

نقش شبکه های عصبی مصنوعی در مدلسازی ورودیهای پرونده الکترونیک پزشکی

زهرا زندهش

کارشناس ارشد مهندسی پزشکی - مدیریت فناوری اطلاعات پزشکی
کارشناس تحلیل گر سیستم - مدیریت آمار و فناوری اطلاعات دانشگاه علوم پزشکی تهران
ZZandesh@yahoo.com

چکیده:

رویکرد این مقاله در جهت نشان دادن اهمیت کاربرد تکنولوژی در پزشکی می باشد بویژه در اینترفیس هوشمند سیستم های EMR، که در حال حاضر در برخی از مراکز بهداشتی و درمانی کشور استرالیا مورد استفاده قرار می گیرد این مقاله در مورد پیش بینی نیازهای مدل های ورودی داده ها که می تواند ورود داده ها را در سیستم های online یکپارچه سازد و اینترفیسی که توانایی تطبیق این داده های ضروری با محتوای اختصاص یافته را داشته باشد بحث می کند. هم چنین نشان می دهد که چگونه یک شبکه عصبی مصنوعی خود سازمانده (SOM) که کوهونن می باشد می تواند داده های بیمار را خوشه بندی کند. افزایش کارایی و عکس العمل پزشکان در محیط بالینی نشان دهنده کارایی این سیستم نسبت به سیستم های الکترونیکی غیرهوشمند است. تکنیکهای محاسبات نرم توانایی خوشه بندی ارتباطات پیچیده مابین مشکلات در سوابق بیمار را دارد و می توانند خود را به مدل های احتمالاتی Bayesian نیز نزدیک سازند. این تکنیک در ناحیه عملکردی بسیار مهمی که همان سیستم EMR است اعمال می گردد، کل این کار و جانمایه این کار می تواند در سایر سیستم های Online وارد کننده داده ها نیز اعمال شود.

واژه های کلیدی: پرونده الکترونیک پزشکی، شبکه عصبی مصنوعی، خلاصه پرونده الکترونیک

۱- مقدمه

تکنولوژی به اشکال مختلف از خدمات پزشکی پشتیبانی می کند که یکی از مهم ترین محدوده ها حیطة پرونده الکترونیکی پزشکی (EMR) است. داشتن سیستم های کامپیوتری مدارک پزشکی منافع زیر را در بردارد مانند (پیشرفت درمان بیماری، کاهش هزینه ها، ارتباط بهتر میان داده های به دست آمده از بیمار، [۱] توانایی بیشتر در بالا بردن کیفیت خدمات بهداشتی [۲]) دلایل مختلفی برای رشد آهسته سیستم های کامپیوتری در پزشکی وجود دارد [۳] که از جمله مساله محرمانگی و امنیت داده ها می باشد [۴]. یکی از مهم ترین اجزاء هر سیستم On-line مرحله ورود دادگان می باشد که در میان مشکلاتی مانند عدم وجود استاندارد و تفاوت های موجود میان نسخه های پزشکان نباید به یک فاکتور حاشیه ای مبدل شود. [۵]

Conventional keying , Mouse manipulation مانند Document scanning, Pen points , Vocal input و سایر راهها به دست آید. هر کدام از این راهها این قدرت را دارند که سیستم را استوارتر سازند البته بسته به این که این داده های ورودی در مرحله تولید باشند یا در مرحله شناسایی ، عملکرد متفاوتی خواهند داشت. تولید وظیفه جداگانه ای از شناسایی است و لازمه اش این است که زمانیکه کاربر داده ها را به منظور ورود خلاصه می کند آیا کلیه جنبه هارا در خلاصه کردن آن در نظر گرفته است یا خیر؟ البته این کوچک سازی داده ها به راههای مختلفی انجام می شود. [۶]

در عوض شناسایی شامل انتخاب موارد مختلف ورودی از میان متغیر های ارائه شده می باشد . که ممکن است شامل انتخاب از روی فهرست ها نیز باشد . در هر دو مورد مدل مناسبی که بتواند داده های ضروری را پیش بینی کند و کمک رسان وارد کردن داده ها چه در مرحله تولید و چه در مرحله شناسایی انواع مختلف داده ها باشد مورد نیاز است .

