

EDA (Exploratory Data Analysis) con SQL

DSML - Facultad de Telemática. Universidad de Colima – rherrera@ucol.mx

El Proceso del Data Science

Etapas del Data Science Process

- Conocimiento del negocio/problema,
- Adquisición de datos,
- Exploración de datos (EDA),
- Preparación de datos, Limpieza de datos,
- Aplicación de ML
(Análisis predictivo, Extracción de Conocimiento),
- Visualización de Datos (dataviz) y StoryTelling
- Toma de decisiones

... en esta ocasión nos enfocaremos a la etapa del EDA, pero ... abordándolo con **SQL!**






EDA con SQL para datos en formato de BD relacional

EDA with SQL

Exploratory Data Analysis
-----> SQL

- **Exploración del dataset:**
estructura, tablas, campos, relaciones, y tipos de datos (numéricos, fechas, textos, categorías),
- **Dimensiones y datos de variables:**
valores mínimos, máximos, promedios, desv-standard, frecuencia, agrupamiento con respecto a otras variables, valores faltantes (nulos), valores fuera de rango (outliers),
- **Representación visual con gráficos:**
distribución, correlación, histogramas, comportamiento a lo largo del tiempo (patrones, tendencias, periodicidades)



DATA





SORTED



ARRANGED



PRESENTED VISUALLY




EDA con SQL para datos en formato de BD relacional

EDA with SQL

Exploratory Data Analysis
-----> SQL

Uso de BD relacional y MySQL para EDA

- Para hacer consultas con joins entre varias tablas (para filtrados y agrupamientos)
- Para generar Transformaciones de datos (hacer categorías a partir de otros campos)
- Para generar Vistas Integradas de datos (simplificar consultas con el detalle requerido)
- Para generar análisis de estadística descriptiva básica (valores mínimo, máximo, promedio, desviación estándar, moda, mediana, Q1, Q2, Q3 y Q4, etc)



Caso práctico - BD Classicmodels

```
-----
-- Para hacer la TABLA de Estadística Basica Descriptiva,
-- Tomamos el CreditLimit que es un campo numerico de relevancia:
-----

SELECT max(creditlimit) as Maximo,           -- $ 227,600.00
       min(creditlimit) as Minimo,          -- $      0.00
       avg(creditlimit) as Promedio,        -- $ 67,659.02
       std(creditlimit) as DesvEstandar    -- $ 44,858.39
       -- median(creditlimit) as Mediana    $      ?
       -- Q1 (25%)                          $      ?
       -- Q2 (50%)                          $      ?
       -- Q3 (75%)                          $      ?
       -- Q4 (100%) -> Max()                 $ 227,600.00
       -- Q0 --> Min()                       $      0

FROM customers;
```

EDA con SQL para datos en formato de BD relacional

EDA with SQL

Exploratory Data Analysis
-----> SQL


Caso práctico - BD Classicmodels

-- SOLUCION:

-- Se Define una funcion UDF para obtener los Cuartiles del CreditLimit

```
SELECT max(creditlimit) as Maximo,          -- $ 227,600.00
       min(creditlimit) as Minimo,          -- $      0.00
       avg(creditlimit) as Promedio,        -- $  67,659.02
       std(creditlimit) as DesvEstandar,    -- $  44,858.39
       quartilCreditLimit(0.50) as Mediana,
       quartilCreditLimit(0.25) as Q1,     -- (25%)
       quartilCreditLimit(0.50) as Q2,     -- (50%)
       quartilCreditLimit(0.75) as Q3,     -- (75%)
       quartilCreditLimit(1.00) as Q4     -- (100%) -> Max()
FROM customers;
```

... habrá que implementar una función propia que contenga la lógica necesaria para obtener los diferentes valores de los cuartiles (incluso se puede generalizar para obtener cualquier decil) ..



-- Maqueta de la funcion UDF

DELIMITER \$\$

CREATE FUNCTION quartilCreditLimit(param_quartil double) RETURNS INTEGER

-- param_quartil: q1=(1/4)=0.25 / q2=(1/2)=0.5 / q3=(3/4)=0.75

BEGIN

DECLARE resultado_quartil, total_filas integer;

-- ... cuerpo de la funcion

-- ...

RETURN resultado_quartil;

END\$\$

DELIMITER ;


EDA con SQL para datos en formato de BD relacional

EDA with SQL

Exploratory Data Analysis

-----> SQL

Caso práctico - BD Classicmodels



... y esto es solo el comienzo..
Manos a la obra...!!

```
-- *****
-- EDA básico. Queries SQL genéricas para conocer la estructura, relaciones
-- integrar datos, agrupar y filtrar información,
-- transformar datos, encapsular consultas elaboradas en vistas
-- *****

-- Sobre los clientes:
SELECT * FROM customers;
SELECT max(customerNumber), min(customerNumber) FROM customers ORDER BY 1 DESC;

-- Cuántos clientes hay de cada país/continente?
SELECT country, count(*) as cant FROM customers
GROUP BY country ORDER BY 2 DESC ;

-- para considerar la región geográfica habria que sacar ese datos de Oficinas
SELECT country, territory, count(*) as cant FROM offices
GROUP BY country, territory ORDER BY 2 DESC ;

--Cuál es el Límite de Credito máximo, mínimo y promedio, devStandard?
SELECT max(creditLimit), min(creditLimit) FROM customers;

-- Hay clientes sin límite de crédito?
SELECT creditLimit, count(creditLimit) as cant FROM customers
GROUP BY creditLimit ORDER BY 1 DESC ; -- 93 filas
```

EDA con SQL para datos en formato de BD relacional



Referencias de información

Libros

- Herrera-Morales, J. R., Peralta-Domínguez, G., & Herrera-Espinoza, A. R. (2020). *El internet de las cosas y la ciencia de datos*. En A. R. Gallardo, J. R. Herrera-Morales, S. Sandoval Carrillo, & M. E. Cabello-Espinosa (Coords.), *El internet de las cosas y su impacto en la educación* (pp. 117-143). Editorial Universidad de Colima. ISBN 9786078549887.
- Cielen, D., Meysman, A. D. B., & Ali, M. (2016). *Introducing Data Science: Big data, machine learning, and more, using Python tools*. Manning Publications.
- McKinney, W. (2022). *Python for data analysis: Data wrangling with Pandas, NumPy, and Jupyter* (3ª ed.). O'Reilly Media.

Base de datos Classic Models

- MySQL Tutorial. (s.f.). *MySQL sample database* [BD]. <https://www.mysqltutorial.org/getting-started-with-mysql/mysql-sample-database/>