

شناسه‌زدایی پرونده الکترونیک سلامت با استفاده از الگوریتم‌های یادگیری ماشین: یک مرور نظاممند

مصطفی لنگریزاده^۱، اعظم اروجی^{۲*}

دریافت مقاله: ۹۶/۶/۱۱ • پذیرش مقاله: ۹۶/۴/۲۶

مقدمه: پرونده الکترونیک سلامت حاوی اطلاعات بالینی زیادی است که برای فعالیتهای چون پایش بهداشت عمومی، بهبود کیفیت و تحقیقات مورد استفاده قرار می‌گیرد. همچنین پرونده الکترونیک سلامت شامل اطلاعات سلامت قبل شناسایی است و همین موضوع اشتراک و استفاده ثانویه از پروندها را محدود می‌کند. شناسه‌زدایی یکی از رایج‌ترین روش‌های حفظ محرمانگی اطلاعات بیماران است. این مقاله مروری نظاممند بر تحقیقات اخیر می‌باشد، که به حذف تمامی شناسه‌ها از پرونده الکترونیک سلامت با استفاده از انواع روش‌های شناسه‌زدایی مبتنی بر یادگیری ماشین پرداخته‌اند.

روش: این مقاله به صورت مروری نظاممند در بازه زمانی ۲۰۱۶ - ۲۰۰۶ در پایگاه‌های Science direct و PubMed انجام شد. مقالات با استفاده از چکلیست CASP و سپس توسط دو ارزیاب به‌طور مستقل بررسی و ارزشیابی شدند. در نهایت ۱۲ مقاله با معیارهای ورود مطالعه همخوانی داشتند.

نتایج: مقالات منتخب بر اساس روش و منابع دانش مورد استفاده، انواع شناسه‌ها، نوع اسناد بالینی، چالش‌ها و نتایج حاصل بررسی شده‌اند. نتایج نشان داد که در زمان انتشار داده‌های بالینی برای اهداف ثانویه شناسه‌زدایی مبتنی بر یادگیری ماشین راهکاری مناسب برای حفظ حریم خصوصی بیماران است. همچنین ترکیب الگوریتم‌های یادگیری ماشین و روش‌هایی چون تطبیق الگو و عبارات منظم می‌تواند نیاز به داده آموزش را کاهش دهد.

نتیجه‌گیری: در پرونده‌های پزشکی اطلاعات شناسایی زیادی وجود دارد. این مطالعه نشان داد که روش‌های شناسه‌زدایی مبتنی بر یادگیری ماشین می‌توانند به طرز چشمگیری خطر افشاگری این اطلاعات را کاهش دهند.

کلید واژه‌ها: محرمانگی، حریم خصوصی، شناسه‌زدایی، یادگیری ماشین، پرونده الکترونیک سلامت

ارجاع: لنگریزاده مصطفی، ارجوی اعظم. شناسه‌زدایی پرونده الکترونیک سلامت با استفاده از الگوریتم‌های یادگیری ماشین: یک مرور نظاممند. مجله انفورماتیک سلامت و زیست پزشکی ۱۳۹۶؛ ۲(۴): ۱۵۴-۱۶۷.

۱. دکترای انفورماتیک پزشکی، گروه مدیریت اطلاعات سلامت، دانشکده مدیریت و اطلاع رسانی پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران

۲. دانشجوی دکترای انفورماتیک پزشکی، گروه مدیریت اطلاعات سلامت، دانشکده مدیریت و اطلاع رسانی پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران

*نویسنده مسئول: تهران، میدان ونک، خیابان ولی‌عصر، خیابان رشید یاسmi، پلاک ۶

• Email: orooji.a@tak.iums.ac.ir

• شماره تماس: ۰۲۱۸۸۷۹۴۳۰۱

مقدمه

تعريف می‌کند [۱۵]. جدول ۱ شناسه‌های تعریف شده توسط HIPAA را نمایش می‌دهد.

جدول ۱: مجموعه ۱۸ دسته PHI که توسط HIPAA معرفی شده است

نامها	•
تمامی تقسیمات جغرافیایی کوچکتر از ایالت شامل خیابان، شهر، استان، کد پستی	•
تمامی اجزای تاریخ‌ها (به جز سال) برای تاریخ‌هایی که مربوط به یک فرد خاص است مثل تاریخ تولد، تاریخ پذیرش و ترجیح، تاریخ فوت و تمامی اجزای تاریخ‌ها (به همراه سال) برای سن‌های بالای ۸۹	•
شماره تلفن‌ها	•
شماره فکس‌ها	•
آدرس پست الکترونیک	•
شماره امنیت اجتماعی	•
شماره بروونده پزشکی	•
شماره بیمه درمانی	•
شماره حساب‌ها	•
شماره گواهینامه مدارک	•
شماره وسائل نقلیه	•
شماره ابزارها و شماره سریال‌ها	•
آدرس صفحات وب	•
شماره آدرس پروتکل اینترنت	•
شناسه‌های بیومتریک مثل انگشت	•
تصویر کامل صورت یا تصاویر دیگر قابل شناسایی	•
هر شماره، خصوصیت یا کدی که باعث شناسایی شود	•

در ایران نیز اصول ۲، ۲۳، ۲۴، ۲۵، ۲۶، ۳۲ و ۳۹ قانون اساسی جمهوری اسلامی تأکید بر حفظ حریم خصوصی افراد مشاهده می‌شود. در مورد حفاظت از داده‌های سلامت، ماده ۶۴۸ قانون مجازات اسلامی، افسای اطلاعات بیماران را جرم دانسته است [۱]. همچنین طبق منشور حقوق بیمار علاوه بر بیمار تنها گروه درمانی، افراد مجاز از طرف بیمار و افرادی که به حکم قانون مجاز تلقی می‌شوند می‌توانند به اطلاعات دسترسی داشته باشند [۱۶].

اساسی‌ترین تکنیک‌ها به منظور حفظ امنیت اطلاعات پزشکی و حریم خصوصی بیمار شامل محافظت فیزیکی، فنی و مدیریتی است. حفاظت فیزیکی به سیاست‌هایی چون نگهداری دستگاه‌ها در مکان‌های ایزووله، ایجاد نسخه کپی و پشتیبان از داده‌ها، جلوگیری کردن از دسترسی فیزیکی افراد ناشاخته به رایانه‌ها و ایجاد یک سیستم مناسب برای امحا اطلاعات می‌شود. حفاظت فنی به راهاندازی دیوار آتش و روش‌های امن برای انتقال اطلاعات چون شبکه خصوصی مجازی و تکنیک‌های شناسایی‌زدایی De-ID(De-Identification) می‌پردازد. حفاظت مدیریتی شامل مواردی چون الزاماتی برای سیاست‌گذاری‌های امنیتی برای بخش مستندسازی، آموزش کارکنان، استفاده از رد ممیزی به منظور پیگیری همه ورود و

حریم خصوصی یکی از حقوق مورد تأیید در قانون اساسی است که به موجب آن افراد حق دارند خلوت شخصی داشته و تنها بمانند، از شهرت بی دلیل در امان باشند و بدون اینکه سر زبان‌ها بیفتند زندگی کنند [۱]. در حوزه مراقبت سلامت، حریم خصوصی به معنی حق افراد برای محدود کردن دسترسی غیرمجاز به اطلاعات مراقبت سلامت آن‌ها است [۲]. پرونده الکترونیک سلامت سیستمی است که شامل اطلاعات پرونده بیمار است که دسترسی به آن‌ها از طریق شبکه‌ای از کامپیوترها میان ارائه‌دهندگان خدمات مراقبتی سازمان‌های مختلف امکان‌پذیر است [۳،۴]. پرونده الکترونیک سلامت EHR (Electronic Health Record) شخصی زیادی است برای مثال، متخصصین حوزه‌های مختلف در یک بیمارستان برای درمان فرد باشیستی به EHR دسترسی داشته باشند همچنین محققین برای انجام کارآزمایی‌ها و مطالعات اپیدمیولوژیک از اطلاعات پرونده استفاده می‌کنند [۶،۵]. مستندات مدارک پزشکی محترمانه است و طبق اصل رازداری مدارک پزشکی، بیمار حق دارد انتظار داشته باشد که مدارک پزشکی مربوط به مراقبت درمانی‌اش محترمانه تلقی شود و بیمارستان از اطلاعات پرونده‌اش در برابر افشای غیرمجاز محافظت نماید [۷،۸]. اهمیت این موضوع سبب شده مطالعات زیادی به تأثیر افشاری غیرمجاز اطلاعات بر افراد و سازمان‌ها بپردازند [۹،۱۰] و اکثر کشورها در این خصوص قوانین وضع کنند. از این جمله می‌توان به لایحه حریم Health شخصی اطلاعات و مدارک بهداشتی‌درمانی (HRIP(Records and Information Privacy Act در استرالیا و قانون حفاظت داده (Data Protection Act) و لایحه مراقبت اجتماعی و بهداشتی- درمانی (The Health and Social Care Act در انگلستان اشاره نمود [۱۱]. در آمریکا نیز قانون پاسخگویی و قابلیت انتقال بیمه بهداشتی- درمانی (Health Insurance Portability and Accountability Act) در سال ۱۹۹۶ تصویب شد که دربردارنده شرایطی برای محافظت از اطلاعات سلامت بیماران در برابر افشاری غیرمجاز است. در این قانون واژه Protected Health (اطلاعات سلامت حفاظت‌شده) که PHI(Information با عنوان "تمام اطلاعات سلامتی که باعث شناسایی بیمار می‌شود،" تعریف شده است [۱۲-۱۴]. HIPAA اطلاعات سلامت حفاظت شده را در ۱۸ طبقه

مطالعات مروری دیگری نیز به بررسی روش‌های مختلف شناسه‌زدایی پرداخته‌اند [۲۰-۲۲؛ ۲۹]: اما هدف این مقاله آن است که مقالات ده سال اخیر که از الگوریتم‌های یادگیری ماشین (Machine Learning ML) برای شناسه‌زدایی بهره برده‌اند به صورت نظاممند جستجو شده و از جنبه‌های مختلف به تفصیل مورد ارزیابی قرار گیرند. بدین منظور مقالات بر حسب روش مورد استفاده، منبع دانش، نوع متنی که برای ارزیابی سیستم استفاده شده، مجموعه شناسه در نظر گرفته شده و نتایج حاصل تقسیم‌بندی، بررسی و مقایسه شده‌اند.

