

پیش‌بینی بیماری قلبی با استفاده از تکنیک داده کاوی شبکه عصبی

مریم کاظمی^۱، حسین مهدی زاده^{*۲}، اردشیر شیری^۳

- (۱) دانشگاه علوم پزشکی ایلام، ایلام، ایران
 (۲) گروه کارآفرینی و توسعه روستایی، دانشکده کشاورزی، دانشگاه ایلام، ایلام، ایران
 (۳) گروه مدیریت، دانشکده ادبیات و علوم انسانی، دانشگاه ایلام، ایلام، ایران

تاریخ پذیرش: ۹۴/۱۲/۸

تاریخ دریافت: ۹۴/۱/۱۶

چکیده

مقدمه: داده کاوی به بررسی و تجزیه و تحلیل مقادیر عظیمی از داده ها به منظور کشف الگوها و قوانین معنی دار اطلاق می‌شود که "عمدتاً" از طریق ساختن مدل ها و الگوریتم ها، ورودی ها را با هدف خاصی مرتبط می نماید. گاهی تکنیک های داده کاوی منجر به شناسایی الگوریتم های معنادار می شوند که می توانند با استفاده از داده های موجود و در دسترس و با هزینه کم، زمینه های ابتلاء، پیشگیری و درمان بیماری ها را در پزشکی فراهم آورده و پزشک ها را در تشخوص به موقع باری رساند.

مواد و روش ها: این مطالعه با هدف استفاده مدیران بیمارستان از نتایج حاصل از داده کاوی سیستم های اطلاعات بیمارستانی جهت پیش‌بینی دقیق تر و تصمیم گیری مؤثرتر در درمان بیماران صورت گرفته است. داده های مورد استفاده در این مطالعه، مربوط به اطلاعات ۲۷۰ بیمار است که از انبار داده سایت UCI استخراج شده و شامل ۱۴ متغیر است. از مدل "شبکه عصبی" برای پیش-بینی مبتلا بودن به بیماری قلبی استفاده شده و دقت پیش‌بینی آن مورد بررسی و مقایسه قرار گرفته است.

یافته های پژوهش: بر اساس نتایج مشاهده می شود مدل شبکه عصبی با ساختار پرسپترون چند لایه با دقتی برابر با ۸۳.۳۳٪ عمل کلاس‌بندی را برای مجموعه مشاهدات آزمون انجام داده است.

بحث و نتیجه گیری: نتایج نشان داد که دقت مدل در کلاس‌بندی رکوردها از لحاظ متغیر پاسخ بیماری قلبی (*Heart-dis*) برای مجموعه رکوردهای مدل ساز ۸۷.۷۵٪ و برای مجموعه رکوردهای آزمون ۸۳.۳۳٪ می باشد. همچنین متغیرهای تعداد عروق بزرگ (*Nbr-ve*s)، کاهش استرس (*Defect*), نقص (*ST-dep*), درد قفسه سینه (*Chest-pain*), اوج استرس (*Peak-ST*), ضربان قلب (*Heart-rate*), آرثرين (*Angina*), جنسیت (*Sex*), سن (*Age*), ایستایی نوار قلب (*Res-elec*), فشار خون (*Blood-press*), قندخون (*Blood-sugar*) و کلسترول سرم (*Serum-chol*) به ترتیب بیشترین اهمیت را از لحاظ مدل "شبکه عصبی با ساختار پرسپترون چند لایه" در پیش‌بینی متغیر پاسخ بیماری قلبی (*Heart-dis*) دارند.

کلمات کلیدی: داده کاوی، شبکه عصبی، بیماری قلبی

* نویسنده مسئول: گروه کارآفرینی و توسعه روستایی، دانشکده کشاورزی، دانشگاه ایلام، ایلام، ایران

Email: Hossein.mahdizadeh@ilam.ac.ir

جمله شیوه هایی است که می تواند این صنعت را از تحلیل عمیق این داده ها بهره مند سازد و به توسعه ای تحقیقات پزشکی و تصمیم گیری های علمی در زمینه‌ی تشخیص و درمان منتج شود(۳).

امروزه در دانش پزشکی جمع آوری داده های فراوان در مورد بیماری های مختلف از اهمیت فراوانی برخوردار است. مراکز پزشکی با مقاصد گوناگونی به جمع آوری این داده ها می پردازند. تحقیق روی این داده ها و به دست آوردن نتایج و الگوهای مفید در رابطه با بیماری ها، یکی از اهداف استفاده از این داده ها است. حجم زیاد این داده ها و سردرگمی حاصل از آن مشکلی است که مانع رسیدن به نتایج قابل توجه می شود. بنابراین از داده کاوی برای غلبه بر این مشکل و به دست آوردن روابط مفید بین عوامل خطرزا در بیماری های قلب و عروق استفاده می شود. این بیماری ها با توجه به شیوه و سهمنی که در مرگ و میر انسان ها دارند از اهمیت بالایی برخوردارند. داده کاوی دانش استخراج روابط و الگوهای مفید پنهان در حجم زیاد دارد(۲).

تحول در صنعت سلامت به واسطه این هدف واحد که چگونه سازمانهای سلامت هزینه ها را کاهش و کیفیت را افزایش دهند و هم چنان رقابتی بمانند؟ به پیش می رود و این مقوله همواره یک چالش بزرگ محسوب می شود. بهبود کیفیت در صنعت سلامت را می توان به واسطه نیروهای محركی که بر آن تاثیرگذار است بهتر تعریف نمود و از جمله این نیروهای محرك، داده های سلامت است، به عبارت دیگر در هر نوع برنامه‌ی بهبود کیفیت متتمرکز بر بیمار، داده ها قلب آن برنامه به حساب می آید. داده ها در عصر امروزی یعنی عصر اطلاعات، عمدۀ ترین دارایی برای سازمان های سلامت بوده و موقیت های سازمان های سلامت در گروی جمع آوری، ذخیره و تحلیل آنها است. با این وجود، جمع آوری و ذخیره ی میزان زیادی از داده ها به شکل سودمند استفاده شده و تبدیل به یک منبع مالی برای سازمان گردد. برای تبدیل این ارزش بالقوه به اطلاعات استراتژیک، بسیاری از سازمان ها به داده کاوی روی آورده اند، چرا که به واسطه داده کاوی امکان کشف روابط، روندها و الگوهای مخفی بین داده

مقدمه

امروزه مدیریت یکی از ارکان اساسی اداره جوامع است، زیرا ترکیب و تلفیق مناسب عوامل موجود و ایجاد هماهنگی میان آنها در نتیجه تصمیم گیری صحیح برای رسیدن به هدف مورد نظر حاصل می شود. تصمیم گیری و مدیریت را می توان مترادف دانست.

