

پیش بینی روش درمان بیماری قلبی با استفاده از الگوریتم های داده کاوی

سجاد مظاہری^۱، مریم عاشوری^۲، زینب بچاری^۳

چکیده

زمینه و هدف: امروزه بیماری قلبی بسیار معمول و یکی از دلایل اصلی مرگ و میر به شمار می رود. به همین علت تشخیص درست و به موقع این بیماری بسیار مهم است. روش های تشخیصی و درمانی این بیماری عوارض جانبی زیاد و پرهزینه ای دارد. بنابراین محققان به دنبال روش های ارزان و با دقت بالا برای تشخیص این بیماری هستند. پژوهش حاضر با هدف شناسایی الگویی برای تشخیص روش درمان بیماری قلبی صورت گرفته است.

روش بررسی: پژوهش حاضر به روش توصیفی- مقطوعی صورت گرفته و نمونه گیری به روش سرشماری بوده است. جامعه ای پژوهش مشتمل از داده های بیمارستان های خاتم الانبیاء(ع) و علی ابن ابی طالب(ع) زاهدان است که با مراجعه ی مستقیم پژوهش گر به سازمان حاصل و به صورت فایل اکسل تهیه گردید. جهت تحلیل داده ها از نرم افزار Clementine12.0 استفاده شده است. در پژوهش حاضر الگوریتم های QUEST و CHAID و C&R Tree و C5.0 و C&R Tree مجموعه داده اجرا گردید.

یافته ها: مقدار صحت ۷۶/۰۴ توسط الگوریتم C&R Tree نشان دهنده ی عملکرد بهتر الگوریتم های درخت تصمیم نسبت به شبکه ی عصبی است.

نتیجه گیری: هدف این مطالعه ارایه مدلی برای پیش بینی روش درمانی مناسب بیماری قلبی به منظور کاهش هزینه های درمان و کیفیت ارایه خدمات بهتر به پزشکان می باشد. با توجه به قابل ملاحظه بودن خطرات اجرای روش های تشخیص تهاجمی مانند آنژیوگرافی و نیز حصول تجارب موقوفیت آمیز داده کاوی در پزشکی، این مطالعه مدلی مبتنی بر تکنیک های داده کاوی ارایه نموده است. نقطعه ی قابل بهبود مدل فوق ارایه سیستمی تصمیم یار جهت کمک به پزشکان برای افزایش صحت تشخیص روش درمان بیماری می باشد.

واژه های کلیدی: داده کاوی، بیماری قلبی، پیش بینی، روش درمان، درخت تصمیم، شبکه عصبی

دریافت مقاله: آذر ۱۳۹۵
پذیرش مقاله: فروردین ۱۳۹۶

*نویسنده مسئول:
سجاد مظاہری؛
اداره کل بیمه سلامت استان سیستان و
بلوچستان

Email :
sajad.mazaheri@gmail.com

مقدمه

معنای افزایش عمر و ایجاد آرامش برای افراد جامعه است. بنابراین پیچیدگی اطلاعات پزشکی و وجود ابزارهای داده کاوی باعث می‌شود که داده کاوی بر روی داده‌های پزشکی و سلامت مهم تلقی گردد^(۳). مهمترین خدمات قابل ارایه با استفاده از روش‌های داده کاوی عبارتند از:

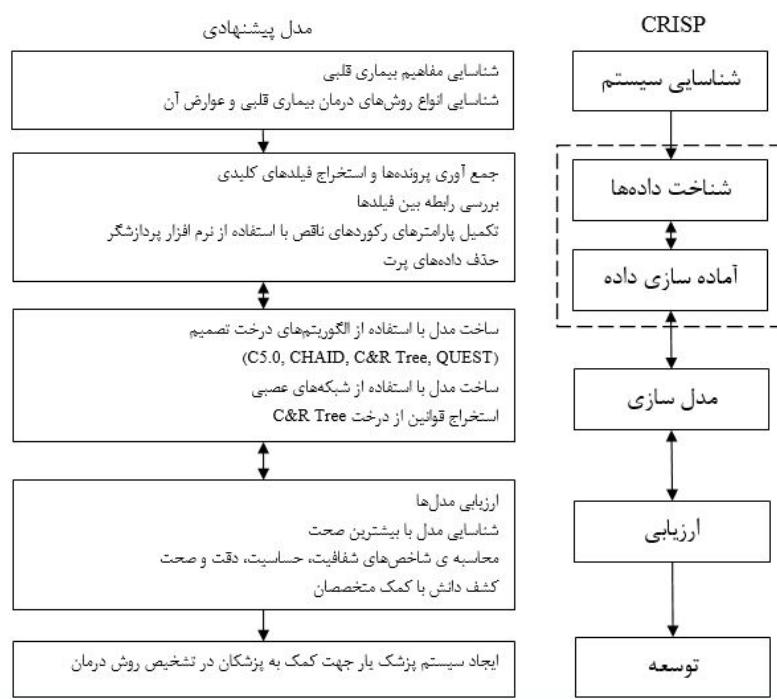
- بررسی میزان تاثیر دارو بر بیماری و اثرات جانبی آن
- تشخیص و پیش‌بینی انواع بیماری‌ها مانند تشخیص یا پیش‌بینی انواع سرطان
- تعیین روش درمان بیماری‌ها
- پیش‌بینی میزان موقوفیت اقدامات پزشکی مانند اعمال جراحی
- تجزیه و تحلیل داده‌های موجود در سیستم‌های اطلاعات سلامت (Health Information System: HIS)

• تحلیل عکس‌های پزشکی

یکی از روش‌های بسیار قوی برای پیاده‌سازی و اجرای پروژه‌های داده کاوی متدولوژی CRISP (Cross Industry Process for Data Mining) است^(۴). در مقاله‌ی حاضر مدل پیشنهادی بر اساس CRISP که شامل پنج فاز است، ارایه شده است. هر یک از این فازها خود شامل زیر بخش‌هایی می‌شوند. حرکت رو به جلو و عقب بین فازهای مختلف نیاز است، زیرا ورودی هر فاز به خروجی فاز مرحله‌ی قبل وابسته است^(۵). هر یک از این پنج فاز در شکل ۱ نشان داده شده‌اند.

