



Investigating the Challenges of Arranging a Data Mining Service in the Field of Health Information Systems

Mohammad Hassan Zarezade¹, Raouf Khayami²

¹ Master student, Department of Computer Engineering and Information Technology, Shiraz University of Technology, Shiraz

mammad1845@gmail.com

² Assistant professor, Department of Computer Engineering and Information Technology, Shiraz University of Technology, Shiraz
khayami@sutech.ac.ir

Abstract

The knowledge of data mining is one of the developing and superior knowledge in the world. This knowledge has been used in various fields such as commerce, electricity, industry and etc. one of the most essential usage of this knowledge is in the health sector that nowadays it has paid special attention to it. In this research we tried to review the following challenges of data mining in health and to accomplish a complete and exhaustive study in this field. at the first, in this research, the literature on the subject and the basic concepts are discussed. Undeniably, any new knowledge will have drawbacks and issues in the beginning and will also produce challenges that will lead the way for further research in this case and also, help to advance this field to enhance and complete it in the future, which will point to several important and vital challenges ahead for the conduct of data mining techniques in the health information system (HIS) including data quality, holding privacy and etc. and then, some of completed works on the challenges and issues will be presented.

Keywords: Data Mining, Health Information System, Data Quality, Privacy



بررسی چالش‌های استقرار سرویس داده کاوی در حوزه سیستم‌های اطلاعات سلامت

* محمد حسن زارع زاده^۱، رئوف خیامی^۲

^۱ دانشجوی کارشناسی ارشد، گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی شیراز، شیراز، mammad1845@gmail.com

^۲ استادیار، گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی شیراز، شیراز khayami@sutech.ac.ir

چکیده

دانش داده کاوی یکی از دانش‌های در حال توسعه و برتر جهان است. این دانش در حوزه‌های مختلفی هم چون تجارت، برق، صنایع و... نیز به کار گرفته شده است. یکی از مهم‌ترین کاربردهای این دانش دربخش بهداشت و درمان نیز می‌باشد که امروزه توجه ویژه‌ای به آن شده است. در این تحقیق سعی شده که مرواری بر چالش‌های پیش رو داده کاوی در بهداشت و درمان صورت پذیرد و بررسی کامل و جامعی در این زمینه انجام گیرد. در ابتدا در این تحقیق به ادبیات موضوع و مفاهیم اولیه پرداخته می‌شود. بدیهی است هر دانش نوین و نوپایی در ابتدای امر معایب و مشکلاتی به همراه خواهد داشت و چالش‌هایی را نیز به وجود می‌آورد که خود زمینه ساز تحقیقات بیشتر در این مورد خواهد شد و همچنین کمک به پیشرفت این حوزه جهت بهبود و تکمیل آن در آینده نیز خواهد کرد، که اشاره به چندین چالش مهم و حیاتی پیش رو برای اجرای تکنیک‌های داده کاوی در سیستم اطلاعات سلامت (HIS) از جمله کیفیت داده‌ها، حفظ حریم خصوصی و... خواهد شد. و سپس برخی از کارهای انجام شده در زمینه چالش‌ها و مشکلات مطرح شده ارائه خواهد شد.

کلمات کلیدی

داده کاوی، سیستم اطلاعات سلامت، کیفیت داده‌ها، حفظ حریم خصوصی

داده‌های بهداشتی با افزایش عملکرد و ظایف مربوط به مدیریت بیمار، مراقبت‌های بهداشتی بیماران را بهبود می‌بخشد [1].

تمامی مؤسسات مراقبت‌های بهداشتی نیاز به تجزیه و تحلیل تخصصی داده‌های پزشکی خود دارند، که این کار زمانبند و پرهزینه است. توانایی استفاده از داده‌ها در پایگاه‌های داده به منظور استخراج اطلاعات مفید برای مراقبت‌های بهداشتی با کیفیت، رمز موقفيت مؤسسات مراقبت‌های بهداشتی است [2]. در این زمان صحبت از داده کاوی به میان خواهد آمد که می‌تواند حجم گستردگی از داده‌ها را مورد تحلیل قرار دهد. برای بدست آوردن نتایج مطلوب بايستی دانش و اطلاعات کافی از الگوریتم‌های مختلف داده کاوی را دارا بود. از جمله این روش‌ها و تکنیک‌ها که در سیستم‌های HIS به کار گرفته شده می‌توان به: خوشبندی، طبقه‌بندی، درخت تصمیم، K-

- نزدیک‌ترین همسایه و... اشاره کرد.

۱- مقدمه

سازمان‌های مراقبت بهداشتی که با مشکل حجم زیاد داده‌ها برای ذخیره‌سازی و هزینه‌های سنگین نگهداری رو به رو بودند، امروزه با استفاده از سیستم‌های اطلاعات سلامت (HIS) که حجم عظیمی از داده‌ها اعم از داده‌های بیماران، پزشکان و... در آن ذخیره می‌شود، برطرف گردیده است. در این سیستم، داده‌ها با روش‌هایی همچون سوابق بیمه، نظر سنجی توسط بیماران، پرونده‌های الکترونیک سلامت^۱ (EHR) و... جمع‌آوری می‌شود. داده‌های جمع‌آوری شده حاوی اطلاعات ارزشمندی است که با تجزیه و تحلیل مناسب می‌توان آن‌ها را استخراج نمود. همچنین تجزیه و تحلیل



۳- داده کاوی

اندازه داده‌ها به طور کلی روز به روز در حال رشد است. اکنون نیاز به درک مجموعه داده‌های بزرگ، پیچیده و غنی شده با اطلاعات در زمینه‌های مختلف از جمله فناوری، تجارت و علوم افزایش یافته است [7]. برای ذخیره چنین حجم زیادی از داده‌ها یا اطلاعات، اندازه پایگاه‌های داده به سرعت افزایش می‌یابد. این پایگاه‌ها اطلاعات بسیار مفیدی دارند که ممکن است برای فرایند تصمیم‌گیری در هر زمینه‌ای بسیار مفید باشد. این کار با کمک داده کاوی یا دانش در پایگاه داده^{*} (KDD) امکان پذیر است [8]. تعاریف مختلفی از اصطلاح داده کاوی وجود دارد. یکی از پر کاربردترین تعاریف بیان می‌کند که "داده کاوی تجزیه و تحلیل مجموعه داده‌های مشاهده‌ای (غالباً بزرگ) برای یافتن روابط نامشخص و جمع‌بندی داده‌ها به روش‌های جدید است که برای صاحب داده قابل فهم و مفید باشد" [9].

۴- اهداف داده کاوی در HIS

داده کاوی به طور عملده الگوهای معنی داری را که قابل شناسایی نبودند، استخراج می‌کند. سپس این الگوها می‌توانند با دانش ادغام شده و به کمک این دانش تصمیمات اساسی گرفته شود.

