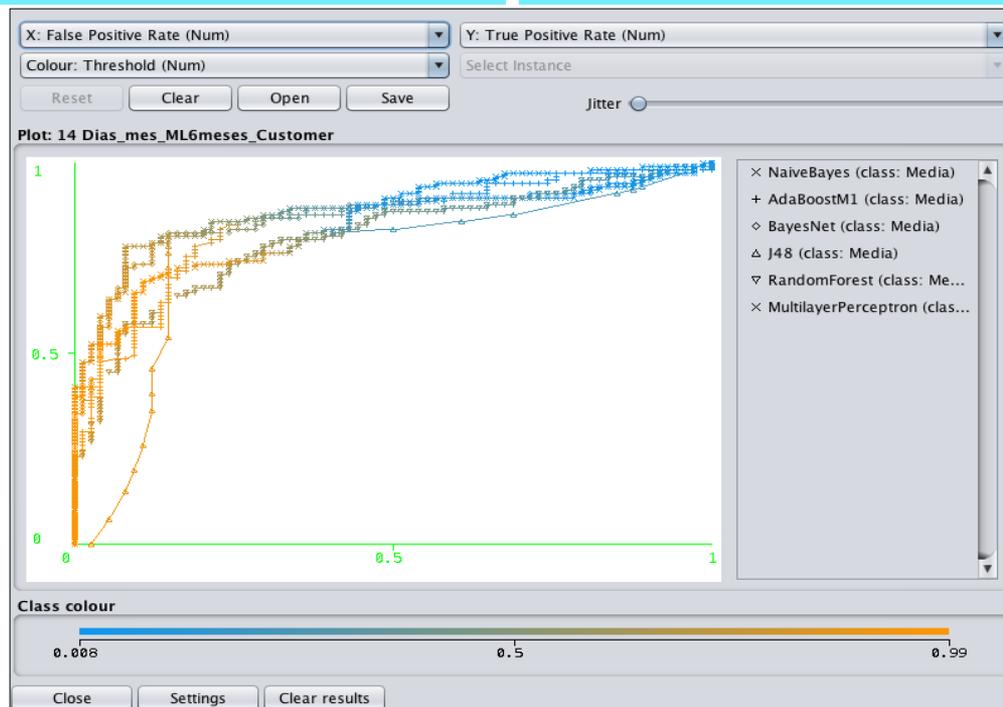
| <i>F measure</i> | J48 | AdaBoostM1 | Random Forest | Red Neuronal | Red Bayesiana | Naive Bayes | JRip(*) |
|--|------|------------|---------------|--------------|---------------|-------------|---------|
| Conjunto datos variable "dia" nominal (solo formato fecha) | 0.67 | 0.67 | - | 0.55 | 0.55 | 0.54 * | --- |
| Conjunto datos variable "dia" agrupada (rango 1 a 31) | 0.67 | 0.62 | 0.24 * | 0.53 | 0.52 * | 0.57 | 0.838 |

| | J48 | AdaBoostM1 | Random Forest | Red Neurona l | Red Bayesiana | Naive Bayes | JRip(*) |
|----------------------------|---------|------------|---------------|---------------|---------------|-------------|---------|
| % Clasificación correcta | 81.4208 | 77.0492 | 70.4918 | 71.5847 | 77.0492 | 78.1421 | 84.153 |
| % Clasificación incorrecta | 18.5792 | 22.9508 | 29.5082 | 28.4153 | 22.9508 | 21.8579 | 15.847 |
| Precisión media pond. | 0.821 | 0.768 | 0.641 | 0.719 | 0.759 | 0.772 | 0.84 |
| AUC ROC media pond. | 0.786 | 0.855 | 0.824 | 0.869 | 0.873 | 0.88 | 0.887 |

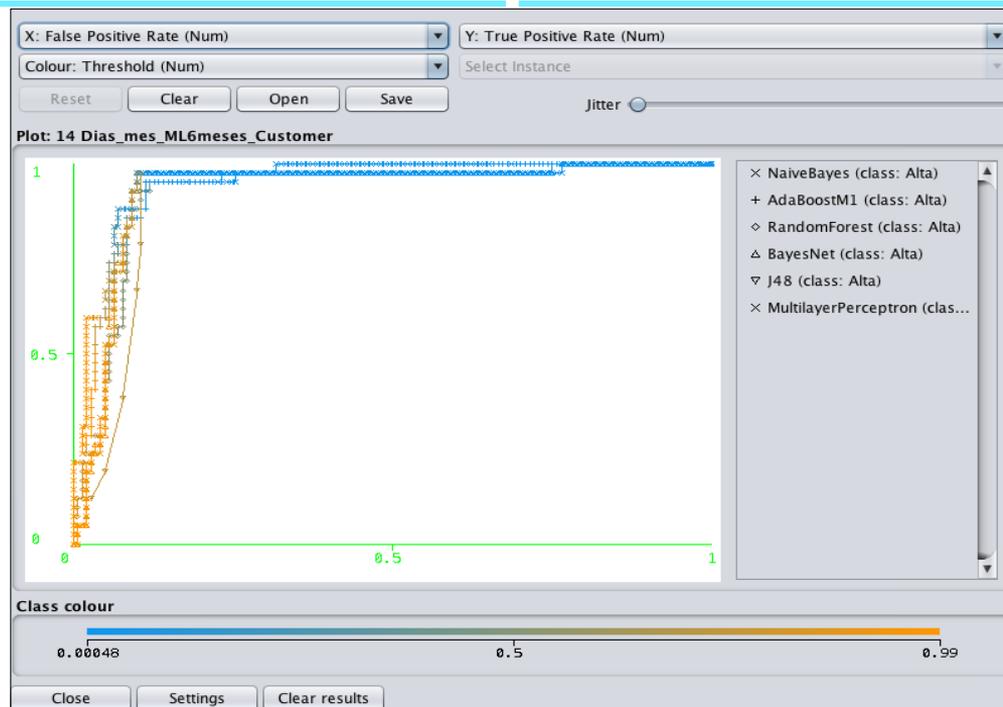
Modelos: clasificación. AUC ROC demanda Baja



