

秘密分散データを用いた医療データ検索システム

1235067 中村 巴

February 10, 2021

ネットワーク信号処理研究室

東日本大震災では津波により病院に保存してたカルテが消失



患者が服用していた薬が分からない

⇒ 適切な診療が行えない

カルテを保全し，災害時に活用

ただ保全すれば災害時に活用できるわけではない

災害時には、

- ネットワークや電源などのリソース不足
- 必ずしもカルテの全てが必要とは限らない

カルテを保全し、
欲しい情報だけ入手できる仕組み

カルテを保全するための手法

カルテを保全するには、遠隔地に安全にバックアップ



- カルテ電子保存の3原則 (真正性, 見読性, 保存性)
- バックアップの条件 (秘匿性, 冗長性)


を満たす必要

(k, n) しきい値秘密分散法

(k, n) しきい値秘密分散法の問題

元のデータを復元するかしないかであり

欲しい情報だけを部分的に復元することはできない



部分的な復元が可能な秘密分散法の実現


部分復元可能な秘密分散法¹

秘密分散したデータの一部だけを部分的に復元する。

- データを項目ごとに分割しそれぞれ秘密分散
- 欲しい項目のシェアを結合して復元

¹田中麻実, 福富英次, 福本昌弘, “秘密分散バックアップした医療データの部分復元,” 信学技報 IA2015-74, pp. 31–36, 2015.

部分復元可能な秘密分散バックアップした医療データを用いた診療



検索の仕組みは無い



名前などの識別情報のみを部分復元してから検索

部分復元可能な秘密分散法における検索の問題

- 医療データのシェアの組み合わせを知っている必要
⇒ 医療データ不正復元の可能性
- 復元は方程式を解くため $O(l^3)$ (医療データのデータ長を l) の計算量
- 全員分の識別情報を復元してから検索
⇒ 検索に時間を要するため、診療を始めることができない

目的

- 安全性を落とすことなく検索にかかる計算量の削減

目標


- シェアの状態での検索を実現
- 70 万データを 15 秒以内に検索

シェア間の係数の差の比較による検索

従来の検索方法



シェア間の係数の差の比較による検索



タグ、検索タグの作成方法

$$\begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} \begin{pmatrix} kw \\ r \end{pmatrix} \equiv \begin{pmatrix} t_1 \\ t_2 \\ \vdots \\ t_n \end{pmatrix} \pmod{p}$$

行列 X 保持  タグ シェアに対応付けて保存

$$\begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} \begin{pmatrix} kw' \\ r' \end{pmatrix} \equiv \begin{pmatrix} t'_1 \\ t'_2 \\ \vdots \\ t'_n \end{pmatrix} \pmod{p}$$

行列 X  検索タグ

シェア間の係数の差の比較

$$\text{タグ} : t_u \equiv kw + rx_u \pmod{p}$$

$$\text{検索タグ} : t'_u \equiv kw' + r'x_u \pmod{p}$$

$$\begin{aligned} \text{係数の差} : (t_u - t'_u)x_u^{-1} &\equiv (kw - kw')x_u^{-1} + (r - r')x_u x_u^{-1} \\ &\pmod{p} \end{aligned}$$

$$(u = 1, 2, \dots, n)$$

同じ添字のタグと検索タグを正しく比較

同一識別情報から作成したタグの組み合わせが分かる

⇒ 連立方程式の式の組み合わせが分かる



タグの組み合わせは分かるが、シェアの組み合わせは分からない
ような仕組み

Table 1: 添字が 1 のストレージ

医療データのシェア	タグ ₁	タグ ₂
A さんシェア ₁	A さん _{t₁}	A さん _{t₂}
B さんシェア ₁	B さん _{t₁}	B さん _{t₂}
⋮	⋮	⋮

各ストレージで一致判定ができ、シェアをランダムに保存することが可能

⇒ 一致判定に必要なタグの組み合わせは分かるが、2 個以上のシェアの組み合わせは分からない


- 識別情報，検索キーワードは 144bit(平仮名 9 文字)
- データ全体のサイズは 3000byte

従来方法

識別情報を部分復元し，検索キーワードと一致判定

シェア間の係数差の比較による検索

検索タグを作成し，タグと一致判定



ここまでのまとめ

- シェア間の係数の差の比較による検索を提案
- シェアとタグの保存方法を提案



- シェアの状態で検索可能になり, 計算量を $\mathcal{O}(d^2)$ (識別情報のデータ長を d) に削減
- 検索時間は目標の 15 秒に大きく近づいた
- 第三者がストレージにアクセスしても医療データは復元不可