روش

این مطالعه از مرور نظاممند جهت اطمینان از دقت و جامعیت فرآیند جستجو و بازیابی استفاده کرده است. برای این پژوهش مقالات پایگاه‌های Sciencedirect و PubMed که در بازه زمانی ۱/۱/۲۰۰۶ تا ۱/۱/۲۰۱۶ و به زبان انگلیسی منتشر شده‌اند با ترکیب کلیدواژه‌های مختلف بررسی شد. جستجوی موردنظر در شکل ۱ نمایش داده شده است. همچنین معیارهای ورود و خروج مطالعه در جدول ۲ آمده است. از میان مقالات، تنها مواردی که برای شناسه‌زدایی از الگوریتم‌های ML استفاده کرده‌اند و ارزیابی سیستم خود را بر اساس EHR نوشتene شده به زبان انگلیسی انجام داده‌اند وارد مطالعه شدند.

خروج‌ها و تغییرات در داده‌ها می‌باشد [۱۳، ۳].
پروسه حذف یا تغییر تمام شناسه‌های موجود به منظور حداقل کردن خطر بازشناسایی افراد را شناسه‌زدایی گویند [۱۷، ۳].
شناسه‌زدایی در گذشته غالب به شکل دستی انجام می‌گرفت؛ اما Dorr و همکاران زمان موردنیاز برای شناسه‌زدایی دستی را مورد ارزیابی قرار داده (میانگین $64 \pm 87/2$ ثانیه برای هر یادداشت) و نتیجه‌گیری کردند که این کار بسیار زمان بر است [۱۸]. همچنین از آنجا که یکی از معیارهای ارزیابی سازمان جهانی بهداشت از سیستم سلامت هر کشور استفاده از فناوری اطلاعات در مراقبت بهداشتی است [۱۹]، اغلب پژوهشگران بر روش‌های خودکار شناسه‌زدایی متمرکز شدند [۲۰]. بعدها اثر ترکیبی این دو نیز بررسی گشت. برای مثال South و همکاران یک رابط تعاملی برای شناسه‌زدایی ارائه کردند که از یک روش شناسه‌زدایی خودکار به عنوان پیش پردازشگر برای شناسه‌زدایی دستی استفاده کردند [۲۱]. برای شناسه‌زدایی خودکار از تکنیک‌های یادگیری ماشین استفاده می‌شود، زیرا این روش‌ها به کرات در مدیریت متون پژوهشی استفاده شده‌اند و به نتایج مطلوبی دست یافته‌اند [۲۲].

با توجه به اهمیت حفظ محرمانگی اطلاعات بیماران و توجه ویژه به شناسه‌زدایی خودکار در سال‌های اخیر، این مقاله به طور نظاممند به مطالعه روش‌های مختلف شناسه‌زدایی خودکار از پرونده‌های الکترونیک بیماران پرداخته است. اگرچه

شکل ۱: جستجوی مورد استفاده برای بازیابی مطالعات مورد نظر

Science Direct	Pub-date > 2005 and pub-date < 2016 and (TITLE-ABSTR-KEY(de-identif*) or TITLE-ABSTR-KEY(deidentif*) or TITLE-ABSTR-KEY(Anonymization) or TITLE-ABSTR-KEY(De-personalization) or TITLE-ABSTR-KEY(Depersonalization) or TITLE-ABSTR-KEY(Pseudonymization)) and ("electronic health record" or "electronic medical record").
PubMed	(Electronic health record [All Fields] OR Electronic medical record [All Fields]) AND (de-identif*[Title/Abstract] OR deidentif*[Title/Abstract] OR Anonymization[Title/Abstract] OR De-personalization [Title/Abstract] OR Depersonalization [Title/Abstract] OR Pseudonymization [Title/Abstract]) AND ("2006/01/01"[PDAT] : "2016/01/01"[PDAT])

جدول ۲: معیارهای ورود و خروج مطالعات

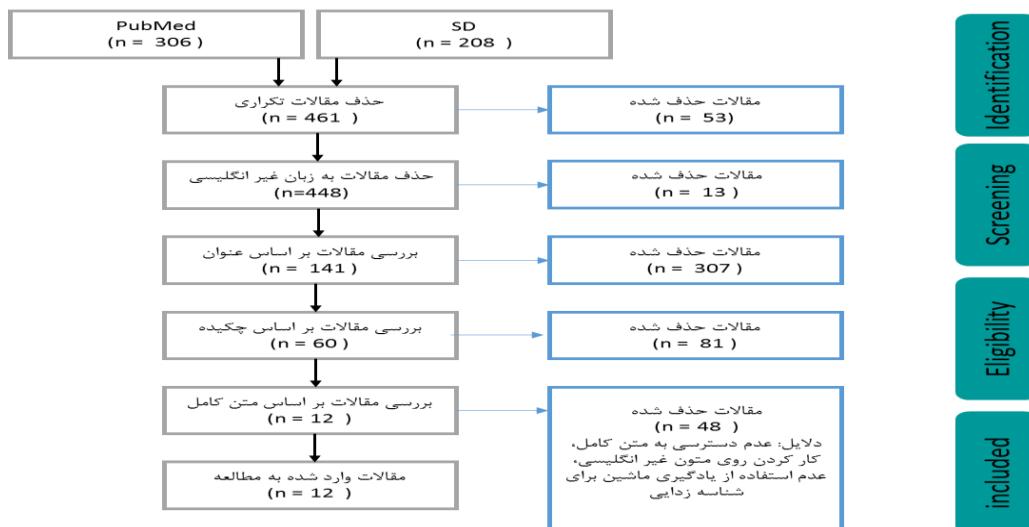
معیارهای خروج	معیارهای ورود
حذف مقالاتی که به متن کامل آن‌ها دسترسی نبود.	• مقالاتی که روی پرونده‌های پژوهشی به زبان انگلیسی کار کرده‌اند.
حذف روزنامه، نامه به سردبیر، کارگاه، پوستر، گزارش کوتاه، کتاب و پایان‌نامه	• استفاده از الگوریتم‌های یادگیری ماشین برای شناسه‌زدایی

در نظر گرفتن معیارهای ورود و خروج یافت شد، در مرحله بعد سنجش کیفی مقالات بر اساس چکلیست ۱۲ سؤالی مطالعات تست تشخیصی (Critical Appraisal Skills) CASP (Programme [۳۰]) انجام شد. نتایج حاصل از

PRISMA به منظور انتخاب مقالات از نمودار جریان کار استفاده شد. با استفاده از جستجوی شکل ۱ تعداد ۵۱۴ مقاله که پس از سازمان‌دهی آن‌ها در نرم‌افزار اندنوت (Endnote) و بررسی مستقل دو ناظر به ترتیب عنوان، چکیده و متن کامل با

پروتکل جستجو در شکل ۲ نمایش داده شده است.

چکلیست با استفاده از نرمافزار اکسل ۲۰۱۳ سازماندهی شد.



شکل ۲: پروتکل جستجو بر اساس نمودار جریان کاری انتخاب مقالات PRISMA

نتایج

(P<0.001). در نهایت، تعداد ۱۲ مقاله وارد مطالعه شدند که به همراه نمره CASP، سال چاپ و نام مجله‌ای که آن را چاپ کرده در جدول ۳ نشان داده شده‌اند. مقالات منتخب در دو بخش مورد بررسی قرار گرفته‌اند.

طی ارزیابی معیارهای ورود و خروج توسط ناظرین، موارد تناقض میان دو ناظر با برگزاری یک جلسه مشترک رفع گشت همچنین میزان توافق میان دو ناظر با استفاده از آزمون آماری کاپا محاسبه و برابر ۸۱٪ شد که از نظر آماری معنی‌دار بود

جدول ۳: نمره CASP برای مقالاتی که وارد مطالعه شدند. به هر آیتم موجود در چکلیست با واژه‌های بله (نمره = ۲)، خیر (نمره = ۱) و نمی‌توان گفت (نمره = ۰) امتیاز تعلق گرفت.