همچنین تکنیک‌های داده کاوی در حوزه بهداشت و درمان بسیار مفید هستند. آنها خدمات پژوهشی بهتری را به بیماران ارائه می‌دهند و در تصمیمات مختلف مدیریت پژوهشی به سازمانهای بهداشتی کمک می‌کنند. برخی از خدمات ارائه شده توسط تکنیک‌های داده کاوی در مراقبت‌های بهداشتی عبارتند از: تعداد روزهای اقامت در بیمارستان، رتبه‌بندی بیمارستان‌ها، درمان‌های موثرتر، ادعاهای بیمه کالا‌بهرداری توسط بیماران و همچنین ارائه دیهندگان، بستری مجدد بیماران، شناسایی روش‌های درمانی بهتر برای گروه خاصی از بیماران، ساخت سیستم‌های توصیه داروی مؤثر و ... با توجه به همه این دلایل، محققان بسیار تحت تأثیر قابلیت‌های داده کاوی قرار دارند [8].

۳- چالش‌های داده کاوی در HIS

۱- مقدمه

استفاده از داده کاوی در زمینه پژوهشی به دلیل ویژگی‌های خاص حرفه پژوهشی اقدامی بسیار چالش برانگیز است [6]. برخی تحقیق‌ها در زمینه چالش‌های استفاده از تکنیک‌های داده کاوی در HIS صورت گرفته است. همچنین این موضوع از صحنه‌های مختلف با چالش رو به رو است.

به طور کلی، مهمترین چالش‌هایی که باعث شده داده کاوی در برنامه‌های مراقبت‌های بهداشتی با سایر برنامه‌ها متفاوت باشد، موارد زیر است:

باید توجه داشت که داده کاوی در بهداشت یک حرکت نوپا است و به همین دلیل با موانع و چالش‌های متعددی رو به رو شده و برای عملکرد بهینه آن در حوزه بهداشت و درمان بایستی به این موانع توجه ویژه‌ای شود تا بتوان با صرف وقت و هزینه کمتری به نتایج مطلوبی رسید.

۲- مروری بر ادبیات موضوع

۱- تعریف HIS

امروزه، استفاده گسترده از فناوری‌های اطلاعات و ارتباطات^{*} (ICT) تقریباً در همه جنبه‌های زندگی از جمله بخش مراقبت‌های بهداشتی نفوذ کرده است. HIS برای استفاده کامل به خصوص از اینترنت در ارائه خدمات بهداشتی بهتر معرفی شد. HIS اغلب به تعامل بین مردم، فرآیند و فناوری برای پشتیبانی از عملیات و مدیریت در ارائه اطلاعات ضروری به منظور بهبود کیفیت خدمات بهداشتی و درمانی اشاره دارد. هدف HIS بهبود کیفیت مراقبت از بیمار است [3].

HIS زمینه‌های تصمیم‌گیری را فراهم می‌کند و دارای چهار عملکرد اصلی است: تولید داده، گردآوری، تجزیه و تحلیل، سنتر، برقراری ارتباط و استفاده. HIS داده‌ها را از بخش بهداشت و سایر بخش‌های مربوط جمع‌آوری می‌کند، سپس داده‌های جمع‌آوری شده را تجزیه و تحلیل کرده و پس از اطمینان از کیفیت، ارتباط و به موقع بودن آنها، داده‌ها جهت تصمیم‌گیری در ارتباط با سلامت، به اطلاعات تبدیل می‌کنند [4]. HIS به طور گسترده در سازمان‌های مراقبت‌های بهداشتی مورد استفاده قرار می‌گیرد تا از پردازش داده‌های متدال از جمله صور تحساب بیمار، حسابداری، کنترل موجودی، محاسبه آمار و نگهداری سابقه بیمار پشتیبانی کند. [5].

۲- چالش HIS

در سال ۱۸۵۴ جان اسنو که پدر اپیدمیولوژی مدرن محسوب می‌شود، با استفاده از نمودارهایی توانست مکان انتقال وبا را که از طریق منبع آب بود پیدا کند. اسنو تعداد مرگ‌های ناشی از وبا را شمرد و آدرس قربانیان را روی نقشه لندن به عنوان میله‌های سیاه طراحی کرد. وی کشف کرد که بیشتر مرگ‌ها به سمت یک پمپ آب خاص در لندن جمع شده است. اسنو قادر بود شخصاً داده‌ها را در زمان خود جمع‌آوری و تجزیه و تحلیل کند زیرا حجم اطلاعات قبل کنترل بود. امروزه با توجه به اندازه جمیعت، حجم داده‌ها و سرعت شیوع بیماری، تحقق کاری که اسنو انجام داده تقریباً غیرممکن است. اینجاست که داده کاوی برای مراقبت‌های بهداشتی مفید می‌شود ... [6].



اطمینان حاصل کند که شامل اصطلاحات مربوط به هستی‌شناسی است. سپس با اختساب نمرات داده شده به پست هر کاربر ارزیابی کیفیت صورت گرفت. در جدول (۱) خلاصه کارهای صورت گرفته در زمینه حل مشکلات کیفیت داده‌ها آورده شده است.

۳-۳-اشتراک و حریم خصوصی داده‌ها:

کیفیت داده‌ها به عوامل مختلفی از جمله حذف داده‌های پرسرو صدا، داده‌های از دست رفته و ... بستگی دارد. برای حفظ کیفیت در داده‌های مراقبت‌های بهداشتی باید تمام اقدامات لازم انجام شود. اشتراک داده‌ها یک چالش مهم دیگر است. نه بیماران و نه سازمانهای بهداشتی علاقه‌ای به اشتراک اطلاعات خصوصی خود ندارند. همچنین حریم خصوصی سوابق و استفاده اخلاقی از اطلاعات بیمار نیز یکی از موانع بزرگ در داده کاوی در مراقبت‌های بهداشتی است. برای اینکه داده کاوی دقیق‌تر باشد، به تعداد قابل توجهی از سوابق واقعی نیاز دارد. سوابق بهداشتی اطلاعات خصوصی هستند و با این حال، استفاده از این پرونده‌های خصوصی ممکن است به جلوگیری از بیماری‌های کشنده کمک کند [6].

برای اینکه بتوانید به داده‌های بهداشتی مورد نیاز برای تجزیه و تحلیل دسترسی پیدا کنید، باید پروتکلهای امنیتی کافی در سایت انبار داده اجرا شود، تا تحلیلگران بتوانند برای اجرای تجزیه و تحلیل مورد نیاز، به داده‌ها برسند. اگرچه اجرای این پروتکلهای امنیتی ممکن است آزاردهنده باشد، اما وجود آنها برای هم محافظت از حریم خصوصی بیماران تا آنجا که ممکن است و هم به تحلیلگران امکان دسترسی به داده‌ها برای انجام تجزیه و تحلیل خواهد داد، می‌تواند کمک کننده باشد [10].

