

# El mecanismo de Laplace

Guillermo Navarro-Arribas

January 24, 2022

Sabemos que una manera de proporcionar privacidad diferencial es mediante el uso de un mecanismo aleatorio que puede consistir en añadir ruido a una consulta (o mecanismo) que se realiza a la base de datos.

Ahora veremos un ejemplo de mecanismo aleatorio basado en esta idea conocido como el **mecanismo de Laplace**. Se trata de uno de los mecanismo más estudiados y sencillos utilizados en privacidad diferencial.

Para introducir este mecanismo veremos que es la **sensibilidad** de una función, un concepto importante en privacidad diferencial. Esto nos permitirá determinar, en cierta manera, la cantidad de ruido que tenemos que añadir para conseguir un nivel de privacidad determinado a una consulta o función.

Vamos a repasar también, aunque de forma muy rápida, como es una distribución de Laplace, que nos determinará el ruido generado.

## 1 Distribución de Laplace

La distribución de Laplace (también conocida como doble exponencial) es una distribución de probabilidades continua. Su función de densidad de probabilidad se expresa como:

$$f(x|\mu, b) = \frac{1}{2b} \exp\left(-\frac{|x - \mu|}{b}\right)$$

donde  $\mu$  es un parámetro de posición o localización y  $b > 0$  un parámetro de escala (o diversidad). Denotaremos esta distribución como  $Lap(\mu, b)$ .

A continuación mostramos la distribución de Laplace  $Lap(0, 1)$ , es decir, con  $\mu = 0$  y  $b = 1$ .

```

import scipy.stats
import matplotlib.pyplot as plt
import numpy as np

x = np.linspace(-10,10,1000)
dist = scipy.stats.laplace(0, 1)
plt.clf()
plt.plot(x, dist.pdf(x))
plt.grid()
fname = "img/laplace.png"
plt.savefig(fname)
fname

```

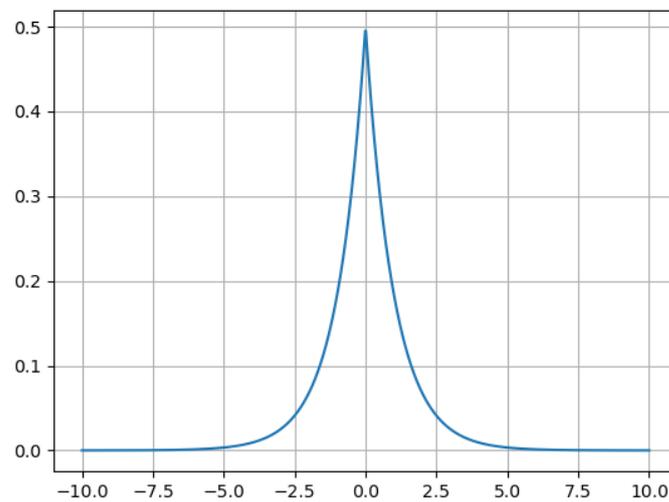


Figure 1:  $Lap(0,1)$

El parámetro  $\mu$  (la media de la distribución) determina la posición o localización de la distribución. Por ejemplo:

```

plt.clf()
for loc in [-3, 0, 3, 6]:
    dist = scipy.stats.laplace(loc, 1)
    plt.plot(x, dist.pdf(x), label=f"$\mu = {loc}$")
plt.grid()
plt.legend()
fname = "img/laplace-mu.png"

```

```
plt.savefig(fname)
fname
```

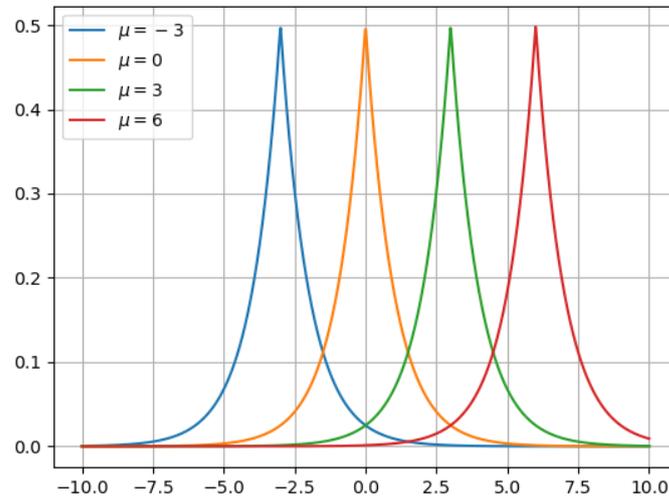


Figure 2:  $Lap(\mu, 1)$  para  $\mu \in \{-3, 0, 3, 6\}$

Por otra parte el parámetro  $b$  determina la forma de la distribución (o escala):

```
plt.clf()
for scale in [1, 2, 3, 4]:
    dist = scipy.stats.laplace(0, scale)
    plt.plot(x, dist.pdf(x), label=f"$b = {scale}$")
plt.grid()
plt.legend()
fname = "img/laplace-scale.png"
plt.savefig(fname)
fname
```

La media de la distribución de Laplace  $Lap(\mu, b)$  es  $\mu$ , que coincide con la mediana, y su varianza es  $2b^2$ .