زندگی انسان‌ها وابسته به عملکرد مناسب قلب است و اگر عملکرد قلب به صورت مناسب صورت نگیرد روی سایر قسمت‌های بدن از قبیل ذهن، کلیه و غیره اثر خواهد گذاشت^(۱). بیماری‌های قلبی و عروقی مهم ترین عامل مرگ و میر در دنیا می‌باشند. طبق اعلام سازمان جهانی بهداشت ۱۲ میلیون مرگ در کل دنیا بر اثر بیماری‌های قلبی صورت می‌گیرد. بیشترین علت مرگ و میرها در ایران ناشی از ابتلا به بیماری قلبی و عروقی است و مرگ ۳۸ درصد ایرانیان بر اثر بیماری قلبی رقم بسیار بالایی محسوب می‌شود^(۲).

طبق نظر کارشناسان، دانش نوین داده کاوی از جمله دانش‌های در حال توسعه است که در سال‌های اخیر در تمامی عرصه‌ها جایگاه خود را تثبیت کرده است؛ به گونه‌ای که رشد آن در مقایسه با سایر دانش‌های برتر، فزاینده است. همکاری متخصصان در زمینه‌ی کامپیوتر و پزشکی راه حل جدیدی را در تحلیل داده‌های پزشکی و به دست آوردن الگوهای مفید و کاربردی ارایه می‌دهد که همان داده کاوی پزشکی است. حوزه‌ی پزشکی و سلامت از بخش‌های مهم در جوامع صنعتی است. استخراج دانایی از میان حجم انبوه داده‌های مرتبط با سوابق بیماری و پرونده‌های پزشکی افراد با استفاده از فرایند داده کاوی می‌تواند منجر به شناسایی قوانین حاکم بر ایجاد، رشد و تسری بیماری‌ها، تشخیص، پیش‌بینی و درمان منظور شناسایی علل رخداد بیماری‌ها، تشخیص، پیش‌بینی و درمان بیماری‌ها با توجه به عوامل محیطی حاکم در اختیار متخصصان و دست اندکاران حوزه‌ی سلامت قرار دهد. نتیجه‌ی این مسئله به



آنفارکتوس قلبی استفاده نموده اند. صحت ۹۳/۴ درصد برای درخت تصمیم C5.0 نشان دهنده ی عملکرد بهتر این الگوریتم نسبت به سایر الگوریتم های درخت تصمیم و شبکه عصبی روی مجموعه داده ی مورد بررسی است(۱۳).

علیزاده ثانی به ارایه سیستمی برای تشخیص بیماری های قلبی روی ۳۰۳ نمونه ۸۷ نمونه سالم و ۲۱۶ نمونه بیمار(پرداخت) (۱۴). محمودی و همکاران نیز به پیش بینی عروق کرونر با استفاده از شبکه های عصبی و گرینش متغیر مبتنی بر درخت رگرسیون و طبقه بندي پرداختند. مقادیر ۷۴/۱۹، ۳۳/۲۵ و ۹۲/۴۱ برای شاخص های دقت، ویژگی و حساسیت حاصل گردید(۱۵).

امروزه بسیاری از بیمارستان ها از سیستم مدیریت اطلاعات بیمارستان برای مدیریت داده های بیماران و یا بهداشت و درمان استفاده می کنند. این سیستم ها مقدار زیادی داده شامل اعداد، متون، نمودارها و عکس ها ایجاد می کنند. متاسفانه این داده ها به ندرت در تصمیم گیری های کلینیکی مورد استفاده قرار می گیرند. سوالی که ذهن اکثر متخصصان این حوزه را به خود مشغول کرده این است که چگونه می توان داده ها را تبدیل به اطلاعات مفید نمود که قادر پزشکی را قادر به تصمیمات کلینیکی هوشمندانه نماید. از سوی دیگر، روش های داده کاوی روی داده ها به دنبال تایید آنچه از قبل وجود دارد، نیستند بلکه به دنبال مشخص کردن الگوهای از قبل شناخته نشده هستند. همچین هزینه و عوارض جانبی روش های تشخیصی بیماری قلب سبب شد که محققان به دنبال روش های ارزان و با دقت بالا برای تشخیص این بیماری باشند.

بنابراین پژوهش حاضر به دنبال پاسخگویی به این قبيل سوال هاست:

- چگونه می توان داده های موجود را به اطلاعات مفید برای اتخاذ تصمیمات کلینیکی هوشمند تبدیل نمود؟

- چگونه می توان از داده های موجود، الگوهایی را که از قبل شناخته نشده اند، شناسایی نمود؟

- چگونه می توان روش هایی با دقت بالا و ارزان قیمت برای تشخیص و درمان بیماری ها و به ویژه بیماری قلبی ابداع نمود؟

داده کاوی به عنوان یک حوزه ی نوظهور با پردازش داده ها و اطلاعات موجود به کشف دانش و شناسایی الگوهای جدید می پردازد. استفاده از تکنیک های مختلف داده کاوی، مدل هایی با دقت بالا ارایه می دهد که می توانند به عنوان سیستم های تصمیم یار استفاده شوند. وجود رویکردهایی جهت پیش بینی بیماری قلبی و نبود سیستمی جهت تشخیص روش درمان بیماری سبب گردید که در