یک سری تکنیک وجود دارد که ضمن حفظ اطلاعات کاربران می‌توان از داده‌ها داشت کسب کرد که موسوم به PPDM (Privacy Preserving Data Mining) است و در جدول (۲) آورده شده است. دسته‌بندی های زیادی برای PPDM وجود دارد اما یکی از این دسته‌بندی‌ها مربوط به کرسو و همکاران [17] است که تکنیک‌ها به ۵ دسته کلی تقسیم‌بندی شده‌اند:

ناشناس‌سازی داده‌ها. نیکوچ و همکاران [18] با استفاده از تکنیک ناشناس‌سازی منبع یک طرح جهت حفظ حریم خصوصی در جمع‌آوری و استخراج اطلاعات از داده‌های EHR ارائه دادند. طرح مورد نظر داده‌ها را بدون از دست رفتن هیچ یک از اطلاعات از تمامی سیستم‌های EHR جمع‌آوری کرده و در یک سرور مرکزی ذخیره می‌کند و سپس به تجزیه و تحلیل داده‌ها بدون درگیر شدن EHR‌ها می‌پردازد. در ناشناس‌سازی این نکته حائز اهمیت است که باید توجه داشت میزان ناشناس‌سازی آنقدر زیاد نباشد که دیگر داده‌ها کیفیت اولیه خود را نداشته باشند و مناسب برای تجزیه و تحلیل نباشند. بنابراین ایجاد تعادل بین ناشناس‌سازی امری ضروری و مهم برای محافظت از حریم خصوصی در داده‌ها تحلیلی است [10].

اغتشاش داده‌ها. چامیکارا و همکاران [19] جهت حفظ حریم خصوصی در سیستم‌های فیزیکی سایبری هوشمند چارچوب SEAL را بر

۲-۳-کیفیت داده‌ها

اولین چالش و شاید مهم‌ترین چالش پیش رو این است که برای دستیابی به اطلاعات مفید و قابل اعتماد از فرآیند داده کاوی، به داده‌هایی با کیفیت خوب نیاز است [10]. کیفیت داده را می‌توان با تعدادی از ابعاد ارزیابی کرد؛ کامل بودن، اعتبار، انسجام [11]. جاستین و همکاران [12] معیارها و استانداردهای کیفیت داده را از طریق یک جلسه گروهی با مدیران تعیین کرده سپس معیارهایی بددست آمده را با استفاده از رگرسیون لجستیک دو جمله‌ای پیاده‌سازی کرده‌اند تا همبستگی‌ها و ارتباطات بین معیارها مشخص گردد.

داده‌های بهداشتی معمولاً از پایگاه داده‌های مختلف با طراحی‌های کاملاً متفاوت جمع‌آوری می‌شوند که باعث شده داده‌ها پیچیده، کثیف، دارای تعداد زیادی داده از دست رفته و استانداردهای کدگذاری متفاوت برای زمینه‌های مشابه باشند [13]. اگر یک ارائه دهنده خدمات بهداشتی، به عنوان مثال یک بیمارستان به منظور تجزیه و تحلیل داده‌ها اقدام به جمع‌آوری داده‌ها می‌کند، بایستی یک سری چارچوب‌ها و روش‌ها برای به دست آوردن اطلاعات مفید جهت بهبود کیفیت خدمات و کارآمد ساختن هزینه‌های آنها تعریف کند. این امر به طراحی پایگاه داده بسیار انعطاف‌پذیر و مقیاس‌پذیر برای هر واحد نیاز دارد که هر زمان لازم باشد به راحتی بتوان به آن متصل شد و از همان استانداردها برای وارد کردن داده‌ها استفاده کند [10]. آنجلینا و همکاران [14] با استفاده از داده‌های موجود در پایگاه داده MIMIC-III که از کیفیت بالا و همچنین دسترسی آزاده بخوردار است برای ارزیابی کیفیت داده‌ها بهره برند. آنها برای ارزیابی از چرخه استفاده کرده که شامل ۵ مرحله اصلی بوده: برنامه‌ریزی - ایجاد یک مدل کنترل جریان و اتصال آن به گزارش رویداد - ایجاد یک مدل فرآیند یکپارچه - پشتیبانی. آن‌ها بین مرحله اول و دوم یعنی برنامه‌ریزی و استخراج یک مرحله جدید به منظور آماده‌سازی MIMIC-III جهت عملیات فرآیند کاوی، افزودند این مرحله که بازسازی پایگاه داده مذکور است باعث می‌شود مرحله ۱ تا ۳ به تعداد دفعات مورد نیاز جهت بهبود کیفیت داده‌ها تکرار شود. رابرت و همکاران [15] یک رویکرد فرآیند محور و مبتنی بر کیفیت داده‌ها که برگرفته شده از (Cross Industry Standard Process for Data Crisp-DM) است ارائه دادند. آن‌ها با استفاده از روش پیشنهادی مشکلات Mining) که بازسازی پایگاه داده مذکور است باعث می‌شود مرحله ۱ تا ۳ به تعداد دفعات مورد نیاز جهت بهبود کیفیت داده‌ها تکرار شود. رابرت و همکاران [16] یک رویکرد فرآیند محور و مبتنی بر کیفیت داده‌ها که برگرفته شده از (Cross Industry Standard Process for Data Crisp-DM) است ارائه دادند. آن‌ها با استفاده از روش پیشنهادی شامل ۴ فاز بود: کشف و تشخیص موضوع - جمع‌آوری داده‌ها - آماده‌سازی داده‌ها ارزیابی کیفیت - تجزیه و تحلیل و نتایج. آن‌ها برای بررسی کیفیت داده‌ها از یک ماتریس تجزیه و تحلیل که داده‌های پردازش شده انجام دادند. طارق و همکاران [16] برای کاهش محدودیت‌های مربوط به تشخیص موضوع و کیفیت داده‌ها یک چارچوب پیشنهاد دادند. چارچوب پیشنهادی شامل ۴ فاز بود: کشف و تشخیص موضوع - جمع‌آوری داده‌ها - آماده‌سازی داده‌ها ارزیابی کیفیت - تجزیه و تحلیل و نتایج. آن‌ها برای بررسی کیفیت داده‌ها از یک ماتریس تجزیه و تحلیل که داده‌های پردازش شده انجام دادند. طارق و همکاران [16] ماتریس مربوطه، پست هر کاربر را در مجموعه داده‌ها بررسی می‌کند تا