زیرا تصمیم گیری جزء اصلی مدیریت است(۱).

اطلاعات اساس تصمیم گیری است. مدیر برای تصمیم گیری صحیح نیاز به استفاده از اطلاعات درست و نیز ابزارها و مدل های تصمیم گیری دارد. همکاری متخصصان در زمینه کامپیوتر و پزشکی راه حل جدیدی را در تحلیل این داده ها و به دست آوردن الگوهای مفید و کاربردی ارائه می دهد که همان داده کاوی است. در داده کاوی برخلاف علم آمار به دنبال پیشگویی هستند نه کشف یا اثبات. بدین معنا که با استفاده از روش های داده کاوی به دنبال تأیید آنچه از قبل وجود دارد نیستند، بلکه به دنبال مشخص کردن الگوهای از قبل شناخته نشده هستند(۲).

در واقع داده کاوی شکل پیشرفتۀ پشتیبانی از تصمیم است و برخلاف ابزارهای پرس و جوی غیرفعال Passive، بدون الزام به طرح سوال از طرف کاربر، به تولید الگو، روندها و قواعد برنامه ریزی شده می پردازد. به عبارت دیگر قدرت داده کاوی در این است که می تواند الگوهایی را که در جستجوی کاربر مورد توجه قرار نگرفته است، افشا کند و پاسخ هایی را برای سوالاتی که هرگز درخواست نشده بود، تولید نماید(۳).

در حقیقت بیان کاربرد عملی داده کاوی در حوزه های مختلف، با استفاده از داده های ثبت شده در پایگاه داده است که به فراهم کردن اطلاعات ضروری و دانش مورد نیاز پزشکان در تصمیم گیری بهتر کمک می کند. یکی از مواردی که در آن با افزایش حجم داده روپرتو هستیم، دانش پزشکی و صنعت سلامت است.

صنعت سلامت به طور مستمر در حال تولید میزان زیادی از داده ها می باشد. افرادی که با این نوع داده ها، مواجه هستند، دریافته اند که بین جمع آوری تا تفسیر آن ها شکاف وسیعی وجود دارد. حوزه ای به نسبت جوان و در حال رشد داده کاوی در سلامت، از

به شمار می آید. از یک سو به دلیل اهمیت شیوه های تصمیم گیری مدیران بیمارستان ها در پیشبرد اهداف بیمارستان و اهمیت قدرت پیش بینی آنان در حل مشکلات درمانی بیماران، و از سوی دیگر به دلیل عدم انجام مطالعات مشابه در این زمینه، این مطالعه با هدف استفاده مدیران بیمارستان ها از نتایج حاصل از داده کاوی سیستم های اطلاعات بیمارستانی (HIS) جهت پیش بینی دقیق تر و تصمیم گیری بهتر و مؤثر تر برای درمان بیماران صورت گرفته است. گاهی تکنیک های داده کاوی منجر به شناسایی الگوریتم های معنادار می شوند که می توانند با استفاده از داده های موجود و در دسترس و با هزینه کم، زمینه های ابتلا، پیشگیری و درمان بیماری ها را در پژوهش فراهم آورده و می توانند پژوهش که را در تشخض به موقع یاری رسانند.

پیشینه تحقیق:

هدف داده کاوی کشف انگاره های معتبر، جدید و قابل ردیابی در حجم عظیمی از داده ها با استفاده از ابزارهای آماری و هوش مصنوعی است. تاریخچه کشف دانش در پایگاه های اطلاعاتی که امروزه به داده کاوی مشهور است قدمت چندانی ندارد. پژوهشی در خصوص بیماران مبتلا به سرطان پستان که حداقل هر کدام به مدت دو سال تحت پیگیری بوده اند، انجام دادند. اطلاعات این بیماران در مرکز تحقیقات سرطان پستان جهاد دانشگاهی برای پیگیری اقدامات درمانی ثبت و بیماران حداقل به مدت دو سال پس از تشخیص، تحت نظر این مرکز بوده و پیگیری های بعدی برای آنها انجام شد. بررسیهای صورت گرفته نشان داد که دقت در سه الگوریتم داده کاوی، یعنی درخت تصمیم گیری، ANN، SVM، به ترتیب ۰/۹۳۶، ۰/۹۴۷، ۰/۹۵۷ بوده است(۷).

محمودی و همکاران(۱۳۹۲) در تحقیقی به شناسایی مدل پیش بینی بیماری عروق کرونر با استفاده از شبکه های عصبی و گزینش متغیر مبتنی بر درخت رگرسیون و طبقه بندی پرداخته اند. در این مطالعه مدل بدست آمده مبتنی بر شبکه های عصبی، علاوه بر توانایی بالا در تشخیص افراد بیمار، تعداد قابل قبولی از افرادی که قادر بیماری عروق کرونر بودند را نیز شناسایی کرد. همچنین، بکار گیری تکنیک های گزینش متغیر در این

ها و دستیابی به دانش نوین در زمینه چالش های آشکار و نهان سازمان میسر خواهد شد(۴).

در سالهای اخیر استفاده از روشهای داده کاوی روی حجم زیادی از داده ها با هدف تولید مدلها و الگوهای پیش بینی کننده در حیطه های متعدد پژوهشی رواج یافته است. در حال حاضر مطالعات متعددی مؤکد این است که تکنیک های داده کاوی ابزار مؤثری را برای شناسایی الگوهای مهم سلامت از درون پرونده های پژوهشی فراهم می کند. پرونده های سلامت کامپیوتری به واسطه ای دربرداشتن مجموعه ای از داده ها درباره ای تشخیص، درمان، اقدامات آزمایشگاهی و دارویی به طور بالقوه منبع غنی از دانش هستند اگر چه کشف دانش از اینویه داده ها در آن ها، هستند برای انسان غیر ممکن نیست، اما امری دشوار است و داده کاوی بهترین شیوه برای حل این چالش می باشد(۳).

بیماریهای قلبی عروقی از مهمترین عوامل مرگ و میر و از عمدۀ ترین مشکلات بهداشتی در کشورهای پیشرفتۀ و در حال توسعه می باشد(۵). بر اساس گزارش سازمان بهداشت جهانی ۴۱/۳ درصد کل مرگهای سال ۲۰۰۵ در ایران ناشی از بیماریهای قلبی عروقی بوده است و با کمال تأسف پیش بینی می شود تا سال ۲۰۳۰ این میزان به ۴۴/۸ درصد برسد(۶).

