



Privacy Preserving Classification in Vertically Distributed Datasets

Mohammad Reza Ebrahimi Dishabi*

Department of Computer Engineering, Miyaneh Branch, Islamic Azad University, Miyaneh, Iran.

mrebrahimi@m-iau.ac.ir

Corresponding author's address: Mohammad Reza Ebrahimi Dishabi, Miyaneh Branch, Islamic Azad University, Miyaneh, Iran.

Abstract- Nowadays, preserving the privacy of data is an important issue during data mining techniques. several algorithms have been proposed to preserve the privacy of data. The most important problems with these algorithms are their unprovable privacy, the low importance of considering the adversary's background knowledge and lack of dimensionality reduction process over the original data. In this paper, differential privacy mechanism has been used to prove the privacy of vertical distributed data to be used for classification. In differential privacy, it is no matter what background knowledge has an adversary about the published data. Also, Haar wavelet transform has been used for dimension reduction of the original data. The privacy of data has been proved mathematically and the accuracy of data measured using the K-NN algorithm. Finally, it has been mathematically proved that the proposed algorithm adds noise with less standard deviation to the data than the compared algorithm, resulting in higher classification accuracy. The result shows that our algorithm has more secure compared to previous algorithms.

Keywords- Data Mining, Classification, Haar Wavelet Transform, Differential Privacy.

حفظ حریم خصوصی در رده‌بندی داده‌های توزیع شده عمودی

محمد رضا ابراهیمی دیشابی*

گروه کامپیوتر، واحد میانه، دانشگاه آزاد اسلامی، میانه، ایران.

*mrebrahimy@m-iau.ac.ir

* نشانی نویسنده مسئول: محمد رضا ابراهیمی دیشابی، میانه، بلوار شهدای زینبیه (جاده ترانزیت)، ساختمان سردار شهید حاج قاسم سلیمانی (ساختمان مرکزی)، گروه کامپیوتر، واحد میانه، دانشگاه آزاد اسلامی.

چکیده- امروزه، حفظ حریم خصوصی داده‌های منتشر شده، از اهمیت زیادی برخوردار است. الگوریتم‌های مختلفی برای حفظ حریم خصوصی داده‌ها ابداع شده است. مهمترین مشکلات این الگوریتم‌ها، غیر قابل اثبات بودن حریم خصوصی آنها، اهمیت کم در نظر گرفته شده برای دانش پیش‌زمینه فرد متخصص و عدم کاهش ابعاد داده‌های اولیه است. در این مقاله، برای اثبات حریم خصوصی داده‌ها از مفهوم حریم خصوصی تفاضلی در انتشار داده‌های توزیع شده عمودی و رده‌بندی آنها استفاده شده است. در حریم خصوصی تفاضلی، دانش پیش‌زمینه فرد متخصص در مورد داده‌های منتشر شده، اهمیت ندارد. همچنین، با استفاده از تبدیل موجک هار، ابعاد داده‌ها کاهش داده شده است. در نهایت، حریم خصوصی داده‌های منتشر شده به صورت ریاضی اثبات شده است، همچنین، دقت داده‌ها، با استفاده از الگوریتم رده‌بند K-نزدیکترین همسایه نیز اندازه‌گیری شده است و به صورت ریاضی اثبات شده است که الگوریتم پیشنهادی، خدشهایی با انحراف معیار کمتری را نسبت به الگوریتم موردن مقایسه، به داده‌ها اضافه می‌کند و در نتیجه دقت رده‌بندی بالاتری دارد. نتایج به دست آمده نشان دهنده امن‌تر بودن الگوریتم ارائه شده نسبت به الگوریتم‌های موردن مقایسه است.

واژه‌های کلیدی: داده‌کاوی، رده‌بندی داده‌ها، تبدیل موجک هار، حریم خصوصی تفاضلی.

۱- مقدمه

استخراج دانش به اهداف خود برسند. از طرفی، انتشار داده‌ها، باعث فاش شدن اطلاعات خصوصی و حساس بیماران خواهد شد که بر اساس قانون، دارندگان این داده‌ها (بیمارستانها و مراکز درمانی) مجاز به این کار نیستند. پس باید به دنبال روشی جهت انتشار داده‌ها باشیم که هم حریم خصوصی افراد نقض نشود و هم اینکه پژوهشگران بتوانند از داده‌های منتشر شده استفاده شایسته به عمل بیاورند.

جهت غلبه بر مشکل حفظ حریم خصوصی در داده‌کاوی، مفهوم «داده کاوی با حفظ حریم خصوصی»^۱ (PPDM) ابداع شد و در حال حاضر، تحقیقات و پژوهش‌های زیادی در این زمینه در حال انجام است. برای PPDM، راه‌ها و روش‌های گوناگونی پیشنهاد شده است. انتشار داده‌هایی که قابلیت حفظ حریم خصوصی را داشته باشند^۲

مجموعه داده‌ای را در نظر بگیرید که شامل اطلاعات خصوصی و حساس افراد بوده که به نوبه‌ی خود می‌توانند ارزشمند باشند. فرض کنید این داده‌ها اطلاعات مربوط به یک سری بیماری‌هایی است که منطقه به منطقه مشخص شده‌اند. پژوهشگران با استفاده از این اطلاعات، نتایج مهمی را می‌توانند استخراج کنند. به عنوان مثال، با بررسی این اطلاعات، می‌توان همه‌گیر شدن یک بیماری خاص را پیش‌بینی کرد و با برنامه‌ریزی دقیق‌تر، جان انسانها را نجات داد یا می‌توان جهت توزیع بهتر تجهیزات پزشکی و دارویی در مراکز درمانی، از آنها استفاده کرد. از این‌رو این داده‌ها باید در اختیار پژوهشگران قرار داده شوند تا با استفاده از روش‌های داده‌کاوی و

قوی‌ترین تعریف‌هایی است که تا کنون درباره‌ی حریم خصوصی داده‌ها پیشنهاد شده است و از مبنای ریاضی قوی و محکمی برخوردار است.

در این مقاله، حفظ حریم خصوصی داده‌های منتشر شده در هنگام رده‌بندی آنها (PPC) مورد بررسی قرار گرفته است. انگیزه اصلی ما این است که الگوریتمی بر روی داده‌های توزیع شده به منظور رده‌بندی آنها ارائه گردد که (۱) حریم خصوصی داده‌های منتشر شده حفظ گردد و با استفاده از یک مدل ریاضی، قابل اثبات باشد و (۲) بعد داده‌های اولیه را کاهش دهیم طوری که کارآمدی الگوریتم‌های رده‌بندی افزایش پیدا کند و با سرعت بالاتری داده‌ها را در رده‌های مربوطه قرار دهد.

بر این اساس، الگوریتمی بر روی داده‌های توزیعی ارائه شد. الگوریتم ارائه شده، مورد ارزیابی قرار گفت و به صورت ریاضی اثبات گردید که خاصیت حریم خصوصی تفاضلی- ϵ دارد. همچنین، با اجرای الگوریتم پیشنهادی بر روی مجموعه داده‌های مورد آزمایش، میزان کاهش ابعاد داده‌های اولیه در جدولی مشخص گردید. در نهایت، الگوریتم پیشنهادی با الگوریتمی که بر روی داده‌های متکرک ارائه شده است و دو مورد از خاصیت‌های الگوریتم ارائه شده (یعنی، (۱) حریم خصوصی تفاضلی و (۲) کاهش ابعاد داده‌ها) را دارد (خاصیت توزیعی بودن داده‌ها را ندارد)، مورد مقایسه قرار گرفت و به صورت ریاضی نشان داده شد که الگوریتم ارائه شده، هم از نظر میزان حریم خصوصی و هم از نظر دقت رده‌بندی، بهتر از الگوریتم مورد مقایسه است.

ساختار مقاله به این صورت است. در بخش ۲، مفاهیم پایه توضیح داده شده است. در بخش ۳، کارهای مرتبط بیان شده است. در بخش ۴، الگوریتم پیشنهادی ارائه شده است. در بخش ۵، حریم خصوصی تفاضلی الگوریتم پیشنهادی اثبات می‌گردد و مورد ارزیابی قرار می‌گیرد. در بخش ۶، نتیجه‌گیری ارائه می‌گردد.

۲- مفاهیم پایه

در این بخش، مفاهیم پایه توضیح داده می‌شود.

۲-۱- تبدیل موجک هار

موجک به معنای موج کوچک است بنابراین تجزیه تحلیل موجک^{۱۲} به معنای تجزیه و تحلیل یک سیگنال (با انرژی متناهی) در یک بازه‌ی کوچک است و منظور از متناهی بودن انرژی موج f این است که $\int_{-\infty}^{+\infty} |f(t)|^2 dt$ وجود دارد و با نماد $f \in L^2(R)$ f نمایش می‌دهند که در آن $\{ \int_{-\infty}^{+\infty} |f(t)|^2 dt < \infty \mid f(x) = \{f(x) \mid \int_{-\infty}^{+\infty} |f(t)|^2 dt \}$ است. از طریق موجک، سیگنال‌های مورد مطالعه، به شکل‌ها و

یکی از این روش‌ها است که به اختصار PPDP نامیده می‌شود [۱، ۲]. تصادفی‌سازی داده‌ها^۳ [۳]، گمنامی-k^۴ [۴، ۵، ۶] و گوناگونی-^۵ [۷] از مهمترین الگوریتم‌های PPDP هستند. در PPDP، بر روی ابداع الگوریتم‌هایی که باعث تغییر^۶ داده‌های اصلی می‌شوند، فعالیت می‌کنند طوری که داده‌ها را بعد از تغییر، در اختیار کاربران قرار داده و کاربران نیز با استفاده از روش‌های مختلف داده‌کاوی، از جمله رده‌بندی، به دنبال اطلاعات موردنظر خود می‌گردند. از این‌رو، «حفظ حریم خصوصی در رده‌بندی داده‌ها»^۷ (PPC) یکی از زیرشاخه‌های PPDP است. برای PPC، الگوریتم‌های مختلفی ارائه شده است. هر کدام از این الگوریتم‌ها، داده‌ها را طوری تغییر داده و منتشر می‌کنند که امکان نقض حریم خصوصی داده‌های منتشر شده در اثر اعمال الگوریتم‌های رده‌بندی بر روی آنها، میسر نباشد. اکثر الگوریتم‌های ارائه شده برای PPC، دو ایراد اساسی زیر را دارند:

- این الگوریتم‌ها، فرض می‌کنند که فرد مهاجم^۸، اطلاعات پیش‌زنینه^۹ کمی درباره‌ی داده‌های منتشر شده داردند [۲]. اما، تشخیص اینکه یک فرد مهاجم چقدر اطلاعات پیش‌زنینه درباره‌ی داده‌های منتشر شده در اختیار دارد و به طبع آن، شناسایی تمام روش‌هایی که منجر به کشف اطلاعات حساس داده‌های منتشر شده می‌شوند، بسیار دشوار و شاید غیرممکن است. بنابراین اکثر الگوریتم‌های ارائه شده برای PPC در مقابل دانش پیش‌زنینه کاربران آسیب‌پذیر هستند. در [۲]، انواع حملاتی که در اثر دانش پیش‌زنینه، بر روی داده‌های منتشر شده قابل اعمال هستند را به طور کامل توضیح داده است.

- این الگوریتم‌ها، هیوریستیک‌مبنا^{۱۰} بوده و حریم خصوصی قابل اثبات ریاضی، ندارند [۲، ۸].