جدول (۱): خلاصه کارهای صورت گرفته در زمینه کیفیت داده ها

منبع	هدف از انجام	الگوریتم(های) استفاده شده	مجموعه داده(ها)	محققین (سال انتشار)
[12]	بررسی کیفیت داده های تعاملی بین به موقع بودن، اعتبار، کامل بودن و میزان استقاده میان کاربران مراقبت های اولیه	logit binomial regression (LBR)	شامل ۱۹۶۹۶۷ برخورد فردی با بیمار از پایگاه داده ایزاز گزارش متی بر وب	جاستین و همکاران (۲۰۱۷)
[14]	ارزیابی کیفیت داده های فرآیند کاوی مراقبت های بهداشتی با استفاده از MIMIC-III	-	۴۶۵۲۰ بیمار از پایگاه داده Medical Information Mart for Intensive Care III (MIMIC-III)	آنجلینا و همکاران (۲۰۱۹)
[15]	توسعه یک رویکرد فرآیند محور و مبتنی بر کیفیت داده های برای آماده سازی جهت تجزیه و تحلیل فرآیند کاوی با استفاده از روش Crisp-DM	-	Queensland پایگاه داده های Ambulance Service و (QAS) Retrieval Services Queensland (RSQ)	راابت و همکاران (۲۰۱۹)
[16]	توسعه و ارزیابی جارچویی برای استخراج و تجزیه و تحلیل محتوای رسانه های اجتماعی در ارتباط با سو مصرف مواد مخدر به منظور کاهش محدودیت های مربوط به کیفیت داده ها و تشخیص موضوع	Natural Language Processing (NLP)	-	طارق و همکاران (۲۰۲۰)

PPDARM، برای حفظ حریم خصوصی اطلاعات بیماران و بالا بردن دقیقت نتایج قوانین و استنگی در داده های تقسیم بندی شده افقی به کار گرفته شده است. آنها در پژوهشی دیگر [26] به جای استفاده از داده های تقسیم بندی شده افقی از داده های تقسیم بندی شده عمودی برای کشف همبستگی مربوط به بیماری و حفظ حریم خصوصی بیماران استفاده کردند.

شبکه عصبی. مانیکندان و همکاران [27] برای تولید کردن سرو صدا جهت حفظ حریم خصوصی داده های بهداشتی از شبکه عصبی پیش خور استفاده کردند. آنها شبکه تولید شده که از سه لایه ورودی، پنهان، خروجی تشکیل می شود را به کمک الگوریتم پس انتشار طراحی کردند. سپس ورودی های شبکه با استفاده از الگوریتم پس انتشار به خروجی داده می شوند. خروجی حاصل با مقدار هدف مقایسه می شود. اگر هدف و خروجی بدست آمده یکسان باشد، خروجی به عنوان سرو صدا در نظر گرفته می شود. در صورت تناقض، مقدار خروجی دوباره به لایه مخفی انتشار می یابد. وزن ها در لایه پنهان تنظیم و پردازش می شوند. سپس مقدار به لایه خروجی ارسال می شود و دوباره همان روند ادامه می یابد تا زمانی که هدف و مقدار بدست آمده یکسان شوند. **وانگ و همکاران [28]** چارچوب (privacy- PPDP) برای ایجاد یک سیستم پیش بینی بیماری با حفظ حریم خصوصی داده های بهداشتی پیشنهاد کردند. چارچوب پیشنهادی با کمک الگوریتم یادگیری پرسپترون تک لایه پیاده سازی می شود.

۴- از دست دادن اطلاعات در پیش پردازش:

پیش پردازش داده ها، از جمله مدیریت داده های از دست رفته، یک از پر هزینه ترین و زمان بترین قسمت های فرآیند داده کاوی است. متداول ترین روش مورد استفاده در مقاله های بررسی شده نادیده گرفتن یا حذف داده های از دست رفته بود. در یک مطالعه، تقریباً ۳۳٪ از داده ها و ۲۳ پرونده از ۱۳۳

اساس درون یابی چیشیف پیشنهاد کردند. نتایج نشان دهنده آن بود که SEAL در حفظ حریم خصوصی داده های بزرگ و جریانی طبقه بندی شده عملکرد خوبی دارد.

رمزنگاری. شو و همکاران [20] چارچوبی برای حفظ حریم خصوصی با طراحی سه پروتکل به کمک رمزنگاری هم ریختی پیشنهاد دادند. که پروتکل اول برای بهینه سازی عملکرد استخراج و پروتکل دوم و سوم برای بالا بردن تضمین حریم خصوصی طراحی شدند. سین جی و همکاران [21] مدل DAG را برای حفظ حریم خصوصی با استفاده از محاسبات چند جانبه امن (SMC^۰) پیشنهاد دادند. یانگ و همکاران [22] برای پیش بینی خطر ابتلاء به بیماری طرح EPDP را پیشنهاد دادند. EPDP شامل سه مرحله: مقدار دهی اولیه - آموزش مدل و پیش بینی مدل است، که با رمزنگاری هم ریختی پیاده سازی می شود. وانگ و همکاران [23] یک طرح یادگیری مشترک با حفظ حریم خصوصی به نام PCML اجرا کردند که یک مدل تشخیصی برای بهبود نتایج پیش بینی بیماری در سرویس های تشخیص پزشکی اینلاین است. PCML عمده از چهار مرحله تشکیل شده است: (۱) مقدار دهی اولیه (۲) رمز گذاری مدل تشخیص محلی (۳) یادگیری مدل مشارکتی (۴) نتیجه یادگیری مشارکتی. همچنین به طور خاص، قبل از ارسال به ابر، همه مدل های تشخیص محلی توسط صاحب آنها رمز گذاری شده و بدون رمزگشایی در طی فرایند یادگیری مدل مشارکتی محاسبه می شوند. عبدالکرم و همکاران [24] طرح پیشنهادی (PPCDSS) را ارائه دادند. طرح مورد با استفاده از الگوریتم پیشنهادی (PPSDT) و با به کار گیری رمزنگاری هم ریختی جهت تولید مدل طبقه بندی سیستم DSS بدون اشتراک گذاری داده ها پیاده سازی شده است.