در ابتدای قرن بیستم ۱۰ درصد کل مرگ و میرها به علت بیماری های قلبی عروقی بود. در انتهای همین قرن موارد مرگ و میر ناشی از بیماری های قلبی به ۲۵ درصد افزایش یافت و پیش بینی می شود با توجه به روند کنونی تا سال ۲۰۲۵ میلادی بیشتر از ۳۵ تا ۶۰ درصد موارد مرگ و میر در جهان از بیماری های قلبی عروقی ناشی شود(۲).

با توجه به شیوع و سهمی که بیماری های قلبی در مرگ و میر انسان ها دارند، در این پژوهش، اطلاعات مربوط به بیماری های قلبی، با استفاده از تکنیک های داده کاوی، مورد تحلیل قرار گرفته است تا بتوان با استفاده از این اطلاعات، به مدل و الگوی دقیق تری چهت پیش بینی بیماری قلبی دست یافت.

بیمارستان بازوی مهم ارائه خدمات بهداشتی درمانی و اولین سطح ارجاع با قلمرو مسئولیت های مشخص است و به این لحاظ مهمترین سازمان بهداشتی درمانی

پیش بینی بیماری قلبی با استفاده از تکنیک داده کاوی شبکه عصبی ... مریم کاظمی و همکاران

داده اند. در این تحقیق مدلی ترکیبی از داده کاوی ارائه شده تا ضمن تعیین ویژگی های مهم بیماری هپاتیت بالاترین دقت در پیش بینی قابلیت زندگی افراد مبتلا به هپاتیت را ارائه دهد. نتایج تحقیق بدست آمده نشان می دهد که این مدل با کاهش ۶۸٪ ویژگی ها (حذف ۱۳ ویژگی از ۱۹ ویژگی) با دقت ۹۷.۴۲٪ پیش بینی را انجام داده است(۱۲).

در تحقیق انجام شده توسط ژو و دیگران(۲۰۱۰) بر روی ۲۰۰۰۰ بیمار بستری طب سنتی چینی و ۲۰۰۰۰ بیمار سرپایی از روش‌های خوش بندی استفاده گردید که از میان ۵ روش خوش بندی نظیر SVM ، شبکه عصبی و درخت تصمیم، برای سندروم های متفاوت در ۱۰۶۹ مورد اپیدمیولوژی بالینی، روش SVM نتایج پیشگویانه بهتری را نشان داد. همچنین از قوانین وابستگی و تحلیل شبکه پیچیده (CAN) جهت یافتن نقاط مفید برای انجام عمل طب سوزنی و الگوهای ترکیب گیاهان دارویی، از تکنیک آموزش ماشین چندگانه(SVM) جهت پیشگویی شروع نفوپاتی و از شبکه های عصبی برای پیش بینی نقش اطلاعات تشخیصی در اثر درمان آرتوئید روماتوئید بهره جسته شد(۱۳).

کلاهی و رافع(۱۳۹۲) تحقیق را با عنوان ارائه راه حلی برای تشخیص بیماری به کمک تکنیک های داده کاوی به انجام رسانیده اند. در این تحقیق از ترکیب یکی از تکنیک های داده کاوی به نام روش نزدیکترین همسایه مجاور به همراه انتخاب ویژگی جهت تشخیص F- score برای انتخاب مهمترین ویژگی ها استفاده نموده و همچنین معیارهای شbahت مختلف را برای تعیین یک معیار شbahت مناسب مورد بررسی قرار داده و مقدار مناسب k را براساس معیار شbahت انتخاب شده، برای روش KNN تعیین کرده اند. این روش ترکیبی را بر روی مجموعه داده سرطان سینه Wisconsin از مخزن داده UCI پیاده سازی نموده اند(۱۴).

هنرور عراقی(۱۳۸۸) پایان نامه خود را با عنوان آنالیز بیماریهای قلی به روش داده کاوی با تکنیک استخراج دانش مبتنی بر شهود انجام داده است. در این پایان نامه روشی برای انجام تشخیص پزشکی از روی پایگاه داده

مطالعه نیز نتایج خوبی در زمینه کاهش پیچیدگی مدل به همراه داشت و منجر به تولید مدلی متشكل از تنها چهار ریسک فاکتور سن، جنس، دیابت و فشارخون بالا گردید(۸).

در بیمارستان Brigham and Women تحقیقی با فرضیه ای مبنی بر این که " می توان عناصر اطلاعاتی موجود در پرونده ای الکترونیک سلامت را با تکنیک داده کاوی شناسایی و روابط بالینی معنی دار و درستی را کشف کرد " انجام شد؛ در این مطالعه با اجرای داده کاوی بر روی ۱۰۰۰۰۰ پرونده و تمرکز بر مجموعه داده های تشخیصی (۲۷۳۷۴۹ مورد)، دارویی (۴۴۶۵۸۱ مورد) و نتایج آزمایشگاهی (۱۱۸۰۱۰۶۸۱ مورد) روابط علمی مهمی بین مشکلات بیمار، داروها و نتایج آزمایشگاهی آن ها کشف و توصیف شد(۹).

در ایالت آلاباما نوعی سیستم نظارتی وجود دارد که از تکنیکهای داده کاوی استفاده می کند. این سیستم با استفاده از قوانین و روابط داده کاوی بر روی کشت خون بیمار و داده های بالینی به دست آمده از سیستم اطلاعات الگوهای Laboratory information system آزمایشگاه جدید و جالب توجهی را مشخص می سازد و ماهانه الگوهایی که توسط کارشناسان کنترل عفونت مورد بررسی قرار م یگیرد را تهیه می کند. سازندگان این سیستم دریافتته اند که ارتقای کنترل عفونت با سیستم داده کاوی حساس تر از سیستم کنترل عفونت سنتی عمل می کند(۱۰).

در تحقیقی که در سال ۲۰۰۷ توسط گروهی از محققین دانشگاه توکیو انجام گردید از شبکه های عصبی مصنوعی در این خصوص استفاده شد. از ۳۷۲۵۶ بیماری که اطلاعات آنها در یک دوره ۵ ساله از پایگاه داده استخراج شده بود ۸۱٪ متغیر از قبیل سن، جنسیت، مرحله بیماری و... انتخاب گردیدند. نتایج مطالعات میزان دقت این مدل را در پیش بینی بقا بیماران ۸۴/۵٪ نشان داد. یعنی مدل داده کاوی به کار رفته بر مبنای شبکه های عصبی به میزان ۸۴/۵٪ توانست میزان بقا بیماران مبتلا به سرطان پستان را به درستی پیش بینی کند(۱۱).