محل انتشار	نام نویسنده	سال انتشار	نمره CASP (%)
Journal of the American Medical Informatics Association	[۳۴]Szarvas	۲۰۰۷	۵۸/۳
Journal of the American Medical Informatics Association	[۴۱]Wellner	۲۰۰۷	۶۲/۵
IEEE International Symposium on Computer-Based Medical Systems	[۳۶]Gardner	۲۰۰۸	۴۵/۸
Artificial Intelligence in Medicine	[۳۳]Uzuner	۲۰۰۸	۶۶/۷
International Journal of Medical Informatics	[۳۷]Aberdeen	۲۱۰	۷۵/۰
BMC Medical Informatics and Decision Making	[۳۵]McMurry	۲۰۱۳	۶۶/۷
Journal of the American Medical Informatics Association	[۴۲]Ferrández	۲۰۱۳	۷۵/۰
Journal of Biomedical Informatics	[۳۹]He	۲۰۱۵	۶۶/۷
Artificial Intelligence in Medicine	[۴۰]Zuccon	۲۰۱۴	۸۷/۵
Journal of Biomedical Informatics	[۴۰]Dehghan	۲۰۱۵	۶۲/۵
Journal of Biomedical Informatics	[۴۲]Yang	۲۰۱۵	۶۶/۷
Journal of Biomedical Informatics	[۴۷]Liu	۲۰۱۵	۶۶/۷

- روش (الگوریتم‌های) ML مورد استفاده در شناسه زدایی)
- پایگاه دانش (در برخی از مقالات از منابعی مانند واژه‌نامه‌ها یا لیست‌های سرشماری به عنوان لغتنامه در جستجوی شناسه‌ها استفاده شده است).
- مجموعه شناسه‌ها (مجموعه مقادیری که به عنوان شناسه در نظر گرفته شده‌اند که می‌تواند مطابق با مجموعه تعريف شده توسط HIPAA باشد یا خیر؟)

دسته اول، روش‌های شناسه‌زدایی مبتنی بر داده، مقالاتی هستند که تنها بر اساس الگوریتم‌های ML و با دو مرحله آموزش و آزمایش طراحی شده‌اند. در حالی که دسته دوم یعنی روش‌های شناسه‌زدایی ترکیبی علاوه بر الگوریتم‌های ML از لغتنامه‌ها نیز برای جستجوی شناسه‌ها بهره برده‌اند؛ در واقع این گروه ترکیبی از روش‌های مبتنی بر داده و روش‌های مبتنی بر دانش هستند. در این بخش سعی بر آن است که مقالات از جنبه‌های متعددی چون موارد زیر بررسی گردند:

شكل متونی است که در آن ها PHI های مختلف برچسب خورده اند. این سیستم ها از مجموعه های متفاوتی از ویژگی ها استفاده می کنند: ۱) ویژگی های در سطح کلمه (شامل خصوصیات حرفی / لغوی و ریخت شناسی کلمات) این روش که بر اساس n-gram کار می کند رایج ترین و بهترین روش برای شناسه زدایی و طبقه بندی کلمات است. ۲) ویژگی های نحوی Part-of-Speech (POS) Tagging (Tagging). ۳) ویژگی های معنایی (طبقه بندی معناگرای کلمات)، ۴) ویژگی های در سطح سند (مانند واژگان رایج در یک سند) و ۵) ویژگی های مبتنی بر متن (شامل میزان تکرار واژگان) [۲۰، ۳۱، ۳۲]. جدول ۴ خلاصه ای از مقاطع مربوط به شناسه زدایی مبتنی بر داده پرونده الکترونیک سلامت که تنها از روش های ML بهره برده اند را نشان می دهد.

- نوع داده (نوع متنی که روش پیشنهادی روی آن پیاده سازی شده است که می تواند شامل گزارش پاتولوژی، خلاصه ترخیص و ... باشد).

نتایج حاصل

نام سیستم (در صورت وجود)

۱. روش های شناسه زدایی مبتنی بر داده

این روش ها از الگوریتم های مختلف یادگیری ماشین همچون (Support Vector Machine) ماشین بردار پشتیبان (SVM)، درخت تصمیم و میدان تصادفی شرطی CRF (Conditional Random Fields) استفاده می کنند. تمامی این الگوریتم ها برای ساخت مدلی که بتواند کلمات را دریکی از دو دسته PHI, not PHI قرار دهد نیاز دارند که توسط یک مجموعه داده آموزش بینند. این مجموعه اصولاً به

جدول ۴: مشخصات سیستم های شناسه زدایی مبتنی بر داده (یادگیری ماشین)

نام	نوع متن	الگوریتم ML	نویسنده		
شناسه ها	منبع داشت				
۸ شناسه معرفی شده در ۲۰۰۶ i2b2NLP	۵ لیست از اینترنت شامل اسامی، مکان های چهارپایی آمریکا، نام کشورهای جهان، نام شهرهای بزرگ جهان، نام بیماری ها لیستی از واژه های non-PHI مستخرج از داده های آموزش لیستی از واژه های non name entity از پایگاه داده کنفرانس یادگیری زبان طبیعی سال ۲۰۰۳ (http://www.cnts.ua.ac.be/conll2003/) CoNLL				
HIPAA	نadar	Gزارش پاتولوژی	CRF Gardner [۳۴]		
شناسه های معرفی شده توسط HIPAA	۹۸/۲				
۷ گروه شناسه شامل: بیمار (نام و نام خانوادگی بیمار و خانواده اش)، دکتر (نام و نام خانوادگی پزشکان و سایر ارائه دهنده های مرافق)، نام بیمارستان، شماره های شناسایی (شامل هر ترکیبی از اعداد و حروف)، تاریخ ها، آدرس (آیل، شه، نام خیابان، کد پستی، نام و شماره ساختمان ها، شماره تلفن (تلفن و فکس))	۹۹٪ فراخوانی: ۹۷٪ معيار F	۹۹٪ فراخوانی: ۹۷٪ معيار F	واژگان سرعنوان های موضوعی پزشکی (Medical Subject Headings)، لیستی از نام ها، مکان ها و بیمارستان ها	خلاصه ترخیص	SVM Uzuner [۳۵]
۸ شناسه ای از شناسه های معرفی شده توسط HIPAA (شامل نام بیمارستان، بیمار، س، تاریخ، س، مکان، نام بیمار، شماره شناسایی و تلفن)	۶۲٪ دق:	شریعت پزشکی حاشیه گذاری شده توسط cTAKES (۱۲) لیست سرشماری ۱۹۹۰ آمریکا ۱۰- لغت نامه پزشکی شامل ...، UMLS, ICD 10, MESH, SNOMED, LOINC	خلاصه ترخیص	Decision tree (J84)	McMurry [۳۶]
شناسه های معرفی شده توسط HIPAA به علاوه نام مؤسسات MIST	۹۸٪ فراخوانی: ۷۶٪ معيار F1 ۹۸٪ معيار F10	شریعت پزشکی حاشیه گذاری شده توسط اولین ارزیابی: توسط ۱۹۹۰ آمریکا، لیست نام بیمارستان های سرشناس	خلاصه ترخیص	Decision tree (J84)	McMurry [۳۶]
۸ شناسه معرفی شده در ۲۰۰۶ i2b2NLP و شناسه های HIPAA	۹۴٪ ارزیابی اول: ۹۷٪ فراخوانی: ۹۶٪ معيار F ۹۷٪ ارزیابی دوم: ۹۷٪ فراخوانی: ۹۵٪ معيار F	لیست سرشماری ۱۹۹۰ آمریکا، لیست نام بیمارستان های سرشناس ۴ نوع پرونده از مرکز پزشک وندیسیت: خلاصه ترخیص ها، گزارش های آزمایشگاهی، نامه ها و خلاصه دستورها دومن ارزیابی بر اساس خلاصه ترخیص	CRF Aberdeen [۳۷]		
WI-deId	۹۵٪ ارزیابی متین بر شناخته i2b2 با شناسه های	لمنتانه ای مستخرج از مجموعه داده و صفات وب مربوط به شهر، کشور و ایالت (http://en.wikipedia.org/wiki/List_of_United_States_cities_by_population ; http://en.wikipedia.org/wiki/List_of_U.S._stateAbbreviations ; http://en.wikipedia.org/wiki/List_of_countries_and_dependencies_by_area .)	کل پرونده پزشکی	CRF He [۳۸]	
HIPAA	۹۰٪ فراخوانی: ۹۷٪ معيار F ۹۷٪ با شناسه های HIPAA				

قبل و بعد از واژه هدف به تعیین دسته مرتبط با آن (PHI) یا (non PHI) می پردازد. طبقه بندی در این مقاله بر اساس دو

Uzuner و همکاران از SVM به منظور شناسه زدایی استفاده کرده است بدین صورت که سیستم با در نظر گرفتن دو کلمه

لغتنامه‌های پزشکی (مقایسه کلمه با ۱۰ لغتنامه معروف PHIs پزشکی و تعیین حضور و عدم حضور آن) و در نهایت رایج شامل مقایسه کلمه با لیست‌های مربوط به سرشماری ایالات متحده Census Gazetteer) ۱۹۹۰ [http://www.census.gov/geo/www/gazetteer/gazette.html] و عبارات منظمی که برای تشخیص انواع

HIPAA معرفی شده توسط PHIs طراحی شده اند [۳۵]. Xiong و Gardner شناسه‌زدایی از هر دو گروه داده پزشکی چه ساختارمند و چه غیر ساختارمند ارائه کرده که بر اساس CRF طراحی شده است. در این سیستم نیز همچون تمامی روش‌های مبتنی بر یادگیری ماشین در مرحله اول به صورت دستی یا خودکار به برچسبزنی کلمات اسناد پرداخته می‌شود تا به عنوان مجموعه داده آموزش در اختیار طبقه‌بند قرار گیرد؛ اما وجه تمایز این سیستم با سایر روش‌ها در این است که در طول توسعه سیستم دو عمل طبقه‌بندی و برچسبزنی بر اساس نتایج طبقه‌بندی مرتبًا تکرار می‌شوند تا دقت سیستم افزایش یابد [۳۶].

