

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 الگوهای قوانین معنی دار اطلاق می‌شود که "عمدتاً" از طریق ساختن مدل ها و الگوریتم ها، ورودی ها را با هدف خاصی مرتبط می‌نماید. گاهی تکنیک های داده کاوی منجر به شناسایی الگوریتم های معنادار می‌شوند که می‌توانند 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 تشخیص 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 می‌شود، 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٪ می‌باشد. 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*), آرثیزین (*Angina*), جنسیت (*Sex*), سن (*Age*), ایستایی نوار قلب (*Res-elec*), فشار خون (*Blood-press*), قندخون (*Blood-sugar*) و کلسیترون 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

مقدمه

نسبت جوان و در حال رشد داده کاوی در سلامت، از 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 شیوع و سهمی که در مرگ و میر انسان ها دارند از اهمیت بالایی برخوردارند. داده کاوی دانش استخراج روابط و الگوهای مفید پنهان در حجم زیاد داده است(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 متمرکز 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 موقوفیت های سازمان های سلامت در گروی جمع آوری، ذخیره و تحلیل آنها است. با این وجود، جمع آوری و ذخیره‌ی 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

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

زیرا تضمیم گیری جزء اصلی مدیریت است(۱). اطلاعات اساس تضمیم گیری است. مدیر برای تضمیم گیری صحیح نیاز به استفاده از اطلاعات درست و نیز ابزارها و مدل های تضمیم 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 بر خلاف 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 پیشرفته پشتیبانی از تضمیم 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 تضمیم گیری بهتر کمک می کند. یکی از مواردی که در آن با افزایش حجم داده رویرو 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. حوزه‌ی به

است و به این لحاظ مهمترین سازمان بهداشتی درمانی به شمار می‌آید. از یک سو به دلیل اهمیت شیوه‌های تصمیم‌گیری مدیران بیمارستان‌ها 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 بیمارستان‌ها از نتایج حاصل از داده کاوی سیستم‌های اطلاعات بیمارستانی (HIS) جهت پیش‌بینی دقیق‌تر و تصمیم‌گیری بهتر و مؤثرتر برای درمان بیماران صورت گرفته است. گاهی تکنیک‌های داده کاوی منجر به شناسایی الگوریتم‌های معنادار می‌شوند که می‌توانند با استفاده از داده‌های موجود و در دسترس و با هزینه کم، زمینه‌های ابتلا، پیشگیری و درمان بیماری‌ها را در پژوهشی فراهم آورده و می‌توانند پژوهش‌ها را در تشخیص به موقع یاری رسانند.

پیشینه تحقیق:

هدف داده کاوی کشف انگاره‌های معتبر، جدید و قابل ردیابی در حجم عظیمی از داده‌ها با استفاده از ابزارهای آماری و هوش مصنوعی است. تاریخچه کشف دانش در پایگاه‌های 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 بوده‌اند، 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 پیگیری‌های بعدی برای آنها انجام شد. بررسیهای صورت گرفته نشان داد که دقت در سه الگوریتم داده کاوی، یعنی درخت تصمیم‌گیری، ANN، SVM، به ترتیب ۰/۹۴۷، ۰/۹۳۶ و ۰/۹۵۷ بوده است.^(۷)

محمودی و همکاران^(۱۳۹۲) در تحقیقی به شناسایی مدل پیش‌بینی بیماری عروق کرونر با استفاده از شبکه‌های عصبی و گزینش متغیر مبتنی بر درخت رگرسیون و طبقه‌بندی پرداخته‌اند. در این مطالعه مدل بدست آمده مبتنی بر شبکه‌های عصبی، علاوه بر توانایی بالا در تشخیص افراد بیمار، تعداد قابل قبولی از افرادی که قادر بیماری عروق کرونر بودند را نیز شناسایی کرد.

امکان کشف روابط، روندها و الگوهای مخفی بین داده‌ها و دستیابی به دانش نوین در زمینه چالش‌های آشکار و نهان سازمان میسر خواهد شد^(۴).

در سالهای اخیر استفاده از روشهای داده کاوی روی حجم زیادی از داده‌ها با هدف تولید مدلها و الگوهای پیش‌بینی کننده در حیطه‌های متعدد پژوهشی رواج یافته است. در حال حاضر مطالعات متعددی مؤکد این است که تکنیک‌های داده کاوی ابزار مؤثری را برای شناسایی الگوهای مهم سلامت از درون پرونده‌های پژوهشی فراهم می‌کند. پرونده‌های سلامت کامپیوتراز به واسطه‌ی دربرداشتن مجموعه‌ای از داده‌ها درباره‌ی تشخیص، درمان، اقدامات آزمایشگاهی و دارویی به طور بالقوه منع غنی از دانش هستند اگرچه کشف دانش از آنبوه داده‌ها در آن‌ها، هستند برای انسان غیرممکن نیست، اما امری دشوار است و داده کاوی بهترین شیوه برای حل این چالش می‌باشد^(۳).

