دانشور
پزشکی

دوماهنامه علمی–پژوهشی
دانشگاه شاهد
سال بیست‌ویکم–شماره ۱۱۲
شهریور ۱۳۹۳

شناسایی عوامل تأثیرگذار بر سکته قلبی در بیماران دیابتی با استفاده از الگوریتم C&R

نویسندگان: حکیمه عامری*[۱]، سمیه علیزاده و اکبر برزگری[۳]

۱- کارشناس ارشد فناوری اطلاعات – تجارت الکترونیک، دانشکده مهندسی صنایع دانشگاه خواجه نصیرالدین طوسی تهران، ایران
۲- استادیار دانشگاه خواجه نصیرالدین طوسی تهران، دانشکده مهندسی صنایع دانشگاه خواجه نصیرالدین طوسی تهران، ایران
۳- پزشک، دانشگاه علوم پزشکی گرگان، ایران

* نویسنده مسئول: حکیمه عامری E-mail: hameri@mail.kntu.ac.ir

دریافت: ۱۳۹۳/۰۳/۲۱
آخرین اصلاح‌ها: ۱۳۹۳/۰۵/۱۸
پذیرش: ۱۳۹۳/۰۵/۲۲

چکیده

مقدمه و هدف: بیماری‌های قلبی، شایع‌ترین علت مرگ‌ومیر در کشورهای توسعه‌یافته و همچنین در کل دنیا هستند و طبق پیش‌بینی سازمان بهداشت جهانی، عامل اصلی مرگ‌ومیر در سراسر دنیا در سال ۲۰۲۰ خواهندبود. طبق آخرین گزارش‌های سازمان بهداشت جهانی از هر ۲۰ مرگ‌ومیر، یکی به دلیل دیابت است. بیماری‌های قلبی و سکته قلبی از مهم‌ترین عوارض دیابت به‌شمارمی‌آیند. در این تحقیق با استفاده از الگوریتم‌های داده‌کاوی، احتمال بروز سکته قلبی در بیماران دیابتی را با دقتی قابل‌قبول پیش‌بینی‌کرده، عوامل مؤثر در بروز سکته قلبی شناسایی‌شده‌اند.

مواد و روش‌ها: در این مطالعه که به‌صورت گذشته‌نگر انجام‌شد، ۸۵۶ پرونده سال ۱۳۸۸شمسی مرکز دیابت گرگان بررسی‌شده‌اند. اطلاعات موجود در پرونده بیماران با استفاده از روش های داده‌کاوی با نرم‌افزارSPSS CLEMENTINE تجزیه‌وتحلیل‌شدند. برای شناسایی عوامل مؤثر بر بروز سکته قلبی از الگوریتم‌های دسته‌بندی داده‌کاوی استفاده‌شد.

نتایج: با استفاده از الگوریتم درخت تصمیم C&R، مدلی با دقت ۹۴ درصد معرفی‌شده‌است. براساس درخت تصمیم C&R، سابقه فشارخون، شاخص BMI، فشارخون سیستولیک و دیاستولیک، چربی خون با چگالی پایین، میزان فعالیت روزانه و سن از مهم‌ترین عوامل مؤثر در[بروز] سکته قلبی در بیماران دیابتی شناسایی‌شده‌اند.

نتیجه‌گیری: می‌توان با استفاده از قوانین ایجادشده و شناسایی ویژگی‌های تأثیرگذار و کنترل عوامل مؤثر در بروز سکته قلبی در بیماران دیابتی، میزان مرگ‌ومیر ناشی از این عارضه را تاحدی کاهش‌داد.

واژگان کلیدی: داده‌کاوی، دیابت، سکته قلبی، الگوریتم درخت تصمیم.

مقدمه

بروز دیابت در ده سال اخیر در سطح جهان دو برابر شده‌است و حدود ۲۰۰ میلیون نفر به این بیماری مبتلا هستند و سالانه شیوع دیابت در جهان، حدود ٦ درصد افزایش‌می‌یابد. در مطالعه‌ای که در ایران انجام‌شده‌است، گزارش‌شده که ۷/۷ درصد بالغان ۲۵ تا ٦٤ ساله که حدود ۲میلیون نفرند، به دیابت، مبتلا بوده، ١٦/٨ درصد بالغان معادل با ٤ میلیون نفر در وضعیت عدم تحمل گلوکز قراردارند که تعداد زیادی از این بیماران در آینده به دیابت مبتلا خواهندشد(۱). براساس جدیدترین آمار ارائه‌شده، هر ۱۰ ثانیه، ۱ نفر به دلیل عوارض دیابت در جهان می‌میرد و هر ۱۰ ثانیه ۲ نفر به این بیماری مبتلا می‌شوند. از هر ۲۰ مرگ‌ومیر، یکی به دلیل دیابت است. که معادل ۸۷۰۰ مرگ در هر روز، یا شش مورد مرگ در هر دقیقه است. افراد مبتلا به دیابت، دو تا چهار برابر بیشتر احتمال‌دارد به بیماری‌های قلبی – عروقی، مبتلا شوند(۲).