یکی از مهم‌ترین ابتکارات در زمینه شناسه‌زدایی بسته MITRE Identification نرم‌افزاری حذف شناسه (MIST) Scrubber Toolkit است که محیطی تحت وب را برای توسعه شناسه‌زدایی خودکار از انواع متفاوتی از اسناد فراهم می‌کند. MIST به شناسه‌زدایی به صورت یک مسئله برچسبزنی دنباله می‌نگرد و با استفاده از CRF به طبقه‌بندی کلمات به دو گروه جزئی از PHI و عدم ارتباط با PHI پرداخته است. ساختار منعطف این سیستم این اجازه را به کاربران می‌دهد تا ویژگی‌های یادگیری جدیدی را به منظور بالا بردن دقت طبقه‌بند به آن اضافه کنند، در واقع عملکرد این سیستم به مجموعه آموزش آن وابسته است. یکی از مزایای این سیستم این است که برای تیم‌های مختلف پزشکی که قصد شناسه‌زدایی نوع خاصی از متون پزشکی را دارند این امکان را فراهم می‌کند تا سیستم را سفارشی کنند بدون این که نیاز باشد به اصل مدارک پزشکی دسترسی داشته باشند و همین امر باعث شده که در مقالات زیادی برای ارزیابی نکات مختلف شناسه‌زدایی از این سیستم استفاده شود [۳۷]. برای مثال Li و همکاران [۳۸] موضوع تعمیم‌پذیری شناسه‌زدایی ML را مطرح کرده‌اند و به انتخاب داده آموزش مبتنی بر مناسب اشاره دارند. در واقع زمانی که یک مدل بر اساس نوع خاصی از متون بالینی آموزش بییند بهترین پاسخ‌ها را در مرحله آزمون نیز برای همان نوع خاص متون خواهد داشت. این مقاله

دسته ویژگی املایی (شامل طول کلمه، حروف کوچک و بزرگ و ...) و نحوی (شامل POS خود کلمه و کلمات مجاورش) صورت می‌گیرد. این سیستم نقاط ضعفی دارد از جمله این که در آن به نحوه شناسایی انواع PHI به صورت مجزا پرداخته نشده است [۳۳].

Szarvas و همکاران [۳۴] از یک روش طبقه‌بندی با یادگیری تکراری مبتنی بر درخت تصمیم برای شناسه‌زدایی استفاده می‌کند. در این مقاله برای ترکیب سه طبقه‌بند که همگی C4.5 هستند از الگوریتم ترکیبی (Boosting) استفاده شده است. به علاوه برای طبقه‌بندی از ویژگی‌های مختلف کلمات استفاده شده است، برای مثال شناسنامه‌ها از عنوان گزارش‌ها استخراج شده‌اند تا کارایی روش را بهبود دهند، یا مثلاً از عبارات منظم برای توصیف خصوصیات مشترک کلاس‌های داده‌های خوش فرم مثل اعداد و تاریخ‌ها استفاده شده است و ویژگی‌هایی چون طول کلمه، تکرار آن و یکسری لغتنامه برای شناسایی اسمی و محل‌های جغرافیایی مورداستفاده قرار گرفته‌اند. لغتنامه‌هایی که در اینجا استفاده شده است شامل پنج لیست مستخرج از اینترنت برای نام افراد، مکان‌های جغرافیایی آمریکا، کشورها، شهرهای بزرگ جهان و بیماری‌ها و دو لیست از داده‌های non PHI و non NER است. نتایج حاصل از اجرای این سیستم روی مجموعه داده مربوط به چالش پردازش زبان طبیعی (Natural Language Processing i2b2 NLP) در سال ۲۰۰۶ که شامل ۸۸۹ خلاصه ترخیص بی‌نام شده می‌باشد [۲۳] که نشان دهنده عملکرد ضعیف آن در تشخیص برخی شناسه‌ها چون محل، شماره تلفن، نام بیمارستان و تاریخ است.

McMurry و همکاران روشی مبتنی بر J84 ارائه کرده‌اند که بر عکس سایر رویکردها، همزمان با شناسایی PHIs به دنبال کشف کلماتی است که PHI نیستند. در این مقاله دو موضوع مهم مطرح می‌شود، اول اینکه روش ارائه شده برای آموزش به مجموعه داده شناسه‌زدایی شده نیاز ندارد، زیرا از لغتنامه‌ها و مراجعی که برای عموم در دسترس است استفاده می‌کند. دوم اینکه با فرض این که کلماتی در مقالات زیاد تکرار شده‌اند یا در لغتنامه‌های پزشکی آمده‌اند احتمال اینکه PHI باشند بسیار کم است، توانسته همزمان به تعیین PHI و non-PHI پردازد. در این مقاله برای هر کلمه چهار گروه ویژگی استخراج شده است: ویژگی‌های لغوی (POS)، حروف بزرگ موجود در کلمه، طول کلمه، حرف یا عدد بودن آن)، تکرار (تکرار نسبی آن در متون پزشکی عمومی و تخصصی)،

تعدادی نمونه برای آموزش و سپس آزمایش مدل استفاده شود. ویژگی‌هایی که در این کار در نظر گرفته شدند عبارت‌اند از: اساس ویژگی‌های گام دوم و سپس^(۴) (طبقه‌بندی با CRF). این مقاله سیستم پیشنهادی را از دو جهت ارزیابی می‌کند. اول تأثیر مرحله پیش پردازش بررسی می‌شود و سپس به تأثیر هر دسته از ویژگی‌ها در کارایی سیستم پرداخته می‌شود.

۲. روش‌های شناسه‌زدایی ترکیبی

روش‌های شناسه‌زدایی مبتنی بر داده برای یادگیری مدل خود به داده آموزش کامل و جامعی نیاز دارند تا دقت خوبی داشته باشند و این موضوع بزرگ‌ترین ایرادی است که به آن‌ها وارد می‌شود. ازین‌رو برخی از مقالات علاوه بر الگوریتم‌های یادگیری ماشین، با استفاده از تکنیک‌هایی چون تطبیق الگو، جستجو در لغتنامه‌ها و یا تعریف عبارات منظم به تشخیص گروهی از شناسه‌ها پرداخته‌اند. نتیجه نهایی درواقع ترکیبی از خروجی حاصل از دو مدل (مبتنی بر دانش و مبتنی بر داده) می‌باشد^[۴۰]. جدول ۵ خلاصه‌ای از مقالات مربوط به شناسه‌زدایی متون بالینی که از روش‌های ترکیبی بهره برده‌اند را نشان می‌دهد.

پیشنهاد می‌دهد که ابتدا متون بر اساس ویژگی‌های مربوط به پیچیدگی نوشتاری، خوشبندی شوند و سپس از هر خوشبندی خوانایی (که بر اساس تعداد بخش‌های یک کلمه و تعداد کلمات هر جمله برای هر متن محاسبه می‌شود) و غنای متن (هر چه یک متن کلمات منحصر به فرد بیشتری داشته باشد) غنای بیشتری دارد) تأثیر این رویکرد بر شناسه‌زدای MIST (بررسی شده و نشان داده شد که میزان معیار F- (Measure) از ۸۸٪ (در حالتی که نمونه‌ها تصادفی انتخاب شدند) به ۹۲٪ (انتخاب نمونه‌ها از خوشبندی مختلف) افزایش یافت.

و همکاران [۳۹] رویکردی را بر اساس CRF معرفی می‌کنند به نام WI-deId که دارای چهار مازول است: ۱) پیش‌پردازش متن: در این مرحله کارهایی از قبیل مرزبندی جملات و نشانه‌گذاری و سرهم کردن کلمات چند بخشی توسط یک مجموعه عبارات منظم انجام می‌شود، ۲) تولید ویژگی: سه گروه ویژگی به منظور آموزش مدل معرفی می‌شوند شامل ویژگی‌های لغوی، ریخت‌شناسی و لغت‌نامه‌ای، ۳) آموزش بر

جدول ۵: مشخصات سیستم‌های شناسه‌زدایی ترکیبی

نویسنده	روش	نوع متن	منبع دانش	نتایج (درصد)	نام سیستم	شناسه‌ها
Wellner [۴۱]	CRF, HMM, عبارات منظم	خلاصه ترخیص	لیست ایالتهای آمریکا، ماهها و کلمات رایج	۹۹/۲۲: دقت	-	۸ شناسه معرفی شده در ۲۰۰۶
Ferrández [۴۲]	CRF, SVM	خلاصه ترخیص	لیست ایاللهای از سرشماری آمریکا، لیست اسامی ایالتهای شهرها، کشورها و شرکت‌های از وب (Wikipedia, usps.com)	۸۷/۸: دقت ۹۷/۵۰: فراخوانی ۹۷/۲۵: معیار F	BOB	۱۶ شناسه شامل: نام بیمار و بستگان وی، نام ارائه‌دهنده مراقبت، سایر نام‌ها، شهر/خیابان، ایالت/کشور، کد پستی، متفرقه، واحدهای مراقبت سلامت، سایر سازمان‌ها، تاریخ، سن بالای ۸۹ سال، شماره تلفن، آدرس الکترونیک، کد ملی، سایر شماره‌های شناسایی
Dehghan [۴۰]	CRF	از ریاضی اول: اسامی ایاللهای شهرها و شرکت‌های از وب	لیست نام و نام خانوادگی از سرشماری آمریکا، لیست ایاللهای از وب (Wikipedia, usps.com)	۹۲/۱: دقت ۸۶/۴: معیار F1 ۸۹/۷: معیار F2	-	۲۵ شناسه تعریف شده در ۲۰۱۴
Yang [۴۳]	کل برونده پژوهشی و deid	لغت‌نامه‌ای جمع‌آوری شده از ویکی‌پدیا، GATE	لغت‌نامه‌ای جمع‌آوری شده از ویکی‌پدیا، GATE	۹۷/۲۲: دقت ۹۷/۵۰: فراخوانی ۹۴/۸۰: معیار F1 ۹۷/۹۷: ارزیابی دوم ۹۵/۴۲: فراخوانی ۹۶/۶۸: معیار F1	-	۲۵ ارزیابی اول: شناسه معرفی شده توسط HIPAA
	کل برونده پژوهشی و CRF	لغت‌نامه خودساخته	لغت‌نامه خودساخته	۹۷/۱۵: دقت ۹۴/۱۴: فراخوانی ۹۶/۱۱: معیار F1 ۹۸/۸۹: ارزیابی دوم ۹۶/۲۹: فراخوانی ۹۷/۵۷: معیار F1	-	۲۵ ارزیابی اول: شناسه معرفی شده در ۲۰۱۴