درمان بطور شاخص شامل انواع نسخه ها ، انواع جراحی ها و یا مشاوره ها می باشد . این نوع سازماندهی مدارک پزشکی حرکتی در جهت کد گذاری مدارک پزشکی را نیز با خود همراه خواهد داشت. کد گذاری سنگین و مفهومی نتیجه مفاهیم استنباط شده از مدارک پزشکی است . از زمانیکه امکان کد گذاری Online بوجود آمده است ترقیب بیشتری برای الکترونیکی شدن مدارک نیز ایجاد شده است . این ساختار چهار مدلی مدارک پزشکی مشکل ورود داده ها را سازماندهی و حل کرد . [۷]

در سیستم EMR نوع داده های ورودی ممکن است برحسب بیمار یا پزشک متغیر باشد . شرایطی را که بیمار توصیف می کند از نوع داده هایی است که پزشک باید وارد کند . این اطلاعات با دانش پزشکی گره خورده است. برای مثال دانش نسبت به این که بیمار به بیماری خاصی مبتلا است روی نوع درمانی که برای بهبود بیمار انتخاب می شود تاثیر گذار خواهد بود و دانش نسبت به علائم ، روی تشخیص بهتر بیماری نیز تاثیر گذار خواهد بود و غیره [۸،۹]

هدف از این مقاله معرفی چگونگی مدل کردن و یکپارچه کردن ورودیهای ضروری به منظور پیش بینی کردن داده های ورودی با آدرس های ویژه ای در سیستم EMR است . بویژه به معرفی مدلی می پردازد که به صورت اتوماتیکی از یک شبکه عصبی خود سازمانده کوهونن از مدارک الکترونیکی بیمار بوجود می آید و در نهایت می تواند در تولید خلاصه پرونده الکترونیک از پرونده پزشکی بیمار نیز بسیار موثر واقع شود.

۲- مدل کردن داده های ضروری برای کاربران

تکنیکهای متعددی به منظور پیش بینی ورودیهای ضروری در سیستم های Online مدارک بیمار اعمال شده است. هرمن و اشلیمر [۱۰] چگونگی پر کردن فرمهای online را تشریح نمودند . قوانینی که آیتم های مختلف در فرمها را به هم مربوط می کرد شامل قوانینی می شد که ممکن است ورودیهای کاربران را پیش بینی کند. در نتیجه آزمایش آنان ، در مرحله ورودی سیستم ۹۰٪ فرمها درست پیش بینی شده بودند و در ۸۷٪ موارد نیز شبکه عصبی مصنوعی نقش به سزایی در تکمیل وظیفه کاربران داشت در زمان ذخیره کردن مدارک داشت.

ابرت [۱۱] چگونگی آموزش شبکه های عصبی مصنوعی به منظور کاربرد در جایگاههای مناسب یک سیستم را تشریح کرد. به عنوان نمونه راههای مختلفی برای رسیدن به هدف وجود دارد. آموزش شبکه عصبی مصنوعی یکی از این راههاست که می تواند به کاربران کمک کند و در نهایت ارتباط موثری بوجود آورد.

کانفیلد [۱۲] مدلی بر اساس میزان تکراری بودن داده های موجود در سیستم طراحی کرد. تکراری ترین گزینه ها که در گذشته ایجاد شده بودند برای آینده مورد استفاده قرار می گرفتند. اسپنسلی [۱۳] که یک پزشک عمومی بود مدل ساده تحلیل براساس میزان تکرار را گسترش داد و مدل احتمالاتی شرطی Bayesian را با توانایی پیش بینی ورودیهای آیتیم های مرتبط بوجود آورد. این مدل احتمالاتی توانایی بیشتری در مدل کردن ورودیهای مورد احتیاج کاربران نسبت به مدل مبتنی بر تکرار داشت این نتیجه به پیش بینی برنامه درمانی بر اساس مشکل تشخیص داده شده، نیز تعمیم داده شدو هم چنین از مدلهای آماری مانند رگرسیون های چند گانه خطی و شاخص های تحلیلی جهت تشریح استفاده کرد، مدل احتمالاتی به طور بارزی بهتر و موثرتر است. این مدل مشکل مدلسازی دادگان پزشکان عمومی را با ایجاد مدلی به منظور ورود داده ها در سیستم EMR که بر مبنای مدل احتمالاتی کار می کند حل می نماید. به خصوص که از شبکه عصبی مصنوعی برای خوشه بندی داده ها استفاده می نماید. [۱۴]