منطق فازی. نیکونج و همکاران [25] روشی برای ادغام سیستم های HER محلی بدون اشتراک گذاری داده ها ارائه کردند. این روش موسوم به



جدول (۲): تکنیک‌های PPDM

منبع	توضیحات روش پیشنهادی	هدف از انجام	مجموعه داده(ها)	نام طرح	محققین (سال انتشار)	تکنیک
[18]	طرح پیشنهادی داده‌ها را از تمام سیستم‌های EHR بدون هیچ گونه از دست دادن اطلاعات جمع‌آوری کرده و در یک سرور داده کاوی مرکزی ذخیره می‌کند. سرور می‌تواند هر تکنیک داده کاوی را که توسط محققان پژوهشکار با پژوهشکار بر روی داده‌های جمع‌آوری شده مراقبت‌های بهداشتی انتخاب شده است. برای کشف الگوهای دقیق مراقبت‌های بهداشتی اجرا کند.	بهبود خدمات مراقبت‌های بهداشتی با حفظ حریم خصوصی به کمک روش منبع ناشناس	مجموعه داده بیماری‌های قلبی شامل ۳۰۳ پرونده بیمار از پایگاه UCI داده	-	نیکونج و همکاران (۲۰۲۰)	ناشناس‌سازی داده‌ها
[19]	یک سیستم اغتشاش خطی که بر اساس درون یابی چند جمله‌ای چیزیف ساخته شده است. و شامل سه مرحله جهت پردازش داده‌ها است: تعیین حساسیت مجموعه داده - هدایت درون یابی چند جمله با سروصدای کالبیره شده - تولید داده‌های اغتشاشی به کمک تابع تقیی.	طراطی الگوریتم SEAL برای حفظ حریم خصوصی در سامانه فیزیکی-سایبری هوشمند	UCI	(SEAL)	چامپکارا و همکاران (۲۰۱۹)	اغتشاش داده‌ها
[20]	ایجاد یک چارچوب جهت حفظ حریم خصوصی با طراحی سه پروتکل به کمک رمزگذاری همیختی. پروتکل اول برای بهینه‌سازی عملکرد استخراج و پروتکل دوم و سوم برای بالا بردن تضمین حریم خصوصی طراحی شدند.	حفظ حریم خصوصی در استخراج مجموعه اقلام مکرر بر روی داده‌های این رمزگذاری شده	-	-	شو و همکاران (۲۰۱۷)	
[32]	در مدل مورد نظر از سه پروتکل استفاده شده است: ۱- شباهت بین موارد توسط پروتکل اول ایجاد می‌شود ۲- محاسبه طول بردار موارد را پروتکل دوم انجام می‌دهد ۳- پیش‌بینی ها توسط پروتکل سوم تولید می‌شود.	حفظ حریم خصوصی در سیستم‌های توصیه گر مراقبت‌های بهداشتی به کمک پالایش گروهی	۱- داده‌های مراقبت‌های بهداشتی ۱۰۰۰۰ بیمار از ۵۰۰ پژوهشکار ۲- مجموعه داده MovieLens شامل ۹۴۳ کاربر برای فیلم ۱۶۸۲	(PPCF)	کاور و همکاران (۲۰۱۸)	
[21]	مدل مورد نظر شامل ۷ عملگر پایه است و دارای سه نوع گره است: منبع که ورودی مدل، سینک که خروجی مدل و عملگر هم ۷ عملیات پایه است. همچنین مدل با کمک پروتکل SMC طراحی شده است	ایجاد چارچوبی برپایه SMC برای حفظ حریم خصوصی	دو مجموعه داده از UCI اولی شامل ۱۵۹۸ تاپل و دومی ۲۸۰،۰۴۹ تاپل	(DAG)	سین جی و همکاران (۲۰۱۸)	
[22]	سیستم دارای دو مرحله است یکی آموزش مدل و دیگری پیش‌بینی مدل که هر دو از راه دور انجام می‌شود. در مرحله آموزش مدل از طبقه‌بندی کننده بیز ساده استفاده شده است. سپس در مرحله پیش‌بینی با استفاده از داده ساختار فیلتر بولون به تشخیص بیماری بیماران کمک می‌کند.	ارائه طرح EPDP چهت پیش‌بینی بیماری در مراقبت‌های بهداشتی با حفظ حریم خصوصی	مجموعه داده AID شامل ۱۲۰ نمونه از پایگاه UCI و مجموعه ۵۰۰ داده ترکیبی تولید شده از تاپل	(EPDP)	یانگ و همکاران (۲۰۱۹)	رمزگذاری
[23]	در اینجا پارامترهای سیستم توسط مرجع قابل اعتماد تولید شده سپس با استفاده از سیستم رمزگذاری کلید عمومی PK و خصوصی SK محاسبه شده و کلید SK را به چند قسمت برای مراکز بهداشتی و سرور ابری تقسیم می‌کند. سپس مراکز بهداشتی مدل‌های تشخیص خود را رمزگذاری کرده و به سرور ارسال می‌کنند و سرور پس از محاسبات، نتایج بدست امده را به مراکز بهداشتی ارسال کرده و	بهبود نتایج پیش‌بینی بیماری در سرویس‌های تثخیص پژوهشکار اینلاین با حفظ حریم خصوصی	مجموعه داده بیماری تبروئید با ۳۱۷۵ مورد و مجموعه داده بیماری‌های قلب با ۸۹۸ مورد	(PCML)	وانگ و همکاران (۲۰۱۹)	

	آنها بعد از رمزگشایی می‌توانند مدل تشخیصی را بدست آورند				
[24]	مدل مورد نظر بر اساس الگوریتم پیشنهادی PPSDT است که از ترکیب الگوریتم C4.5 با رمزگاری همیختی paillier به وجود می‌آید	طبقه‌بندی علائم بیماران در سیستم پیش‌بینی مجموعه داده التهاب حاد از پایگاه داده UCI	(PPCDSS)	عبدالکرم و همکاران (۲۰۱۹)	
[25]	رویکرد مورد نظر حداقل به سه شرکت کننده نیاز دارد. فرض بر این است که کانال‌های ارتباطی بین شرکت کنندگان نامن هستند، هر دشمن می‌تواند تمام ارتباطات بین شرکت کنندگان را ذخیره کند تا p-value برخی دیگر از شرکت کنندگان را بیاموزد. برای جلوگیری از این مشکل از الگوریتم محاسباتی دیفی هلمن ⁹ (CDH) استفاده شده است. روش پیشنهادی براساس این فرض که حل مسئله CDH از نظر محاسباتی سخت است، این است.	حل مشکل استخراج قوانین و استنتاج بدون اشتراک گذاری داده‌های محلی EHR	مجموعه داده‌های بیماری‌های قلبی UCI شامل ۳۰۳ بیمار	(PPDARM)	نیکونج و همکاران (۲۰۱۸) منطق فازی
[26]	-	حفظ حریم خصوصی در هنگام اشتراک گذاری داده‌های بهداشتی جهت یکپارچه‌سازی سیستم EHR	پایگاه داده معاینه سلامت یک بیمارستان محلی در تایوان شامل ۱۲۲۶۵۸ مورد	-	نیکونج و همکاران (۲۰۱۹)
[27]	ورودی‌های شبکه با استفاده از الگوریتم پس انتشار به خروجی داده می‌شوند. خروجی حاصل با مقدار هدف مقایسه می‌شود. اگر هدف و خروجی بدست آمده پیکسان باشد، خروجی به عنوان سروصدای در نظر گرفته می‌شود. در صورت تناقض، مقدار خروجی دوباره به لایه مخفی انتشار می‌باید. وزن‌ها در لایه پنهان تنظیم و پردازش می‌شوند. سپس مقدار به لایه خروجی ارسال می‌شود و دوباره همان روند ادامه می‌باید تا زمانی که هدف و مقدار بدست آمده پیکسان شوند.	حفظ حریم خصوصی داده‌های بهداشتی با استفاده از شبکه عصبی	مجموعه داده EHR	-	مانیکاندان و همکاران (۲۰۱۷) شبکه عصبی
[28]	چارچوب پیشنهادی بین شکل عمل می‌کند که بیمار برای پیش‌بینی بیماری خود علائم را به بیمارستان ارسال کرده سپس بیمارستان علائم رمزگذاری شده را به سور ابری فرستاده و ابر از مدل‌های پیش‌بینی آموزش دیده رمزگذاری شده برای تشخیص استفاده خواهد کرد و به بیمارستان ارسال می‌کند. در نهایت بیمارستان نتایج پیش‌بینی را به بیمار بر می‌گرداند	توسعه یک سیستم پیش‌بینی بیماری با حفظ اطلاعات بیماران به کمک چارچوب PPDP مبتنی بر سور ابری	مجموعه داده‌های سلطان سینه شامل ۶۸۳ نمونه و بیماری‌های قلبی شامل ۲۹۷ نمونه از UCI	(PPDP)	ژانگ و همکاران (۲۰۱۸)