جدول ۵: مشخصات سیستم‌های شناسه‌زدایی ترکیبی (ادامه)

			ندارد	کل پرونده پزشکی	Liu [۴۷]	قوانين اگر-آنگاه، عبارات CRF، منظم
از زیبایی اول: ۲۵ شناسه‌های تعریف شده در i2b2-2014	-	از زیبایی اول: ۹۵/۶۴ دقت: فراخوانی: ۹۳/۶۶ میار: F1	ندارد			
از زیبایی دوم: شناسه‌های معرفی شده توسط HIPAA		از زیبایی دوم: ۹۷/۴۸ دقت: فراخوانی: ۹۵/۷۸ میار: F1				
گروه شناسه شامل: ۸ بیمار (نام و نام خانوادگی بیمار و خانواده‌اش)، دکتر (نام و نام خانوادگی پزشکان و سایر ارائه‌دهندگان مراقبت)، نام بیمارستان، شماره-های شناسایی (شامل هر ترکیبی از اعداد و حروف)، تاریخ‌ها، آدرس (ایالت، شهر، نام خیابان، کد پستی، نام و شماره ساختمان‌ها)، شماره تلفن (تلفن، موبایل و فکس)، اعداد Anonym		از زیبایی اول: ۹۸/۹۹ دقت: فراخوانی: ۸۸/۵۹ میار: F	ندارد			
		از زیبایی دوم: ۹۷/۰۶ میار: F				
		از زیبایی سوم: ۸۷/۴۸ میار: F				

بخش ارائه شد: ۱) بهبود هر چه بیشتر محترمانگی اطلاعات بیمار با حذف شناسه‌ها تا جایی که امکان دارد و ۲) سندی که شناسه‌زدایی شد حاوی حداکثر اطلاعات بالینی قبل استفاده باشد. BoB سیستمی ترکیبی است که روش‌های مختلف مبتنی بر پایگاه قانون و یادگیری ماشین را که در شناسایی نوع خاصی از PHIs به خوبی عمل کرده‌اند را یکپارچه می‌نماید. این سیستم برای شناسه‌زدایی دو جزء دارد: استخراج با حساسیت بالا (که از یک مجموعه قوانین و CRF برای تعیین تمامی PHI ممکن در متن استفاده می‌کند) و فیلترسازی مثبت کاذب (که با استفاده از SVM آن دسته از PHIs که در فاز اول به اشتباه برچسب خورده‌اند را حذف می‌کند). در واقع بخش اول باعث افزایش فراخوانی و دومی سبب بالا رفتن دقت می‌گردد. BoB این امکان را فراهم می‌آورد که کلماتی که در بخش اول به اشتباه به عنوان PHI دسته‌بندی شده‌اند مشخص شوند به عبارت دیگر خروجی بخش اول را به دو گروه مثبت‌های کاذب و مثبت‌های درست تقسیم‌بندی می‌کند با این حال این سیستم نیز در تشخیص شناسه‌هایی نظری آدرس و نام سازمان‌ها ضعیف عمل می‌کند [۴۲]. کارایی این سیستم در مقایسه با دو روش مبتنی بر داده MIST و HIDE در مقاله‌ای دیگر توسط Ferrández و همکاران بررسی شده است [۴۳].

دهقان و همکاران [۴۰] روشی برای شرکت در چالش i2b2NLP سال ۲۰۱۴ [۴۴] ارائه کرده که از ترکیب روش‌های مبتنی بر دانش (پایگاه قانون و لغتنامه‌ها) و روش مبتنی بر داده CRF که از ویژگی‌های املایی، موقعیتی، لغوی و معنایی بهره می‌برد، استفاده می‌کند. ابتدا پیش پردازش متون توسط cTAKES [۴۵] و GATE [۴۶] شامل مرزبندی

در مقاله Wellner و همکاران [۴۱] یک سیستم شناسه‌زدایی بر مبنای وفق‌پذیری سریع دو بسته نرم‌افزاری موجود برای شناسایی موجودیت‌های نامدار (Named Entity) LingPipe و Carafe (Recognition) به نام‌های NER (Recognition) ارائه شده است. در این روش به کلمات برچسب‌های خاصی داده می‌شود که نشان‌دهنده این است که آن کلمه ابتداء، انتها یا بخشی از یک PHI هست یا نه (برچسب‌گذاری یک دنباله). همچنین از عبارات منظم برای شناسایی PHIs عددی استفاده می‌گردد. Carafe نرم‌افزاری است که مبتنی بر CRF بوده و قابلیت مهم آن سهولت اضافه کردن ویژگی‌های جدید به آن است، از این طریق محققان به راحتی می‌توانند با اضافه کردن یکسری ویژگی جدید دقت شناسه‌زدایی را افزایش دهنند. سیستم NER دیگری که در این مقاله به کار گرفته شده LingPipe است که بر اساس مدل مخفی مارکف به برچسب زدن کلمات می‌پردازد. سیستم عملکرد ضعیفی در تشخیص برخی شناسه‌ها داشت و پژوهشگران با اضافه کردن عبارات منظم به سیستم توانستند فراخوانی را افزایش دهند. اضافه کردن ویژگی‌های خاص یک وظیفه بر اساس یک مجموعه داده آموزشی محدود و قابلیت تنظیم کردن الگوریتم برای رسیدن به اهداف متفاوت (گاهی اوقات دقت مهم‌تر از فراخوانی است و گاهی بر عکس این موضوع صادق است) از مزایای این سیستم است.

سیستم ارائه شده توسط Ferrández و همکاران به نام BoB(Best-of-Breed) نیز نمونه‌ای دیگر از سیستم‌های ترکیبی است که به شناسه‌زدایی از اسناد بالینی مدیریت Veterans Health) سلامت بازنشستگان جنگ VHA (Administration می‌پردازد. اهداف این مقاله در دو

از دو نوع CRF استفاده می‌کنند، اولی بر مبنای ویژگی‌هایی در سطح نشانه (مثل POS، ویژگی‌های املایی و نمایش کلمات و غیره) و دومی بر مبنای ویژگی‌های کارکتری که از ویژگی‌هایی همانند ویژگی‌های نشانه‌ای استفاده می‌کنند؛ اما در این CRF جمله به بخش‌های جزئی‌تری (کاراکترها) تجزیه می‌شود. طبقه‌بند مبتنی بر قوانین از عبارات منظم به منظور استخراج PHIs استاندارد مثل شماره تلفن، شماره پرونده پزشکی و غیره بهره می‌برد. در نهایت خروجی این سه طبقه بند با استفاده از یک پایگاه قانون یکپارچه می‌شود؛ آن دسته از PHIs که در بین سیستم‌ها مشترک نیستند مستقیماً به عنوان خروجی کل سیستم در نظر گرفته می‌شوند؛ اما برای نمونه PHIs همپوشان اولویت اول با خروجی طبقه‌بند مبتنی بر عبارات منظم است و بعد از آن به ترتیب اولویت با خروجی طبقه‌بندی‌های مبتنی بر کاراکتر و مبتنی بر نشانه است.

Anonym نام نرم‌افزاری است برای شناسه‌زدایی خودکار EHR که توسط مرکز تحقیقات سلامت از راه دور استرالیا توسعه یافته است. Anonym دارای سه ماثول است: ماثول ایجاد ویژگی (استخراج ویژگی‌های زبانی و لغوی)، ماثول یادگیری مدل که از ویژگی‌های استخراج شده در گام اول بهره CRF می‌برد و ماثول دسته‌بندی که مبتنی بر عبارات منظم و می‌باشد. عملکرد این سیستم با سه مجموعه داده مورد ارزیابی قرار گرفته است: مجموعه داده 2006 NLP i2b2، مجموعه داده MTSpamles که شامل ۱۸۸۵ یادداشت بالینی است که به صورت دستی در دانشگاه کالیفرنیا حاشیه‌گذاری شده‌اند و مجموعه سوم که شامل ۸۵۲ گزارش پاتولوژی و سیتوولوژی مرکز تحقیقات سرطان (New South Wales) می‌باشد. این گزارش‌ها کاغذی بوده و با استفاده از فناوری Optical Character Recognition (OCR) به نسخه الکترونیک تبدیل شده‌اند به همین دلیل مانند دو مجموعه قبل کامل نیستند. حاشیه‌گذاری این مجموعه توسط نویسنده‌گان مقاله انجام شده است؛ اگرچه این سیستم در میان تیم‌های شرکت کننده در چالش i2b2NLP در سال ۲۰۰۶ بهترین عملکرد را ارائه داده است؛ اما نتایج این مقاله نشان داد که اگر مجموعه داده آموزش و آزمایش متفاوت باشند این سیستم عملکرد ضعیفی دارد [۴۸].