برای غلبه بر مشکلات بالا، مفهوم «حریم خصوصی تفاضلی»^{۱۱} ابداع شد. در سال‌های اخیر استفاده از حریم خصوصی تفاضلی گسترش روزافزونی پیدا کرده است. هدف اصلی از حریم خصوصی تفاضلی این است که تغییرات کوچک در داده‌های ورودی، باعث ایجاد تغییرات کوچکی در خروجی الگوریتمی که روی داده‌ها اعمال می‌شود، گردد و معنی آن این است که خروجی الگوریتم، وابسته به هیچ کدام از داده‌های ورودی نباشد. از نظر حریم خصوصی تفاضلی، اینکه یک فرد مهاجم چقدر اطلاعات کمکی در مورد یک داده خاص در اختیار دارد، مهم نیست. از طرف دیگر، قابل اثبات بودن حریم خصوصی داده‌های منتشر شده با استفاده از مفهوم حریم خصوصی تفاضلی، یکی از مهمترین مزایای این مفهوم است. بنابراین یکی از

[۱۱]:

تعريف (۱) [۱۲]. مکانیزم A خاصیت حریم خصوصی تفاضلی- (ϵ, δ) دارد هرگاه برای تمام مجموعه داده‌های T و \hat{T} (که فقط در یک مسخ صه با هم تفاوت دارند) و تمام مجموعه داده‌های خروجی $\hat{D} \subseteq \text{Range}(A)$ ، رابطه‌ی زیر برقرار باشد:

$$\Pr[A(T) \in \hat{D}] \leq e^{\epsilon} \cdot \Pr[A(\hat{T}) \in \hat{D}] + \delta$$

در حریم خصوصی تفاضلی- ϵ ، مقدار $\delta = 0$ است.

در حریم خصوصی تفاضلی فرضی در مورد دانش پیش زمینه‌ی کاربر گرفته نمی‌شود به عبارت دیگر داشتن دانش پیش زمینه مهم نیست. حساسیت- L_1 یکی از کلیدی‌ترین مفاهیمی است که در ساختن داده‌های با خاصیت حریم خصوصی تفاضلی از آن استفاده شده است و به صورت زیر تعریف می‌شود:

تعريف (۲). تابع $f: X^* \rightarrow R^k$ را در نظر بگیرید. حساسیت- L_1 تابع f عبارت است از $S(f) = \max_{T, \hat{T}} |f(T) - f(\hat{T})|$ به طوریکه مجموعه داده‌های T, \hat{T} فقط در یک مشخصه با هم اختلاف داشته باشند.

برای ایجاد داده‌هایی با خاصیت حریم خصوصی تفاضلی، راهها و روش‌های متفاوتی وجود دارند. مکانیزم لاپلاس یکی از آنها است. در [۹] مکانیزم لاپلاس به صورت زیر تعریف شده است:

تعريف (۳). اگر $f: X^* \rightarrow R^k$ یک تابع باشد، مکانیزم لاپلاس به صورت زیر تعریف می‌شود:

$$M_L(D, f(.)) = f(D) + (y_1, y_2, \dots, y_k)$$

که y_i ها، به صورت مستقل از توزیع لاپلاس $\text{Lap}_{\epsilon}^{(f)}$ انتخاب می‌شوند.

قضیه ۱ [۱۳]. اگر F نشان دهنده مجموعه از توابع حقیقی با حساسیت $S(F)$ باشد و اگر A الگوریتمی باشد که به خروجی هر کدام از این توابع، خدشه‌ی با توزیع لاپلاس که دارای میانگین صفر و دامنه‌ی λ هستند را اضافه کند در این صورت مکانیزم A خاصیت «حریم خصوصی تفاضلی- $(\frac{S(F)}{\lambda})$ » خواهد داشت.

۱- کارهای مرتبط

دو روش کلی جهت حفظ حریم خصوصی داده‌ها در الگوریتم‌های داده‌کاوی وجود دارند که عبارتند از [۱۴]: PBA و TBA.^{۲۱} در PBA، یک محیط توزیعی از داده‌ها در نظر گرفته می‌شود که در آن، مالکان داده تمایل دارند تا داده‌های خود را بدون اینکه حریم خصوصی آنها نقض گردد، به منظور داده‌کاوی در اختیار دیگران قرار دهند. در این حالت، فرضی در مورد نحوه تقسیم‌بندی داده‌ها

حالتهای مفیدتری تبدیل می‌شوند که این تبدیل را تبدیل موجک می‌گویند.^{۱۳}

جهت محاسبه‌ی کارآمد تبدیلات موجک، «تجزیه و تحلیل چند تفکیکی»^{۱۴} (MRA) توسط «مالات و مایر»^{۱۵} معرفی شد. با استفاده از MRA، یک سیگنال یا یک داده، به صورت ترکیبی از داده‌های با آهنگ تغییر کند^{۱۶} (آهسته) (داده‌هایی که به آهستگی تغییر پیدا می‌کنند) و داده‌های با آهنگ تغییر تند^{۱۷} (داده‌هایی که در یک زمان کوتاه به شدت تغییر پیدا می‌کنند)، مشاهده می‌شود. MRA، پلی است که ارتباط بین تجزیه و تحلیل موجک یک سیگنال و فیلترینگ آن سیگنال را برقرار می‌کند. با استفاده از MRA و با انتخاب مناسب سطح تفکیک، تقریب خوبی برای داده به دست خواهد آمد.

در تبدیل موجک هار (غیر نرمال)، فیلترهای پایین گذر و بالا گذر به ترتیب عبارتند از $\{g_0, g_1\}$ و $\{h_0, h_1\}$ که در آن $h_0 = 1/2$ و $h_1 = 1/2$ و $g_0 = -1/2$ و $g_1 = 1/2$ است. مطابق با الگوریتم «مالات و مایر»، با اعمال فیلترهای پایین گذر (بالاگذر) بر روی مجموعه ضرایب تقریب (موجک) در یک سطح، مجموعه ضرایب تقریب (موجک) در سطح پایین به دست خواهد آمد. این الگوریتم تا رسیدن به ضرایب سطح صفر به صورت بازگشتشی اجرا می‌شود.

۲- حریم خصوصی تفاضلی

یکی از قوی‌ترین تعریف‌هایی است که توسط دیورک [۹] درباره‌ی حریم خصوصی ارائه گردید. این تعریف، با در نظر گرفتن قدرت محاسباتی فرد مهاجم، حریم خصوصی تفاضلی، مطمئن خواهیم شد که [۱۰]. از طریق حریم خصوصی تفاضلی، مطمئن خواهیم شد که حذف یا اضافه کردن یک رکورد در مجموعه داده‌ها، تاثیری در خروجی الگوریتم‌ها نخواهد داشت. به عبارت دیگر، از فاش شدن اطلاعات یک رکورد، جلوگیری خواهد کرد.

دو مجموعه داده‌ی T و \hat{T} که فقط در یک مشخصه^{۱۹} با هم تفاوت دارند، را در نظر بگیرید. اگر f تابعی روی آنها باشد به طوری که $f(T) = x$ و $f(\hat{T}) = \hat{x}$ باشند در این صورت گفته می‌شود که سیستم دارای خاصیت حریم خصوصی تفاضلی است اگر خروجی های x و \hat{x} تقریباً با هم برابر باشند. به عبارت دیگر، کاربر متوجه تغییرات صورت گرفته در مجموعه داده‌ی T نباشد. از این‌رو به مکانیزمی مانند A نیاز داریم تا ارتباط بین خروجی واقعی و درست تابع f و کاربر را برقرار کند. مکانیزم A با دریافت خروجی تابع f، طوری آن را تغییر داده و در اختیار کاربر قرار می‌دهد تا کاربر متوجه تغییرات صورت گرفته در T نباشد. یکی از این تغییرات، اضافه کردن توزیع لاپلاس در خروجی f است. با کمی تغییر، تعریف زیر را داریم

داده‌ها است. از این‌رو، دقت داده‌کاوی به دلیل مخدوش نشدن داده‌ها حفظ می‌گردد. الگوریتم ارائه شده در این روش، روی تک تک داده‌های یک مجموعه داده اعمال می‌شود از این‌رو، یکی از اشکالات این روش، زیاد بودن پیچیدگی ارتباط بین کاربران است.

نوع دیگری از مخدوش‌سازی اطلاعات، مخدوش‌سازی ضربی^{۳۴} است. این نوع مخدوش‌سازی بر پایه LM جانسون-لیندن‌اشتراس^{۳۵} [۲۰] بنا نهاده شده است. اگر داده‌های با بعد بالاتر را به داده‌های با بعد پایین‌تر نگاشت کنیم، فاصله بین داده‌ها، تقریباً حفظ شده و به دلیل از دست رفتن برخی اطلاعات در هنگام نگاشت از بعد بالاتر به بعد پایین‌تر، بازیابی اطلاعات اصلی با استفاده از داده‌های با بعد پایین‌تر، امکان پذیر نخواهد شد. PCA، یکی از بهترین روش‌ها جهت استفاده در کاهش ابعاد داده‌ها است. با استفاده از این روش، مشخصه‌های با واریانس بالاتر انتخاب (نسبت به سایر مشخصه‌ها) یک مجموعه داده و سپس، داده‌ها را به این مشخصه‌ها نگاشت می‌کنند. پیچیدگی زمانی این روش $(nd^2 + o(d^3))$ است که n بعد داده‌ی اصلی و d ، بعد داده‌ی به دست آمده از نگاشت است. به دلیل بالا بودن پیچیدگی زمانی الگوریتم فوق برای داده‌های با ابعاد بالا، در [۲۱، ۲۲] روشی به نام «افکنشن تصادفی»^{۳۶} (RP) ارائه شد. RP نسبت به PCA، از دقت پایین‌تر برخوردار است ولی پیچیدگی زمانی $Y = XM$ کمتری نسبت به آن دارد. RP، را می‌توان به صورت در آن، X مجموعه داده‌ی اصلی با بعد $d \times n$ و M ، ماتریس تصادفی با بعد $d \times e$ است، نشان داد. درایه‌های ماتریس M ، دارای «توزیع مستقل و یکسان»^{۳۷} هستند و Y نیز، ماتریس حاصل از نگاشت داده‌های با بعد $n \times e$ است. انتخاب ماتریس تصادفی M ، یکی از مهمترین مسایلی است که در این الگوریتم مورد بررسی قرار می‌گیرد [۲۳].

الگوریتم‌های فوق، نه تنها هیوریستیک مبنا بوده و حریم خصوصی قابل اثباتی ندارند بلکه در مقابل دانش پیش‌زمینه کاربران نیز آسیب پذیر هستند. بنابراین، امکان استفاده از حملات «پیوند رکوردي»، «پیوند مشخصه‌ای»، «پیوند جدولی» و «حملات احتمالی» به منظور آسیب رساندن به حریم خصوصی داده‌ها وجود خواهد داشت. برای این منظور، مفهوم «حریم خصوصی تفاضلی»^{۳۸} [۹] برای غلبه بر مشکل دانش پیش‌زمینه کاربران ابداع شد. در این مفهوم، حذف یا اضافه کردن یک مشخصه جدید در داده‌ها، تاثیری در خروجی الگوریتم‌های داده‌کاوی نخواهد داشت. الگوریتم‌های مختلفی در محیط‌های تفاضلی ارائه شده‌اند. در [۲۴] و [۲۵]، الگوریتم‌هایی به منظور محاسبه‌ی نقاط مرکزی الگوریتم k-means^{۳۹} ارائه شده‌اند. پایه و اساس الگوریتم ارائه شده در [۲۴]، ساختاری به نام SULQ است. در [۲۶] از فرایندی به نام GSB^{۴۰} به منظور انتشار امن نقاط

(افقی یا عمودی) در بین افراد یا سازمانها در نظر گرفته می‌شود و معمولاً، الگوریتم‌های شناخته شده موجود را طوری تغییر می‌دهند که بتوان از آنها جهت حفظ حریم خصوصی داده‌ها، استفاده کرد. پروتکل‌های پیشنهاد شده (مانند «محاسبات چند جانبی امن»^{۳۳} (SMC)، اطلاعات ارسالی بین افراد یا سازمانها را طوری کنترل می‌کنند تا از عدم انتشار اطلاعات حساس مربوط به داده‌ها مطمئن گردد. در TBA، ضمن تبدیل داده‌های اصلی به داده‌های مخدوش شده، سعی می‌کنند تا شباهت بین داده‌های اصلی و تبدیل شده حفظ گردد. به عبارت دیگر، عملگر تبدیل طوری انتخاب می‌شود تا ضمن مخدوش شدن داده‌ها، نتایج بهتری از داده‌کاوی به دست آورند. الگوریتم‌های PBA نسبت به الگوریتم‌های TBA، نتایج دقیق‌تری را در داده‌کاوی داده‌ها به دست می‌آورند. در صورتی که از الگوریتم PBA در داده‌کاوی داده‌ها استفاده گردد، امنیت داده‌ها قابل اثبات خواهد بود [۱۵]. در حالت کلی، الگوریتم‌های PBA، به دلیل سربار زیاد پیامهای ارسال شده در بین کاربران، از کارایی کمتری برخوردار هستند.