است. تحقیق‌های آینده باید به جای چشم پوشی از داده‌های پرت، آنها را تجزیه و تحلیل کرده تا بینش پیدا کند [13].

۳-۵- تکیه بر مدل‌های پیش‌بینی کننده
نایاب انتظارات غیرواقعی از مدل‌های داده کاوی ساخته شده وجود داشته باشد. هر مدل دقیقی دارد. وقتی یک مدل پیش‌بینی برای تشخیص یک مسئله

پرونده به دلیل ثبت نشدن در پایگاه داده حذف شدند [12]. با حذف موارد با ارزش مفقود شده و هزینه‌های اضافی، مقدار قابل توجهی از اطلاعات از دست می‌رود. تحقیق‌های آینده باید یافتن روشی بهتر برای برآورد ارزش از دست رفته نسبت به حذف باشد. علاوه بر این، تکنیک‌های جمع‌آوری داده باید توسعه داده یا اصلاح شوند تا این مسئله جلوگیری شود. مشابه داده‌های از دست رفته، حذف یا نادیده گرفتن روشی متدالوبل برای مدیریت داده‌های پرت



۳-۸-اتوماسیون فرآیند داده کاوی برای کاربران غیر متخصص

کاربران نهایی داده کاوی در مراقبت‌های بهداشتی پزشکان، پرستاران و متخصصان مراقبت‌های بهداشتی هستند که آموزش محدودی در زمینه تجزیه و تحلیل دارند. یک راه حل برای این مشکل توسعه یک سیستم خودکار [29] (یعنی بدون نظارت انسانی) برای کاربران نهایی است. تانیا و همکاران [29] عماری ADA-HEALTH را معرفی کردند که بر پایه تجزیه و تحلیل اطلاعات داده‌های بهداشتی با حداقل دخالت کاربر است. آنها با استفاده از روش خوشه‌بندی K میانگین به متوسط دقت 79.72% رسیدند. راه دیگر این است که می‌توان یک ساختار خودکار مبتنی بر ابر برای جلوگیری از خطاهای پزشکی ایجاد کرد [28]. اما این وظیفه چالش برانگیز است زیرا شامل زمینه‌های مختلف کاربردی است و یک الگوریتم برای همه برنامه‌ها دقت مشابهی نخواهد داشت [13].

۳-۹-ماهیت میان رشته‌ای مطالعه و دانش تخصصی حوزه

تجزیه و تحلیل بهداشت و درمان یک زمینه تحقیقاتی بین رشته‌ای است. کشف دانش از داده‌های پزشکی یک کار دشوار است زیرا داده‌های موجود پر سر و صدا، بی ربط و گسترش نیز هستند [30]. به عنوان نوعی تجزیه و تحلیل، داده کاوی باید در ترکیب با نظر متخصص از حوزه‌های خاص مراقبت‌های بهداشتی و مشکل خاص (به عنوان مثال انکولوژیست برای مطالعه سرطان، متخصص قلب برای CVD) استفاده شود. یکی از پژوهش‌های صورت گرفته در این راستا مربوط به آشونی و همکاران [31] است که به طور خاص برای ایجاد یک شبکه بیز از متغیرهای متخصص دامنه استفاده کرده‌اند و همچنین روشی را برای استخراج قضاوت متخصص ارائه کرden. تقریباً 32% از مقاله‌های تحلیلی از نظر متخصص به هیچ وجه استفاده نکردن. تحقیق‌های آینده باید شامل اعضای رشته‌های مختلف از جمله مراقبت‌های بهداشتی باشد [13].

۱۰-عدم توانایی تغییر عادات پزشکان

حتی اگر نتایج داده کاوی معتبر باشد، مقاعده کردن پزشکان برای تغییر عادات‌های خود بر اساس شواهد ممکن است مشکل بزرگتری باشد. چند مورد مشاهده شده که پزشکان بیمارستان حتی در مواجهه با شواهد از تغییر سیاست بیمارستان خودداری می‌کنند. در یک مورد مشخص شد که پزشکان از کالبد شکافی بدون شستن دست بیرون می‌آیند و منجر به احتمال بالای مرگ در بیمارانی شده که پس از کالبد شکافی آنها را معالجه می‌کنند. با ارائه این شواهد، پزشکان هنوز از تغییر عادات‌های خود سر باز زندن [13].

سلامتی به عنوان مثال تشخیص نوع غده تیروئید ساخته شده است، معمولاً 100% دقت ندارد. بسته به میزان دقت مدل و اهمیت تصمیم‌گیری با استفاده از آن مدل، باید تصمیم بگیریم که چقدر می‌توانیم به نتایج این مدل داده کاوی اعتماد کنیم. به خصوص هنگامی که ما با تصمیمات پزشکی بالینی مبتنی بر نتایج یک یا چند مطالعه داده کاوی سر و کار داریم، مهم است که در نظر بگیریم که تنها انکا به مدل‌های پیش‌بینی هنگام تصمیم‌گیری‌های حیاتی که مستقیماً بر زندگی بیمار تأثیر می‌گذارد، خطرناک خواهد بود و این را نباید از مدل پیش‌بینی انتظار داشت.