## 2 Sensibilidad global

Consideramos un mecanismo o función  $f$  que realiza una consulta a la base de datos  $D$  generando una respuesta  $f(D)$ . Suponemos que los datos a consultar son numéricos y

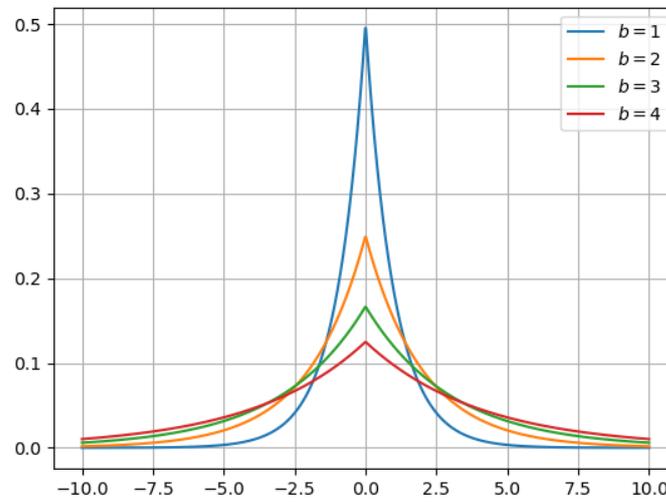


Figure 3:  $Lap(0, b)$  para  $b \in \{1, 2, 3, 4\}$

que el resultado puede ser un vector de  $M$  elementos. De esta manera, si  $\mathcal{D}$  es el conjunto de todas las posibles bases de datos,  $f : \mathcal{D} \rightarrow \mathbb{R}^M$ .

La sensibilidad global (*global sensitivity*) de una función  $f$  se suele denotar como  $\Delta f$  o  $GS(f)$ , y a veces se llama también  $l_1$ -sensitivity. Queda definida de la siguiente manera:

**Definición 1** La sensibilidad global de una función  $f : \mathcal{D} \rightarrow \mathbb{R}^M$  es:

$$\Delta f = \max_{D_1, D_2 \in \mathcal{D}, d(D_1, D_2)=1} \|f(D_1) - f(D_2)\|_1 \quad (1)$$

En esta definición se utiliza la norma  $l_1$  ( $l_1$ -norm) denotada como  $\|\cdot\|_1$ . Dado un vector  $x \in \mathbb{R}^M$ ,  $\|x\|_1 = \sum_{i=1}^M |x_i|$ . Podemos ver la norma  $l_1$  simplemente como la suma del valor absoluto de todos los elementos del vector.

**Ejemplo 1** Por ejemplo, para el vector  $v = (2, 3, -4, 6)$ , su norma  $l_1$  es:

$$\|v\|_1 = \sum_{i=1}^4 |v_i| = |2| + |3| + |-4| + |6| = 15$$

La sensibilidad global expresa la máxima diferencia que podemos encontrar al aplicar la función a dos bases de datos que difieren en un solo elemento.

**Ejemplo 2** Supongamos que tenemos una base de datos censal con información de la población de nuestra ciudad. Definimos entonces la función  $f_1$  que retorna el número de individuos mayores de edad (con edad mayor o igual a 18).

Tenemos dos versiones de la base de datos que difieren en un solo registro, de manera que, por ejemplo:

$$\begin{aligned}f_1(D_1) &= 120 \\f_1(D_2) &= 121\end{aligned}$$

en este caso podemos decir que el resultado difiere en 1, pero no es difícil ver que en el caso general la diferencia máxima entre la consulta hecha a dos bases de datos vecinas será 1. Es más, dicha diferencia será siempre -1, 0 ó 1. Podemos entonces decir que la sensibilidad global de  $f_1$  es 1:

$$\Delta f_1 = 1$$

En general, para cualquier función que consista en contar elementos, como en el ejemplo anterior, tendremos el mismo resultado respecto a su sensibilidad global.

**Ejemplo 3** Suponemos ahora que tenemos una segunda función  $f_2$  que retorna el número de individuos que han leído el Quijote (información que también incluye la base de datos anterior) y por ejemplo tenemos que:

$$\begin{aligned}f_2(D_1) &= 10 \\f_2(D_2) &= 10\end{aligned}$$

Al igual que con  $f_1$  es fácil ver que  $\Delta f_2 = 1$ .

Vamos ahora a ver la función  $f_c$  que definimos como aquella que retorna un vector con las dos consultas correspondientes a  $f_1$  y  $f_2$ , de manera que  $f_c(D) = (f_1(D), f_2(D))$ . Siguiendo el ejemplo anterior podríamos tener:

$$\begin{aligned}f_c(D_1) &= (120, 10) \\f_c(D_2) &= (121, 10)\end{aligned}$$

En este caso la sensibilidad global será de 2. La diferencia máxima para cada función es 1, con lo que la norma  $l_1$  será 2. Es decir  $\Delta f_c = 2$

El lector obviamente se preguntará que pasa en el caso de funciones más complejas e

interesantes. Aquí es donde se puede complicar un poco el asunto ya que podríamos tener funciones para las que su sensibilidad global sea infinito o resulte difícil poder estimar un cálculo. En general necesitaremos que la función este acotada para poder calcular su sensibilidad global. Queda pendiente ver con mayor detalle casos diferentes a funciones que cuenten registros.