الگوریتم‌های مختلفی بر اساس روش‌های PBA و TBA ارائه شده‌اند. اولی‌ویرا^{۴۱} و زایانس^{۴۲} [۱۶]، الگوریتمی بر مبنای TBA برای داده‌های توزیع شده افقی ارائه کردند. در [۱۷، ۱۶]، از «تبدیلات هندسی»^{۴۳} شامل انتقال^{۴۴}، مقیاس‌پذیری^{۴۵} و چرخش^{۴۶}، جهت مخدوش کردن داده‌های اصلی استفاده شد. یکی از مشکلات تبدیلات اقلیدسی، آسیب‌پذیر بودن آنها در مقابل حملات «وروودی-خروجی شناخته شده»^{۴۷} است. در این نوع حمله، فرد مهاجم علاوه بر داشتن تعدادی از داده‌های مخدوش شده، داده‌های اصلی متناظر با آنها را نیز در اختیار دارد. [۱۶]، به منظور رفع این مشکل، از متغیرهای تصادفی یکنواخت یا نرمال استفاده کرد. به این ترتیب که این متغیرها را به ارزش مقداری مشخصه‌های حساس هر رکورد اضافه کرده سپس آنها را منتشر می‌کنند و می‌توان آن را به صورت $r_i = x_i + r_i$ نشان داد که x_i نشان دهندهٔ مقدار اصلی و r_i نشان دهندهٔ متغیر تصادفی یکنواخت یا متغیر تصادفی نرمال است. این روش، برای داده‌های با وابستگی بالا^{۴۸}، مناسب نیست و امکان آسیب‌پذیری آن از طریق روش‌هایی مانند PCA و تحلیل بیز وجود دارد. به این نوع حمله، «حمله آنالیز-ویژه»^{۴۹} گفته می‌شود. [۱۸] الگوریتمی جهت حل این مشکل ارائه کرد که در آن از خدشه‌های دارای کواریانس یکسان با داده‌های اصلی استفاده شد.

در [۱۹]، داده‌ها به مشخصه‌های مختلفی تقسیم شده سپس بین کاربران توزیع می‌گردد و در نهایت، جهت حفظ حریم خصوصی داده‌ها از پروتکل SMC که توسط یا لو^{۵۰} ارائه شده بود استفاده شد. در این الگوریتم، تمام محاسبات بر پایه‌ی رمزگذاری و رمزگشایی

از معایب اصلی الگوریتم ارائه شده در [۳۵] این است که به منظور افزایش کارایی داده‌های ایجاد شده، الگوریتم K-NN (K-Nearest Neighbor) را تغییر داده است. در [۳۶] الگوریتمی برای حفظ حریم خصوصی در ردیابی داده‌ها در محیط رایانش ابری ارائه شده است و به منظور رسیدن به حریم خصوصی تفاضلی داده‌ها از خدشهای لایاس استفاده شده است. در [۳۷، ۳۸]، الگوریتم‌هایی برای حفظ حریم خصوصی ردیابی داده‌ها ارائه شده است یکی از مهمترین مشکلات این الگوریتم‌ها این است که یا حریم خصوصی قابل اثبات ندارند یا اینکه (در صورت استفاده از مفهوم حریم خصوصی تفاضلی) هم‌مان، قادر به کاهش ابعاد داده‌های اولیه نیستند. در مرجع [۳۹]، الگوریتمی تفاضلی برای حفظ حریم خصوصی داده‌ها در خوشه‌بندی ارائه شده است. ایراد این الگوریتم این است که سطح توقف تجزیه داده‌ها به صورت خودکار مشخص نمی‌گردد. اکثر این الگوریتم‌ها در مقابل دانش پیش‌زمینه کاربران آسیب پذیر هستند.

با توجه به مطالب گفته شده، حفظ حریم خصوصی داده‌ها در داده‌کاوی، یکی از مهمترین مسائلی است که پژوهشگران روی آن کار می‌کنند. یکی از روش‌های حفظ حریم خصوصی، روش TBA است. در این روش، داده‌های اصلی را طوری مخدوش می‌کنند که شباهت بین داده‌های اصلی و مخدوش شده حفظ گردد. الگوریتم‌ها مختلفی مبتنی بر TBA ارائه شده است. اکثر این الگوریتم‌ها، داده‌هایی را تولید می‌کنند که حریم خصوصی آنها با استفاده از مدل ریاضی قابل اثبات نیست. برای رفع این مشکل، مفهوم حریم خصوصی تفاضلی ابداع شد. در حریم خصوصی تفاضلی، داده‌های اصلی را با اضافه کردن خدشهایی مخدوش می‌کنند ولی تفاوت آن با الگوریتم‌های قبلی این است که حریم خصوصی این داده‌ها از طریق مدل ریاضی قابل اثبات است. یکی دیگر از مشکلات در داده‌کاوی، ابعاد بالای داده‌ها است. هر قدر ابعاد داده‌ها کاهش پیدا کند به همان میزان دقت داده‌کاوی کاهش پیدا می‌کند. از این‌رو، کاهش ابعاد داده‌ها باید طوری باشد که تعادلی بین کاهش ابعاد و دقت داده‌کاوی برقرار گردد. تا کنون، با جستجوهای صورت گرفته، الگوریتمی که بتواند چهار مشخصه (۱) قابل اثبات بودن حریم خصوصی داده‌ها با مدل ریاضی، (۲) کاهش ابعاد داده‌ها، (۳) اعمال روی داده‌های توزیع شده و (۴) ردیابی را هم‌مان مورد بررسی قرار دهد، پیدا نشد. از این‌رو در این مقاله، الگوریتمی با استفاده از مفاهیم «تبديل موجک» و «حریم خصوصی تفاضلی» برای ارائه یک راه حل قابل قبول برای این سه مورد پیشنهاد گردید.

مرکزی الگوریتم k-means استفاده شده است. از طریق ساختار GSB امکان انتشار امن تابعی مانند $f(x)$ بر روی مجموعه داده‌ی x وجود خواهد داشت. در [۲۷] ساختاری به نام PINQ^۱ (که در واقع یک ساختار توسعه پذیر برای تجزیه و تحلیل داده‌ها است) به منظور حفظ بی قید و شرط حریم خصوصی داده‌های مورد نظر ارائه شد. در [۲۷] با استفاده از ساختار PINQ ویرایش ساده‌ای از الگوریتم k-means (که در مرجع [۲۴] معرفی شده است) پیاده‌سازی شده است. در [۲۸] الگوریتمی به منظور ایجاد ساختارهای هندسی مبتنی بر حریم خصوصی تفاضلی به نام Core-Sets معرفی شد به این صورت که ابتدا، الگوریتم فوق را بر روی مجموعه داده اولیه T اعمال کرده تا Core-Sets^۲ به نام C را ایجاد نماید. سپس تمام الگوریتم‌های خوشه‌بندی مبتنی بر k-median به جای اجرا روی T بر روی C اجرا خواهد شد.

در [۲۹]، الگوریتمی برای حفظ حریم خصوصی در «کاوش دنباله‌های متناوب»^۳ مبتنی بر حریم خصوصی تفاضلی ارائه شده است. این الگوریتم از دو مرحله تشکیل شده است. در مرحله اول، پیش‌پردازشی روی داده‌ها انجام می‌دهد و در مرحله دوم، عمل کاوش روی داده‌ها را اجرا می‌کند. در مرحله پیش‌پردازش از تقسیم‌بندی جدیدی برای تغییر در پایگاه دادها استفاده کرده است تا از این طریق، محramانگی داده‌ها را ارتقاء دهد. در [۳۰]، یک الگوریتم مبتنی بر حریم خصوصی تفاضلی برای حل مشکل عدم یکنواختی داده‌های چند رسانه‌ای^۴ دو بعدی ارائه داده است. الگوریتم‌های معمولی حفظ حریم خصوصی، فضای داده‌های مکانی^۵ را به شبکه تقسیم می‌کنند و سپس به هر شبکه در همان مقیاس نویز می‌دهند. به منظور حل مشکل افزایش خطای نسبی و کاهش دقت، یک الگوریتم تخصیص پویای خدشهای حریم خصوصی تفاضلی پیشنهاد شده است. در [۳۱]، با استفاده از خدشهای لایاس، الگوریتمی برای حفظ حریم خصوصی داده‌ها ارائه شده است. در [۳۲]، انتشار داده‌ها در شبکه‌های اجتماعی مورد بررسی قرار گرفته است و الگوریتمی مبتنی بر حریم خصوصی تفاضلی ارائه شده است که از طریق آن می‌توان داده‌های حساس را در اختیار دیگران قرار داد. در [۳۳] با استفاده از تبدیلات فوریه، حریم خصوصی تفاضلی را در ردیابی داده‌های یک شبکه هوشمند^۶ ایجاد کرده است. در [۳۴]، از طریق اضافه کردن خدشه به داده‌ها، مجموعه داده‌های تفاضلی را در یک محیط رایانش لبه‌ای^۷، ایجاده کرده و با سایر افراد به اشتراک می‌گذارند. در [۳۵]، الگوریتمی برای ردیابی داده‌ها معرفی شده است که پایه و اساس آن، اضافه کردن خدشهای لایاس (یکی از روش‌های ایجاد داده‌های مبتنی بر حریم خصوصی تفاضلی) به داده‌ها می‌باشد. یکی

۴- الگوریتم پیشنهادی

۳-۳- جزییات الگوریتم پیشنهادی

به منظور طراحی الگوریتم برای داده‌های توزیع شده به صورت عمودی، از خاصیت خطی تبدیلات موجک [۴۱] استفاده می‌کنیم. این خاصیت بیان می‌کند که اگر مجموعه‌ی داده‌ی T را به دو مجموعه داده‌ی جدا از هم عمودی T_1 و T_2 تقسیم کنیم (یعنی $HWT(T) = (T_1, T_2)$) در این صورت رابطه‌ی زیر را داریم:

$$HWT(T) = HWT(T_1) + HWT(T_2) \quad (1)$$

رابطه‌ی (1) بیان می‌کند که اگر تبدیل موجک هار را بر روی تک تک مجموعه‌های T_1 و T_2 اعمال کنیم و سپس آنها را با هم جمع کنیم، نتیجه‌ی بهدست آمده همان نتیجه‌ی حاصل از اعمال تبدیل موجک هار بر روی مجموعه داده‌ی T است. لازم به ذکر است که اندیس مجموعه داده‌های T_1 و T_2 در رابطه‌ی $(T_1, T_2) = T$ ، به ترتیب برابر با ۱ و ۲ است. در تبدیل موجک هار، اندازه هر مجموعه داده باید توانی از دو باشد. از این‌رو اگر اندازه هر مجموعه داده توانی از دو نباشد باید به اندازه کافی عدد صفر به انتهای آن اضافه شود تا به توان دو برسد. به منظور افزایش دقت رده‌بندی و جلوگیری از همپوشانی ضرایب تولید شده، از روش زیر برای اضافه کردن عدد صفر به انتهای مجموعه داده‌ها استفاده می‌شود:

فرض کنید که تعداد سایتها برابر با G بوده و مجموعه داده‌ی T_g با ابعاد $m \times n_g$ متعلق به سایت g باشد. ماتریس T_g را به صورت $T_g = \begin{pmatrix} t_{11}^g & \dots & t_{1n_g}^g \\ \vdots & \ddots & \vdots \\ t_{m1}^g & \dots & t_{mn_g}^g \end{pmatrix}$ در نظر بگیرید. واضح است که $1 \leq g \leq G$ است. همچنین فرض کنید که نماد $|A|$ نشان دهنده تعداد مشخصه‌های (اندازه‌ی) یک مجموعه داده باشد. ترکیب کلی عمودی $(T_1, \dots, T_g, \dots, T_G)_{m \times n} = (T_1, \dots, T_g)_{m \times n_g} + (T_g, \dots, T_G)_{n_g \times n}$ را در نظر بگیرید که در آن رابطه $n = \sum_{g=1}^G n_g$ برقرار است. واضح است که اندیس (موقعیت) t_{ij}^g در T برابر با g است. کوچکترین عدد صحیح n را طوری انتخاب می‌کنیم که بزرگتر یا مساوی n بوده و توانی از $2^{m \times n}$ باشد. هر سایت g ، مجموعه داده‌ی R_g با ابعاد $(G \times n) \times (n \times n)$ را فاصله‌ی اقلیدسی که در این‌جا آن برابر با صفر باشد. سپس، در این‌جا فرض می‌کنیم که سایت‌ها با استفاده از یک سیستم رمزگذاری عمومی، اطلاعات را به یکدیگر ارسال یا از یکدیگر دریافت می‌کنند. به عبارت دیگر، هر سایت دارای یک کلید عمومی و یک کلید خصوصی است. همچنین، TTP ، کلید عمومی تمام سایت‌ها و تمام سایت‌ها نیز کلید عمومی TTP را می‌دانند.

در این بخش الگوریتم پیشنهادی بر روی داده‌های توزیعی عمودی ارائه شده است.

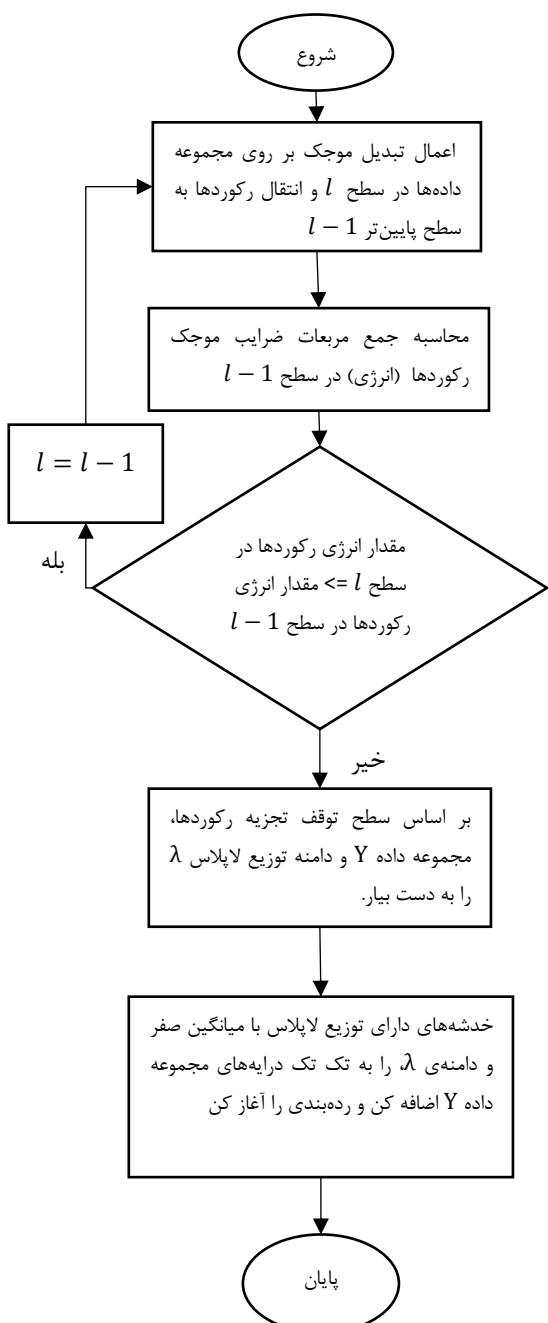
۴-۱- فرضیات مساله

فرض‌های در نظر گرفته شده در این مقاله، عبارتند از (۱) مجموعه داده‌ای که الگوریتم‌های ارائه شده بر روی آنها اعمال خواهند شد را به صورت یک ماتریس دو بعدی $T_{m \times n}$ در نظر می‌گیریم. به عبارت دیگر، این ماتریس دارای m سطر و n ستون است که هر سطر اطلاعات مربوط به یک موجودیت خاص با n مشخصه را نشان می‌دهد، (۲) مقادیر مربوط به مشخصه‌های هر رکورد را به صورت یک دنباله‌ی عددی در نظر می‌گیریم و (۳) مقدار مثبت T_{Max} چنان وجود دارد که قدر مطلق تمام درایه‌های ماتریس $T_{m \times n}$ ، کوچکتر یا مساوی T_{Max} است.

۴-۲- مدل تهدید

در الگوریتم‌های توزیعی، یکی از دو مدل ارتباطی زیر را در بین سیستم‌ها در نظر می‌گیرند [۴۰]: (۱) مدل بدخواه^۴ (۲) مدل نیمه-صادق^۵. در مدل بدخواه، طرف بدخواه مجبور نیست تا قواعد در نظر گرفته شده در پروتکل را رعایت کند و امکان دارد با استفاده از داده‌هایی که از سایرین دریافت می‌کند، شروع به سازمان دادن حمله‌هایی بر ضد افراد شرکت کننده نماید. ولی در مدل نیمه-صادق، فرض بر این است که شرکت کننده‌گان قابل اعتماد و کنجدکاو هستند. در این مدل، افراد شرکت کننده، قواعد در نظر گرفته شده را رعایت کرده ولی ممکن است بخواهند اطلاعاتی بیشتر از آنچه برای یک فرد در نظر گرفته شده است را به دست آورند. در اکثر الگوریتم‌های ارائه شده برای حفظ حریم خصوص داده‌ها، از مدل نیمه-صادق برای ارائه الگوریتم خود استفاده می‌کنند. در این مقاله فرض می‌شود که افراد^۶ شرکت کننده در الگوریتم، نیمه-صادق هستند. همچنین از یک «طرف سوم»^۷ (TTP)، به منظور کنترل ارتباط بین افراد شرکت کننده در الگوریتم استفاده شده است. TTP می‌تواند مستقل یا یکی از افراد شرکت کننده در مساله باشد. TTP را هم به عنوان یک فرد نیمه-صادق در نظر می‌گیریم. همچنین فرض می‌کنیم که سایت‌ها با استفاده از یک سیستم رمزگذاری عمومی، اطلاعات را به یکدیگر ارسال یا از یکدیگر دریافت می‌کنند. به عبارت دیگر، هر سایت دارای یک کلید عمومی و یک کلید خصوصی است. همچنین، TTP ، کلید عمومی تمام سایت‌ها و تمام سایت‌ها نیز کلید عمومی TTP را می‌دانند.

داده‌ها تا رسیدن به شرط گفته شده در بالا ادامه پیدا می‌کند. در [۴۲] نشان داده شده است که ضرایب تقریب به دست آمده یک مجموعه داده که شرط انرژی گفته شده در آن برقرار باشد، جایگزین خوبی برای مجموعه داده‌های اولیه خواهد بود.



شکل ۱: فلوچارت الگوریتم پیشنهادی

به منظور افزایش دقت رده‌بندی، احتمال اینکه در سطوح پایین‌تر بتوانیم به یک مجموعه داده‌ای برسیم که کارایی خوبی داشته باشد، وجود دارد. از این‌رو در خط ۱۱، براساس دقت به دست آمده برای مجموعه داده، سطح مورد نظر برای توقف را انتخاب می‌کنیم. فرض کنید شرط توقف تجزیه برای مقدار S برابر با ۲ برقرار باشد. مطابق

(۶) در نظر گرفته و تبدیل موجک هار را تا سطح ۰ بر روی آنها اعمال کنیم، به هیچ عنوان همپوشانی ضرایب تقریب در سطوح مختلف اتفاق نخواهد افتاد و این باعث افزایش دقت رده‌بندی خواهد شد. برای مثال، مجموعه داده‌ی کلی T با یک رکورد و ۶ مشخصه را به صورت $(4, 2, 1, 3, 5, 1)_{1 \times 6}$ در نظر بگیرید. همچنین فرض کنید که T به دو قسمت عمودی $T_1 = (4, 2, 1)_{1 \times 3}$ و $T_2 = (3, 5, 1)_{1 \times 3}$ تقسیم شده و در دو سایت مختلف پخش شده باشند. بدون اینکه خلی در بیان مساله پیش بباید فرض می‌کنیم T_1 در سایت ۱ و T_2 در سایت ۲ قرار داده شده‌اند. به منظور اعمال تبدیل موجک هار بر روی مجموعه داده‌های T_1 و T_2 ، طول رکوردهای آنها باید توانی از ۲ باشد. در غیر این صورت، به تعداد کافی صفر به تک تک رکوردهای این مجموعه‌ها اضافه می‌شود تا اندازه‌ی هر رکورد توانی از ۲ باشد. در مثال فوق مقدار $G = 6$ است. جدول ۱، تجزیه مجموعه داده‌های متعلق به سایتها ۱ و ۲ (مثال فوق) را با استفاده از روش گفته شده برای اضافه کردن صفر به مجموعه داده‌ها را نشان می‌دهد. همان‌طوری که ملاحظه می‌شود، اگر از رابطه‌ی ۱، برای محاسبه ضرایب تقریب و ضرایب موجک مجموعه داده‌ی ترکیبی کلی T استفاده شود، در این صورت هیچ گونه همپوشانی در بین ضرایب تقریب و ضرایب موجک مجموعه داده‌های متعلق به سایتها اتفاق نخواهد افتاد.