مطالعات موجود در زمینه ی ترکیب دو حوزه ی داده کاوی و بیماری قلب موید این مطلب است که Awang و Palaniappan سیستم پیش بینی بیماری به نام قلب هوشمند را با استفاده از تکنیک های داده کاوی درخت تصمیم، شبکه بیز و شبکه عصبی توسعه داده اند. این سیستم به سوالات پیچیده ی پزشکی بر مبنای اگر و آنگاه پاسخ می دهد در حالی که سیستم های سنتی نمی توانند به این سوالات پاسخ دهنند. سیستم مورد نظر مبتنی بر وب، کاربرپسند، مقیاس پذیر، قابل اعتماد و قابل ارتقا بوده و با استفاده از داده کاوی روی پارامترهای پزشکی از قبیل: سن، جنسیت، فشار خون، قند خون و غیره می توان احتمال بیمارشدن به بیماری های قلبی را پیش بینی کرد(۶). Venkatalakshmi و Shivilankar سیستمی برای پیش بینی بیماری قلبی مبتنی بر تکنیک های داده کاوی پرداختند. مقدار ۸۴/۰۱ درصد برای صحت مدل ایجاد شده با درخت تصمیم حاصل گردید(۷). Masethe و Masethe برای پیش بینی حمله قلبی با صحت ۹۹٪ پرداختند. پارامترهای مورد بررسی شامل: جنسیت، سن، نوع درد قفسه سینه، افزایش ضربان قلب، کلسترول، سیگاری بودن، قند خون، فشارخون، دستگاه ثبت ضربان قلب، رژیم غذایی و الكل بود(۸).

Srinivas و همکاران پیش بینی بیماری قلبی را با تکنیک دسته بندي و الگوریتم های شبکه ی عصبی، شبکه ی بیزی، درخت تصمیم و ماشین بردار پشتیبان انجام دادند. شبکه بیزی وابستگی های شرطی بین متغیرها را شرح می دهد. بررسی نتایج پژوهش وی نشان می دهد که درخت تصمیم نسبت به سایر الگوریتم ها از دقت بالاتری برخوردار بوده است(۹). Soni و همکاران به بررسی عملکرد الگوریتم های مختلف داده کاوی با هدف پیش بینی حمله قلبی موثر پرداختند. نتایج نشان داد که درخت های تصمیم و شبکه ی عصبی صحت برابر و بهتر نسبت به سایر الگوریتم ها چون شبکه ی عصبی داشتند(۱۰). Tanejaaneja با استفاده از الگوریتم های داده کاوی به ارایه سیستمی برای پیش بینی حمله ی قلبی پرداخت. وی سه الگوریتم J48 و شبکه بیزی و شبکه عصبی را به کار برد که الگوریتم J48 هرس شده با میزان صحت ۹۵/۵۶٪ و میزان دقت ۹۵/۵٪ بهترین مدل را ایجاد نمود(۱۱).

رحمی شاطرانلو و علیزاده با ارایه مدل ترکیبی درخت تصمیم-شبکه بیزی به پیش بینی بیماری کرونری قلبی پرداختند. دقت و صحت مدل ترکیبی برابر ۹۵٪ و ۹۵٪ بود که بر مدل اولیه شبکه بیز با صحت ۸۹٪ و دقت ۹۰٪ برتری داشت(۱۲). صدری و همکاران از الگوریتم های شبکه عصبی و درخت تصمیم برای پیشگویی ابتلا به

ابی طالب(ع) زاهدان می باشد. نمونه گیری به روش سرشماری بوده و ۱۲۵ بیمار را در فاصله ی زمستان ۱۳۹۳ تا تابستان ۱۳۹۴ شامل می گردد. میانگین سن بیماران ۵۰ سال و ۴۲ درصد آن ها مرد و مابقی زن هستند. ۹ درصد بیماران سیگاری، ۸۴ درصد دارای فشارخون، ۸۲ درصد دارای چربی خون و ۶۱ درصد دارای قند خون هستند. ویژگی های آزمایشگاهی بیماران در این مرحله بررسی و شناسایی شد. در مهمن ترین گام تحقیق(آماده سازی داده ها یا پیش پردازش داده ها) به بررسی پرونده های بیماران پرداخته شده است. در جهان واقعی، داده همیشه کامل نیست و در مورد اطلاعات پزشکی این موضوع همیشه درست است. برای حذف تعدادی از تناقص ها و داده های ناقص در ارتباط با داده ها از پردازش داده استفاده گردید. بسیاری از تکنیک های پردازش داده توسط عامری و همکاران ارایه شده است(۵).

در مرحله‌ی آماده سازی داده‌ها جهت پاکسازی مجموعه داده با نظر افراد خبره اعمال زیر انجام گرفت: ابتدا فیلدهای خالی برخی از پرونده‌های بیماران قلبی با مراجعت به نرم افزار پردازش گر و بررسی سابقه پزشکی افراد از قبل ساقه‌ی داروهای مصرفی و آزمایش‌های انجام شده، مقداردهی گردید. رکوردهایی که در این مرحله همچنان دارای مقادیر از دست رفته (Missing Values) بودند، حذف گردیدند. همچنین برخی از رکوردهای دارای داده‌های پرت (Outlier) بودند که براساس میانگین‌گیری و استنتاج از داده‌های هم نوع بهینه شدند و برخی رکوردها که هیچ وجه تشابه‌ی با سایر داده‌ها نداشتند، حذف گردیدند. لذا در مرحله آماده سازی داده‌ها تعداد بیماران مورد بررسی به ۱۱۸ مورد رسید. داده‌ها با مراجعتی مستقیم پژوهش گر به صورت فایل اکسل تهیه گردید و محتوای داده‌ها مورد تایید متخصصان حوزه‌ی مربوط می‌باشد. در نهایت ۱۲۵ رکورد اولیه از بیماران پس از پالایش و حذف برخی رکوردها به ۱۱۸ رکورد نهایی کاهش یافت.