در مدل دیگری در کشور استرالیا داده های بیمار شامل تعدادی از کدهای بیماری و هم چنین برنامه های درمانی درویزیتهای مختلف می باشد. کلیه مشکلات هر بیماری در بردار یا مولفه منفرد جمع می شود که در نهایت در بردارنده خلاصه سابقه بیمار خواهد بود. این مولفه ها سپس توسط شبکه خود سازمانده کوهونن در طبقات مختلف خوشه بندی می شود که مبنای آن سوابق بیمار خواهد بود.

سپس به طور مجزا یک مدل احتمالاتی برای هر طبقه ای با در نظر گرفتن بیماران آن طبقه و تشخیص ها و برنامه های درمانی موجود در مدارک پزشکی آنها اختصاص داده شده بود. این مدل با وارد کردن داده های ضروری اولیه یک بیمار جدید به منظور پیش بینی برنامه درمانی آزمایش شد. در ابتدا بیمار بر اساس مشکلات موجود در سابقه اش طبقه بندی شد، طبقه بیمار تعریف شد و مدل احتمالاتی مناسب با آن طبقه شروع به فعالیت کرد. سپس این مدل در ویزیتهای جدید اقدام به پیش بینی برنامه درمانی بر اساس مشکلات نمود. نتایج به دست آمده نشان داد که خوشه بندی داده ها و پیاده سازی انفرادی مدلهای احتمالاتی Bayesian در هر طبقه می تواند توانایی پیش بینی یک مدل احتمالاتی واحد برای کل داده ها را افزایش دهد. این موضوع کاملاً صحیح است که در طبقاتی که بر مبنای طول رشته ها^۱ بوجود آمده، اطلاعات ناپایدار در داده ها بسیار ارزشمند می باشد. لازم به ذکر است شبکه عصبی مصنوعی تاثیر بیشتری نسبت به سایر تکنیکهای آماری در این حیطه داشتند.

این مدل در کاربرد های مختلف برای وارد کردن داده های ضروری مورد استفاده قرار می گیرد. برای مثال پیش بینی ممکن است در بخشهای مختلفی کاربرد داشته باشد.

۱. قرار دادن داده ها به صورت پیش فرض در هر فیلدی (که نتیجه فقط با یک کلیک کردن ساده و یا وارد کردن یک حرف از ورودی کل ، ورودی نهایی قابل بازیابی باشد).
 ۲. بوجود آوردن منوهای تشکیلی یافته از گزینه هایی که بیشترین ارتباط را با یکدیگر دارند .
 ۳. کامل کردن واژه های کلیدی همانطور که در سیستم های کاغذی نوشته یا تایپ می شوند (که در نتیجه زمان لازم برای وارد کردن اسامی طولانی داروها را کاهش می دهد)
 ۴. شناسایی حروف در زمان نوشتن از دست نوشته ها و یا شناسایی آوای کلمات در سیستم های باز شناسی گفتار
 ۵. دستیابی به کلیه عوامل مرتبط با یکدیگر
- یکی از مهم ترین روشهای کاربری مدل پیش بینی ، ایجاد متن های مرتبط با فهرست ها و در نتیجه تطبیق سیستم به ویژه با تاثیر متقابل آن در محتوا می باشد .

۳-روش اجرای پروژه

پایگاه داده پرونده های پزشکی الکترونیکی از ۲۳۴۵ بیمار جمع آوری شده این دادگان از طریق ویزیت های یک پزشک در استرالیا جمع آوری و ارائه گردید. این پرونده ها مطابق با فرمت نوشتاری SOAP^۲ بودند. به طور اختصاصی هر پرونده شامل فیلدهای تشخیصی کد شده و فیلد درمانی است. کدهای تشخیصی بر اساس کدهای بین المللی تعریف شده بودند. در این پایگاه داده ۷۵۷ کد یکتا وجود داشت و فیلد درمانی شامل داروهای تجویز شده بود. نام داروها نیز در این فیلد کد شده بودند. این پایگاه داده شامل ۳۹۳ درمان دارویی نیز بود. کدهای درمانی و مشکلات تشخیصی هر ویزیت نیز در این مطالعه مورد استفاده قرار گرفت. هر بیمار بین ۱ تا ۱۳۳ ویزیت داشته است که در مجموع ۱۳۹۰۷ ویزیت گزارش شده بود. بیماران که ۵، ۱۰، ۱۵ و ۲۰ مراجعه داشتند، مشخص شدند.