شکل ۱، فلوچارت الگوریتم پیشنهادی را نشان می‌دهد. در محله اول، تبدیلات موجک روی مجموعه داده‌ها اعمال می‌شود. در مرحله بعد، انرژی رکوردها در سطح پایین‌تر با انرژی رکوردهای سطح بالاتر مقایسه شده و بر اساس آن، سطح توقف تجزیه مشخص می‌گردد. در نهایت با توجه به سطح توقف، میزان خداشتهای مشخص شده و به مجموعه داده‌ها اضافه می‌گردد. همچنین، شکل ۲، شبکه کد الگوریتم ارائه شده بر روی داده‌های توزیع شده به صورت عمودی را نشان می‌دهد. خط ۱ و ۲ الگوریتم، پیش پردازشی را بر روی مجموعه داده اولیه به منظور اعمال روش گفته شده، انجام می‌دهد. در بین خطوط ۳ تا ۱۰، تبدیل موجک هار بر روی مجموعه داده اعمال می‌شود تا آن را تجزیه نماید. در مرجع [۴۲]، تبدیل موجک هار را بر روی مجموعه داده‌های اعمال کرده سپس مجموع انرژی مربوط به ضرایب موجک تمام رکوردهای سطح جاری را با هم جمع کرده و آن را با مقدار حاصل از جمع انرژی سطح قبلی (که قبلًاً محاسبه کرده بود) مقایسه می‌نماید. اگر جمع انرژی سطح قبلی کمتر از جمع انرژی سطح جاری باشد در این صورت پیغام «توقف تجزیه» را به تمام سایتها ارسال کرده و سطح قبلی را به عنوان سطح توقف تجزیه مشخص می‌کند. در غیر این صورت، تبدیل موجک بر روی

را به اندازه‌ی η تغییر بدهیم. بدون اینکه خلی در اثبات قضیه وارد شود، فرض کنید مقدار درایه‌ی $(t_g)_{\alpha\beta}$ به $1 \leq \alpha \leq m, 1 \leq \beta \leq n_g$ (۱) به مقدار η تغییر پیدا کرده باشد. مجموعه داده‌ی به دست آمده را T_g نامیم. واضح است که با اجرای خطوط ۱ تا ۱۳ الگوریتم *PrivacyCL* بر مجموعه داده T_g ، فقط درایه $(y_g)_{\alpha\theta}$ مربوط به مجموعه داده‌ی Y_g تغییر پیدا می‌کند که در آن مقدار θ برابر با $+1 - \frac{2^{S \times \beta}}{n}$ است چرا که در تبدیل موجک هار، طول فیلترهای بالاگذر و پایین‌گذر برابر با ۲ است و اگر تغییری در یک مشخصه ایجاد شود در این صورت تغییر اعمال شده فقط به یکی از ضرایب به دست آمده در هر سطح پایین منتقل می‌گردد. لازم به ذکر است که در ارائه الگوریتم *PrivacyCL* از حالت غیر نرمال تبدیل موجک هار استفاده شده است. برای اندازه‌گیری مقدار تغییر اتفاق افتاده در درایه $(y_g)_{\alpha\theta}$ ، مراحل زیر را طی می‌کنیم:

در خط ۲ الگوریتم *PrivacyCL*، درایه‌های T_g بر عدد T_{Max} تقسیم می‌شوند. بنابراین اندازه‌ی تغییر اتفاق افتاده در درایه‌ای با سطر α و ستون β مربوط به مجموعه داده‌ی T_g نسبت به درایه‌ی متناظر آن در مجموعه داده‌ی T_g برابر با $\frac{\eta}{T_{Max}}$ خواهد بود. در خطوط ۳ تا ۱۱، تبدیل موجک هار تا سطح توقف S و به صورت مستقل بر روی رکوردهای T_g اعمال می‌شوند. بنابراین تمام ضرایب تقریب به دست آمده برای هر رکورد در سطح S حاصل جمع دو به دوی تقسیم شده‌ی درایه‌های همان رکورد در سطح اولیه بر $\frac{\eta}{2^S}$ است. از این‌رو مقدار θ در سطح S برابر با $= \frac{2^{S \times \theta}}{n} = \frac{2^{S \times \theta}}{(2^S)}$ است. لازم به ذکر است که تبدیل موجک هار به صورت مستقل بر روی رکوردها اعمال می‌شود. بنابراین، به غیر از درایه‌ی $(y_g)_{\alpha\theta} \in Y_g$ (۲)، هیچ‌کدام از درایه‌های مجموعه داده‌ی Y_g تغییر پیدا نخواهد کرد (درایه‌های ماتریس Y_g ، همان ضرایب تقریب رکوردها در سطح توقف تجزیه (یا S هستند).

طبق مطالب گفته شده در بالا، اندازه‌ی تغییر درایه‌ی $(y_g)_{\alpha\theta}$ (نسبت به درایه‌ی متناظر آن که از T_g به دست آمده است) برابر با $\frac{2^{S \times \theta}}{n}$ خواهد شد.

با خط ۱۲ الگوریتم *PrivacyCL* مقادیر sa_1, ea_1, sa_2 و ea_2 به ترتیب برابر با ۱، ۲، ۵ و ۶ محاسبه خواهند شد. از این‌رو مقادیر d_1 و d_2 برابر با ۲ خواهند بود. سپس، ماتریس‌های $(3, 0.5)$ و $Y_1 = (4, 0.5)$ بر اساس خط ۱۳ محاسبه می‌شوند. فرض کنید مقدار متغیر *hasnegativevalues* برابر با *false* باشد. در این صورت مقدار ۹ برابر با ۱ خواهد شد (خط ۱۴). با فرض $\epsilon = 0.03, -0.05$ و $\Delta_1 = (0.39, -0.80)$ و $\Delta_2 = (4.39, -0.30)$ و $P_1 = Y_1 + \Delta_1 = (3.03, 0.045)$ و $P_2 = Y_2 + \Delta_2 = (4.39, -0.30)$ را محاسبه کرده و آنها را منتشر می‌کنیم. در خط ۲، به منظور غلبه بر مشکل همپوشانی ضرایب تقریب در توزیع عمودی داده‌ها (که باعث کاهش کارایی داده‌های تولید شده می‌شود)، از روشی که برای اضافه کردن مقادیر صفر به مجموعه داده گفته شد، برای اضافه کردن صفر به مجموعه داده R_g استفاده شده است. بنابراین، صفرهایی را به سمت چپ و راست مجموعه داده‌ی R_g اضافه می‌کنیم. از این‌رو، بعد از توقف تجزیه در سطح S ، ضرایب واقعی سایت g ، در بین اندیس‌های sa_g و ea_g قرار خواهند گرفت. بنابراین، فقط ضرایب قرار گرفته در بین اندیس‌های sa_g و ea_g در مجموعه داده Y_g قرار داده می‌شود.

۵- ارزیابی الگوریتم ارائه شده

در این بخش، الگوریتم ارائه شده را بر اساس حریم خصوصی و دقت رده‌بندی ارزیابی می‌کنیم.

۱-۵- ارزیابی حریم خصوصی

ابتدا حریم خصوصی تفاضلی الگوریتم ارائه شده، بررسی می‌گردد. برای این منظور قضیه زیر را دارم.

قضیه (۲): الگوریتم پیشنهادی *PrivacyCL* خاصیت حریم خصوصی تفاضلی ϵ دارد.

اثبات. فرض کنید مجموعه داده‌ی Y_g با ابعاد $m \times d_g$ در اثر اجرای خطوط ۱ تا ۱۳ الگوریتم *PrivacyCL* (شکل ۲) بر روی مجموعه داده‌ی اصلی T_g به ابعاد $m \times n_g$ به دست آمده باشد. همچنین T_g فرض کنید که فقط یکی از مشخصه‌های مجموعه داده‌ی اصلی T_g

جدول ۱: تجزیه مجموعه داده‌های متعلق به سایت‌ها با استفاده از روش جدید اضافه کردن صفر

سطح	مجموعه داده متعلق به سایت ۱	مجموعه داده متعلق به سایت ۲
۳	$R_1 = (4, 2, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0)_{1 \times 16}$	$R_2 = (0, 0, 0, 0, 0, 0, 0, 3, 5, 1, 0, 0, 0, 0, 0)_{1 \times 16}$
۲	$R_{1_{ac^2}} = (3, 0.5, 0, 0, 0, 0, 0), R_{1_{wc^2}} = (1, 0.5, 0, 0, 0, 0, 0)$	$R_{2_{ac^2}} = (0, 0, 0, 0, 4, 0.5, 0, 0), R_{2_{wc^2}} = (0, 0, 0, 0, -1, 0.5, 0, 0)$
۱	$R_{1_{ac^1}} = (1.75, 0, 0, 0), R_{1_{wc^1}} = (1.25, 0, 0, 0)$	$R_{2_{ac^1}} = (0, 0, 2.25, 0), R_{2_{wc^1}} = (0, 0, 1.75, 0)$
.	$R_{1_{ac^0}} = (0.875, 0), R_{1_{wc^0}} = (0.875, 0)$	$R_{2_{ac^0}} = (0, 1.125), R_{2_{wc^0}} = (0, 1.125)$

الگوریتم پیشنهادی PrivacyCL برای داده‌های توزیعی عمودی

- درودی:

- ماتریسی از تقدیمات عمودی $T_{m \times n} = (T_1, T_2, \dots, T_G)$ به طوریکه ماتریس T_g با ابعاد $m \times n_g$, متعلق به سایت g است. همچنین رابطه‌ی $n = \sum_{g=1}^G n_g$ برقرار است.
- قدر مطلق تمام درایه‌های مجموعه داده‌ی کلی T_g , کوچکتر یا مساوی T_{Max} هستند. مقدار T_{Max} با همکاری تمام سایتها و TTP مشخص می‌شود.
- ϵ : پارامتر مربوط به میزان حریم خصوصی است.
- a : دقت رده‌بندی مورد نظر.
- خروجی: ماتریس مخدوش شده‌ی $P_{m \times d} = (P_1, P_2, \dots, P_G)$: به طوریکه ماتریس P_g با ابعاد $m \times d_g$, مخدوش شده‌ی ماتریس T_g است. همچنین رابطه‌ی $d = \sum_{g=1}^G d_g$ برقرار است.
- هر سایت g , خطوط ۱ تا ۱۱ را اجرا می‌کند:
 - (۱) کوچکترین عدد صحیح بزرگتر یا مساوی n که توانی از ۲ باشد را پیدا کرده و آن را \hat{n} بنامید. (با همکاری تمام سایتها و TTP مشخص می‌شود).
 - (۲) تمام درایه‌های ماتریس T_g را برابر T_{Max} تقسیم کن و مجموعه داده‌ی دو بعدی R_g با ابعاد $m \times (\hat{n} \times G)$ را طوری بساز که درایه‌های آن برابر با صفر باشد. سپس، درایه‌ی t_{ij}^g را از ماتریس T_g برداشته و آن را در سطر i ام و ستون j $(\hat{n} \times G)$ ام ماتریس R_g کمی کن.
 - (۳) قرار بده $EH = +\infty$ و $l = \log(\hat{n})$ (تمام رکوردهای اولیه، در سطح $\log(\hat{n})$ در نظر گرفته می‌شوند).
 - (۴) مراحل ۵ تا ۱۰ را تا خارج شدن از حلقه ادامه بده
 - (۵) با استفاده از تبدیل موجک هار، m رکورد مجموعه داده‌ی R_g را به طور مستقل تجزیه کن تا در سطح $1 - l$ قرار بگیرند.
 - (۶) WC_i^{l-1} (ضرایب موجک رکوردهای l ام در سطح $1 - l$ ام) و AC_i^{l-1} (ضرایب تقریب رکوردهای l ام در سطح $1 - l$ ام) را برای هر رکورد به دست بیاور.
 - (۷) «جمع مراعات ضرایب موجک» یعنی $EL_g = \sum_m (WC_m^{l-1})^2$ را محاسبه کن و به TTP ارسال کن.
 - (۸) TTP , جمع انرژیهای ارسال شده توسط همه سایتها را را محاسبه می‌کند تا سطح مورد نظر برای توقف تجزیه داده‌ها مشخص گردد. یعنی مقدار $EL = \sum_{g=1}^G EL_g$ توسط TTP محاسبه می‌شود.
 - (۹) اگر $EL \leq EH$ باشد آنگاه:
 - (۹-۱) قرار بده $EH = EL$ و $l = 1 - l$ و برو به مرحله ۵.
 - (۹-۲) اگر $EH > EL$ باشد آنگاه:
 - (۱۰-۱) قرار بده $ML = l$ و برو به مرحله ۱۱.
 - (۱۰-۲) اگر $EH \leq EL$ باشد آنگاه:
 - (۱۱-۱) از بین سطح‌های ۰ تا ML سطحی را پیدا کن که اگر الگوریتم K-NN (برای مقدار $K=5$) را بر روی ضرایب تقریب در آن سطح، به منظور رده‌بندی، اعمال کنیم در این صورت، دقت رده‌بندی بزرگتر یا مساوی a باشد.
 - (۱۱-۲) در صورت پیدا شدن سطح مورد نظر با شرایط گفته شده: مقدار سطح پیدا شده را در متغیر S قرار بده در غیر این صورت: مقدار ML را در متغیر S قرار بده.
 - (۱۱-۳) قرار بده $sa_g = g.2^s - \left\lfloor \frac{2^s \times (\hat{n}-n_g)}{\hat{n}} \right\rfloor$ و $ea_g = (g-1).2^s + 1 - \left\lfloor \frac{2^s \times (\hat{n}-n_g)}{\hat{n}} \right\rfloor$
 - (۱۱-۴) ماتریس Y_g با ابعاد $m \times d_g$ را بساز، سپس تمام ضرایب تقریب سطح S را که اندیس آنها بین sa_g و ea_g است را به ترتیب از اندیس پایین تا اندیس بالا انتخاب کرده و آن را در رکوردهای l ام ماتریس Y_g قرار بده.
 - (۱۱-۵) قرار بده $\lambda = \frac{2^s \times \theta}{n \times \epsilon}$
 - (۱۱-۶) ماتریس تصادفی Δ_g با ابعاد $d_g \times m$ را که درایه‌های آن، متغیرهای تصادفی دارای توزیع لایپلاس با میانگین صفر و دامنه‌ی λ هستند را بساز.
 - (۱۱-۷) قرار بده $P_g = Y_g + \Delta_g$ که در آن ماتریس P_g از بعد d_g به m می‌باشد.
 - (۱۱-۸) $P = (P_1, P_2, \dots, P_G)$ را به خروجی ارسال کن.