مطالعه‌ی حاضر به شناسایی الگویی برای تشخیص روش درمان بیماری‌های قلبی پرداخته شود. در این پژوهش، هدف، شناسایی افراد بیمار قلبی نیست بلکه تشخیص روش درمان مناسب مورد توجه است. بنابراین روش دسته بنده مورد توجه قرار گرفت و الگوریتم‌های QUEST، CHAID، C&R Tree، C5.0 و شبکه عصبی مصنوعی روی مجموعه داده اجرا گردید. مقدار صحت الگوریتم C&R Tree نشان دهنده‌ی عملکرد بهتر الگوریتم‌های درخت تصمیم نسبت به شبکه عصبی می‌باشد.

روش بررسی

الف) شناخت سیستم

در این مرحله به شناخت سیستم مورد نظر پرداخته می شود و سپس اهداف مورد نظر و عوامل موقیت کلیدی سیستم تعیین و بازنگری می گردد. طبق نظر متخصصان قلب، با توجه به رشد روز افزون بیماری های قلبی، هزینه های سرسام آور درمان این بیماری و عوارض شدیدی که روی اعضای حیاتی بدن در دراز مدت می گذارد، بررسی داده های جمع آوری شده در رابطه با این بیماری برای تشخیص روش درمان بیماران جدید می تواند مفید باشد. بیماران جدید می توانند تا حد ممکن از توصیه های پژوهشکی تجویز شده مناسب با بیماران دسته ای که در آن قرار گرفته اند، بهره ببرند. همچنین از رژیم غذایی و نوع برنامه غذایی تجویز شده برای آن بیماران استفاده کنند تا شدت بیماری آن ها تا حدودی مهار گردد.

ب) شناخت داده ها و آماده سازی آن ها
در این فاز به جمع آوری داده های اولیه، توصیف داده ها، بازرسی و بررسی داده ها و اعتبار سنجی کیفیت داده ها پرداخته شده است. مطالعه‌ی حاضر از نوع توصیفی - مقطعی بوده و مجموعه داده های آن متعلق به بیمارستان های خاتم الانبیاء(ع) و علمی، این

جدول ۱: داده ها و نوع آن ها پس از پاکسازی

نوع	توضیحات	مشخصه
اسمی	جنسیت	Sex
عددی	سن	Age
رتبه ای	فشارخون	Blood Pressure
رتبه ای	قند خون	Blood Sugar
رتبه ای	کلسترول	Cholesterol
رتبه ای	سیگار	Cigarette
رتبه ای	وزن	Weight
رتبه ای	شغل	Job
اسنجی	روش درمان	Cure Method

باشند(۱۷). برای بیان قوانین استخراج شده، مسیر ریشه تا برگ درخت پیمایش می شود و قوانین به صورت شرطی بیان می شود.

در پژوهش حاضر مدل سازی با استفاده از نرم افزار SPSS Clementine 12.0 کاوی پیش بینانه می باشد و از الگوریتم های درخت تصمیم استفاده شده است تا بهترین نسبت بین فیلدهای مختلف به دست آید(۱۷). اجرای الگوریتم های درخت تصمیم شامل C5.0 Tree، CHAID و QUEST و شبکه عصبی روی داده های موجود با هدف پیش بینی روش درمان بیماران قلبی صورت گرفت که تحقق این امر با اندازه گیری پارامترهای فشارخون، قند خون و سیگاری بودن به عنوان عوامل مهم و تاثیرگذار در بیماری قلبی صورت گرفت. برای تولید مدل، ابتدا داده های مورد بررسی به دو بخش آموزش و آزمایش تقسیم گردید. داده های بخش آموزش(۸۵ درصد) درخت را تولید می نمایند و داده های بخش آزمایش(۱۵ درصد) درخت تولید شده را تست و برچسب مربوط به رکوردهای مذکور را تعیین می نمایند. برای آموزش درخت تصمیم یک متغیر طبقه ای باید فیلد خروجی باشد و یک یا تعداد بیشتری فیلد ورودی وجود داشته باشد. فیلد های ورودی مقادیر به دست آمده از آزمایش های بیماران و خروجی نوع درمان در نظر گرفته شده برای آن ها بود.

هر رکورد دارای ۹ صفت می باشد که مشخصات صفات شامل نوع آن ها در جدول ۱ داده شده است.

ج) مدل سازی

روش های داده کاوی بسیاری برای مدل سازی وجود دارد. در این فاز با استفاده از تکنیک های مختلف داده کاوی به تولید مدل و الگوی بهینه پرداخته شده است. دسته بنده به عنوان یکی از شناخته شده ترین روش های داده کاوی از دو مرحله تشکیل می شود. در مرحله ای اول که مرحله ای استنتاج است هدف کشف مدلی برای تعریف دسته هایی از پیش مشخص شده ی داده هاست. مدل بر اساس نمونه های آموزشی ارایه شده به سیستم ایجاد می شود. الگوریتم استنتاج با استفاده از مقادیر مشخصه های نمونه هایی که به هر دسته تعلق دارند، تعریفی برای آن دسته خاص ایجاد می کند. در مرحله دوم که پیش بینی نام دارد، برای نمونه هایی که تعلق آن ها به دسته خاصی مشخص نیست، بر اساس مدل استنتاج شده می توان تعلق آن ها را پیش بینی نمود(۱۶).