با این حال، مدل‌های داده کاوی و به طور خاص مدل‌های پیش‌بینی هنگامی که به عنوان نظر دوم برای تصمیم‌پرداز در مورد درمان استفاده می‌شوند، می‌توانند بسیار مفید باشند. در برخی موارد، پزشک ممکن است شدت بیماری بیمار را کم ارزیابی کند و مدل ساخته شده به وی هشدار می‌دهد تا برخی از جنبه‌هایی را که ممکن است از دست رفته باشد و بیمار را در معرض خطر قرار دهد، در نظر بگیرد. از طرف دیگر، اگر پزشک از اینکه بیمار نیاز به جراحی دارد یا خیر این مدل‌ها می‌توانند در تشخیص صحیح به پزشک کمک کنند [10].

۳-۶-أنواع روش‌ها و رياضيات پيچيده

از آنجا که رياضيات پايه‌اي تقربياً همه تكنيك‌های داده کاوی پيچيده است و برای افراد غير فني به راحتی قابل درک نیست، بنابراین، پزشکان و اپيديمولوژист‌ها معمولاً ترجيح می‌دهند که با روش‌های سنتي آمار ادامه کار دهند. علاوه بر اين، از آنجا که تكنيك‌ها و روش‌های مختلف در داده کاوی وجود دارد، برای پزشکان دشوار است که با تمام روش‌های مختلف آشنا شوند و به راحتی روش مناسب را انتخاب کنند.

در اين مورد، لازم است از تحليلگرانی که با تكنيك‌های مختلف داده کاوی آشنایی بيشتری دارند کمک گرفته شود تا بتوانند روش‌های مختلفی را به کار گيرند و از قدرت داده کاوی در برخورد با مجموعه‌های داده بزرگ و پذيرش ويژگي‌های ورودی بيشتر در مقایسه با آمار سنتي استفاده کنند [10].

۷-۳-ادغام در سیستم مراقبت‌های بهداشتی

تعداد کمی از تحقیق‌های انجام شده تلاش کردن تا فرآیند داده کاوی را در چارچوب تصمیم‌گیری واقعی ادغام کنند. تأثیر کشف دانش از طریق داده کاوی بر حجم کار و زمان حرفه‌ای مراقبت‌های بهداشتی مشخص نیست. مطالعه‌های آینده باید یکپارچه‌سازی سیستم توسعه یافته را در نظر بگيرند و تأثیر آن را بر محیط کار بررسی کنند [13].

داده کاوی در پژوهشی هنوز در مراحل اولیه خود به سر می برد و به بلوغ لازم نرسیده است و راه برای پیشرفت آن زیاد است. تحقیق‌های آینده باستی به مسائل مطرح شده توجه ویژه‌ای داشته باشند تا بتوان دقت مدل‌های پیش‌بینی کننده را بالا برد و دریخش‌های مختلف به بهترین شکل ممکن از این مدل‌ها استفاده کرد.

مراجع

- [1] E. M. Beulah *et al.*, "Application of Data mining in healthcare: A survey," *Asian Jr. of Microbiol. Biotech. Env. Sc.*, vol. 18, no. 4, 2016.
- [2] I. Tăranu, "Data mining in healthcare: decision making and precision," *Database Systems Journal*, vol. 6, no. 4, pp. 33-40, 2016.
- [3] M. N. Almunawar and M. Anshari, "Health information systems (HIS): Concept and technology," *arXiv preprint arXiv:1203.3923*, 2012.
- [4] W. H. Organization, *Framework and standards for country health information systems*. World Health Organization, 2008.
- [5] M. Mohd, A. Papazafeiroglou, R. J. Paul, and L. K. Stergioulas, "Investigating evaluation frameworks for health information systems," *Int. J. Medical Informatics*, vol. 77, no. 6, pp. 377-385, 2008.
- [6] N. Soni and C. Gandhi, "Application of data mining to health care," *International Journal of Computer Science and its Applications*, 2010.
- [7] N. Jothi and W. Husain, "Data mining in healthcare—a review," *Procedia computer science*, vol. 72, pp. 306-313, 2015.
- [8] P. Ahmad, S. Qamar, and S. Q. A. Rizvi, "Techniques of data mining in healthcare: a review," *International Journal of Computer Applications*, vol. 120, no. 15, 2015.
- [9] I. Yoo *et al.*, "Data mining in healthcare and biomedicine: a survey of the literature," *Journal of medical systems*, vol. 36, no. 4, pp. 2431-2448, 2012.
- [10] M. H. Tekieh and B. Raahemi, "Importance of data mining in healthcare: a survey," in *Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining 2015*, ۲۰۱۵, pp. 1057-1062.
- [11] N. Garcelon, A. Burgun, R. Salomon, and A. Neuraz, "Electronic health records for the diagnosis of rare diseases," *Kidney International*, vol. 97, no. 4, pp. 676-686, 2020.
- [12] J. St-Maurice and C. Burns, "An exploratory case study to understand primary care users and their data quality tradeoffs," *Journal of Data and Information Quality (JDIQ)*, vol. 8, no. 3-4, pp. 1-24, 2017.
- [13] M. S. Islam, M. M. Hasan, X. Wang, and H. D. Germack, "A systematic review on healthcare analytics: application and theoretical perspective of data mining," in

۳-۱۱-تفاوت داده کاوی سنتی و پژوهشی

در تحقیق‌های پژوهشی، داده کاوی با یک فرضیه آغاز می‌شود و سپس نتایج متناسب با آن فرضیه تنظیم می‌شود. این فرآیند از عمل استاندارد داده کاوی، که به سادگی با مجموعه داده‌ها و بدون فرضیه شروع می‌شود، متفاوت است. همچنین، داده کاوی سنتی نگران‌الگوها و روند در مجموعه داده‌ها است، در حالی که داده کاوی در پژوهشی بیشتر به اقلیتی علاقه‌مند است که با الگوها و روندهای مطابقت نداشته باشد. علاوه بر این، بیشتر نتایج استاندارد داده کاوی مربوط به توصیف اما عدم توضیح الگوها و روندهای است. در مقابل، پژوهشی که این توضیحات نیاز دارد زیرا یک تفاوت جزئی می‌تواند تعادل بین مرگ و زندگی را تغییر دهد [6].

۴- نتیجه گیری

با توجه به رشد روز افزون بهره مندی از دانش داده کاوی در حوزه سلامت که منجر به نتایج بهتر شده، مشکلاتی را با خود همراه داشته که منجر به بدست نیامدن نتایج مطلوب گردیده است. تکنیک‌هایی به کار گرفته شده در مطالعه‌های اخیر حاکی از آن بوده که دقت مدل‌های پیش‌بینی متناسب با هر تکنیک متفاوت است. با توجه به این موضوع دقت هیچ کدام از مدل‌ها ۱۰۰ درصد نیست و از آن جایی که حوزه سلامت، حوزه‌ای بسیار حساس و کوچک‌ترین اشتباہ در پیش‌بینی انجام شده به جان انسان‌ها ختم شده، مدل‌های پیش‌بینی کننده در اولویت‌های بعدی برای استفاده قرار می‌گیرند. دلایل متعددی برای عدم کارکرد صحیح این مدل‌ها وجود دارد که دریخش ۳ به آن اشاره گردید.