شکل ۲: الگوریتم PrivacyCL بر روی داده‌های توزیعی عمودی

(تا رابطه‌ی $|t_{g\alpha\beta} + \eta| \leq T_{Max}$ برقرار گردد). از این‌رو، $|t_{g\alpha\beta}| \leq T_{Max}$ و $|\eta| \leq 2 \times T_{Max}$ $\Rightarrow |\eta| \leq 2 \times T_{Max}$ $\Rightarrow |\eta| \leq \frac{\eta}{T_{Max}}$ ≤ 2 نظر گرفته شده $|t_{g\alpha\beta}| \leq T_{Max}$ است. اما اگر فرض کنیم که درایه‌های ماتریس T_g فقط مقادیر مثبت می‌توانند اختیار کنند، در این صورت مطابق با توضیح بالا، بیشینه مقدار قدر مطلق θ برابر با

مطابق با خط ۱۴، اگر فرض کنیم که درایه‌های ماتریس T_g هم مثبت و هم منفی می‌توانند باشند، در این صورت بیشینه قدر مطلق مقدار θ برابر با ۲ خواهد بود زیرا، در بدترین حالت اگر $(t_{g\alpha\beta}) = (T_{Max} - T_{Max})$ باشد در این صورت طبق فرض در نظر گرفته شده (که قدر مطلق تمام درایه‌های ماتریس T_g ، کمتر یا مساوی T_{Max} هستند)، بیشینه مقدار η می‌تواند $(2 \times T_{Max}) - 2$ باشد

$$\epsilon = \frac{S(F)}{\lambda} \Rightarrow \lambda = \frac{S(F)}{\epsilon} = \frac{2^s \times \theta}{n \times \epsilon} \quad (4)$$

بنابراین خواهیم داشت:

$$\lambda = \frac{2^s \times \theta}{n \times \epsilon} \quad (5)$$

در خط ۱۶ الگوریتم **PrivacyCL** ماتریس تصادفی Δ به ابعاد $m \times d_g$ را طوری می‌سازیم که درایه‌های آن دارای توزیع لابلاس با میانگین صفر و دامنه‌ی $\frac{2^s \times \theta}{n \times \epsilon}$ باشد. سپس، در خط ۱۷، ماتریس Δ را به ماتریس Y_g اضافه کرده و نتیجه‌ی به دست آمده را منتشر می‌کنیم. بنابراین، الگوریتم پیشنهادی **PrivacyCL**، حریم خصوصی تفاضلی- ϵ دارد. ■

۲-۵- ارزیابی دقت ردهبندی

برای پیاده‌سازی الگوریتم ارائه شده، از زبان برنامه نویسی C#.Net و سیستم مدیریت پایگاه داده‌ی SQL SERVER استفاده شده است. پایه و اساس الگوریتم ارائه شده، متغیرهای تصادفی هستند. از این‌رو در هر بار اجرای الگوریتم ارائه شده مورد نظر، نتیجه‌ی متفاوتی را نسبت به نتیجه‌ی حاصل از اجرای قبلی به دست خواهیم آورد. بنابراین به منظور افزایش دقت نتایج، الگوریتم ارائه شده را ۱۰۰ بار روی یک مجموعه داده‌ی مورد نظر اجرا می‌کنیم و در هر بار، نتایج به دست آمده را در پایگاه داده‌ی SQL SERVER ذخیره می‌کنیم. در نهایت با استفاده از دستورات SQL، نتایج ذخیره شده را به دست آورده و آنها را به صورت جدول بیان می‌کنیم. الگوریتم پیشنهادی را بر روی هشت مجموعه داده‌ی واقعی و یک مجموعه داده‌ی تصنیع^{۵۲} (SCCTS) اجرا نمودیم. این مجموعه داده‌ها از مرجع [۴۳] به دست آمده‌اند. جدول ۲، مشخصات این مجموعه داده‌ها را بیان می‌کند.

به منظور ردهبندی داده‌ها، الگوریتم‌های مختلفی ارائه شده‌اند. یکی از مهمترین و شناخته شده‌ترین آنها، الگوریتم *K-NN* است. این الگوریتم، در اکثر پژوهش‌های ارائه شده در حوزه‌ی ردهبندی، به عنوان استانداردی برای مقایسه بین الگوریتم ارائه شده و الگوریتم‌های موجود مورد استفاده قرار گرفته است. در این مقاله، از الگوریتم *K-NN* به منظور ردهبندی داده‌ها استفاده شده است. الگوریتم ارائه شده، خدشهایی را جهت ایجاد شرایط حریم خصوصی تفاضلی به داده‌های نهایی اضافه می‌کند. از این‌رو، بعد از انتخاب ده درصد داده‌ها به عنوان «داده‌های آزمون»، هر آزمایش را ۱۰۰ بار تکرار کرده (۱۰۰ بار الگوریتم *K-NN* را بر روی داده‌های نهایی اجرا می‌کنیم) و بیشینه «دقت ردهبندی» حاصل از اجرای الگوریتم را محاسبه می‌کنیم. همچنین مقدار ϵ یک مقدار عمومی^{۵۳}

۱ خواهد بود. بنابراین، اندازه‌ی تغییر درایه‌ی $(y_g)_{\alpha\theta}$ برابر با $\frac{2^s \times \theta}{n}$ است که در آن مقدار θ برابر با ۲ یا ۱ خواهد بود.

هر کدام از درایه‌های $(y_g)_{ij}$ در Y_g را می‌توان به عنوان نگاشتی از یک تابع حقیقی در نظر گرفت طوریکه f_{ij} مجموعه داده‌ی اولیه T_g را به $(y_g)_{ij}$ نگاشت کند. $f_{ij}(T_g) = (y_g)_{ij}$ دیگر عبارت دارد. از این‌رو، مجموعه‌ای شامل توابع حقیقی، به صورت $\{f_{ij} | 1 \leq i \leq m, 1 \leq j \leq d_g\}$ است. از نظر می‌گیریم طوریکه درایه‌های Y_g را به درایه‌های T_g نگاشت کند (در واقع، تابع حقیقی f_{ij} خطوط ۱ تا ۱۱ الگوریتم **PrivacyCL** را بر روی درایه‌ی $(y_g)_{ij}$ اجرا می‌کند). فرض کنید که فقط یکی از درایه‌های ماتریس T_g ، یعنی $(t_g)_{\alpha\beta}$ ، را به اندازه‌ی θ تغییر داده و مجموعه داده‌ی جدید را \tilde{T}_g بنامیم. اگر مجموعه توابع F را به طور مستقل بر روی T_g و \tilde{T}_g اعمال کنیم، در این صورت، ماتریس‌های Y_g به دست آمده برای T_g و \tilde{T}_g ، در تمام درایه‌ها به غیر از درایه‌ی $1 + \left\lfloor \frac{2^s \times \beta}{n} \right\rfloor = \theta$ مقادیر یکسانی را خواهند داشت. مطابق با توضیحات بالا، مقدار تغییر به دست آمده برابر با $\frac{2^s \times \theta}{n}$ خواهد بود که در آن مقدار θ برابر با ۱ یا ۲ است. پس رابطه (۲) را خواهیم داشت.

$$\begin{vmatrix} f_{ij}(T_g) \\ -f_{ij}(\tilde{T}_g) \end{vmatrix} = \begin{cases} 0 & \text{where } i \in \{1, 2, \dots, m\} - \{\alpha\} \text{ and } j \in \{1, 2, \dots, d_g\} \\ -\left\lfloor \frac{2^s \times \beta}{n} \right\rfloor + 1 & \\ \frac{2^s \times \theta}{n} & \text{where } i = \alpha, \\ & j = \left\lfloor \frac{2^s \times \beta}{n} \right\rfloor + 1 \\ & \text{and } (\theta = 2 \text{ or } \theta = 1) \end{cases} \quad (2)$$

بنابراین با استفاده از رابطه (۲) رابطه (۳) را خواهیم داشت داریم:

$$\sum_{f_{ij} \in F} |f_{ij}(T_g) - f_{ij}(\tilde{T}_g)| = \frac{2^s \times \theta}{n}, \quad (3)$$

$$1 \leq i \leq m \text{ and } 1 \leq j \leq d_g$$

از این‌رو، با استفاده از تعریف ۲، حساسیت- L_1 مجموعه توابع F برابر با $S(F) = \frac{2^s \times \theta}{n}$ خواهد شد. پس، با استفاده از قضیه ۱، اگر متغیرهای تصادفی لابلاس با میانگین صفر و دامنه‌ی λ را به خروجی‌های هر تابع حقیقی $f \in F$ اضافه کنیم، در این صورت، الگوریتم **PrivacyCL** خاصیت حریم خصوصی تفاضلی- ϵ خواهد داشت که در آن، مقدار λ از رابطه‌ی زیر محاسبه می‌شود:

کمتر از ابعاد ماتریس T است، ایجاد گردد. در قدم بعدی، ماتریس تصادفی $\Delta_{m \times d}$ که درایه‌های آن دارای توزیع نرمال هستند را ایجاد کرده و آن را با ماتریس $Y_{m \times d}$ جمع می‌کنیم تا مجموعه داده‌ی $P_{m \times d}$ به دست آید.

در نهایت، ماتریس $P_{m \times d}$ را منتشر می‌کنیم تا کاربران از آن استفاده نمایند.

در [۱۲]، ثابت شده است که الگوریتم **PrivateProjection** خاصیت «حریم خصوصی تفاضلی- (ϵ, δ) ^{۵۵}» دارد. در این قسمت ثابت می‌کنیم که الگوریتم پیشنهای، هم حریم خصوصی بالاتر و هم دقت رده‌بندی بهتری نسبت به الگوریتم **PrivateProjection** دارد. لم زیر در مورد الگوریتم **PrivateProjection** در [۱۲] اثبات شده است:

لم ۱: [۱۲]. افکنش تصادفی $R_{n \times d}$ که درایه‌های آن دارای توزیع نرمال با میانگین صفر و واریانس $1/d$ هستند را در نظر بگیرید. اگر در الگوریتم **PrivateProjection** درایه‌های ماتریس تصادفی $\Delta_{m \times d}$ داری توزیع نرمال $N(0, \sigma^2)$ باشند در این صورت **PrivateProjection** خاصیت حریم خصوصی تفاضلی- (ϵ, δ) دارد هرگاه روابط زیر برقرار باشند:

$$\sigma \geq \frac{4}{\epsilon} \sqrt{\ln(1/\delta)}, \quad d > 2(\ln(n) + \ln(2/\delta)),$$

$$\epsilon < \ln(1/\delta) \blacksquare.$$

برای مقایسه الگوریتم ارائه شده با الگوریتم **PrivateProjection** لم زیر را اثبات می‌کنیم.