کاظمی و همکاران(۱۳۹۲) تحقیق را با عنوان تشخیص بیماری هپاتیت با ترکیب روش‌های داده کاوی انجام

تحقیق حاضر دارای ۱۴ متغیر می‌باشد که از این میان ۱۳ متغیر بعنوان متغیر توضیحی (ورودی) و یک متغیر بعنوان متغیر پاسخ در نظر گرفته می‌شود.

در این تحقیق از آمار توصیفی برای توصیف مشخصات دموگرافیک استفاده شده و برای بررسی سوالات Clementine تحقیق از ابزارهای داده‌کاوی در نرم افزار استفاده شده است. ابزارهای مختلفی به منظور کلاس-بندی وجود دارند که از جمله پرکاربردترین آنها می‌توان به شبکه عصبی(NeuralNetwork)، کارت، جنگل تصادفی(RandomForest)، ماشین بردار پشتیبان (SupportVectorMachine) و رگرسیون LogisticRegression اشاره کرد. در این پژوهش با استفاده از مدل شبکه عصبی، عمل کلاس-بندی برای پیش‌بینی بیماری قلبی انجام شده است. در زیر به بررسی این مدل می‌پردازیم.

مدل شبکه عصبی

شبکه‌های عصبی مصنوعی، رده‌ای از روش‌های یادگیری است که در زمینه‌های آماری و هوش مصنوعی رشد و توسعه یافته است و دارای قابلیت رگرسیونی و کلاس‌بندی می‌باشد. در مدل شبکه عصبی، متغیرهای توضیحی و متغیر پاسخ می‌توانند از نوع کمی یا کمی باشند و همچنین متغیر پاسخ، رابطه‌ای غیرخطی و غیر مستقیم با متغیرهای توضیحی دارد. چارچوب شبکه‌های عصبی از چند لایه به نام‌های لایه ورودی، لایه (های) پنهان و لایه خروجی تشکیل شده است. شکل ۲-۱، ساختار شماتیکی یک شبکه را با یک لایه پنهان نشان می‌دهد که در آن متغیرهای توضیحی و متغیر پاسخ به ترتیب در لایه ورودی و لایه خروجی واقع شده و اجزای لایه پنهان، Z_i ها، نورون یا گره(Node) نامیده می‌شوند.

ی پژوهشی پیشنهاد شده است که شامل ایجاد فاکتور اطمینان از روی اپیزودهای پژوهشی با توجه به داده‌های بالینی- تشخیصی، تعیین توابع وزنی از روی این فاکتور با دو روش نگاشت و فازی، ترکیب توابع وزنی از اپیزودهای مختلف و در نهایت تشخیص نهایی است. روش ارائه شده با صحت قابل قبولی توانایی تشخیص آنفارکتوس میوکارد و محل آنرا فراهم کرد. همچنین این روش توانایی بکارگیری در سایر تشخیص‌های پژوهشی را نیز دارا می‌باشد(۱۵).

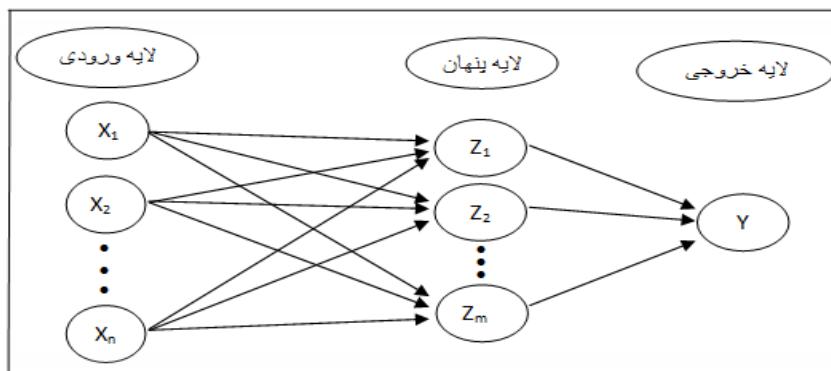
بنابراین از داده کاوی برای غلبه بر این مشکل استفاده می‌شود و با توجه به شیوع و سهمی که بیماری‌های قلبی در مرگ و میر انسان‌ها دارند، در این پژوهش، اطلاعات مربوط به بیماری‌های قلبی، با استفاده از تکنیک‌های داده کاوی، مورد تحلیل قرار گرفته است تا بتوان با استفاده از این اطلاعات، به مدل و الگوی دقیق تری جهت پیش‌بینی بیماری قلبی دست یافت.

تعاریف مفهومی متغیرهای پژوهش:

- داده کاوی: داده کاوی به بررسی و تجزیه و تحلیل مقادیر عظیمی از داده‌ها به منظور کشف الگوها و قوانین معنی دار اطلاق می‌شود که عمدتاً از طریق ساختن مدل‌ها و الگوریتم‌ها، ورودی‌ها را با هدف یا مقصد خاصی مرتبط می‌نماید.

- شبکه‌های عصبی: شبکه‌های عصبی با الهام گیری از الگوی مغز انسان ضمن فرایند آموزش، اطلاعات مربوطه را درون شبکه ذخیره می‌نمایند. این شبکه امکان یادگیری داشته و همانند شبکه‌های زیستی میتواند با توجه به اطلاعات اولیه چیزی را بیاموزد و یا بر اساس آموخته‌های خود تصمیم گیری نماید(۱۶).

مواد و روش‌ها



شکل شماره ۱ - شمایی از ساختار شبکه عصبی

هایپربولیک(HyperbolicTangent)، آرک تانژانت(ArcTangent) و سینوس(Sin) اشاره کرد. همچنین تابع f ، خطی یا غیر خطی بوده و در صورت غیر خطی بودن می‌تواند همانند σ دارای یکی از فرم‌های مذکور باشد. در برآورد پارامترهای مدل ابتدا مقادیر اولیه این پارامترها به تصادف انتخاب شده و سپس طی یک فرآیند یادگیری، این مقادیر دائماً "بروز می‌شوند تا زمانی که میزان خطای کلاس‌بندی به حالت نسبتاً پایداری برسد(۱۷). نهایتاً شبکه عصبی با محاسبه احتمال شرطی قرار گرفتن مشاهده‌ی جدید x_0 در کلاس ۰ یا ۱ که به آن احتمال پسین گویند، بیماری قلبی را پیش‌بینی می‌کند، به اینصورت که اگر $P(Y=1|x_0) > 0.5$ آنگاه مشاهده‌ی جدید x_0 به کلاس ۱ و در غیر اینصورت به کلاس ۰ تخصیص می‌یابد(۱۷).

