

# Ataque de reconstrucción de base de datos

Una persona realiza una serie de preguntas a una base de datos para investigar que hay en ella. Son ataques de inferencia para saber que hay dentro de una base de datos que ha sido curada. Utilizando la base de datos curada se trata de obtener datos sobre la base de datos original. Se recomienda evitar tener demasiados detalles en la versión curada.

## Preguntas de un adversario

- Una posibilidad es denegar respuestas que podrían ser peligrosas
- El problema es que las denegaciones pueden filtrar información.

## Censo ficticio del censo de EEUU

Se construyó una base de datos falsa con 7 personas simulando la del censo. Algunos datos como la edad han sido suprimidos para ciertas personas con el objetivo de proteger contra ataques de inferencia al haber demasiada poca gente cuyos datos como estos coinciden. A pesar de estar estos datos eliminados, se da acceso a datos estadísticos como la media y la mediana, lo que permite ir induciendo poco a poco las edades que han sido ocultadas. Con todo esto se puede proponer un sistema de inecuaciones que se puede aplicar a un algoritmo solver, resultando en que se pueden obtener los datos ocultos de esta forma. Como resultado de esto, el censo hizo un ataque de reconstrucción a su base de datos en 2010 utilizando los mismos principios y fueron capaces de reconstruir un 46% de la base de datos. Si se tolerara un pequeño margen de error se habría reconstruido un 71% de la base de datos. En total se pudieron identificar 50 millones de personas. A raíz de esto el censo comenzó a utilizar privacidad diferencial en 2020 que consiste en añadir ruido a las respuestas para dificultar este tipo de ataques.

## Modelo de base de datos para peticiones de subset

Un cuasi identificador es un conjunto de atributos que con información externa permiten identificar a una persona externa. Tomamos como ejemplo una tabla con  $n$  componentes que contiene varias columnas con nombre, id, código zip cumpleaños, género y una pregunta sensible. La pregunta sensible sería el secreto.

- $n$ : número de filas de una base de datos
- $d \in \{0,1\}^n$ : vector secreto
- $d_i$ : secreto en la fila  $i$
- Vector de petición:  $s \in \{0,1\}^n$  tiene la misma estructura que el vector secreto, especifica un subset de filas que tienen cierto valor secreto.
- La respuesta a la petición  $s$ :  $a(s)$
- Contador de peticiones: producto escalar entre  $s$  y  $d$ .

From:

<http://knoppia.net/> - **Knoppia**

Permanent link:

<http://knoppia.net/doku.php?id=pan:recbdddattack&rev=1726673596>

Last update: **2024/09/18 15:33**