درخت تصمیم برای دسته بنده مورد استفاده قرار می گیرد. عموماً مجموعه های قوانین مهمترین اطلاعات مرتبط با درخت تصمیم را در بردارند. درخت بر اساس یک معیار تقسیم شاخه به زیر شاخه هایی شکسته می شود و این روند به صورت تناوبی ادامه می یابد تا در نهایت، داده های هر گروه در یک دسته قرار داشته

جدول ۲؛ برچسب دسته مدل

برچسب دسته	توضیحات
۱	آنژیوگرافی: در این روش تعداد عروق کرونر مسدود شده، محل انسداد و میزان آن مشخص می شود و مستقیم ترین راه کشف مشکلات شریان های کرونری قلب است.
۲	آنژیوپلاستی: در این روش سرخرگ های کرونر تنگ یا مسدود شده به وسیله ی رسوب چربی و لخته، بدون نیاز به عمل جراحی باز می گردند.
۳	درمان طبی: در این روش با آگاهی دادن به بیمار و تجویز داروهای مربوط به بیماری به بهبود سلامت بیمار کمک می شود.
۴	Pace maker: به بخشی از قلب و یا در حالت مصنوعی دستگاهی که عمل ضربان سازی را تقلید می کند گفته می شود که ضریان ایجاد کرده و آهنگ آن را تنظیم می کند.
۵	قلب باز: در صورتی که تعداد عروق تنگ، زیاد بوده و یا تنگی در محل خطرناک نظریه اصلی سرخرگ چپ یا در ابتدای شریان کرونری قلب یا محل دوشاخه شدن عروق کرونر باشد، امکان آنژیوپلاستی وجود نداشته، نیاز به عمل جراحی پیوند عروق قلب می باشد.

جدول ۲ برچسب دسته (روشن درمان) را به همراه توضیحات

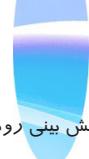
نشان می دهد.

د) ارزیابی

پس از اجرای مدل سازی باید به ارزیابی نتایج حاصل پرداخت. نتایج ارزیابی باعث بهبود مدل می شود و مدل را قابل استفاده می نماید. شاخص های مختلفی مانند شفافیت (Specificity)،

حساسیت (Sensitivity)، دقت (Precision) و صحت (Accuracy)

برای ارزیابی روش های دسته بنده وجود دارند که طبق روابط ۱ تا ۴ محاسبه می گردند. برای محاسبه می میزان شاخص ها می توان از ماتریس اغتشاش (Confusion Matrix) استفاده کرد. این ماتریس ابار مفیدی برای تحلیل چگونگی عملکرد روش دسته بنده در تشخیص داده ها یا مشاهدات دسته های مختلف است. حالت



$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (4)$$

و) توسعه

ساخت مدل، پایان یک پروژه نیست و هدف از پروژه های داده کاوی کشف دانش و استفاده از دانش کشف شده به صورت عملی در آینده می باشد. در حقیقت هدف از انجام مراحل مختلف کشف دانش، دست یابی به نتایجی است که بتوان از آن ها در دنیای واقعی و برای بهبود کارایی سازمان ها استفاده کرد. دانش کشف شده باید سازماندهی شود و به شکل قابل استفاده برای دیگران نیز درآید. به طور کلی وجود رویکردهای سازمان دهی شده جهت پیش بینی روش درمان بیماران قلبی به منظور کمک به پزشک برای افزایش صحت تشخیص و جلوگیری از عوارض ناشی از تشخیص نادرست ضروری است. نقطه ای قابل بهبود در حیطه ای مورد بررسی، ایجاد سیستمی پزشک یار جهت کمک به پزشکان در تشخیص روش درمان می باشد.

یافته ها

الگوریتم های C5.0، CHAID، C&R Tree و QUEST و شبکه عصبی مصنوعی روی مجموعه داده ای مورد بررسی اجرا گردید.

ایده آل این است که بیشتر داده های مرتبط با مشاهدات روی قطر اصلی ماتریس قرار گرفته باشند و مابقی مقادیر ماتریس صفر یا نزدیک صفر باشند (۱۴ و ۱۸).

TN: بیانگر تعداد رکوردهایی است که دسته ای واقعی آنها منفی بوده و الگوریتم دسته بندی نیز دسته ای آنها را به درستی منفی تشخیص داده است.

TP: بیانگر تعداد رکوردهایی است که دسته ای واقعی آنها مثبت بوده و الگوریتم دسته بندی نیز دسته ای آنها را به درستی مثبت تشخیص داده است.

FP: بیانگر تعداد رکوردهایی است که دسته ای واقعی آنها منفی بوده و الگوریتم دسته بندی دسته ای آنها را به اشتباه مثبت تشخیص داده است.

FN: بیانگر تعداد رکوردهایی است که دسته ای واقعی آنها مثبت بوده و الگوریتم دسته بندی دسته ای آنها را به اشتباه منفی تشخیص داده است.

$$\text{Specificity} = \frac{TN}{FP + TN} \quad (1)$$

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (2)$$

جدول ۳: مقدار صحت برای مدل های تولید شده

نوع الگوریتم	نام الگوریتم	داده آزمایش (درصد)	داده آموزش (درصد)	درخت تصمیم
	C&R Tree	۷۶/۰۴	۵۶/۵۲	
	QUEST	۶۶/۶۷	۵۶/۵۲	
	CHAID	۶۳/۵۴	۵۲/۱۷	
	C5.0	۶۵/۶۲	۴۷/۸۳	
شبکه عصبی	Neural Net	۵۷/۲۹	۳۹/۱۳	

گره درخت C&R Tree به دست آمد. بنابراین از درخت C&R Tree برای تعیین روش درمان استفاده شده است.

مقدار صحت مدل های تولید شده برای داده های آموزش و آزمایش طبق جدول ۳ می باشد. بیشترین میزان صحت با استفاده از

جدول ۴: مقدار شاخص ها برای الگوریتم C&R Tree

بر حسب دسته	شفافیت	حساسیت	دقت	صحت
۱	%۳۴	%۷۱	%۹۲	%۷۶
۲	%۹۷	%۱۰۰	%۴۳	%۹۷
۳	%۸۹	%۹۲	%۴۲	%۸۷
۴	%۹۷	%۶۰	%۶۰	%۹۷
۵	%۹۱	%۶۳	%۵۹	%۸۹

C&R Tree شفافیت و ۷۷/۲ درصد برای حساسیت توسط الگوریتم نشان می دهد که درخت تولیده شده می تواند قوانین جامعی برای پیش بینی وضعیت بیماران آینده ارایه نماید.