یک نگاشت خود سازمانده کوهونن با یک لایه خروجی ۵×۵ و یک لایه ورودی ۷۵۷ عضوی پیاده سازی شد. از یک تابع همسایگی مربع استفاده گردید که در ابتدا این تابع منطبق با اندازه لایه خروجی بود. در طی تعلیم این همسایگی بعد از هر گذر از دادگان تعلیم کاهش یافت و کوچکتر شد. ده گذر از طریق دادگان تعلیم صورت گرفت. این مکانیزم موجب شد که یک گره خروجی متناوباً به عنوان گره برنده انتخاب نشود (مکانیسم De seino). [۱۶]

بیمارانی با مشکلات دائمی در تمامی ویزیت هایشان با نمایان ساختن یک بردار خلاصه مشخص گردیدند این بردارهای خوشه بندی شده در شبکه عصبی استفاده می شوند. این شبکه SOM بردارها را بر اساس شباهت الگوها خوشه بندی می کند. بردارهای با ویژگی های مشابه در مناطق یکسانی از نگاشت خروجی قرار می گیرند. در این روش دسته های بیماران بر اساس مشخصات و ویژگی های سابقه بیماری شان مشخص می شود. دسته های بیماران که بر اساس سابقه بیماری ایجاد شده بود برای ایجاد ۲۵ مدل احتمالاتی مجزا مورد استفاده قرار گرفتند. این ۲۵ مدل با شناسایی دسته بندی این بیماران در دسته های مخصوص و بازیابی

ویزیت‌های فردی هر بیمار به دست آمد. ویزیت فرد را می‌توان به عنوان نمونه‌ای از مدل احتمالاتی برای مشخصات درمانی و مشکل بیمار که از دسته مربوطه ناشی شده است، ذکر کرد.

اندازه‌گیری عملکرد مدل شامل محاسبه Hit-rate با تعیین نسبت داروهای پیش‌بینی شده و داروهای مورد نیاز است. Hit-rateها بیشتر از ۲۰ پیش‌گویی دارویی مدل را تعیین می‌کردند. اگر این مدل برای تولید یک منوی انشعابی هوشمند استفاده شود، حتی امکان پیش‌بینی‌های متعددی نیز در متن دارد مثل ورودی دست‌خط یا ورودی‌های گفتاری که با ارزش باشد. خوشه‌بندی ۲۵ مدل احتمالاتی مجزا با استفاده از ویزیت‌های به دست آمده از بیماران، آزمایش شدند. ابتدا دسته مشکلات و مسائلی که زیاد تکرار شده بودند بر روی سابقه بیمار ایجاد گردید و مدل احتمالات مناسبی دوباره به دست آمد. مشکلات موجود در ویزیت کنونی بیمار برای پیش‌بینی درمان مناسبی بر اساس مدل احتمالاتی مطلوب مورد استفاده قرار گرفت. نتایج به دست آمده از ۲۵ مدل احتمالاتی بر اساس سابقه مجموعه نوروهای برانگیخته با مدل‌های احتمالاتی ساده به دست آمده از دادگان خوشه‌بندی نشده مقایسه شدند.