بیماریهای قلبی عروقی از مهمترین عوامل مرگ و میر و از عمدۀ ترین مشکلات بهداشتی در کشورهای پیشرفته و در حال توسعه می‌باشد^(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 پیش‌بینی می‌شود تا سال ۲۰۳۰ این میزان به ۴۴/۸ درصد برسد^(۶).

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

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 دقیق‌تری چهت پیش‌بینی بیماری قلبی دست یافت.

بیمارستان بازوی مهم ارائه خدمات بهداشتی درمانی و اولین سطح ارجاع با قلمرو مسئولیت‌های مشخص

کاظمی و همکاران(۱۳۹۲) تحقیق را با عنوان تشخیص بیماری هپاتیت با ترکیب روش‌های داده کاوی انجام داده اند. در این تحقیق مدلی ترکیبی از داده کاوی ارائه شده تا ضمن تعیین ویژگی‌های مهم بیماری هپاتیت بالاترین دقت در پیش بینی قابلیت زندگی افراد مبتلا به هپاتیت را ارائه دهد. نتایج تحقیق بدست آمده نشان می‌دهد که این مدل با کاهش ۶۸٪ ویژگی‌ها (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 ۲۰۰۰ بیمار بستری طب سنتی چینی و ۲۰۰۰ بیمار سرپایی از روش‌های خوش بندی استفاده گردید که از میان ۵ روش خوش بندی نظری SVM ، شبکه عصبی و درخت تصمیم، برای سندروم‌های 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 نفوذپاتی و از شبکه‌های 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 تکنیک‌های داده کاوی به انجام رسانیده اند. در این تحقیق از ترکیب یکی از تکنیک‌های داده کاوی به نام روش نزدیکترین همسایه مجاور به همراه انتخاب ویژگی جهت تشخیص F- و پیش بینی سلطان سینه استفاده شده و از تکنیک score برای انتخاب مهمترین ویژگی‌ها استفاده نموده و همچنین معیارهای شباht مختلف را برای تعیین یک معیار شباht مناسب مورد بررسی قرار داده و مقدار مناسب k را براساس معیار شباht انتخاب شده، برای روش KNN تعیین کرده اند. این روش ترکیبی را بر روی مجموعه داده سلطان سینه Wisconsin از مخزن داده UCI پیداhe سازی نموده اند(۱۴).

هنرور عراقی(۱۳۸۸) پایان نامه خود را با عنوان آنالیز بیماریهای قلبی به روش داده کاوی با تکنیک استخراج

همچنین، بکار گیری تکنیک‌های گزینش متغیر در این 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 "می‌توان عناصر اطلاعاتی موجود در پرونده‌ی 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 ۱۰۰۰۰ پرونده و تمرکز بر مجموعه داده های تشخیصی (۲۷۲۷۴۹ مورد)، دارویی (۴۴۲۶۵۸ مورد) و نتایج آزمایشگاهی (۱۱۸۰۱۰۶۸ مورد) روابط علمی مهمی بین مشکلات بیمار، داروها و نتایج آزمایشگاهی آن‌ها کشف و توصیف شد(۹).

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

در تحقیقی که در سال ۲۰۰۷ توسط گروهی از محققین دانشگاه توکیو انجام گردید از شبکه‌های 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 شبکه‌های عصبی به میزان ۸۴/۵٪ توانست میزان بقا بیماران مبتلا به سلطان پستان را به درستی پیش بینی کند(۱۱).

مواد و روش ها

تحقیق حاضر دارای ۱۴ متغیر می باشد که از این میان ۱۳ متغیر عنوان متغیر توضیحی (ورودی) و یک متغیر عنوان متغیر پاسخ در نظر گرفته می شود. در این تحقیق از آمار توصیفی برای توصیف مشخصات دموگرافیک استفاده شده و برای بررسی سوالات تحقیق از ابزارهای داده کاوی در نرم افزار Clementine استفاده شده است. ابزارهای مختلفی به منظور کلاس-بندی وجود دارند که از جمله پر کاربردترین آنها می توان 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 می پردازیم.

مدل شبکه عصبی

شبکه های عصبی مصنوعی، رده ای از روش های یادگیری است که در زمینه های آماری و هوش مصنوعی رشد و توسعه یافته است و دارای قابلیت رگرسیونی و کلاس-بندی می باشد. در مدل شبکه عصبی، متغیرهای توضیحی و متغیر پاسخ می توانند از نوع کمی یا کیفی باشند و همچنین متغیر های توضیحی ای غیرخطی و غیر مستقیم با متغیر های توضیحی دارد. چارچوب شبکه های عصبی از چند لایه به نام های لایه ورودی، لایه (های) پنهان و لایه خروجی تشکیل شده است. شکل ۲-۱، ساختار شماتیکی یک شبکه را با یک لایه پنهان نشان می دهد 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 می شوند.