جدول ۴ مقادیر چهار شاخص برای هر کدام از برچسب دسته ها را نشان می دهد که برای الگوریتم C&R Tree و با استفاده از ماتریس اختشاش محاسبه گردیده است. مقدار ۸۹/۲ درصد برای میانگین کلی صحت مدل، ۵۹/۲ درصد برای دقت، ۸۱/۶ درصد برای

جدول ۵: قواعد تلازمی تولید شده توسط درفت تصمیم C&R Tree

قوانین	برچسب دسته
if Cholesterol <= 0.5 and Age <= 66 and Blood Pressure <= 0.5 and Age <= 32.5 and Age > 29.5 Then Label=1	۱
if Cholesterol > 0.5 and Cigarette <= 0.5 and Blood Sugar <= 0.5 and Blood Pressure > 0.5 Then Label=1	
if Cholesterol > 0.5 and Cigarette <= 0.5 and Blood Sugar > 0.5 and Age > 37 Then Label=1	
if Cholesterol > 0.5 and Cigarette > 0.5 and Blood Pressure > 0.5 and Blood Sugar <= 0.5 Then Label=1	
if Cholesterol <= 0.5 and Age <= 66 and Blood Pressure > 0.5 and Sex=M and Age <= 53.5 Then Label=2	۲
if Cholesterol <= 0.5 and Age > 66 and Age > 70.5 and Sex=F and Blood Sugar > 0.5 Then Label=2	
if Cholesterol <= 0.5 and Age <= 66 and Blood Pressure <= 0.5 and Age <= 32.5 and Age <= 29.5 Then Label=3	۳
if Cholesterol <= 0.5 and Age <= 66 and Blood Pressure <= 0.5 and Age > 32.5 Then Label=3	
if Cholesterol <= 0.5 and Age <= 66 and Blood Pressure > 0.5 and Sex=F and Age <= 53.5 Then Label=3	
if Cholesterol <= 0.5 and Age <= 66 and Blood Pressure > 0.5 and Sex=M and Age > 53.5 Then Label=3	
if Cholesterol > 0.5 and Cigarette <= 0.5 and Blood Sugar <= 0.5 and Blood Pressure <= 0.5 and Age <= 67.5 Then Label=3	
if Cholesterol <= 0.5 and Age > 66 and Age > 70.5 and Sex=F and Blood Sugar <= 0.500 Then Label=4	۴
if Cholesterol <= 0.5 and Age > 66 and Age > 70.5 and Sex=M Then Label=4	
if Cholesterol > 0.5 and Cigarette <= 0.5 and Blood Sugar <= 0.5 and Blood Pressure <= 0.5 and Age > 67.5 Then Label=4	
if Cholesterol <= 0.5 and Age <= 66 and Blood Pressure > 0.5 and Sex=F and Age > 53.5 Then Label=5	۵
if Cholesterol <= 0.5 and Age > 66 and Age <= 70.5 Then Label=5	
if Cholesterol > 0.5 and Cigarette <= 0.5 and Blood Sugar > 0.5 and Age <= 37 Then Label=5	
if Cholesterol > 0.5 and Cigarette > 0.5 and Blood Pressure <= 0.5 Then Label=5	
if Cholesterol > 0.5 and Cigarette > 0.5 and Blood Pressure > 0.5 and Blood Sugar > 0.5 Then Label=5	

شده اند. پارامتر جنسیت اهمیت کمتری نسبت به سایر پارامترها دارد. با استفاده از قوانین ایجاد شده برای یک نمونه ی جدید با ویژگی های مشخص، می توان پیش بینی کرد که چه روش درمانی مناسب نمونه ی جدید است. به طور کلی داشت خراج شده از مدل های داده کاوی می تواند به عنوان یک سیستم تصمیم یار در دنیای واقعی استفاده شود.

جدول ۵ نشان می دهد که اگر فرد کلسترول و فشارخون نداشته باشد و سن وی بین ۲۹/۵ و ۳۲/۵ باشد برچسب دسته یک می شود و روش آنتیوگرافی برای درمان وی مناسب است. داشت خراج شده از مدل C&R Tree می تواند به عنوان الگویی جهت پیش بینی روش درمانی مناسب توصیه شود که این قوانین پارامترهای اثرگذار را در روش درمانی مشخص می کنند. قواعد تلازمی ارایه شده

دانش یا قوانین استخراج شده در جدول ۵ نشان داده شده است.

بحث

از داده کاوی برای 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. ویژگی متمایز مطالعه ی حاضر کشف الگویی برای شناسایی روش درمان بیماران قلبی با استفاده از الگوریتم های درخت تصمیم و شبکه عصبی است. از بین الگوریتم های مورد استفاده، بهترین نتایج از الگوریتم C&R Tree با دقت ۵۹/۲ و صحت ۷۶/۰۴ به دست آمد. تاثیرگذارترین پارامترها در انتخاب روش درمان بیماری قلبی کلسترول، سیگاری بودن، قند خون، فشارخون و سن شناخته



مدل‌ها چون شبکه عصبی برتری داشته اند(۱۳-۹۷)، که در این مطالعه هم این نتیجه تایید گردید. عدم ثبت صفاتی چون درصد انسداد رگ و منبع انتخاب روش درمان می‌تواند جزو محدودیت‌های سیستم ارایه شده محسوب گردد. همچنین محدود بودن تعداد نمونه‌های با روش درمان Pace maker را می‌توان جزو محدودیت‌های سیستم به شمار آورد.