Modelos: clasificación. AUC ROC demanda Media

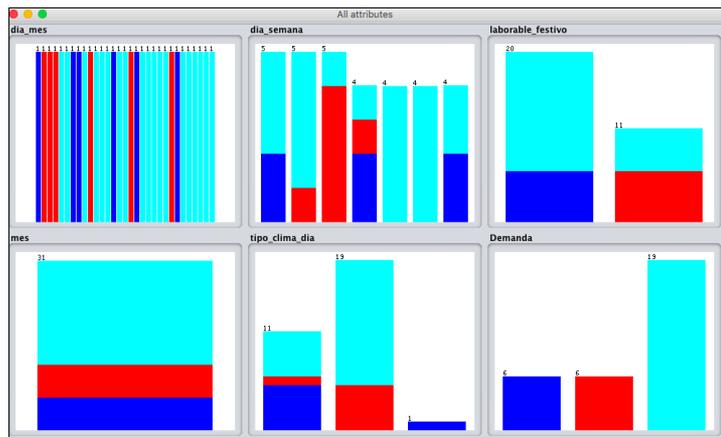


Modelos: clasificación. AUC ROC demanda Alta



Predicción de los modelos sobre nuevos datos

- 1.380.110 observaciones en un mes (julio 2016) agrupadas por día en:
- 31 observaciones, y 6 variables
- No existieron días con etiqueta “Lluvia ocasional” para el atributo *tipo_clima_dia*



| | Número de Aciertos | Tasa de Aciertos | Número de Errores | Tasa de Error |
|---------------|--------------------|------------------|-------------------|---------------|
| Red Neuronal | 25 | 0.8065 | 6 | 0.1935 |
| J48 | 24 | 0.7742 | 7 | 0.2258 |
| JRip | 23 | 0.7419 | 8 | 0.2581 |
| AdaBoostM1 | 22 | 0.7097 | 9 | 0.2903 |
| Random Forest | 21 | 0.6774 | 10 | 0.3226 |
| Red Bayesiana | 21 | 0.6774 | 10 | 0.3226 |
| Naive Bayes | 21 | 0.6774 | 10 | 0.3226 |

Conclusiones

Conclusiones (I)

- Patrones diferentes entre los distintos tipos de usuarios
- Los eventos identificados con días festivos es una variable sustancial e incluso más determinante clasificando que las precipitaciones
- Importancia del preprocesado y proceso de preparación de conjuntos de datos de entrenamiento y test: condicionante de resultados
- Red Neuronal Artificial (ANN) como mejor modelo predictor, teniendo en cuenta asimismo:
 - Pocas diferencias con significación estadística en la clasificación
 - F más concluyente que AUC ROC para resultados entre clasificación y predicción ()
 - Peores en la clasificación correcta: Random Forest y Red Bayesiana, frente a J48.

Conclusiones (II)

- Importancia de incorporar el proceso y la metodología de la Ciencia de Datos dentro de la propia organización pública, para el alineamiento con los objetivos organizacionales
- Necesaria orientación al dato para el avance hacia *Smart Government*
- Los resultados podrían ser útiles para la toma de decisiones en cuanto
 - Planificar la potenciación del uso de zonas específicas con nuevas rutas
 - Incorporar estaciones en zonas donde antes no existían
 - Reducir la presencia de las mismas donde su uso es muy bajo
 - Utilizar puntos de información en lugares de preferencia
- Estrategia para favorecer de un modo selectivo una mayor afluencia de usuarios a determinadas zonas.
- Importancia de que las Administraciones Públicas incorporen una estrategia de apertura de datos transversal, siguiendo unos estándares y requisitos mínimos, que permitan aprovechar adecuadamente los datos.

Universitat Oberta
de Catalunya

 @estratic

 carlosjg@uoc.edu

 www.estratic.com

 www.linkedin.com/in/carlosejimenez

UOC