لم ۲. فرض کنید ماتریس $P_g = Y_g + \Delta_g$ در اثر اعمال الگوریتم **PrivacyCL** بر روی مجموعه داده‌ی T_g به دست آمده باشد که در آن، درایه‌های ماتریس تصادفی Δ_g دارای توزیع لاپلاس با میانگین صفر و دامنه $\frac{2^{s \times \theta}}{n \times \epsilon} = \lambda$ است. در این صورت، انحراف معیار خدشه‌های اضافه شده به ماتریس Y_g از رابطه‌ی زیر پیروی می‌کنند:

$$\sigma \leq \frac{\sqrt{2}}{\epsilon} \blacksquare.$$

در نظر گرفته شده است ولی به نظر می‌رسد که مقادیر انتخاب شده برای ϵ ، بهتر است بیشتر از عدد ۱ نباشد. در این مقاله، مقدار ϵ را عدد یک در نظر گرفته‌ایم. همچنین مقدار پارامتر a برابر با 0.85 در نظر گرفته شده است.

جدول ۲: مشخصات مجموعه داده‌های آزمایش

عنوان مجموعه داده	مشخصه	تعداد رکورد	تعداد کلاس
breast cancer Wisconsin (B.C.W)		۳۱	۲
chess		۳۶	۲
glass		۱۰	۷
habermans survival (H.S)		۳	۲
Ionosphere		۳۵	۲
iris		۴	۳
SCCTS		۶۰	۶
SPECTF		۴۵	۲

جدول ۳، نتایج حاصل از اجرای الگوریتم **PrivacyCL** را بر روی ۲ سایت نشان می‌دهد. در این جدول، اعداد نوشته شده در ستون‌های Par.1 و Par.2 به ترتیب نشان دهنده تعداد مشخصه‌های پخش شده بر روی سایت ۱ و سایت ۲ است.

بیشینه مقدار «دقت رده‌بندی» در ۱۰۰ بار آزمایش است. d_r d_o ، T_{Max} و D.P.# نیز به ترتیب، «تعداد مشخصه مجموعه داده‌ی اصلی»، «تعداد مشخصه مجموعه داده‌ی منتشر شده» و «تعداد مراحل تجزیه توسط موجک هار» و «بیشینه مقدار موجود در مجموعه داده» است. همان‌طوریکه ملاحظه می‌شود، الگوریتم‌های ارائه شده دقت رده‌بندی متناسبی را علاوه بر داشتن خاصیت حریم خصوصی تفاضلی، دارد. بر اساس جستجوهایی که انجام شد، مشخص شد که تا کنون، الگوریتمی در محیط‌های توزیعی برای تبدیل داده‌های اصلی به داده‌های مبتنی بر حریم خصوصی تفاضلی (با هدف رده‌بندی داده‌ها) همراه با کاهش ابعاد داده‌های منتشر شده ارائه نشده است. اکثر الگوریتم‌های ارائه شده در محیط‌های توزیعی برای PPC هیوریستیک‌مبنا بوده و در مقابل دانش پیش‌زمینه کاربران حریم خصوصی داده‌ها را نقض می‌کنند. با این حال، در مرجع [۱۲]، الگوریتم متمنکری به نام **PrivateProjection** ارائه شده است که هم خاصیت حریم خصوصی تفاضلی دارد و هم ابعاد داده‌های اولیه را کاهش می‌دهد. پایه و اساس الگوریتم **PrivateProjection** تبدیلات جانسون-لیندن‌اشتراس [۲۰] است. الگوریتم **PrivateProjection** به این صورت اجرا می‌شود: مجموعه داده‌ی اولیه $T_{m \times n}$ که درایه‌های آن مقادیر بولی $false$ و $true$ (به جای $0, 1$) قرار دارند استفاده کرد) هستند را در نظر بگیرید. ابتدا، ماتریس افکنش^{۵۶} تصادفی R به ابعاد $d \times n$ را ایجاد کرده سپس آن را در مجموعه داده‌ی T ضرب می‌کنیم تا ماتریس $Y_{m \times d}$ که ابعاد آن به مراتب

جدول ۳: نتایج حاصل از اجرای $K\text{-}NN$ و $PrivacyCL$ بر روی دو سایت ($\epsilon = 1$)

مجموعه داده‌ها	تعداد رکوردها در هر سایت				n	T_{Max}	D.P#	بیشینه دقت ردهبندی در آزمایش ۱۰۰
	Par. 1	Par. 2	d_r	در هر سایت				
Breast Cancer Wisconsin ($d_o=31$, $s=0$, $\lambda = 0.03$, $\theta = 1$)	15	16	1	32	911320502	5	0.91	
Chess ($d_o=36$, $s=5$, $\lambda = 0.5$, $\theta = 1$)	18	18	18	64	73	1	0.77	
Glass ($d_o=10$, $s=1$, $\lambda = 0.125$, $\theta = 1$)	5	5	2	16	214	3	1.0	
Habermans survival (H.S) ($d_o=3$, $s=0$, $\lambda = 0.25$, $\theta = 1$)	1	2	1	4	83	2	1.0	
Ionosphere ($d_o=35$, $s=0$, $\lambda = 0.031$, $\theta = 2$)	17	18	14	64	1	6	0.97	
Iris ($d_o=4$, $s=0$, $\lambda = 0.25$, $\theta = 1$)	2	2	1	4	7.9	2	1.0	
SCCTS ($d_o=60$, $s=0$, $\lambda = 0.031$, $\theta = 2$)	30	30	1	64	63.8281	6	0.86	
SPECTF ($d_o=45$, $s=0$, $\lambda = 0.015$, $\theta = 1$)	22	23	1	64	89	6	1.0	

$\sigma \rightarrow \infty$ میل خواهد کرد. به عنوان مثال، فرض کنید که مقدار ϵ و δ به ترتیب برابر با 1 و 0.1 در نظر گرفته شوند. در این صورت، مقدار 5 در الگوریتم $PrivacyCL$ حداقل برابر با $\sqrt{2}$ خواهد شد در صورتی که در الگوریتم $PrivateProjection$ این مقدار حداقل برابر با 6.06 خواهد شد. همچنین نامعادله‌ی چیزیش^{۵۶} [۴۴] بیان می‌کند که $0.75 \cdot 0.4 \cdot \log(n) \leq \delta$ درصد از متغیرهای تصادفی ایجاد شده از یک توزیع احتمالی، در فاصله‌ی دو برابر «انحراف معیار» از مقدار میانگین قرار می‌گیرند. بنابراین، الگوریتم $PrivacyCL$ به مراتب خدشه‌ی کمتری را نسبت به الگوریتم $PrivateProjection$ به داده‌های منتشر شده اضافه خواهد کرد. از طرفی، خدشه‌ی کمتر باعث تغییر کمتری در مقدار فاصله‌ی اقلیدسی خواهد شد. از این‌رو، دقت ردهبندی بهتری را ایجاد خواهد کرد. پس، ردهبندی الگوریتم $PrivacyCL$ به مراتب بهتر از دقت ردهبندی الگوریتم $PrivateProjection$ خواهد شد.

حال دو الگوریتم $PrivateProjection$ و $PrivacyCL$ را بر اساس درجه حریم خصوصی مقایسه می‌کنیم. بر اساس شکل ۲، در الگوریتم $PrivacyCL$ از متغیرهای لایپلاس با میانگین صفر و دامنه‌ی λ ، به منظور ایجاد داده‌های تفاضلی استفاده می‌گردد ولی در الگوریتم $PrivateProjection$ از متغیرهای تصادفی نرمال برای ایجاد داده‌های تفاضلی استفاده می‌شود. اما، متغیرهای لایپلاس، حریم خصوصی داده‌های منتشر شده را در بدترین فرضیات در نظر گرفته شده برای نقض حریم خصوصی، حفظ می‌کند در صورتی که متغیرهای تصادفی نرمال، حالت ملايمتری از فرضیات را در نظر می‌گيرند. ثابت شد که الگوریتم $PrivacyCL$ خاصیت حریم

اثبات: همان‌طوری که قبلاً گفته شد، به منظور اعمال تبدیل موجک هار، داده‌های اصلی در سطح اولیه قرار داده می‌شوند. اما، در سطح اولیه، هنوز تجزیه‌ای صورت نگرفته است از این‌رو، در این سطح، ضرایب تقریب را به جای ضرایب موجک تمام استفاده قرار خواهیم داد. بنابراین، جمع انرژی ضرایب موجک تمام رکوردها در سطح اولیه پایین‌تر به مراتب کمتر از جمع انرژی ضرایب تقریب در سطح اولیه (که همان داده‌های اصلی هستند) خواهد بود. پس حداقل یک بار عمل تجزیه‌ی داده‌ی اصلی با استفاده از تبدیل موجک هار، اجرا شده و در بدترین حالت، ابعاد داده‌ی تبدیل شده نصف ابعاد داده‌ی اصلی خواهد بود. به عبارت دیگر $1 - \log(n) \leq S$ است (S نشان دهنده‌ی سطح توقف تجزیه است). بنابراین نامعادله‌ی $\frac{1}{2} \leq \frac{\epsilon^2}{n}$ را خواهیم داشت. همچنین بیشینه مقدار متغیر θ برابر با 2 است. بنابراین $\frac{1}{n \times \epsilon} \leq \frac{2^S \times \theta}{\lambda} = \lambda$ خواهد شد. از طرفی، واریانس توزیع لایپلاس با میانگین صفر و دامنه‌ی λ برابر با $\lambda^2 = 2\lambda^2$ است. پس، رابطه‌ی $\sigma = \lambda\sqrt{2} \leq \sqrt{\epsilon}$ را به دست خواهیم آورد. ■

اکنون، دو الگوریتم $PrivateProjection$ و $PrivacyCL$ را بر اساس مقدار خدشه‌ی اضافه شده به داده‌های منتشر شده مورد مقایسه قرار می‌دهیم. در الگوریتم $PrivacyCL$ ، مقدار δ برابر با صفر است و برای مقدار ثابتی از ϵ حداقل مقدار δ برابر با $\frac{\epsilon}{\sqrt{2}}$ خواهد شد. در صورتی که در الگوریتم $PrivateProjection$ مقدار δ وابسته به مقدار δ است. مطابق با $\ln(1/\delta) \geq \frac{4}{\epsilon^2} \sqrt{\ln(1/\delta)}$ نامعادله‌ی δ برابر با ϵ است. الگوریتم $PrivateProjection$ برقرار است. بنابراین، اگر برای مقدار ثابتی از ϵ ، مقدار δ به سمت صفر میل کند($0 \rightarrow \delta$)، در این صورت