همچنین با توجه به یکی از بزرگترین چالش‌های پیش رو که کیفیت داده‌های جمع‌آوری شده است بایستی زمینه همکاری بین سازمان‌های بهداشتی و تحلیل گران بیشتر شود تا بتوان داده‌هایی با کیفیت برای عمل تجزیه و تحلیل در اختیار مهندسین داده قرار داد. بایستی پایگاه داده‌های منسجم و یکپارچه که امکان به اشتراک گذاری اطلاعات وجود داشته باشد، ایجاد کرد. همچنین سازمان‌های بهداشتی همکاری بیشتری با سازمان‌های جمع‌آوری کننده اطلاعات بهداشتی داشته باشند تا داده‌های با کیفیت در اختیار مهندسین تحلیل گر قرار دهند. موردی که کمتر به آن در تحقیق‌های صورت گرفته توجه شده است مسئله استفاده از دانش متخصص حوزه می‌باشد که باعث شده نتایج بدست آمده مورد رضایت نبوده و به کار گرفته نشوند.

داده‌های پژوهشی بر اثر دو عامل مهم از کیفیت پایینی برخودار هستند: اول عدم همکاری سازمان‌های بهداشتی با پایگاه داده‌های جمع‌آوری کننده اطلاعات که به آن اشاره گردید و مورد دوم عدم حفظ حریم خصوصی می‌باشد که در این زمینه فعالیت‌هایی صورت گرفته است اما همچنان به طور کامل مشکل حریم خصوصی را برطرف نکرده و این عامل باعث شده تا سازمان‌های بهداشتی میل و رغبت کمتری نسبت به دادن اطلاعات بیماران به تحلیلگران داده نشان دهند.

- [26] N. Domadiya and U. P. Rao, "Privacy preserving distributed association rule mining approach on vertically partitioned healthcare data," *Procedia computer science*, vol. 148, pp. 303-312, 2019.
- [27] G. Manikandan, N. Sairam, M. Sathya Priya, and H. V. Sri Radha Madhuri, "A new approach for ensuring medical data privacy using neural networks.",
- [28] C. Zhang, L. Zhu, C. Xu, and R. Lu, "PPDP: An efficient and privacy-preserving disease prediction scheme in cloud-based e-Healthcare system," *Future Generation Computer Systems*, vol. 79, pp. 16-25, 2018.
- [29] T. Cerquitelli, E. Baralis, L. Morra, and S. Chiusano, "Data mining for better healthcare: A path towards automated data analysis?", in *2016 IEEE 32nd International Conference on Data Engineering Workshops (ICDEW)*, 2016: IEEE, pp. 60-63 .
- [30] M. Durairaj and V. Ranjani, "Data mining applications in healthcare sector: a study," *International journal of scientific & technology research*, vol. 2, no. 10, pp. 29-35, 2013.
- [31] A. C. Constantinou, N. Fenton, and M. Neil, "Integrating expert knowledge with data in Bayesian networks: Preserving data-driven expectations when the expert variables remain unobserved," *Expert systems with applications*, vol. 56, pp. 197-208, 2016.
- [32] H. Kaur, N. Kumar, and S. Batra, "An efficient multi-party scheme for privacy preserving collaborative filtering for healthcare recommender system," *Future Generation Computer Systems*, vol. 86, pp. 297-307, 2018.
- [14] A. P. Kurniati, E. Rojas, D. Hogg, G. Hall, and O. A. Johnson, "The assessment of data quality issues for process mining in healthcare using Medical Information Mart for Intensive Care III, a freely available e-health record database," *Health informatics journal*, vol. 25, no. 4, pp. 1878-1893, 2019.
- [15] R. Andrews *et al.*, "Leveraging data quality to better prepare for process mining: an approach illustrated through analysing road trauma pre-hospital retrieval and transport processes in Queensland," *International journal of environmental research and public health*, vol. 16, no. 7, p. 1138, 2019.
- [16] T. Nasralah, O. El-Gayar, and Y. Wang, "Social media text mining framework for drug abuse: Development and validation study with an opioid crisis case analysis," *Journal of medical Internet research*, vol. 22, no. 8, p. e18350, 2020.
- [17] I. Kreso, A. Kapo, and L. Turulja, "Data mining privacy preserving: Research agenda," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, p. e1392, 2020.
- [18] N. Domadiya and U. P. Rao, "Improving healthcare services using source anonymous scheme with privacy preserving distributed healthcare data collection and mining," *Computing*, pp. 1-23, 2020.
- [19] M. A. P. Chamikara, P. Bertók, D. Liu, S. Camtepe, and I. Khalil, "An efficient and scalable privacy preserving algorithm for big data and data streams ",*Computers & Security*, vol. 87, p. 101570, 2019.
- [20] S. Qiu, B. Wang, M. Li, J. Liu, and Y. Shi, "Toward practical privacy-preserving frequent itemset mining on encrypted cloud data," *IEEE Transactions on Cloud Computing*, 2017.
- [21] S. G. Teo, J. Cao, and V. C. Lee, "Dag: A general model for privacy-preserving data mining," *IEEE Transactions on Knowledge and Data Engineering*, vol. 32, no. 1, pp. 40-53, 2018.
- [22] X. Yang, R. Lu, J. Shao, X. Tang, and H. Yang, "An efficient and privacy-preserving disease risk prediction scheme for e-healthcare," *IEEE Internet of Things Journal*, vol. 6, no. 2, pp. 3284-3297, 2018.
- [23] F. Wang *et al.*, "Privacy-preserving collaborative model learning scheme for E-healthcare," *IEEE Access*, vol. 7, pp. 166054-166065, 2019.
- [24] A. Alabdulkarim, M. Al-Rodhaan, T. Ma, and Y. Tian, "PPSDT: A novel privacy-preserving single decision tree algorithm for clinical decision-support systems using IoT devices," *Sensors*, vol. 19, no. 1, p. 142, 2019.
- [25] N. Domadiya and U. P. Rao, "Privacy-preserving association rule mining for horizontally partitioned healthcare data: a case study on the heart diseases," *Sādhana*, vol. 43, no. 8, pp. 1-9, 2018.

زیرنویس‌ها

¹ Health Information System

² Electronic Health Record

³ Information and Communications Technology

⁴ Knowledge Discovery in Databases

⁵ Secure multi-party computation

⁶ Computational Diffie–Hellman