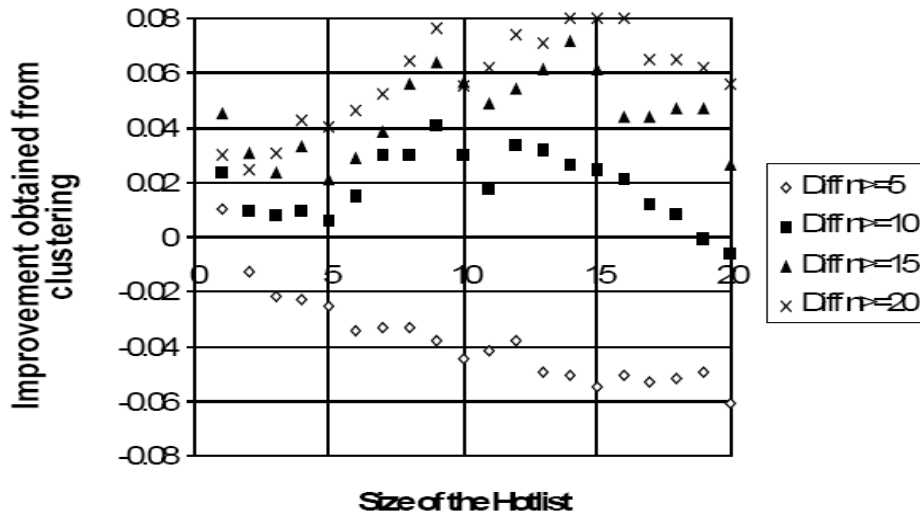
نتایج نشان دادند که سوابق بیماری گزارش شده در توالی از ویزیت‌هایی که بسیار تکرار شده بودند مانعی برای به دست آوردن اطلاعات مفید برای خوشه‌بندی دادگان است. این نتیجه بعداً با استفاده از توالی‌های ویزیت‌هایی که کمتر تکرار شده بودند مورد آزمایش قرار گرفت. برای آزمایش شبکه از ویزیت‌هایی با تکرار کمتر استفاده شد. در حالی که برای ارزیابی شبکه از مجموعه دادگان آموزشی شبکه یعنی ویزیت‌هایی با تکرارهای بیشتر استفاده شد.

مدل‌های احتمالاتی دوباره بر اساس خوشه‌بندی‌های ایجاد شده توسط دادگان تولید شدند. همچنین hit-rateها برای hot listهایی با طول ۱ تا ۲۰ تعیین شدند. علی‌الخصوص بیمارانی با سابقه مراجعه بیشتر از ۱۰، ۱۵ و ۲۰ با استفاده از شبکه به دست آمده از دادگان گذشته خوشه‌بندی شده از ۲۰ ویزیت یا بیشتر خوشه‌بندی شدند.

۴- نتایج و بحث‌ها

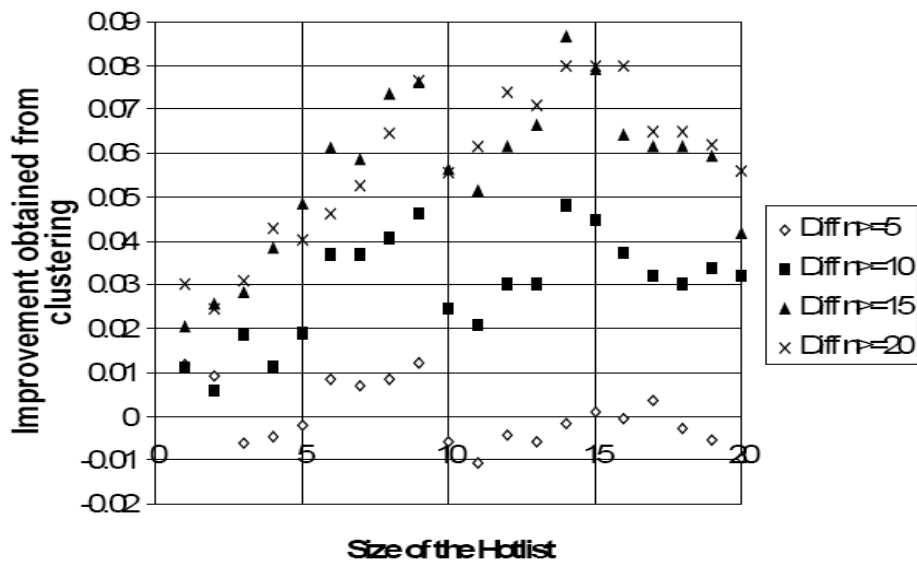
نتایج نشان دادند که قدرت پیش‌گویی مدل احتمالاتی ممکن است با استفاده از خوشه‌بندی بر اساس سوابقی که بسیار تکرار می‌شوند، بهبود یابند. شکل ۱ تفاوت hit-rateها را برای دادگان خوشه‌بندی شده و خوشه‌بندی نشده نشان می‌دهد. یک تفاوت مشهود حاکی از این امر است که دادگان خوشه‌بندی شده نتایج بهتری را به دست می‌آورند، علی‌الخصوص hit-rateهای بهتر برای توالی‌هایی که بسیار تکرار می‌شوند که شامل ۱۰، ۱۵ و ۲۰ مراجعه یا بیشتر هستند، دیده می‌شوند. کاهش قدرت پیش‌گویی بیانگر توالی‌هایی از ویزیت‌هایی است که کمتر مراجعه داشته‌اند. Hit-rateها برای بیمارانی با ۵ ویزیت و یا بیشتر به شدت کاهش می‌یابد. (که در شکل ۱ با علامت \diamond مشخص شده‌اند).