- [9] C. Dwork, "Differential Privacy," Proceedings of the 33rd International Colloquium on Automata, Languages and Programming (ICALP'06), pp. 1–12, 2006.
- [10] B.C.M. Fung, K. Wang, A.W.C. Fu and P.S. Yu, "Introduction to Privacy-Preserving Data Publishing Concepts and Techniques," Taylor & Francis Group, 2011.
- [11] C. Dwork, F. McSherry, K. Nissim and A. Smith, "Calibrating noise to sensitivity in private data analysis," in TCC, pp. 265–284 2006.
- [12] K. Kenthapadi, A. Korolova, I. Mironov and N. Mishra, "Privacy via the Johnson-Lindenstrauss Transform," CoRR, abs/1204.2606, 2012.
- [13] X. Xiaokui, W. Guozhang, G.Johannes, "Differential Privacy via Wavelet Transforms," IEEE Transactions on Knowledge and Data Engineering 23(8), pp. 1200-1214, 2011.
- [14] A.G. Divanis, V.S. Verykios, "Association Rule Hiding for Data Mining," Springer, 2010.
- [15] Y. Cui, W.K. Wong, and D.W. Cheung, "Privacy-Preserving Clustering with High Accuracy and Low Time Complexity," In Proceedings of the 14th International Conference on Database Systems for Advanced Applications, DASFAA 2009, Brisbane, Australia, 2009.
- [16] S.R.M. Oliveira, and O.R. Zaïane, "Privacy preserving clustering by data transformation," Proc. of the 18th Brazilian Symposium on Databases, Manaus, Amazonas, Brazil, pp. 304–318, 2003.
- [17] W. Du and Z. Zhan, "Using randomized response techniques for privacy-preserving data mining," In Proc. of the 9th International Conf. on Knowledge Discovery and Data Mining (KDD'03), pp. 505–510, 2003.
- [18] Z. Huang, W. Du, and B. Chen, "Deriving Private Information from Randomized Data," In Proceedings of the ACM SIGMOD Conference on Management of Data, Baltimore, Maryland, USA, pp. 37-48, 2005.
- [19] J. Vaidya and C. Clifton, "Privacy-Preserving K-means Clustering over Vertically Partitioned Data," In Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining, pp. 206 – 215, 2003.
- [20] W.B. Johnson and J. Lindenstrauss, "Extensions of Lipschitz Maps into a Hilbert Space," Contemporary Mathematics 26, 189–206, 1984.
- [21] E. Bingham and H. Mannila, "Random Projection In Dimensionality Reduction: Applications To Image And Text Data," In Proceedings of the 7th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 245–250, 2001.
- [22] X.Z. Fern, and C.E. Brodley, "Random projection for high dimensional data clustering: a cluster ensemble approach," In Proc. of the 20th international conf. on machine learning, Washington DC, USA, pp. 102-110, 2003.
- [23] S.R.M. Oliveira and O.R. Zaïane, "A Privacy-Preserving Clustering Approach Toward Secure and Effective Data Analysis for Business Collaboration," Computers & Security 26(1), 81-93, 2007.
- [24] A. Blum, C. Dwork, F. McSherry, and K. Nissim, "Practical Privacy: The SuLQ Framework," In: Proceedings of the 2005 SIGMOD/PODS Conference, pp. 128–138, 2005.
- [25] C. Dwork, and N. Nissim, "Privacy-Preserving Data mining on Vertically Partitioned Databases," In: Proceedings of the 24th Annual International Cryptology Conference Advances in Cryptology (CRYPTO'04), Santa Barbara, California, USA, pp. 528-544, 2004.
- [26] K. Nissim, S. Raskhodnikova, and A. Smith, "Smooth Sensitivity and Sampling in Private Data Analysis," In: Proceedings of the 39th ACM Symposium on the Theory of Computing (STOC'07), pp. 75-84, 2007.

خصوصی تفاضلی- ϵ دارد. از طرف دیگر، مطابق با تعریف ۱، حریم خصوصی تفاضلی- $(\epsilon, 0)$ همان حریم خصوصی تفاضلی- ϵ است. به عبارت دیگر، مقدار پارامتر δ در الگوریتم **PrivacyCL** برابر با صفر است. اما مطابق با لم ۱، در صورتی که مقدار δ در الگوریتم **PrivateProjection** به سمت صفر میل کند ($0 \rightarrow \delta$) در این صورت مقدار d نیز به سمت بینهایت میل خواهد کرد (بر اساس شرط $d > 2(\ln(n) + \ln(2/\delta))$). مقدار d محدود میباشد. به عبارت دیگر، مقدار δ در الگوریتم **PrivateProjection** به هیچ عنوان صفر نخواهد شد. پس در یک مقدار ثابت در نظر گرفته شده برای پارامتر ϵ درجه حریم خصوصی الگوریتم **PrivacyCL** به مراتب بهتر از درجه حریم خصوصی الگوریتم **PrivateProjection** است.

۶- نتیجه‌گیری

حفظ حریم خصوصی داده‌ها در داده‌کاوی یکی از مهم‌ترین بحث‌ها است. روش‌ها و الگوریتم‌های مختلفی برای حفظ حریم خصوصی داده‌ها ابداع شده‌اند. اکثر این الگوریتم‌ها دارای معایب (۱) حریم خصوصی قبل اثباتی ندارند (۲) فرض می‌کنند که افراد مهاجم، دانش پیش‌زمینه کمی نداشتند و داده‌ها دارند و (۳) اغلب روی داده‌های با ابعاد بالا، کارایی کمی دارند. در این مقاله برای رفع این مشکل‌ها از مفهوم حریم خصوصی تفاضلی همراه با تبدیل موجک گستته هار استفاده گردید. علاوه بر اثبات حریم خصوصی تفاضلی الگوریتم ارائه شده، نشان داده شد که الگوریتم ارائه شده بعد داده‌ها را کاهش داده و دقت خوبی در ردیابی داده‌ها دارد.

مراجع

- C.C. Aggarwal and P.S. Yu, "Privacy-Preserving Data Mining: Models and Algorithms" Springer-Verlag, New York, 2008.
- B.C.M. Fung, K. Wang, R. Chen and P.S. Yu, "Privacy-Preserving Data Publishing: A Survey on Recent Developments," ACM Computing Surveys 42(4), Article 14, 2010.
- R. Agawam, R. Srikant, "Privacy-Preserving Data Mining," Proceedings of ACM SIGMOD Conference, pp. 439-450, 2000.
- L. Sweeney "k-Anonymity: A Model for Protecting Privacy," Int. J. Unc. Fuzz. Knowl. Based Syst., 10 (5), pp. 557-570, 2002.
- P. Samarati, L. Sweeney, "Protecting Privacy when Disclosing Information: k-Anonymity and its Enforcement Through Generalization and Suppression," IEEE Symp. on Security and Privacy, pp. 188-199, 1998.
- R.J. Bayardo, R. Agrawal, "Data Privacy through Optimal K-Anonymization," Proceedings of ICDE Conference, pp. 217-228, 2005.
- A. Machanavajjhala, J. Gehrke, and D. Kifer, "L-diversity: Privacy beyond k-anonymity," IEEE ICDE Conference, pp. 24, 2006.
- X. Gu, M. Li, L. Xiong and Y. Cao, "Providing Input-Discriminative Protection for Local Differential Privacy," 2020 IEEE 36th International Conference on Data Engineering (ICDE), pp. 505-516, 2020.

- [37] Z. Li, M. Sun, "Privacy-Preserving Classification of Personal Data with Fully Homomorphic Encryption: An Application to High-Quality Ionospheric Data Prediction," International Conference on Machine Learning for Cyber Security, pp. 437-446, 2020.
- [38] P. Li, J. Li, Z. Huang, CZ. Gao, W.B. Chen, K. Chen, "Privacy-preserving outsourced classification in cloud computing," Cluster Computing, Vol. 21, pp. 277-286, 2018.
- [39] M.R.E. Dishabi, M.A. Azgomi, "Differential privacy preserving clustering in distributed datasets using Haar wavelet transform," Intelligent Data Analysis, vol. 19, no. 6, pp. 1323-1353, 2015.
- [40] R. Canetti, U. Feige, O. Goldreich, and M. Naor, "Adaptively Secure Multi-Party Computation," Proceedings of the 28th Annual Symposium on Theory of Computing (STOC'96), ACM Press, pp. 639-648, 1996.
- [41] C.S. Burrus, R.A. Gopinath, and H. Guo, "Introduction to Wavelets and Wavelet Transforms," A Primer Prentice Hall, 1997.
- [42] H. Zhang, T.B. Ho, Y. Zhang and M.S. Lin, "Unsupervised Feature Extraction for Time Series Clustering Using Orthogonal Wavelet Transform," Journal Informatica 30(3), pp. 305-319, 2006.
- [43] "Machine Learning Repository," URL: <http://archive.ics.uci.edu/ml>, Visited: 2020-05-20.
- [44] D.F. Vysochanskij, and Y.I. Petunin, "Justification of the Three Sigma Rule for Unimodal Distributions," Theory of Probability and Mathematical Statistics 21, 25-36, 1980.
- [27] F. McSherry, "Privacy Integrated Queries: An Extensible Platform for Privacy-Preserving Data Analysis." In: Proceedings of the 2009 SIGMOD/PODS Conference, pp. 19-30, 2009.
- [28] D. Feldman, A. Fiat, H. Kaplan, and K. Nissim, "Private Coresets." In: Proceedings of the 41st Symposium on Theory of Computing (STOC), pp. 361-370, 2009.
- [29] S. Xu, X. Cheng, S. Su, et al., Differentially private frequent sequence mining, IEEE Trans. Knowl. Data Eng. 28 (11), 2016.
- [30] G. Zhou, S. Qin, H. Zhou, et al., A differential privacy noise dynamic allocation algorithm for big multimedia data, Multimedia Tools Appl. (8), pp. 1-19, 2018.
- [31] H. Shen, Z. Lu, A new lower bound of privacy budget for distributed differential privacy, in: proceedings of International Conference on IEEE Parallel and Distributed Computing, Applications and Technologies, pp. 25-32, 2018.
- [32] Q. Wang, Y. Zhang, X. X. Lu, Z. Wang, Real-time and spatiotemporal crowd-sourced social network data publishing with differential privacy, IEEE Trans. Dependable Secure Comput. 15 (4), 2018.
- [33] L. Ou, Z. Qin, S. Liao, T. Li, and D. Zhang, "Singular spectrum analysis for local differential privacy of classifications in the smart grid," IEEE Internet of Things Journal, 2020.
- [34] Sun, X., Xu, R., Wu, L. et al. A differentially private distributed data mining scheme with high efficiency for edge computing. J Cloud Comp 10, 7, 2021.
- [35] S. Mukherjee, et al, "A privacy preserving technique for distance-based classification with worst case privacy guarantees," Data & Knowledge Engineering, 66, pp. 264-288, 2008.
- [36] W. Fan, J. He, M. Guo, P. Li, Z. Han, R. Wang, "Privacy preserving classification on local differential privacy in data centers," Journal of Parallel and Distributed Computing, Vol. 135, pp. 70-82, 2020.

²⁹ rotation

³⁰ known input-output

³¹ high correlation

³² Eigen-analysis attack

³³ Yao

³⁴ multiplicative perturbation

³⁵ Johnson-Lindenstrauss

³⁶ random projection

³⁷ independent and identically distributed

³⁸ differential privacy

³⁹ sub-linear query

⁴⁰ generic sampling-based procedure

⁴¹ privacy integrated queries

⁴² frequent sequence mining

⁴³ multi-media

⁴⁴ spatial data space

⁴⁵ smart grid

⁴⁶ Edge computing

⁴⁷ malicious model

⁴⁸ semi-honest

⁴⁹ party

⁵⁰ third party

⁵¹ Haar wavelet transform

⁵² synthetic

⁵³ public

⁵⁴ projection matrix

⁵⁵ (ϵ, δ) -differential privacy

⁵⁶ Chebychev's inequality

¹ Privacy Preserving Data Mining (PPDM)

² Privacy Preserving Data Publishing

³ Randomization

⁴ K-Anonymity

⁵ L-Diversity

⁶ Transformation Methods

⁷ Privacy Preserving Classification

⁸ adversary

⁹ background knowledge

¹⁰ heuristic

¹¹ differential privacy

¹² wavelet analysis

¹³ wavelet transform

¹⁴ multi-resolution analysis

¹⁵ Mallat & Meyer

¹⁶ smooth background

¹⁷ fluctuation

¹⁸ data set

¹⁹ attribute

²⁰ L_1 -sensitivity

²¹ protocol-based approach

²² transformation-based approach

²³ secure multi-party computation

²⁴ Oliveira

²⁵ Zaianc

²⁶ geometric transformation

²⁷ shift

²⁸ scaling