معرفی داده‌ها و متغیرها:

داده‌های مورد استفاده در این مطالعه، مربوط به اطلاعات ۲۷۰ بیمار است که از انبار داده سایت UCI استخراج شده و شامل ۲۷۰ مشاهده و ۱۴ متغیر می‌باشد. در جدول ۲ اطلاعات مربوط به متغیرهای مورد استفاده بطور خلاصه بیان شده است.

شبکه‌های عصبی را از لحاظ نحوهٔ اتصال گره‌ها به دو نوع تقسیم می‌کنند.

۱) شبکه‌های عصبی پیشرو: که در آن گره‌های هر لایه فقط به گره‌های لایه بعدی متصل می‌شوند (شکل ۱).

۲) شبکه‌های عصبی پسرو: که در آن گره‌های هر لایه به گره‌های لایه‌های بعدی یا به خودشان متصل می‌شوند.

در این مطالعه از شبکه‌های عصبی پیشرو استفاده شده است. یکی از متدائل ترین شبکه‌های معماری شبکه‌های عصبی که در آن الگوی ارتباطی بین لایه‌ها مشخص می‌شود، پرسپترون چند لایه(MultilayerPerceptron) است. در این ساختار، هر نورون، تابعی از ترکیب خطی متغیرهای توضیحی، و همچنین متغیر پاسخ نیز تابعی از ترکیب خطی نورون‌ها است. یعنی:

$$Z_i = \sigma \left(\alpha_{0,i} + \sum_{j=1}^n \beta_{j,i} x_j \right); \quad i = 1, 2, \dots, m \quad , \quad y = f(Y + \sum_{i=1}^m \theta_i Z_i)$$

که در آن σ تابع فعال سازی نامیده شده و نمودار این تابع غیر خطی، S-Sigmoid Activation Function (شکل ۲) است که از جمله آنها می‌توان به تائراست

جدول شماره ۱- متغیرهای مورد استفاده در پژوهش

کمی	Age	سن
کیفی	Sex	جنسیت
کیفی	Chest-pain	درد قفسه سینه
کمی	Blood-press	فسار خون
کمی	Serum-chol	کلسترول سرم
کیفی	Blood-sugar	قند خون
کیفی	Res-elec	ایستایی نوار قلب
کمی	Heart-rate	ضریان قاب
کیفی	Angina	آرثیزین
کمی	ST-dep	کاهش ST
کیفی	Peak-ST	اوج ST
کمی	Nbr-ves	تعداد عروق بزرگ
کیفی	Defect	نقص
کیفی	Heart-dis	بیماری قلبی

در جدول ۱، متغیر "بیماری قلبی" به عنوان متغیر پاسخ (پیش‌بینی شونده) و بقیه متغیرها به عنوان متغیر توضیحی (پیش‌بینی کننده) در نظر گرفته می‌شوند.

آمار توصیفی

در این بخش با استفاده از جداول فراوانی، اطلاعات مربوط به متغیرهای جمعیت شناسی تحقیق را توصیف می‌کنیم (جدول شماره ۲ و ۳).

جدول ۲- آمار توصیفی متغیر "سن"

انحراف معیار	میانگین	بیشترین	کمترین
۹.۱۰۹	۵۴.۴۳	۷۷	۲۹

جدول ۳- آمار توصیفی متغیر "جنسیت"

جنسیت	فراآنی	درصد فراآنی
زن	۸۷	۳۲.۲
مرد	۱۸۳	۶۷.۸
مجموع		۱۰۰

(۲۰٪ کل داده‌ها، ۶۶ مراجعه کننده) تقسیم می‌شود. با استفاده از مجموعه داده مدل‌سازی عمل مدل‌سازی مدل مربوطه انجام می‌شود. در نهایت با استفاده از مجموعه داده آزمون دقت مدل برآش داده شده مورد ارزیابی قرار می‌گیرد. کلیه مراحل ذکر شده برای برآش مدل در محیط نرم‌افزار Clementine 14.2 انجام شده است.

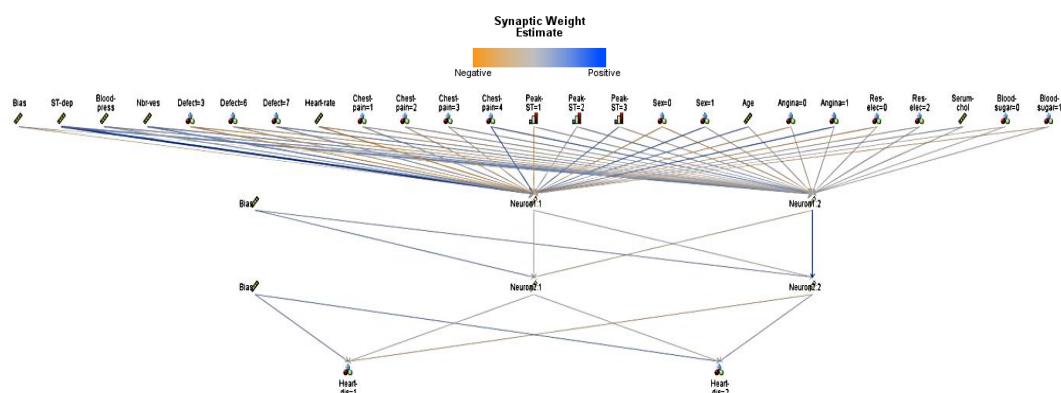
در این بخش با استفاده از مدل شبکه عصبی سعی در پیش‌بینی ابتلا به بیماری قلبی مراجعته کنندگان به بیمارستان بر اساس اطلاعات مربوط به متغیرهای توضیحی می‌شود.

در ابتدا مجموعه اصلی داده‌ها که شامل ۲۷۰ مراجعته کننده است به دو قسمت مجموعه داده مدل‌ساز (۸۰٪) کل داده‌ها، ۲۰۴ مراجعته کننده) و مجموعه داده آزمون

عصبی با ساختار پرسپترون چندلایه برآش داده شده، مدلی دارای دو لایه پنهان و در هر لایه پنهان ۲ نرون است.

یافته های پژوهش

نتایج برآش مدل شبکه عصبی با ساختار پرسپترون چندلایه پس از برآش مدل شبکه عصبی ایجاد شده در شکل ۲ نشان داده شده است. بهترین مدل شبکه



شکل ۲- نمودار مدل شبکه عصبی با دو لایه پنهان و در هر لایه پنهان دو نرون

در لایه های پنهان و لایه خروجی محاسبه کرد. بعنوان مثال، مقادیر گره اول در لایه پنهان اول (Neuron 1.1)، گره اول در لایه پنهان دوم (Neuron 2.1) و گره های موجود در لایه خروجی به صورت زیر محاسبه می شود.