احتمالاً الگوی کافی در تاریخچه برای توزیع مناسب دادگان وجود ندارد و در نتیجه توزیع اطلاعات موجود در خوشه‌ها را کاهش می‌دهد. در مقابل زمانی که خوشه‌بندی بر اساس طول توالی‌های ویزیت‌هایی که بسیار تکرار می‌شوند باشد، بهبود بسیار چشمگیر است (که در شکل ۱ با علامت \times مشخص شده‌اند).



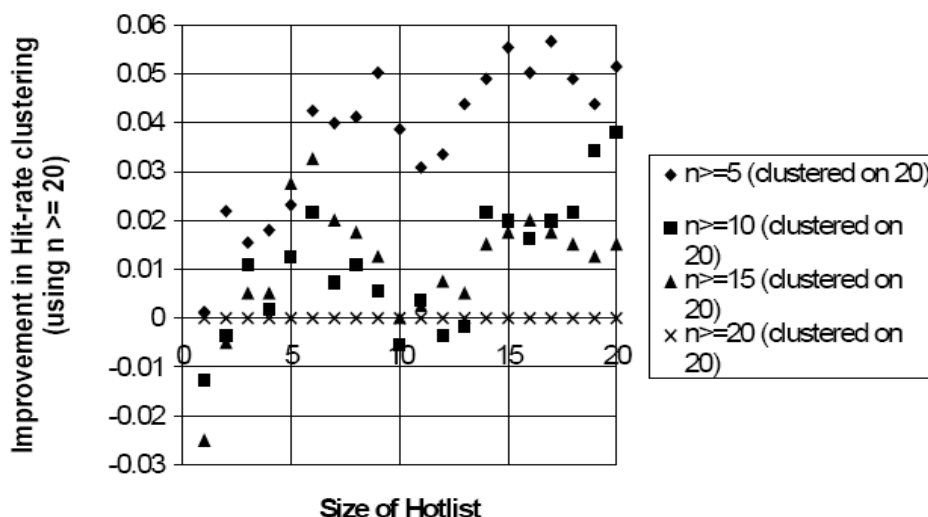
شکل ۱: بهبود hit-rate به دست آمده از خوشه‌بندی روی مجموعه دادگانی که بسیار تکرار می‌شوند ($n \geq 20$ و $n \geq 15$, $n \geq 10$, $n \geq 5$)

توالی‌های بیست تایی یا بیشتر از ویزیت بهترین بهبود را در hit-rate‌های به دست آورند. شبکه آموزش دیده با توالی‌های ویزیت‌هایی که بسیار تکرار شده بودند به عنوان دادگان آموزشی، توالی‌های ویزیت‌هایی که کمتر تکرار شده بود را خوشه‌بندی کرد و نتایج بهتری را در hit-rate‌های به دست آمده از خوشه‌بندی توالی‌های ویزیت‌هایی که کمتر تکرار شده بودند را نشان دادند. (شکل ۲)



شکل ۲: بهبود hit-rate‌های به دست آمده از خوشه‌بندی در توالی‌هایی که بسیار تکرار شده بودند

شکل ۲ تفاوت hit-rate‌های به دست آمده از دادگان خوشه‌بندی شده با نمونه‌هایی با دفعات مراجعه زیاد و مدل‌های احتمالاتی انفرادی را نشان می‌دهد.



شکل ۳: بهبود hit-rate با استفاده از توالی‌های visit‌هایی با تعداد تکرار زیاد $n \geq 20$ برای خوشه‌بندی.