بحث و نتیجه‌گیری

مزیت روش‌های مبتنی بر دانش که از لغتنامه یا عبارات منظم استفاده می‌کنند این است که به داده‌ای برای آموزش نیاز

نمی‌دانند، نشانه‌گذاری و غیره انجام می‌گیرد. سپس دو مدل مبتنی بر ML و دانش اجرا می‌شوند و پاسخ آن‌ها در سه مدل یکپارچه می‌گردد. نتایج نشان داد که رویکرد پیشنهادی در این مطالعه توانایی تشخیص ابهامات را ندارد برای مثال نمی‌تواند میان ملت و زبان یک فرد تمایز قائل شود.

Yang و همکاران [۳۲] سیستم ترکیبی دیگری را معرفی می‌کنند که مانند مقاله دهقان از CRF، پایگاه قانون و لغتنامه برای تشخیص PHI از متون آزاد پزشکی استفاده می‌کند و از مجموعه داده‌های NLP 2014 i2b2 برای ارزیابی سیستم پیشنهادی بهره برده‌اند. سیستم ارائه شده شامل چهار ماثول پردازشی است: ۱) پیش‌پردازش داده‌ها (مانند نشانه‌گذاری به منظور به دست آوردن ویژگی‌هایی چون POS برای آموزش الگوریتم یادگیری ماشین). همچنین در این بخش یکسری ویژگی‌های مبتنی بر سند مانند عناوین بخش‌ها و ویژگی موقعیت جمله توسط یک مجموعه قوانین دستی استخراج می‌شوند. ۲) ایجاد ویژگی (بخشی از ویژگی‌هایی که برای آموزش الگوریتم یادگیری ماشین لازم هستند در گام اول ایجاد می‌شوند و بخشی در این مرحله، در این مقاله شش دسته ویژگی تعیین شده است: ویژگی‌های در سطح کلمه و جمله، ویژگی‌های املایی، سخنی (Discourse)، متنی و خاص وظیفه (Task-specific). ویژگی‌های خاص وظیفه شامل لیستی است از نام‌ها و مخفف‌های ایالات آمریکا، کشورها، زبان‌ها و ... و عباراتی که نشان‌دهنده وقوع یک PHI هستند مثل "Dr." و ارتباطات میان آن‌ها). ۳) مدل ترکیبی شناسایی PHIs (نویسنده‌گان این مقاله برای تشخیص آن دسته از شناسه‌هایی که برای آن‌ها به قدر کافی نمونه آموزش وجود دارد از الگوریتم یادگیری ماشین CRF استفاده می‌کنند. در واقع چندین CRF هر کدام برای یک زیرمجموعه از PHIs آموزش می‌بینند. برای شناسه‌های باقیمانده از پایگاه قانون و لیست کلمات و عبارات منظم استفاده می‌شود). ۴) پس پردازش (در این مرحله تکنیک‌های زیادی برای ایجاد مجموعه واژگان PHI صحیح، با دو هدف به کار گرفته می‌شود: اصلاح کردن خطاهای مرحله شناسایی واژگان یا پیدا کردن PHIs بیشتر). این مطالعه انواع خطاهای را به خوبی تحلیل کرده و نشان داد که سیستم در تشخیص برخی شناسه‌ها چون مکان، واژگان کم تکرار و خاص و حروف اختصاری با مشکل رویه را است.

در مقاله Liu و همکاران [۴۷] از دو نوع طبقه‌بند برای دسته‌بندی PHIs استفاده شده است: مبتنی بر پایگاه قانون و مبتنی بر یادگیری ماشین. دو طبقه‌بند مبتنی بر یادگیری ماشین

برده‌اند؟ مسئله دیگری که بر کارایی سیستم‌ها تأثیر می‌گذارد روشی که برای نمایش دانش (مانند عبارات منظم) یا استدلال (روش‌های طبقه‌بندی مختلف) انتخاب کرده‌اند می‌باشد. پیامد حاصل از این روش‌ها به شدت به مجموعه ویژگی‌هایی است که برای تشخیص PHIs استفاده می‌کنند. در برخی از این مقالات نتایج حاصل از یک الگوریتم با استفاده از مجموعه ویژگی‌های متفاوتی ارزیابی شده است [۴۷].

یکی از مهم‌ترین و مؤثرترین عامل‌ها در کارایی سیستم‌ها نوع متن است. در حقیقت از منظری دیگر نیز می‌توان مطالعات این حوزه را در دو گروه دسته‌بندی کرد و آن نوع متنی که شناسه‌زدایی شده می‌باشد. اکثر مقالات شناسه‌زدایی بر روی یک نوع متن مثل گزارش‌های پاتولوژی [۳۶] و خلاصه ترخیص [۳۵-۴۱،۳۹،۴۰]. تمرکز داشته‌اند، اما تعدادی از مطالعات نیز روشی را برای شناسه‌زدایی از هر نوع متنی معرفی کرده‌اند [۴۲،۳۷،۴۰،۴۲،۴۷]. بدیهی است که الگوریتم‌های معرفی شده در گروه اول چون از لغتنامه‌های خاص منظوره استفاده کرده‌اند تعیین‌پذیری بالایی نداشته و نمی‌توان از آن‌ها برای شناسه‌زدایی از سایر متنون نیز بهره برد این مسئله در مقاله Zucccon و همکاران بررسی شده است [۴۸]. همچنین در برخی از گزارش‌هایی که در مقالات خاص منظوره استفاده می‌گردد همه انواع شناسه وجود ندارد برای مثال عموماً کد پستی و آدرس محل زندگی در یک گزارش پاتولوژی جراحی ذکر نمی‌گردد. بر اساس جداول ۴ و ۵ مشاهده می‌شود خلاصه ترخیص و پرونده پزشکی (به طور کامل) درصد بیشتری از مطالعات را به خود اختصاص داده‌اند و علت این موضوع چالش‌های i2b2NLP در سال‌های ۲۰۰۶ و ۲۰۱۴ بوده است که در ادامه معرفی می‌شود.

به طور کلی، برای ارزیابی عملکرد روش‌های مختلف شناسه‌زدایی بایستی به توسعه متنون استانداردی پرداخت تا بر اساس آن بتوان نتایج گزارش شده توسط مقالات مختلف را مقایسه کرد. در این راستا گروهی به این موضوع (متن مورد استفاده) پرداخته‌اند و به ایجاد استانداردی طلایی که به عنوان ورودی سیستم‌های شناسه‌زدایی استفاده شود، تأکید دارند. برای مثال کار مشترک پردازش زبان طبیعی The i2b2/UTHealth Informatics for Integrating Biology and the (i2b2) and the University of Texas Bedside Health Science Center at Houston (UTHealth) (natural language processing (NLP) shared task در سال ۲۰۱۴ [۴۴] چهار موضوع مطرح کرد که اولین مورد به بحث شناسه‌زدایی پرونده‌های پزشکی به منظور استفاده مجدد

نداشت. همچنین به روز کردن آن‌ها به راحتی و از طریق اضافه کردن یکسری عبارت منظم / واژه‌الگو امکان‌پذیر است. مهم‌ترین ایرادی که به این الگوریتم‌ها وارد می‌شود تعیین‌پذیری پایین آن‌ها است به عبارتی دیگر این امکان وجود دارد که فرد خبره‌ای مسلط به همه انواع PHI موجود در متن، وجود نداشته باشد. به علاوه برای اضافه کردن یک نوع PHI جدید یا برای توسعه دادن این روش‌ها برای انواع دیگری از متون کار زیادی بایستی انجام گیرد [۲۰]. در حالی که مزیت روش‌های مبتنی بر داده این است که آن‌ها می‌توانند به صورت خودکار الگوهای پیچیده تشخیص PHI را یاد بگیرند و درنتیجه نیازی نیست که توسعه‌دهنگان سیستم اطلاعات زیادی از انواع PHI داشته باشند. این سیستم‌ها تعیین‌پذیری بیشتری نسبت به روش‌های مبتنی بر دانش دارند؛ اما برخلاف آن‌ها توانایی کمی در تشخیص شناسه‌های کمیاب و نادر دارند. همچنین پیچیدگی محاسباتی و سرعت این روش‌ها در طول زمان افزایشی ندارد در حالی که در روش‌های مبتنی بر دانش اگر قرار بود آن‌ها برای حوزه یا نوع جدیدی از داده‌ها به کار گرفته شوند، پیچیدگی آن‌ها افزایش می‌یافتد. مهم‌ترین عیب این روش‌ها نیاز به داشتن یک مجموعه به اندازه کافی بزرگ از داده‌های آموزش است. ایراد دیگری که بر این سیستم‌ها وارد است این است که در صورت وجود خطا تشخیص علت آن دشوار است. فرض کنید که الگوریتم موردنظر در یافتن اسم مربوط به یک محل خاص خوب عمل نمی‌کند نمی‌توان مطمئن بود که با اضافه کردن داده‌های آموزش این مشکل رفع می‌شود [۲۰،۳۷،۴۸]؛ با توجه به مزایا و معایب این دو رویکرد، روش‌های ترکیبی ایجاد شدند که همان‌طور که در جدول ۵ مشاهده می‌شود به نتایج خوبی دست یافته‌اند.

همان‌گونه که در نتایج این مقاله اغلب مقالات کارایی سیستم‌های پیشنهادی خود را بر اساس معیارهایی چون دقت، فراخوانی و معیار-F ارزیابی کرده‌اند. در واقع تمامی این معیارها به حذف هر چه بیشتر و درست‌تر انواع PHI تمرکز دارند؛ اما بدیهی است که با توجه به شرایط خاصی که هر مقاله در بخش تعریف مسئله بیان کرده و تأثیر آن‌ها بر اثربخشی رویکرد پیشنهادی، مقایسه این روش‌ها زیاد منطقی نیست.