ضرایب مربوط به اتصال گره ها در لایه های ورودی، پنهان و خروجی در جدول ۴ نشان داده شده است. مشتبث یا منفی بودن هر یک از ضرایب از روی شکل ۲ و رنگ اتصال دهنده ها مشخص می شود. با توجه به شکل ۲ و جدول ۴، می توان مقادیر هر یک از گره ها را

جدول ۴- ضرایب اتصال گره ها در لایه های ورودی، پنهان و خروجی

نام گره (نود)	ضریب گره در لایه بعد	لایه گره	نوع گره
Bias	۲۳.۰۷	اول	scale
Peak-ST=1	۱۲	اول	order_set
Peak-ST=2	۱۱.۰۷۶	اول	order_set
Peak-ST=3	۱۰.۱۵	اول	order_set
ST-dep	۲۲.۱۵	اول	scale
Blood-press	۲۱.۲۳	اول	scale
Nbr-ves	۲۰.۳۰	اول	scale
Heart-rate	۱۶.۶۱	اول	scale
Age	۷.۳۸	اول	scale
Serum-chol	۲.۷۶	اول	scale
Defect=3	۱۹.۳۸	اول	set
Defect=6	۱۸.۴۶	اول	set
Defect=7	۱۷.۵۳	اول	set
Chest-pain=1	۱۵.۶۹	اول	set
Chest-pain=2	۱۴.۷۶	اول	set
Chest-pain=3	۱۳.۸۴	اول	set
Chest-pain=4	۱۲.۹۲	اول	set
Sex=0	۹.۲۳	اول	set
Sex=1	۸.۳۰	اول	set

set	اول	۶.۴۶	Angina=0
set	اول	۵.۵۳	Angina=1
set	اول	۴۶۱	Res-elec=0
set	اول	۳۶۹	Res-elec=2
set	اول	۱۸۴	Blood-sugar=0
set	اول	۰.۹۲	Blood-sugar=1
scale	دوم	۱۸	Bias
scale	دوم	۱۲	Neuron 1.1
scale	دوم	۶	Neuron 1.2
scale	سوم	۱۸	Bias
scale	سوم	۱۲	Neuron 2.1
scale	سوم	۶	Neuron 2.2

$$\begin{aligned} \{Neuron\ 1.1\} &= \text{Tanh}(-۱۲.۰۷ - (۱۲ * \{\text{Peak} = ST = 1\}) + (۱۱.۰۷ * \{\text{Peak} = ST = 2\}) \\ &\quad + (۱۰.۱۵ * \{\text{Peak} = ST = 3\}) - (۱۰.۳۰ * \{Nbr = ves\}) - (۱.۰۷ * \{\text{Serum} = chol\}) \\ &\quad + (۲۱.۲۲ * \{\text{Blood} = press\}) + (۰.۳۸ * \{\text{Age}\}) - (۱۹.۹۱ * \{\text{Heart} = rate\}) \\ &\quad + (۲۲.۱۵ * \{ST = dep\}) + (۱۹.۳۸ * \{\text{Defect} = 3\}) + (۱۸.۴۹ * \{\text{Defect} = 6\}) \\ &\quad - (۱۷.۵۳ * \{\text{Defect} = 7\}) + (۱۵.۶۹ * \{\text{Chest} = pain = 1\}) - (۱۶.۷۹ * \{\text{Chest} = pain = 2\}) \\ &\quad - (۱۷.۸۴ * \{\text{Chest} = pain = 3\}) + (۱۷.۹۱ * \{\text{Chest} = pain = 4\}) - (۱.۲۲ * \{\text{Sex} = 0\}) \\ &\quad + (۸.۳۰ * \{\text{Sex} = 1\}) - (۹.۴۹ * \{\text{Angina} = 0\}) + (۰.۵۳ * \{\text{Angina} = 1\}) \\ &\quad - (۴.۹۱ * \{\text{Res} = elec = 0\}) - (۷.۴۹ * \{\text{Res} = elec = 2\}) - (۱.۸۴ * \{\text{Blood} = sugar = 0\}) \\ &\quad - (۰.۹۲ * \{\text{Blood} = sugar = 1\}) \end{aligned}$$

$$\{Neuron\ 2.1\} = \text{Tanh}(۱۸ - (۱۲ * Neuron\ 1.1) - (۶ * Neuron\ 1.2))$$

$$\{Heart - Dis = 1\} = ۱۸ + (۱۲ * Neuron\ 2.1) - (۶ * Neuron\ 2.2)$$

$$\{Heart - Dis = 2\} = ۱۸ - (۱۲ * Neuron\ 2.1) + (۶ * Neuron\ 2.2)$$

با توجه به روابط بالا اگر برای یک مشاهده جدید، مقدار برآورده شده $\{Heart - Dis = 1\}$ بزرگتر از $\{Heart - Dis = 2\}$ شود، آنگاه فرد مورد نظر به بیماری قلبی مبتلا است. در نهایت با استفاده از شبکه عصبی برآشش داده شده، عمل کلاس‌بندی برای مجموعه مشاهدات مدل‌ساز و آزمون انجام شده که نتایج آن به ترتیب در جداول ۵ و ۶ بیان شده است.

با توجه به روابط بالا اگر برای یک مشاهده جدید، مقدار برآورده شده $\{Heart - Dis = 1\}$ بزرگتر از $\{Heart - Dis = 2\}$ شود، آنگاه فرد مورد نظر به بیماری قلبی مبتلا نیست و بالعکس اگر مقدار برآورده شده $\{Heart - Dis = 1\}$ کوچکتر از

پیش بینی بیماری قلبی با استفاده از تکنیک داده کاوی شبکه عصبی ... مریم کاظمی و همکاران

جدول ۵- کلاس‌بندی متغیر "بیماری قلبی" با استفاده از مدل "شبکه عصبی با ساختار پرسپترون چند لایه" برای مجموعه داده مدل‌ساز

		پیش‌بینی شده			درصد صحیح
		Heart-dis =1	Heart-dis =2	غیرقابل پیش‌بینی	
مشاهده شده	Heart-dis =1	۱۰۸	۹	۱	%۹۱.۵۲
	Heart-dis =2	۱۴	۷۱	۱	%۸۲.۵۵
کل					%۸۷.۷۵