نتیجه گیری

داده کاوی روی داده‌های پزشکی از اهمیت بالایی برخوردار است و طراحی سیستم‌های تصمیم‌یار جهت یاری رساندن به پزشکان در زمینه‌ی تشخیص نوع بیماری یا انتخاب نوع درمان مناسب، با کمک داده کاوی می‌تواند کمک شایانی در زمینه‌ی نجات جان انسان‌ها انجام دهد. در همین راستا در پژوهش حاضر الگوریتم C&R Tree با بهترین عملکرد به پیش‌بینی روش درمان مناسب بیماران قلبی پرداخته است. طبق نظر متخصصان قلب و عروق می‌توان گفت که ریسک پارامترهای سن بالا، مصرف سیگار، فشارخون بالا، چربی خون بالا بیشترین تاثیر را در روش درمانی لحظه شده دارند و این در حالی است که اولویت بندی متغیرها تاثیرگذار قرار داده است. C&R Tree، این متغیرها را جزو پارامترهای تاثیرگذار قرار داده است که نشان از اهمیت این متغیرها در روش درمانی انجام شده دارد. همچنین نتایج حاصل شده نشان می‌دهد که صحت پیش‌بینی درخت تصمیم روی داده‌های مورد بررسی از شبکه‌ی عصبی که یک روش پرکاربرد و مشهور می‌باشد، بیشتر است. استفاده از صفات درصد انسداد رگ و منبع انتخاب روش درمان به همراه صفات موجود می‌تواند سیستمی جامع جهت پیش‌بینی روش درمانی مناسب برای بیماران قلبی ارایه نماید و بدین طریق با کاهش هزینه‌های درمان بیماران و افزایش کیفیت ارایه خدمات به آن‌ها می‌توان گامی موثر در جهت ارتقای سیستماتیک تشخیص پزشکی برداشت.

تشکر و قدردانی

بدین وسیله از کلیه پرسنل محترم بیمارستان‌های خاتم الانبیاء(ع) و علی این ابی طالب(ع) زاهدان تقدیر و تشکر می‌شود. پژوهش حاضر حاصل یک طرح تحقیقاتی با شماره ۳۳ مصوب سازمان پیمه سلامت ایران و بدون حمایت مالی می‌باشد.

در جدول ۵ نحوه‌ی پیش‌بینی مدل را نشان می‌دهد. هر چه تعداد قوانین تولید شده بیشتر باشد بهتر است؛ زیرا این نشان می‌دهد که مدل پیش‌بینی کننده، جزئیات بیشتری را مد نظر قرار داده است. مقادیر بالا برای شاخص‌های حساسیت، شفافیت، صحت و دقت نشان دهنده‌ی این است که طبقه بندی مورد استفاده نمونه‌های بیشتری را در جای درست خود طبقه بندی کرده است. Anandakumar و Ashwinkumar محدودیت‌های اجتماعی، قانونی و اخلاقی روی داده‌های پزشکی از جمله بیماری قلبی را بررسی کرده اند(۱۹). Venkatalakshmi و Palaniappan و Srinivas و Shivasankar و Guru و همکاران در مطالعات خارجی به ارایه سیستم‌هایی برای پیش‌بینی بیماری قلبی پرداخته اند(۹۷ و ۶۹). و همکاران پیش‌بینی بیماری قلبی را بر اساس پارامترهای فشارخون، قند، شکر و غیره انجام داد. جهت انجام کار ۷۸ پرونده با ۱۳ ویژگی به عنوان مجموعه آموزش و آزمایش استفاده شد(۲۰). Parthiban و Subramanian داده کاوی شبکه عصبی را با قابلیت‌های یادگیری با منطق فازی که دارای رویکردی کیفی است ترکیب کرده و از آن برای تشخیص بیماری قلبی استفاده کرده اند(۲۱).

Tanejaaneja و Soni Masethe و همکاران از داده کاوی به منظور پیش‌بینی حمله‌ی قلبی استفاده نمودند(۱۱ و ۱۰). در مطالعات داخلی نیز رحیمی شاطرانلو و علیزاده پیش‌بینی بیماری کرونری قلبی، صدری و همکاران پیش‌بینی ابتلا به آنفارکتوس قلبی، علیزاده ثانی تشخیص بیماری‌های قلبی و محمودی و همکاران پیش‌بینی عروق کرونر را با استفاده از الگوریتم‌های داده کاوی انجام دادند(۱۵-۱۲). شفیعی و ابراهیمی با بهره‌گیری از الگوریتم‌های داده کاوی مدلی جهت تشخیص بیماری عروق کرونری معرفی نمودند و نشان دادند که متغیر اسکن-تالیوم مهم‌ترین ویژگی در تشخیص بیماری‌های قلبی می‌باشد(۲۲).

بررسی مطالعات موجود نشان می‌دهد که تاکنون از داده کاوی برای تشخیص بیماری قلبی و پارامترهای تاثیرگذار در ایجاد بیماری قلبی استفاده گردیده است. از نظر هدف هیچ یک از مطالعات داخلی و خارجی انجام شده تاکنون به پیش‌بینی روش درمان بیماری قلبی نپرداخته اند و اکثر مطالعات روی تشخیص بیماری قلبی در حالی که پژوهش حاضر مدلی برای پیش‌بینی روش درمان بیماری قلبی ارایه داده است. از نظر روش مدل سازی، در اکثر مطالعات انجام شده مدل تولید شده با الگوریتم‌های درخت تصمیم بر سایر

منابع

- Chaitrali SD & Sulabha SA. A data mining approach for prediction of heart disease using neural networks. International Journal of Computer Engineering and Technology 2012; 3(3): 30-40.