یکی از عامل‌های تأثیرگذار بر نتایج حاصل از به کارگیری سیستم‌ها منابع دانشی است که در رویکردهای مختلف مورد استفاده قرار گرفته‌اند. آیا فرد خبره‌ای که برای کار برگزیده‌اند به همه انواع PHI آگاهی داشته است؟ از چه لغتنامه‌هایی و برای تشخیص چه نوع شناسه‌هایی بهره

داشت که تمامی مقالات مورد مطالعه بر متنی که به زبان انگلیسی نوشته شده‌اند تمرکز دارند و همین امر موجب می‌شود تا نتوان به طور قطعی نتیجه گرفت که عملکرد آن‌ها برای سایر زبان‌ها نیز مشابه باشد به خصوص برای زبان‌هایی که از لحاظ ساختاری و نحوی با انگلیسی متفاوت است مانند زبان‌های بدون فاصله ژاپنی و چینی یا زبان راست‌چین فارسی که نحوی متفاوت دارد.

هدف این مطالعه بررسی شناسه‌زدایی به عنوان راه حلی برای حفظ محترمانگی اطلاعات بیماران و تسهیل تحقیقات پزشکی است. در این مقاله مروری بر شناسه‌زدایی مبتنی بر یادگیری ماشین انجام شد و چالش‌های مطرح در به کارگیری و ارزیابی هر کدام از روش‌ها بررسی گشت. اگرچه تمامی مقالات بررسی شده تنها به پروندهای الکترونیک پزشکی که به زبان انگلیسی بودند، پرداخته‌اند؛ اما بسیاری از مسائلی که در آن‌ها مطرح شده بود برای طراحی سیستم شناسه‌زدایی به هر زبانی مشترک است. نتایج نشان می‌دهد که شناسه‌زدایی هرگز باعث حذف تمامی شناسه‌ها نمی‌شود و بنابراین در بررسی عملکرد آن‌ها باید به نوع شناسه‌هایی که در متن باقی می‌ماند توجه شود. نکته قابل توجه این است که با وجود این که هدف شناسه‌زدایی حذف شناسه‌ها است؛ اما باید به موضوعاتی چون احتمال خطر بازشناسی افراد، مناسب بودن داده‌بی‌نام شده برای تحقیقات بالینی و میزان آسیبی که از افسای اخواص شناسه به افراد وارد می‌شود نیز توجه شود که نیازمند کار بیشتر خواهد بود.

تشکر و قدردانی

این مقاله حاصل بخشی از طرح پژوهشی به شماره ۲۷۸۸۱-۱۳۶۰-۰۹۵ می‌باشد که با حمایت دانشگاه علوم پزشکی ایران انجام شده است.

تضاد منافع

بدین‌وسیله نویسنده‌گان تصريح می‌نمایند که هیچ‌گونه تضاد منافعی در خصوص پژوهش حاضر وجود ندارد.

References

1. Faghihi M, Memarzadeh G, Astane H. Protection of patient privacy; A prerequisite for electronic health development. Journal of Medical Ethics 2010;4(2):163-88. Persian
2. Harman LB, Flite CA, Bond K. Electronic health records: privacy, confidentiality, and security. Virtual Mentor 2012;14(9):712-9.

از آن‌ها در تحقیقات و غیره تمرکز دارد. این گروه همچنین، مجموعه داده‌ای با بیش از ۱۳۰۰ پرونده پزشکی که نام‌های بدی برای بیماران آن‌ها استفاده شده است را در اختیار افرادی که بخواهند سیستمی با این مضمون طراحی کنند قرار می‌دهد [۱۵].

در حقیقت پیش از i2b2 مقالات زیادی روی شناسه‌زدایی از متون بالینی کار کرده‌اند؛ اما نتایج آن‌ها با هم قابل مقایسه نبود. i2b2 بستری را برای مقایسه و ارزیابی بهتر سیستم‌های ارائه شده فراهم کرده است. Uzuner که یکی از مسئولان کار مشترک NLP i2b2 است در سال‌های مختلف مروری بر سیستم‌هایی که برای حل این چالش شرکت کرده‌اند، داشته است [۲۷,۲۳].

در این میان، مقالاتی به چالش‌های ایجاد استاندارد طلایی به شکل دستی نیز پرداخته‌اند [۴۹]. برای مثال Deleger و همکاران ابتدا یک گروه کامل از انواع PHI معرفی کرده‌اند و سپس تنها از دو حاشیه‌نویس به منظور حاشیه‌گذاری متون برای کشف انواع PHI، داروها، ارتباطات علائم و بیماری استفاده کرده‌اند [۵۰] هدف Mayer و همکاران [۵۱] نیز NLP ساخت یک مرجع استاندارد برای شناسه‌زدایی مبتنی بر از مجموعه متفاوتی از اسناد بالینی است. ابتدا دو دانشجو روی ۲۰ عدد سند آموزش می‌بینند و سپس ۲۰ سند دیگر را برچسب می‌زنند. موضوع مهمی که در این مقاله به آن پرداخته شده است اهمیت PHIs مختلف است. در واقع برای ارزیابی یک سیستم شناسه‌زدا باید به این نکته توجه شود که سیستم برای چه گروهی از PHIs خوب یا بد کارکرده است (به عبارت دیگر چه PHIs را پیدا نکرده است). از همین رو دو حاشیه‌نویس علاوه بر مشخص کردن PHI به آن‌ها یک رتبه هم اختصاص می‌دهند. سه رتبه‌ای که در این مقاله در نظر گرفته شده عبارت‌اند از: کم، متوسط و زیاد.

اگرچه بررسی نتایج گزارش شده در مقالات دید کلی از مزایا و معایب هر گروه از روش‌های شناسه‌زدایی مبتنی بر ML ایجاد می‌کند؛ اما به منظور مقایسه عملکرد آن‌ها بایستی همگی بر یک نوع متن اعمال شوند. علاوه بر این، باید توجه 3. Andriole KP. Security of electronic medical information and patient privacy: what you need to know. J Am Coll Radiol 2014;11(12 Pt B):1212-6.
4. Gozali E, Langarizadeh M, Sadooghi F, Sadeghi M. Letter to Editor: Electronic Medical Record, Step toward Improving the Quality of Healthcare Services and Treatment Provided to Patients. Journal of Ardabil University of Medical Sciences. 2014;14(1):93-6. Persian