با توجه به جدول ۶ می‌بینیم که مدل "شبکه عصبی با ساختار پرسپترون چند لایه" با دقت ۸۷.۷۵ درصد عمل کلاس‌بندی را برای مجموعه داده مدل‌ساز انجام داده است. با توجه به جدول می‌بینیم که بر اساس مدل، یک مشاهده دارای کلاس متغیر ۱ و Heart-dis = 1 و یک مشاهده دارای کلاس متغیر پاسخ

جدول ۶- کلاس‌بندی متغیر "بیماری قلبی" با استفاده از مدل "شبکه عصبی با ساختار پرسپترون چند لایه" برای مجموعه داده آزمون

		پیش‌بینی شده		درصد صحیح
		Heart-dis =1	Heart-dis =2	
مشاهده شده	Heart-dis =1	۲۹	۳	%۸۷.۵
	Heart-dis =2	۸	۲۶	%۷۶.۴۷
کل				%۸۳.۳۳

با توجه به جدول ۷ می‌بینیم که مدل "شبکه عصبی با ساختار پرسپترون چند لایه" با دقت ۸۳.۳۳ درصد عمل کلاس‌بندی را برای مجموعه داده آزمون انجام داده است.

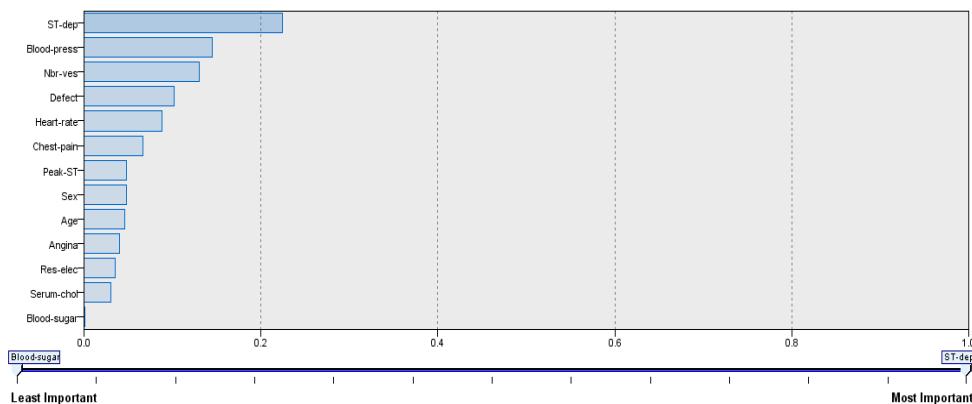
با توجه به جدول ۷ می‌بینیم که مدل "شبکه عصبی با ساختار پرسپترون چند لایه" با دقت ۸۷.۷۵ درصد عمل کلاس‌بندی را برای مجموعه داده مدل‌ساز انجام داده است. با توجه به جدول می‌بینیم که بر اساس مدل، یک مشاهده دارای کلاس متغیر ۱ و Heart-dis = 1 و یک مشاهده دارای کلاس متغیر پاسخ

جدول ۷- کلاس‌بندی متغیر "بیماری قلبی" بر اساس مدل "شبکه عصبی با ساختار پرسپترون چند لایه"

داده‌های آزمون		داده‌های مدل‌ساز		نحوه کلاس‌بندی متغیر	
درصد	تعداد	درصد	تعداد	وابسته	
۸۳.۳۳	۵۵	۸۷.۷۵	۱۷۹	صحیح	
۱۶.۶۷	۱۱	۱۲.۲۵	۲۵	اشتباه	
۱۰۰	۶۶	۱۰۰	۲۰۴	مجموع	

رتبه‌بندی اهمیت متغیرها:

در مدل شبکه عصبی با ساختار پرسپترون چند لایه، ترتیب اهمیت متغیرهای توضیحی برای پیش‌بینی متغیر پاسخ به صورت شکل ۱۰ می‌باشد.



شکل ۳- نمودار اهمیت متغیرها برای پیش‌بینی متغیر پاسخ در مدل شبکه عصبی با ساختار پرسپترون چند لایه

کاوی سیستم های اطلاعات بیمارستانی (HIS) جهت پیش‌بینی دقیق تر و تصمیم‌گیری بهتر و مؤثرتر برای درمان بیماران صورت گرفته است. با توجه به برآورد وزن‌های مدل، نهایتاً مدل با استفاده از رابطه زیر عمل کلاس‌بندی را برای رکوردها انجام می‌دهد.

$$\{Heart - Dis = 1\} = 18 + (12 * Neuron\ 2.1) - (6 * Neuron\ 2.2)$$

$$\{Heart - Dis = 2\} = 18 - (12 * Neuron\ 2.1) + (6 * Neuron\ 2.2)$$

با توجه به روابط بالا اگر برای یک مشاهده جدید، مقدار برآورد شده $\{Heart - Dis = 1\}$ بزرگتر از $\{Heart - Dis = 2\}$ شود، آنگاه فرد مورد نظر به بیماری قلبی مبتلا نیست و بالعکس اگر مقدار برآورد شده کوچکتر از $\{Heart - Dis = 1\}$ شود، آنگاه فرد مورد نظر به بیماری قلبی مبتلا است.

به همین صورت عمل کلاس‌بندی برای تمام رکوردها (مجموعه رکوردهای مدل‌ساز و آزمون) محاسبه شده است. نتایج نشان داد که دقت مدل در کلاس‌بندی رکوردها از لحاظ متغیر پاسخ $\{Heart - dis\}$ برای مجموعه رکوردهای مدل‌ساز 87.75% و برای مجموعه رکوردهای آزمون 83.33% می‌باشد. که این میزان دقت با یافته‌های محمودی و همکاران(۱۳۹۲) همخوانی دارد.

همچنین متغیرهای تعداد عروق بزرگ(*Nbr-ves*), کاهش استرس(*ST-dep*), نقص(*Defect*), درد قفسه سینه(*Chest-pain*), اوج استرس (*Peak-ST*), ضربان قلب (*Heart-rate*), آنژین (Heart-*angina*), جنسیت (*Sex*), سن (*Age*), ایستایی نوار قلب(*Res-elec*), فشار

با توجه به شکل ۳ می‌بینیم که متغیرهای ST-dep (کاهش خون)، Blood-press (فشار خون)، Nbr-ves (تعداد عروق بزرگ)، Defect (نقص)، Chest-pain (درد قفسه سینه)، Sex (جنسیت)، Peak-ST (اوج)، Age (سن)، Res-elec (آنژین)، Serum-chol (کلسیترول سرم) و Blood-sugar (قند خون) به ترتیب بیشترین اهمیت را از لحاظ مدل "شبکه عصبی با ساختار پرسپترون چند لایه" در پیش‌بینی متغیر پاسخ دارند.