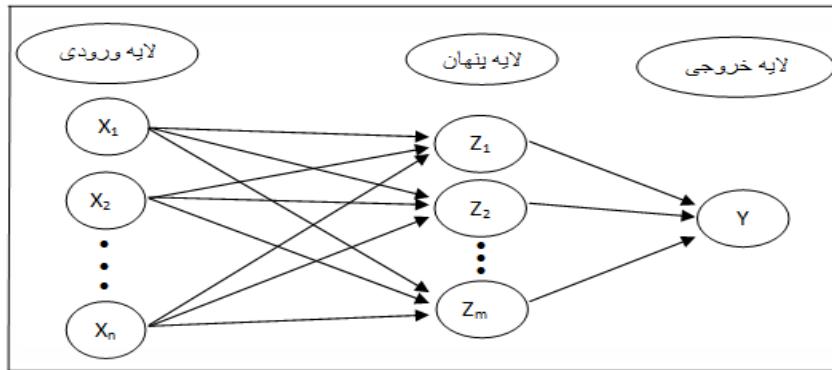
دانش مبتنی بر شهود انجام داده است. در این پایان نامه روشی برای انجام تشخیص پزشکی از روی پایگاه داده ای پزشکی پیشنهاد شده است که شامل ایجاد فاکتور اطمینان از روی اپیزودهای پزشکی با توجه به داده های بالینی- تشخیصی، تعیین توابع وزنی از روی این فاکتور با دو روش نگاشت و فازی، ترکیب توابع وزنی از اپیزودهای 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 تشخیص های پزشکی را نیز دارا می باشد(۱۵).

بنابراین از داده کاوی برای غلبه بر این مشکل استفاده می شود و 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 جهت پیش بینی بیماری قلبی دست یافت.

تعاریف مفهومی متغیرهای پژوهش:

- داده کاوی: داده کاوی به بررسی و تجزیه و تحلیل مقادیر عظیمی از داده ها به منظور کشف الگوها و قوانین معنی دار اطلاق می شود که "عمدتاً" از طریق ساختن مدل ها و الگوریتم ها، ورودی ها را با هدف یا مقصد خاصی مرتبط می نماید.

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



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 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 متداول‌ترین 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 (شکل) است که از جمله آنها می‌توان به تانژانت (Function) اشاره کرد.

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	آرثیز
کمی	ST-dep	کاهش ST
کیفی	Peak-ST	ST اوج
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"

درصد فراوانی	فراوانی	جنسیت
۳۲,۲	۸۷	زن
۶۷,۸	۱۸۳	مرد
۱۰۰		مجموع

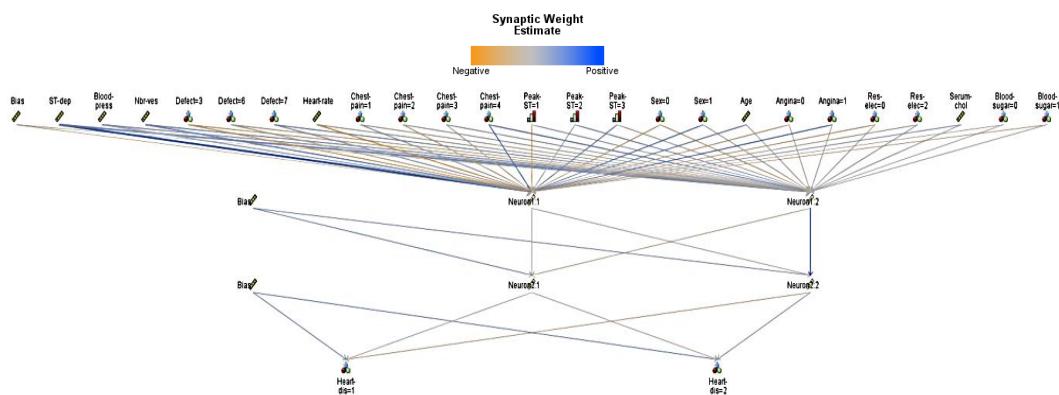
(۲۰٪ کل داده‌ها، ۶۶ مراجعه کننده) تقسیم می‌شود. با استفاده از مجموعه داده مدل‌سازی عمل مدل‌سازی مدل مربوطه انجام می‌شود. در نهایت با استفاده از مجموعه داده آزمون دقت مدل برآش داده شده مورد ارزیابی قرار می‌گیرد. کلیه مراحل ذکر شده برای برآش مدل در محیط نرم‌افزار Clementine 14.2 انجام شده است.