شکل ۳ تفاوت hit-rate‌های به دست آمده بین خوشه‌بندی‌های بر اساس توالی‌های با تعداد مراجعه بسیار زیاد $n \geq 20$ و خوشه‌بندی‌های بر اساس توالی‌هایی با تعداد مراجعه $n \geq 5$ ، $n \geq 10$ و $n \geq 15$ را نشان می‌دهد. به طور کلی یک بهبود در تمامی نتایج دیده می‌شود. یک استثنا وجود دارد و آن زمانی است که خوشه‌بندی بر اساس اطلاعاتی با تعداد دفعات مراجعه بسیار زیاد مفید نبود.

۵- نتیجه‌گیری

این مقاله در مورد چگونگی پیش‌بینی نیازهای مدل‌های ورودی داده‌ها که می‌تواند ورود داده‌ها را در سیستم‌های online یکپارچه سازد و اینترفیس‌هایی که توانایی تطبیق این داده‌های ضروری با محتوای اختصاص یافته را داشته باشد بحث می‌کند.

کاری که انجام شده مدل‌های احتمالاتی ساده و بسیار موثر در مدل‌سازی داده‌ها ضروری را معرفی می‌کند. هدف این مقاله پیش‌بینی بهتر مدل‌های یکپارچه خوشه‌بندی داده‌ها با استفاده از شبکه خود سازمانده کوهونن می‌باشد. شبکه کوهونن به منظور خوشه‌بندی داده‌ها در ۲۵ طبقه مجزا استفاده شد. این طبقات بر مبنای مشکلات مهم سوابق بیماران سازمان یافته‌اند. مدل احتمالاتی جداگانه‌ای به طور مجزا در هر کدام از این طبقات بیماران اعمال شد این مدل‌ها پس از عمل خوشه‌بندی، داده‌های مورد نیاز در ویزیت بعدی بیمار را پیش‌بینی می‌کردند.

نتایج نشان داد که داده‌های خوشه‌بندی شده توانایی پیش‌بینی مدل‌های احتمالاتی انفرادی را نیز افزایش دادند. خصوصاً این کار زمانی بهتر انجام می‌شود که توالی طولانی‌تری از ویزیت‌های متعدد بیمار مبنای خوشه‌بندی قرار بگیرد. در نتیجه اطلاعات گذشته مشکلات بیمار مفید است و می‌تواند به عنوان مبنایی برای تقسیم بهتر داده‌ها و پدید آوردن مدل‌های احتمالاتی کارآمدتر در نظر گرفته شود.

مسیر دیگر برای انجام این کار توسعه اینترفیس اولیه سیستم EMR که می‌تواند در موقعیت‌های بالینی نیز مورد استفاده قرار گیرد باشد. این اینترفیس می‌تواند در مدل پیش‌بینی مشارکت کند و می‌تواند مدل‌های احتمالاتی را به ازای هر ویزیت افزایش دهد. روش‌های ارزیابی سیستم در محیط بالینی با توجه به پیشرفت کارایی و عکس‌العمل پزشکان نشان‌دهنده کارایی این سیستم نسبت به سیستم غیر الکترونیکی

غیر هوشمند است. هم چنین ممکن است داده های بیشتری از پزشکان مختلف در تعریف درجه شباهت و اختلاف موجود ما بین عملکردهای آنها به دست آید مانند تفاوتهایی که در جمعیت بیماران و پزشکان به چشم می خورد. یکپارچه سازی شبکه عصبی کاربرد بهتری در خوشه بندی داده ها بر اساس مشکلات سوابق انواع بیماران دارد. تکنیکهای محاسبات نرم توانایی خوشه بندی ارتباطات پیچیده مابین مشکلات در سوابق بیمار را دارد و می توانند خود را به مدل‌های احتمالاتی Bayesian نیز نزدیک سازند..

مراجع

[۱] R.S. Dick and R.B. Sheen, "The computer-based patient record : an essential technology for health care". Washington DC, National Academy Press (۱۹۹۱).

[۲] T. J. Hannan, "Quality of Care - Input/Processes/Output. How does information management within electronic medical record systems change the processes in the quality of health care?", Fifth Health Informatics Association of New South Wales Conference (HINASW '۹۶), Wollongong, ۹-۱۱ February (۱۹۹۶).

[۳] G.O. Barnett, "The Application of Computer Based Medical Record Systems in Ambulatory Practice". New Eng J Med. ۳۱۰, ۱۹۸۴, ۱۶۴۳ - ۱۶۵۰.