بحث و نتیجه‌گیری

امروزه بخش سلامت بیش ترین نیاز را به داده کاوی پیدا کرده است و حرکت از پزشکی سنتی به سمت پزشکی مبتنی بر شواهد از جمله مواردی است که می‌تواند مؤکد این امر باشد(۲). تعداد و اندازه پایگاه داده های پزشکی به سرعت در حال افزایش است و مدل‌های توسعه یافته تکنیک داده کاوی می‌توانند برای پزشکان جهت کمک در تصمیم‌گیری موثر و کاربردی باشند(۷). بیمارستان بازوی مهم ارائه خدمات بهداشتی درمانی و اولین سطح ارجاع با قلمرو مسئولیت های مشخص است و به این لحاظ مهمترین سازمان بهداشتی درمانی به شمار می‌آید. از یک سو به دلیل اهمیت شیوه های تصمیم‌گیری مدیران بیمارستان ها در پیشبرد اهداف بیمارستان و اهمیت قدرت پیش‌بینی آنان در حل مشکلات درمانی بیماران، و از سوی دیگر به دلیل عدم انجام مطالعات مشابه در این زمینه، این مطالعه با هدف استفاده مدیران بیمارستان ها از نتایج حاصل از داده

پیش بینی بیماری قلبی با استفاده از تکنیک داده کاوی شبکه عصبی ... مریم کاظمی و همکاران

پرسپترون چند لایه" در پیش بینی متغیر پاسخ بیماری قلبی (Heart-dis) دارند.

خون (Blood-sugar)، قند خون (Blood-press) و کلسترول سرم (Serum-chol) به ترتیب بیشترین اهمیت را از لحاظ مدل "شبکه عصبی" با ساختار

References

1. Rezaeian A. Principles of organization and management. Tehran Samt Publication. 2012;P.81-6.
2. Amereh M. [Survey data mining algorithms and compare them on a case study]. Ecommerce 2014; 71:40-2.(Persian)
3. Moghadasi H, Hosseine A, Asadi F, Jahanbakhsh M. [Data mining and its application in health]. Health Inform Manage 2013; 9:297-304. (Persian)
4. Koh HC, Tan G. Data mining applications in healthcare. J Health Inform Manage 2005;19:64-72.
5. Anderson KM. Cardiovascular disease risk profiles. American Heart J 1991;121:293-8.
6. Knight J, Wells S, Marshall R, Exeter D, Jackson R. Developing a synthetic national population to investigate the impact of different cardiovascular disease risk management strategies a derivation and validation study. PLoS One 2017;12: 170-3.
7. Tolueiashlaghi A, Purebrahimi A, Ebrahimi M, Ghasemahmad L. [Predict breast cancer recurrence by three data mining techniques]. Iranian J Breast Dis 2013;5: 24-34.(Persian)
8. Mahmoodi A, Asgarimoghadam R, Moazam M, Saeghian S. [Identify models predict coronary artery disease using Neural networks and variable selection based on classification and regression tree]. J Shahrekord Med Sci Uni 2014; 15:22-7. (Persian)
9. Tavakoli N, Jahanbakhsh M. [Opportunities and challenges of EHR implementation in Isfahan]. J Manage Uni Isfahan 2010;3:41-7. (Persian)
10. Obenshain MK. Application of data mining techniques to healthcare data. Infect Control Hosp Epidemiol 2004; 25:690-5.
11. Endo A, Shibata T, Tanaka H. Comparison of seven algorithms to predict breast cancer survival. Biomed Soft Comput Hum Sci 2008;13:11-6.
12. Kazemi A, Yousof zadeh A, Azimi P. Detect of Hepatitis by combining data mining methods. The first national conference application of intelligent systems in science and technology. 2014.
13. Zhou X. Development of traditional Chinese medicine clinical data warehouse for medical knowledge discovery and decision support. Art Intell Med J 2010;48:139-52.
14. Kolahi S, Rafe W. Presentation a solution to diagnosis using data mining techniques. The first national conference electrical and computer southern Iran. 2014.
15. Henroraraghi B. [Heart disease analysis by data mining techniques to extract knowledge based on intuition]. Msc Thesis Azad Uni 2010.(Persian)
16. Bahramizanvar M. [Data mining discover the hidden data]. Research office and risk control of Bank Sepah 2011. (Persian)
17. Hastie T, Tibshirani R .The Elements of Statistical Learning data mining inference and prediction. 2th ed. Springer Series Statistics Publication. 2009;P.184.



Heart Disease Forecast Using Neural Network Data Mining Technique

Kazemi M¹, Mehdizadeh M^{2*}, Shiri A³

(Received: April 5, 2015 Accepted: February 27, 2016)

Abstract

Introduction: Data mining refers to the study and analysis of large amounts of data for discovering meaningful patterns and rules. Mainly through the models and algorithms, data mining puts the inputs in a specific order. Data mining techniques sometimes lead to the identification of meaningful algorithms which can use available and low-cost data in order to provide us with areas of infection, prevention, and treatment of diseases and help the physicians in timely and accurate diagnosis.

Materials & methods: The present paper aimed to study the use of the results of data mining of hospital information systems by hospital managers for more accurate prediction and more effective decision-making about treatment of patients. The data used in this study included the information of 270 patients (14 variables) extracted from the database of UCI website. A “neural networks” model was used for the prediction of affliction with heart disease and its accuracy was measured and compared.

Findings: According to the results, it can be observed that Multilayer Perceptron Neural Networks Model has classified the set of test observations with an accuracy of 83.33%.

Discussion & conclusions: The results showed that the accuracy of “neural networks” model in classification of records in terms of heart disease response is 87.75% for the set of modeling records and 83.33% for the set of test records. In addition, the findings revealed that the variables of the number of large vessels (Nbr-ves), stress reduction (ST-dep), defect, chest pain, stress peak (Peak-ST), heart rate, angina, gender, age, static ECG (Res-elec), blood pressure (Blood-press), blood sugar, and serum cholesterol (Serum-chol), respectively, have the highest importance in “Multilayer Perceptron Neural Networks” model for the prediction of heart disease response.

Keywords: Data mining, Neural Network, Heart-disease

1. Ilam University of Medical Sciences ,Ilam, Iran

2. Dept of Entrepreneurship and Rural Development, Faculty of Agriculture, Ilam University,Ilam, Iran

3. Dept of Management, Faculty of Humanities, Ilam University,Ilam, Iran

* Corresponding author Email: Hossein.mehdizadeh@ilam.ac.ir