1. タグ t_1 , t_2 , しきい値 k , 素数 p が漏洩
2. タグ t_1 , t_2 , しきい値 k , x_1 , x_2 が漏洩



識別情報 kw が有限個に絞り込まれる

1. タグ t_1, t_2 , しきい値 k , 素数 p が漏洩

$$\begin{cases} t_1 \equiv kw + rx_1 \pmod{p} \\ t_2 \equiv kw + rx_2 \pmod{p} \end{cases}$$

解くには x_1, x_2 が必要

t の作成条件より $x_1, x_2 \in \mathbb{Z}/p\mathbb{Z} - \{0\}$, $x_1 \neq x_2$

$\implies x_1, x_2$ の組み合わせにより kw が絞られる

$$\begin{array}{ll}
 \left\{ \begin{array}{l} 0 \equiv 2 + 3 \times 1 \pmod{5} \\ 1 \equiv 2 + 3 \times 3 \pmod{5} \end{array} \right. & \begin{array}{l} t_1, t_2, p \text{ が漏洩} \downarrow \\ \left\{ \begin{array}{l} \textcolor{red}{0} \equiv kw + r \times x_1 \pmod{\textcolor{red}{5}} \\ \textcolor{red}{1} \equiv kw + r \times x_2 \pmod{\textcolor{red}{5}} \end{array} \right. \end{array}
 \end{array}$$

kw について解くと,

$$kw \equiv \frac{0 \times x_2 - 1 \times x_1}{x_2 - x_1} \pmod{5}$$

$\Rightarrow x_1, x_2$ の組み合わせは 12 通り, $kw = 2, 3, 4$

$$\begin{cases} t_1 \equiv kw + rx_1 \pmod{p} \\ t_2 \equiv kw + rx_2 \pmod{p} \end{cases}$$

kw について解くと,

$$kw \equiv \frac{t_1x_2 - t_2x_1}{x_2 - x_1} \pmod{p}$$

x_1, x_2 の組み合わせは $(p-1)(p-2)$ 通り

kw は $p-2$ 通り以下に絞られる

2. タグ t_1, t_2 , しきい値 k , x_1, x_2 が漏洩

$$\begin{cases} t_1 \equiv kw + r\mathbf{x_1} \pmod{p} \\ t_2 \equiv kw + r\mathbf{x_2} \pmod{p} \end{cases}$$

kw について除算を行わず解き進め, p を総当たり

⇒ ある条件下において, kw が有限個に絞られる

$$\begin{array}{lcl}
 & & t_1, t_2, x_1, x_2 \text{ が漏洩} \downarrow \\
 \left\{ \begin{array}{l} 9 \equiv 7 + 2 \times 1 \pmod{11} \\ 0 \equiv 7 + 2 \times 2 \pmod{11} \end{array} \right. & & \left\{ \begin{array}{l} \textcolor{red}{9} \equiv kw + r \times \textcolor{red}{1} \pmod{p} \\ \textcolor{red}{0} \equiv kw + r \times \textcolor{red}{2} \pmod{p} \end{array} \right.
 \end{array}$$

kw について除算を行わずに解き進めると,

$$kw \equiv \frac{9 \times 2 - 0 \times 1}{2 - 1} \equiv 18 \pmod{p}$$

$$\begin{aligned}
 \Rightarrow & (p = 11, kw = 7) \ (p = 13, kw = 5) \ (p = 17, kw = 1) \\
 & (p = 19, kw = 18) \ (p = 23, kw = 18) \cdots
 \end{aligned}$$

$$\begin{cases} t_1 \equiv kw + rx_1 \pmod{p} \\ t_2 \equiv kw + rx_2 \pmod{p} \end{cases}$$

kw について解くと,

$$kw \equiv \frac{t_1x_2 - t_2x_1}{x_2 - x_1} \pmod{p}$$

$\frac{t_1x_2 - t_2x_1}{x_2 - x_1}$ がとる最大値は $(p-1)^2$

$\Rightarrow kw$ は $(p-1)^2$ 未満の素数の個数通り以下に絞られる

識別情報 kw が有限個に絞り込まれる



t, X, p をシステムで秘匿する


t

ストレージへのアクセス制限

X, p

拠点病院内のアクセスが管理できる場所に設置した端末に保存

t, X, p を秘匿したシステム構成



- 目的
 - 安全性を落とさず検索にかかる計算量の削減
- シェア間の係数の差の比較による検索を提案
 - 計算量が $\mathcal{O}(l^3)$ から $\mathcal{O}(d^2)$ に削減
 - 検索時間は目標の 15 秒に大きく近づいた
- シェアとタグの保存方法を提案
 - 第三者がストレージにアクセスしても医療データは復元不可
- 安全性の評価
 - 識別情報 kw が有限個に絞り込まれる
 - システムで t, X, p を秘匿
- 今後の課題
 - さらなる高速化
 - システムを作成し、ネットワーク越しで実験