- 5.** Abdelhak M, Grostick S, Hanken MA. Health Information: Management of a Strategic Resource. 4th ed: Louis Missouri: Saunders; 2014.
- 6.** Gozali E, Langarizadeh M, Sadoughi F. a survey of the possibility of electronic medical records implementation in teaching hospitals affiliated to Urmia University of Medical Sciences. *J Urmia Nurs Midwifery Fac* 2013; 11(5):391-7. Persian
- 7.** Pozgar GD, Santucci NM. Legal Aspects of Health Care Administration. USA: Jones & Bartlett Learning; 2003.
- 8.** Farzandipoor M. Review on policies about medical records release in university hospitals in Tehran [dissertation]. Tehran: Iran University of Medical Sciences; 1995. Persian
- 9.** Affairs Dov. Review of Issues Related to the Loss of VA Information Involving the Identity of Millions of Veterans. 2006. Available from: <https://www.va.gov/oig/pubs/VAOIG-06-02238-163.pdf>
- 10.** Fernández-Alemán JL, Señor IC, Lozoya PÁ, Toval A. Security and privacy in electronic health records: a systematic literature review. *J Biomed Inform* 2013;46(3):541-62.
- 11.** Ghaderi NL, Yarmohammadian MH, Raeisi AR, Tavakoli N. Medical record information disclosure laws and policies for purpose law enforcement among selected countries *Health Info Manage* 2011; 8(3):335-44. Persian.
- 12.** Annas GJ. HIPAA regulations - a new era of medical-record privacy? *N Engl J Med* 2003;348(15):1486-90.
- 13.** Wager KA, Lee FW, Glaser JP. Health care information systems: a practical approach for health care management. 3th ed. San Francisco, CA, USA: John Wiley & Sons; 2013.
- 14.** Government Publications Office. Health Insurance Portability And Accountability Act of 1996. [cited 2017 Mar 12]. Available from: <https://www.gpo.gov/fdsys/pkg/PLAW-104publ191/pdf/PLAW-104publ191.pdf>.
- 15.** Stubbs A, Uzuner O. Annotating longitudinal clinical narratives for de-identification: The 2014 i2b2/UTHealth corpus. *J Biomed Inform* 2015;58 Suppl:S20-9.
- 16.** Khorshidi E. Patient's Bill of Rights. [cited 2016 Oct 20]. Available from: <http://www.e-khorshidi-lawyer.ir/index.php?ToDo>ShowArticles&AID=13145> Persian
- 17.** Committee IIIT. IHE IT Infrastructure Handbook De-Identification 2014 [cited 2015 Sep 24]. Available from: http://www.ihe.net/uploadedFiles/Documents/ITI/IHE_ITI_Handbook_De-Identification_Rev1.1_2014-06-06.pdf.
- 18.** Dorr D, Phillips W, Phansalkar S, Sims S, Hurdle J. Assessing the difficulty and time cost of de-identification in clinical narratives. *Methods Inf Med* 2006;45(3):246-52.
- 19.** Gozali E, Langarizadeh M, Sadoughi F. The Ability of Educational Hospitals Affiliated to Urmia University of Medical Sciences in Establishment of Electronic Medical Records from Organizational Perspective. *Iranian Journal of Medical Informatics* 2013;2(3):8-12.
- 20.** Meystre SM, Friedlin FJ, South BR, Shen S, Samore MH. Automatic de-identification of textual documents in the electronic health record: a review of recent research. *BMC Med Res Methodol* 2010;10:70.
- 21.** South BR, Mowery D, Suo Y, Leng J, Ferrández Ó, Meystre SM, et al. Evaluating the effects of machine pre-annotation and an interactive annotation interface on manual de-identification of clinical text. *J Biomed Inform* 2014;50:162-72.
- 22.** Meystre SM, Savova GK, Kipper-Schuler KC, Hurdle JF. Extracting information from textual documents in the electronic health record: a review of recent research. *Yearb Med Inform* 2008;128-44.
- 23.** Uzuner O, Luo Y, Szolovits P. Evaluating the state-of-the-art in automatic de-identification. *J Am Med Inform Assoc* 2007;14(5):550-63.
- 24.** Fenz S, Heurix J, Neubauer T, Rella A. De-identification of unstructured paper-based health records for privacy-preserving secondary use. *J Med Eng Technol* 2014;38(5):260-8.
- 25.** Kayaalp M, Browne AC, Dodd ZA, Sagan P, McDonald CJ, editors. De-identification of Address, Date, and Alphanumeric Identifiers in Narrative Clinical Reports. *AMIA Annu Symp Proc* 2014; 2014: 767-76.
- 26.** Névéol A, Zweigenbaum P. Clinical Natural Language Processing in 2014: Foundational Methods Supporting Efficient Healthcare. *Yearb Med Inform* 2015 ;10(1):194-8.
- 27.** Stubbs A, Kotfila C, Uzuner Ö. Automated systems for the de-identification of longitudinal clinical narratives: Overview of 2014 i2b2/UTHealth shared task Track 1. *J Biomed Inform* 2015;58 Suppl:S11-9.
- 28.** Ferrández O, South BR, Shen S, Friedlin FJ, Samore MH, Meystre SM. Evaluating current automatic de-identification methods with Veteran's health administration clinical documents. *BMC Medical Research Methodology* 2012;12(1):109.
- 29.** Velupillai S, Mowery D, South BR, Kvist M, Dalianis H. Recent Advances in Clinical Natural Language Processing in Support of Semantic Analysis. *Yearb Med Inform* 2015;10(1):183-93.
- 30.** Jaeschke R, Guyatt GH, Sackett DL, Guyatt G, Bass E, Brill-Edwards P, et al. Users' guides to the medical literature. III. How to use an article about a diagnostic test. B. What are the results and will they help me in caring for my patients? The Evidence-Based Medicine Working Group. *JAMA* 1994;271(9):703-7.
- 31.** Hanauer DA, Mei Q, Malin B, Zheng K. Location Bias of Identifiers in Clinical Narratives. *AMIA Annu Symp Proc* 2013; 2013: 560-9.
- 32.** Yang H, Garibaldi JM. Automatic detection of protected health information from clinic narratives. *J Biomed Inform* 2015;58 Suppl:S30-8.
- 33.** Uzuner Ö, Sibanda TC, Luo Y, Szolovits P. A de-identifier for medical discharge summaries. *Artificial Intelligence in Medicine* 2008;42(1):13-35.

- 34.** Szarvas G, Farkas R, Busa-Fekete R. State-of-the-art anonymization of medical records using an iterative machine learning framework. *J Am Med Inform Assoc* 2007;14(5):574-80.
- 35.** McMurry AJ, Fitch B, Savova G, Kohane IS, Reis BY. Improved de-identification of physician notes through integrative modeling of both public and private medical text. *BMC Med Inform Decis Mak* 2013;13:112.
- 36.** Gardner J, Xiong L. HIDE: An Integrated System for Health Information DE-identification. 21st IEEE International Symposium on Computer-Based Medical Systems; 2008 Jun 17-19; Jyvaskyla, Finland: IEEE; 2008.
- 37.** Aberdeen J, Bayer S, Yeniterzi R, Wellner B, Clark C, Hanauer D, et al. The MITRE Identification Scrubber Toolkit: design, training, and assessment. *Int J Med Inform* 2010;79(12):849-59.
- 38.** Li M, Carrell D, Aberdeen J, Hirschman L, Malin BA. De-identification of clinical narratives through writing complexity measures. *Int J Med Inform* 2014;83(10):750-67.
39. He B, Guan Y, Cheng J, Cen K, Hua W. CRFs based de-identification of medical records. *J Biomed Inform* 2015; 58(Suppl): S39–S46.
- 40.** Dehghan A, Kovacevic A, Karytianis G, Keane JA, Nenadic G. Combining knowledge- and data-driven methods for de-identification of clinical narratives. *J Biomed Inform.* 2015;58 Suppl:S53-9.
- 41.** Wellner B, Huyck M, Mardis S, Aberdeen J, Morgan A, Peshkin L, et al. Rapidly retargetable approaches to de-identification in medical records. *J Am Med Inform Assoc* 2007;14(5):564-73.
- 42.** Ferrández O, South BR, Shen S, Friedlin FJ, Samore MH, Meystre SM. BoB, a best-of-breed automated text de-identification system for VHA clinical documents. *J Am Med Inform Assoc* 2013;20(1):77-83.
- 43.** Ferrández O, South BR, Shen S, Friedlin FJ, Samore MH, Meystre SM. Generalizability and comparison of automatic clinical text de-identification methods and resources. *AMIA Annu Symp Proc* 2012;2012:199-208.
- 44.** 2014 NLP Shared Task [cited 2015 Sep 22]. Available from: <https://www.i2b2.org/NLP/HeartDisease/Main.php>.
- 45.** Savova GK, Masanz JJ, Ogren PV, Zheng J, Sohn S, Kipper-Schuler KC, et al. Mayo clinical Text Analysis and Knowledge Extraction System (cTAKES): architecture, component evaluation and applications. *J Am Med Inform Assoc* 2010;17(5):507-13.
- 46.** Cunningham H, Maynard D, Bontcheva K, Tablan V. GATE: A Framework and Graphical Development Environment for Robust NLP Tools and Applications; 2002 Jul 6-12; Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics, Philadelphia, PA, USA: Association for Computational Linguistics; 2002. p. 168-75.
- 47.** Liu Z, Chen Y, Tang B, Wang X, Chen Q, Li H, et al. Automatic de-identification of electronic medical records using token-level and character-level conditional random fields. *J Biomed Inform* 2015;58 Suppl:S47-52.
- 48.** Zuccon G, Kotzur D, Nguyen A, Bergheim A. De-identification of health records using Anonym: effectiveness and robustness across datasets. *Artif Intell Med* 2014;61(3):145-51.
- 49.** Browne AC, Kayaalp M, Dodd ZA, Sagan P, McDonald CJ. The Challenges of Creating a Gold Standard for De-identification Research. *AMIA Annu Symp Proc* 2014;2014:353-8.
- 50.** Deleger L, Li Q, Lingren T, Kaiser M, Molnar K, Stoutenborough L, et al. Building gold standard corpora for medical natural language processing tasks. *AMIA Annu Symp Proc* 2012;2012:144-53.
- 51.** Mayer J, Shen S, South BR, Meystre S, Friedlin FJ, Ray WR, et al. Inductive creation of an annotation schema and a reference standard for de-identification of VA electronic clinical notes. *AMIA Annu Symp Proc* 2009; 2009: 416–20.

De-identification of Electronic Health Records Using Machine Learning Algorithms

Langarizadeh Mostafa¹, Orooji Azam^{2*}

• Received: 17 Jul, 2017

• Accepted: 2 Sep, 2017

Introduction: Electronic Health Record (EHR) contains valuable clinical information that can be useful for activities such as public health surveillance, quality improvement, and research. However, EHRs often contain identifiable health information that their presence limits the use of the records for sharing and secondary usages. De-identification is one of the common methods for protecting the confidentiality of patient information. This systematic review has focused on recently published studies on the usage of de-identification methods based on Machine Learning (ML) approaches for removing all identifiable information from electronic health records.

Methods: A systematic review was performed in electronic databases like PubMed and ScienceDirect between 2006 and 2016. Studies were assessed for adherence to the CASP checklists and reviewed independently by two investigators. Finally, 12 articles were matched with inclusion criteria.

Results: The selected studies have been discussed in terms of used methods and knowledge resources, types of identifiers detected, types of clinical documents, challenges and achieved results. The results showed that ML-based de-identification is a widely invoked approach to protect patient privacy when disclosing clinical data for secondary purposes, such as research. Also, the combination of the ML algorithms and some techniques such as pattern matching and regular expression matching could decrease need to train data.

Conclusion: There is a lot of identifiable information in medical records. This study showed ML-based de-identification methods can intensively reduce the disclosure risk of information.

Keywords: Confidentiality, Privacy, De-identification, Machine Learning

• **Citation:** Langarizadeh M, Orooji A. De-identification of Electronic Health Records Using Machine Learning Algorithms. Journal of Health and Biomedical Informatics 2017; 4(2): 154-167.

1. Ph.D. of Medical Informatics, Health Information Management Dept., School of Health Management and Information Sciences, Iran University of Medical Sciences, Tehran, Iran.

2. Ph.D Student of Medical Informatics, Health Information Management Dept., School of Health Management and Information Sciences, Iran University of Medical Sciences, Tehran, Iran.

*Correspondence: No. 6, Rashid Yasemi Av. Vali-e-Asr St., Vanak Sq., Tehran, Iran.

• Tel: 02188794301

• Email: orooji.a@tak.iums.ac.ir