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

در ابتدا مجموعه اصلی داده‌ها که شامل ۲۷۰ مرجعه کننده است به دو قسمت مجموعه داده مدل‌ساز (۸۰٪) کل داده‌ها، ۲۰۴ مرجعه 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	لایه گره	نوع گره
	در لایه بعد		لایه متغیر
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	۴,۶۱	Res-elec=0
set	اول	۳,۶۹	Res-elec=2
set	اول	۱,۸۴	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

$$\begin{aligned} \{Neuron\ 1.1\} &= Tanh(-۰,۲۳ + ۰,۷ - (۱۲ * \{\text{Peak} = ST = 1\}) + (۱۱,۰۷ * \{\text{Peak} = ST = 2\}) \\ &\quad + (۱۰,۱۵ * \{\text{Peak} = ST = 3\}) - (۲۰,۳۰ * \{Nbr = ves\}) - (۲,۷۹ * \{\text{Serum} = chol\}) \\ &\quad + (۲۱,۲۲ * \{\text{Blood} = press\}) + (۷,۳۸ * \{\text{Age}\}) - (۱۹,۹۱ * \{\text{Heart} = rate\}) \\ &\quad + (۲۲,۱۵ * \{ST = dep\}) + (۱۹,۳۸ * \{\text{Defect} = 3\}) + (۱۸,۴۹ * \{\text{Defect} = 6\}) \\ &\quad - (۱۷,۵۳ * \{\text{Defect} = 7\}) + (۱۵,۶۹ * \{\text{Chest} = pain = 1\}) - (۱۶,۷۹ * \{\text{Chest} = pain = 2\}) \\ &\quad - (۱۷,۸۴ * \{\text{Chest} = pain = 3\}) + (۱۷,۹۱ * \{\text{Chest} = pain = 4\}) - (۱,۲۲ * \{\text{Sex} = 0\}) \\ &\quad + (۸,۲۰ * \{\text{Sex} = 1\}) - (۹,۴۹ * \{\text{Angina} = 0\}) + (۵,۵۳ * \{\text{Angina} = 1\}) \\ &\quad - (۴,۹۱ * \{\text{Res} = elec = 0\}) - (۷,۶۹ * \{\text{Res} = elec = 2\}) - (۱,۸۴ * \{\text{Blood} = sugar = 0\}) \\ &\quad - (۰,۹۲ * \{\text{Blood} = sugar = 1\}) \end{aligned}$$

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

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

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

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 برآش داده شده، عمل کلاس‌بندی برای مجموعه مشاهدات مدل‌ساز و آزمون انجام شده که نتایج آن به ترتیب در جدول 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

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

مشاهده شده		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 = 2 و یک مشاهده دارای کلاس متغیر پاسخ

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 آزمون 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

مشاهده شده		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

بطور کلی نحوه کلاس‌بندی مدل شبکه عصبی با ساختار پرسپترون چند لایه را برای دو مجموعه داده مدل‌ساز و آزمون در جدول ۷ می‌توان مشاهده کرد.

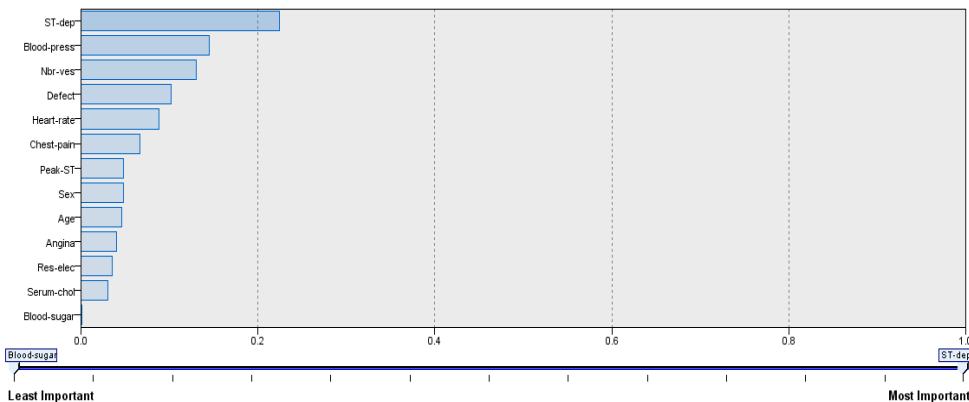
با توجه به جدول ۸ می‌بینیم که مدل "شبکه عصبی با ساختار پرسپترون چند لایه" با دقت ۸۳,۳۳ درصد عمل کلاس‌بندی را برای مجموعه داده آزمون انجام داده است.

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 rate (ضربان قلب)، (درد قفسه سینه)، Sex (جنسیت)، Peak-ST (اوج)، Res-elec (آنژین)، Age (سن)، 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

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 J1991;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 One2017;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 Uni2014; 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 Sci2008;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 J2010;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 Uni2010.(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