[۴] M. Pringle, S. Robins and G. Brown, "Computers in the surgery : the patient's view". BMJ; ۲۸۸: ۱۹۸۴, ۲۸۹ - ۲۹۱.

[۵] D. V. O' Dell, T. G. Tape and J. R. Campbell, "Increasing Physician Acceptance and use of the Computerized Ambulatory Medical Record". Symposium on Computer Applications in Medical Care, ۱۹۹۱, ۸۴۸ - ۸۵۲.

[۶] L. Weed, Medical Records. Medical Education and Patient Care, Case Western Reserve, Cleveland, (۱۹۶۹, Ohio Press).

[۷] SNOMED, College of American Pathologists. SNOMED III, Systematized Nomenclature of Medicine Version ۳, International, Illinois, (۱۹۹۳).

[۸] T. Kohonen. "Self-organized formation of topologically correct feature maps", Biological Cybernetics ۴۳, ۱۹۸۲, ۵۹ - ۶۹.

[۹] T. Kohonen. Chapter ۵ "Self-organization and associative memory", ۲nd ed. New York : Springer-Verlag, ۱۹۸۸.

[۱۰] L. A. Hermens and J. C. Schlimmer, "A machine learning apprentice for the completion of repetitive forms", IEEE Expert ۹ (Sept), ۱۹۹۴, ۲۸ - ۳۳.

[۱۱] R. Eberts, L. Villegas, C. Phillips and C. Eberts, "Using neural net modeling for user assistance in HCI tasks". International Journal of Human-Computer Interaction, ۱۹۹۲, ۵۹ - ۷۷.

[۱۲] K. Canfield, "Priming intelligent split menus with text corpora for computerized patient record data-entry". International Journal of Biomedical Computing ۳۹, ۱۹۹۵, ۲۶۳ - ۲۷۳.

[۱۳] S. E. Spenceley, J. R. Warren and S. K. Mudali, Kirkwood I, "Intelligent Data Entry for Physicians by Machine Learning of an Anticipative Task Mode", in V.L. Narasimhan and L.C. Jain eds, Proceedings of the Fourth Australian and New Zealand Intelligent Information System Conference (ANZIIS-۹۶), Piscataway, New Jersey, IEEE ۶۴-۶۷, (۱۹۹۷).

[۱۴] S. E. Spenceley, J. R. Warren and S. K. Mudali, "Toward the Intelligent Physicians' Interface : use of diagnosis codes to anticipate drug therapy", Technical Report CIS-۹۶-۰۰۴, Department of Computer and Information Science, University of South Australia (۱۹۹۶).

[۱۵] Sears and Schneiderman. "Split Menus : Effectively using selection frequency to organise menus", ACM TOCHI ۱(۱), ۱۹۹۵, ۲ - ۵۱.

[۱۶] Neural Computing : A Technology handbook for professional II/ PLUS and NeuralWorks Explorer (NeuralWare Inc. Penn Center West, Building IV, Pittsburgh, PS ۱۵۲۷۶), NeuralWare, ۱۹۹۳.

Neural Network role in modeling the input requirement for electronic medical record

Zahra Zandesh

MSc biomedical engineering –Medical Information Technology Management
Information Technology analyst –IT Center of Tehran University of Medical Science - IRAN

Abstract

This paper presents work that has been conducted towards predicting user input requirements with view to making an intelligent interface to support data input in the context of an online electronic medical record system .the paper investigates how an artificial neural network ,the self organizing feature map (SOM)suggested by kohonen , may cluster patient data .separate Bayesian probability models (for treatment given diagnoses)are derived for each cluster class (on SOM with ν output layer nodes). Clustering are made on the basis of aggregate diagnoses over all the visits for particular patients considering longitudinal sequences of $n \geq 0$, $n \geq 1$, $n \geq 10$, and $n \geq \nu$ visits.

Clusterings produced from the longest visit sequence ($n \geq \nu$) are found to be most useful in clustering the data .the predictions made from the ν separate probability models compare most favorably with predictions made by a single probability model derived from unclustered Data . clustering based upon shorter visit sequence also makes an improvement to the predictions made with unclustered data .the improved predictive power is explained by the use of longitudinal information ie . patient history .the improved power translates into better prediction of the input requirements and hence user need.

Keyword: Electronic Medical Record , Neural Network ,Electronic Discharge summery