2. Karimi S, Javadi M & Jafarzadeh F. Economic burden and costs of chronic diseases in Iran and the world. *Health Information Management* 2012; 8(7): 984-96[Article in Persian].
3. Jooriyan N & Ashoori M. Predicting the effectiveness of preeclampsia medications based on dose and method of drug consumption using data mining. *Iranian Journal of Obstetrics, Gynecology and Infertility* 2014; 17(123): 13-22[Article in Persian].
4. Alizadeh S, Ghazanfari M & Teimorpour B. Data mining and knowledge discovery. 2nd ed. Tehran: Publication of Iran University of Science and Technology; 2011: 70-250[Book in Persian].
5. Ameri H, Alizadeh S & Barzegari A. Knowledge extraction of diabetics' data by decision tree method. *Health Management* 2013; 16(53): 58-72[Article in Persian].
6. Palaniappan S & Awang R. Intelligent heart disease prediction system using data mining techniques. *International Journal of Computer Science and Network Security* 2008; 8(8): 343-50.
7. Venkatalakshmi B & Shivasankar MV. Heart disease diagnosis using predictive data mining. *International Journal of Innovative Research in Science, Engineering and Technology* 2014; 3(3): 1873-7.
8. Masethe HD & Masethe MA. Prediction of heart disease using classification algorithms, USA: Proceedings of The World Congress on Engineering and Computer Science, 2014.
9. Srinivas B, Kavihta KA, Govrdhan R & Karimnagar J. Applications of data mining techniques in healthcare and prediction of heart attacks. *International Journal on Computer Science and Engineering* 2010; 2(1): 250-5.
10. Soni j, Ansari U, Sharma D & Soni S. Predictive data mining for medical diagnosis: An overview of heart disease prediction. *International Journal of Computer Applications* 2011; 17(8): 43-8.
11. Tanejaaneja A. Heart disease prediction system using data mining techniques. *Journal of Computer Science & Technology* 2013; 6(4): 457-66.
12. Rahimi Shateranloo E & Alizadeh S. Prediction of coronary heart disease using hybrid data mining. *Journal of Soft Computing and information Technology* 2014; 3(1): 56-62[Article in Persian].
13. Safdari R, Ghazi Saeedi M, Gharooni M, Nasiri M & Arji G. Comparing performance of decision tree and neural network in predicting myocardial infarction. *Journal of Paramedical Science and Rehabilitation* 2014; 3(2): 26-37[Article in Persian].
14. Alizadeh Sani R. Diagnosis of heart disease using data mining [Thesis in Persian]. Tehran: Sharif University of Technology; 2012.
15. Mahmoudi I, Askari Moghadam R, Moazzam M & Sadeghian S. Prediction model for coronary artery disease using neural networks and feature selection based on classification and regression tree. *Journal of Shahrekord University of Medical Sciences* 2013; 15(5): 47-56[Article in Persian].
16. Ashoori M, Naji Moghaddam V, Alizadeh S & Safi M. Classification and clustering algorithm application for prediction of tablet numbers: Case study diabetes disease. *Health Information Management* 2013; 10(5): 739-49[Article in Persian].
17. Chen G & Astebro T. How to deal with missing categorical data: Test of a simple bayesian method. *Organizational Research Methods* 2003; 6(3): 309-27.
18. Han J & Kamber M. Data mining: Concepts and techniques. 2nd ed. United States: Morgan Kaufman; 2006: 360-2.
19. Ashwinkumar UM & Anandakumar KR. Ethical and legal issues for medical data mining. *International Journal of Computer Applications* 2010; 1(28): 7-11.
20. Guru N, Dahiya A & Rajpal N. Decision support system for heart disease diagnosis using neural network. *Delhi Business Review* 2007; 8(1): 1-6.
21. Parthiban L & Subramanian R. Intelligent heart disease prediction system using canfis and genetic algorithm. *International Journal of Biological & Medical Sciences* 2008; 3(3): 157-64.
22. Shafiee H & Ebrahimi M. Accurate prediction of coronary artery disease using bioinformatics algorithms. *Qom Univ Med Sci* 2016; 10(4): 22-35[Article in Persian].

A Model to Predict Heart Disease Treatment Using Data Mining

Mazaheri Sajad¹ (M.S.) – Ashoori Maryam² (M.S.) – Bechari Zeynab³ (B.S.)

1 Master of Science in Computer Engineering Software, The Health Insurance Office of Sistan & Baluchestan Province, Iran Health Insurance Organization, Zahedan, Iran

2 Instructor, Information Technology Department, Higher Educational Complex of Saravan, Saravan, Iran

3 Bachelor of Science in Nursing, The Health Insurance Office of Sistan & Baluchestan Province, Iran Health Insurance Organization, Zahedan, Iran

Abstract

Received: Nov 2016

Accepted: Mar 2017

Background and Aim: Nowadays heart disease is very common and is a major cause of mortality. Proper and early diagnosis of this disease is very important. Diagnostic methods and treatments of the disease are so expensive and have many side effects. Therefore, researchers are looking for cheaper ways to diagnose it with high precision. This study aimed to identify a model for the treatment of heart disease.

Materials and Methods: In this descriptive cross-sectional study, the sampling method was census. The sample consisted of data from Khatam and Ali Ibn Abi Talib Hospitals in Zahedan. The data were developed as an Excel file, and Clementine12.0 software was used for data analysis. In the present study, C5.0, C & R Tree, CHAID, and QUEST algorithms and artificial neural network were carried out on the collected data.

Results: The accuracy of 76.04 by C & R algorithm indicates the better performance of Decision Tree Algorithms than that of the Neural Network.

Conclusion: This study aimed to provide a model for the prediction of a suitable heart disease treatment to reduce treatment costs and provide better quality of services for physicians. Due to considerable implementation risks of invasive diagnostic procedures such as angiography and also obtaining successful experiences of data analysis in medicine, this study has presented a model based on data analysis techniques. The improvable point of this model is the provision of a decision support system to help physicians to increase the accuracy of diagnosis in the treatment of diseases.

Keywords: Data Mining, Heart Disease, Prediction, Cure Method, Decision Tree, Neural Network

* Corresponding Author:
Mazaheri S;
Email:
sajad.mazaheri@gmail.com