### 3 El mecanismo de Laplace

Llegamos ya a poder ver uno de los mecanismos aleatorios más populares en privacidad diferencial, el conocido como **mecanismo de Laplace**. Sin muchas sorpresas, éste consiste en añadir ruido siguiendo una distribución de Laplace a la respuesta.

Consideramos una consulta o mecanismo  $f$  que realiza una consulta a la base de datos  $D$  generando una respuesta  $f(D)$ . A modo de generalización suponemos que los datos a consultar son numéricos y la respuesta, un vector de  $M$  elementos. De esta manera, si  $\mathcal{D}$  es el conjunto de todas las posibles bases de datos,  $f : \mathcal{D} \rightarrow \mathbb{R}^M$ .

**Definición 2** El mecanismo de Laplace para la función  $f : \mathcal{D} \rightarrow \mathbb{R}^M$  es:

$$M_L(D, f, \epsilon) = f(D) + (N_1, \dots, N_M)$$

donde  $D \in \mathcal{D}$ , y  $N_i$  son variables aleatorias independientes que se obtienen a partir de una distribución de Laplace  $N_i \sim \text{Lap}(0, \Delta f / \epsilon)$ .

**Ejemplo 4** Siguiendo el ejemplo anterior podemos definir  $M_L(D_1, f_c, 1)$  y podríamos obtener que, por ejemplo:

$$\begin{aligned} M_L(D_1, f_c, 1) &= f_c(D_1) + (N_1, N_2) = (120, 10) + (3, -2) = (123, 8) \\ M_L(D_2, f_c, 1) &= f_c(D_2) + (N_1, N_2) = (121, 10) + (-1, 0) = (120, 10) \end{aligned}$$

donde los valores  $N_i$  los obtenemos de forma aleatoria con una distribución  $\text{Lap}(0, 2)$  (en este caso redondeamos a números enteros para mayor claridad).

Podemos probar rápidamente valores obtenidos de una distribución  $\text{Lap}(0, 2)$  de la siguiente manera

```
import scipy.stats
dist = scipy.stats.laplace(0, 2)
dist.rvs()
```

Lo primero que podemos observar es el papel que juega el parámetro  $\epsilon$ . Al utilizar una

distribución  $N_i \sim Lap(0, \Delta f/\epsilon)$  vemos que a medida que aumentamos  $\epsilon$ , disminuye el parámetro  $b$  de la distribución. Como se puede observar en la figura 3 cuanto menor es el parámetro  $b$ , la distribución de Laplace presenta mayor probabilidad en valores cercanos a  $\mu$ , en nuestro caso a 0. Esto quiere decir que cuanto mayor sea  $\epsilon$ , menor será  $b$  y por tanto, menor será el ruido añadido.

Uno de los puntos más interesantes sobre este mecanismo de Laplace es que resulta fácil demostrar que satisface  $\epsilon$ -privacidad diferencial. Esto se suele denotar en forma de teorema:

**Teorema 1** El mecanismo de Laplace satisface  $\epsilon$ -privacidad diferencial.

Si tenemos dos bases de datos vecinas que difieren en un solo elemento  $D_1, D_2$  y el mecanismo de Laplace  $M_L$  para la función  $f$  podemos ver la probabilidad de obtener un mismo resultado  $s$ :

$$\begin{aligned} \frac{P[M_L(D_1, f, \epsilon) = s]}{P[M_L(D_2, f, \epsilon) = s]} &= \frac{P[f(D_1) + Lap(0, \frac{\Delta f}{\epsilon}) = s]}{P[f(D_2) + Lap(0, \frac{\Delta f}{\epsilon}) = s]} \\ &= \frac{P[Lap(0, \frac{\Delta f}{\epsilon}) = s - f(D_1)]}{P[Lap(0, \frac{\Delta f}{\epsilon}) = s - f(D_2)]} = \frac{\frac{1}{2b} \exp(-\frac{|s-f(D_1)|}{b})}{\frac{1}{2b} \exp(-\frac{|s-f(D_2)|}{b})} \\ &= \exp\left(\frac{|s - f(D_1)| - |s - f(D_2)|}{b}\right) \leq \exp\left(\frac{|f(D_1) - f(D_2)|}{b}\right) \\ &\leq \exp\left(\frac{\Delta f}{b}\right) = \exp(\epsilon) \end{aligned}$$

## 4 Continuará...

¿Como podemos aplicar el mecanismo de Laplace en un ejemplo un poco más interesante?  
 ¿Existen otros mecanismos mejores?...

This work is licensed under a “CC BY-NC-SA 4.0” license.