داده‌کاوی از رشته‌هایی جدید است که با به‌کارگیری و استفاده از داده‌های آماری، به استخراج اطلاعات و الگوهای مفید می‌پردازد. داده‌کاوی نشان‌دهنده پیشرفتی قابل‌توجه در انواع ابزار تحلیلی دردسترس است و به‌عنوان روشی معتبر، حساس و قابل‌اعتماد برای کشف الگوها و روابط میان آنها درنظرگرفته‌می‌شود(۳). یکی از زمینه‌های که می‌توان این دانش را به‌نحوی مؤثر استفاده‌کرد و نتایجی قابل‌توجه به‌دست‌آورد، داده‌های پزشکی است. خواجوی و جایالاکشی، افزایش دقت تشخیص، کاهش هزینه‌ها و کاهش منابع انسانی را به‌عنوان مزایای معرفی داده‌کاوی در تجزیه‌وتحلیل پزشکی ثابت‌کرده‌اند(٤و٥). دسته‌بندی داده‌کاوی در پزشکی، عبارت‌است از: «بررسی میزان تأثیر دارو بر بیماری، شناسایی عوارض جانبی داروها، تعیین نوع درمان، تجزیه‌وتحلیل داده‌های موجود در پرونده الکترونیک سلامت(EHR)، تشخیص و پیش‌بینی انواع بیماری‌ها مانند سرطان، تحلیل عکس‌های پزشکی مانند ماموگرافی، التراسونیک، اشعه X و MRI، ارائه مدل‌های توصیفی بر روی داده‌های پزشکی، کنترل عفونت بیمارستان و بهره‌برداری از خدمات سلامت»(٦)؛ برای نمونه، *زایری* و همکاران (۱۳۹۱)، مطالعه‌ای روی عوامل تأثیرگذار بر مرگ‌ومیر پس از عمل جراحی کرونری بای‌پاس در بیماران غیروابسته به دیالیز انجام‌داده‌اند. داده‌ها از یک مطالعه مقطعی از ۱۳۹۰ بیمار در مدت ۳ سال از بیمارستان قلب شریعتی تهران جمع‌آوری‌شدند؛ در این تحقیق برای پیش‌بینی میزان مرگ‌ومیر از مدل‌های رگرسیون لجستیک و رده‌بندی درختی با نرم‌افزارهای SPSS و CART استفاده‌شده‌است و نتایج با یکدیگر مقایسه‌شدند. در مدل رده‌بندی با دقت ۹۰ درصد، متغیرهای نارسایی کلیوی شدید، کارگذاری بالن پمپ داخل آئورتی حین و پس از عمل، تنفس طولانی‌مدت از راه دستگاه، مدت زمان خون‌رسانی قلب حین عمل بیش از١٦٠ به‌عنوان زیرگروه‌های دارای خطر بالای مرگ و افراد با عوارض قلبی بطنی پس از عمل جراحی به‌عنوان زیرگروه با خطر متوسط مرگ معرفی‌شدند؛ شاخص‌های حساسیت و ویژگی برای این مدل، به‌ترتیب ۸۲ درصد و ۸۹ درصد و برای مدل لجستیک ۸۰/٤ درصد و ۸۸ درصد به‌دست‌آمده‌اند(۷).

مطالعاتی بسیار درزمینه دیابت نوع ۲ با استفاده از روش‌های داده‌کاوی انجام‌شده‌اند. مطالعات انجام‌گرفته را می‌توان به پنج گروه کلی که در شکل ۱ نمایش‌داده‌شده‌است، تقسیم‌کرد(۱۲–۸).

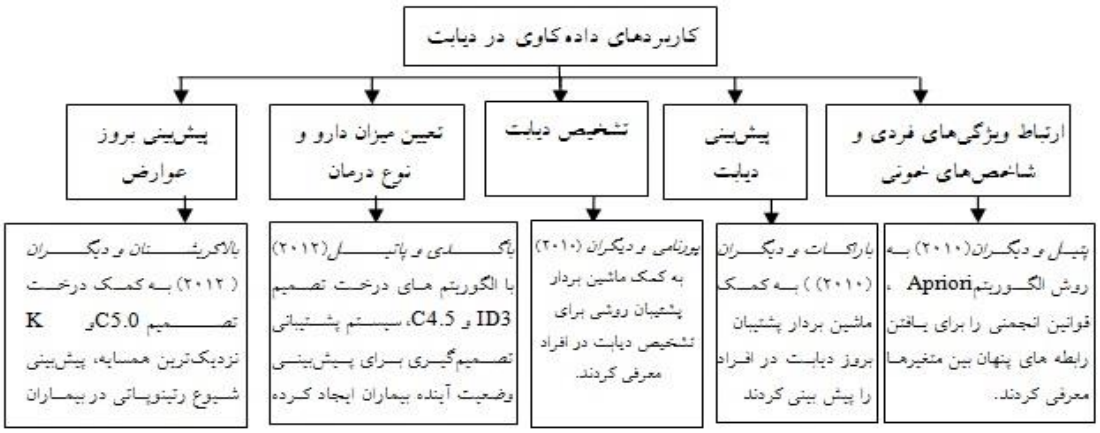

شکل۱. کاربردهای داده‌کاوی در دیابت

مطالعاتی معدود درزمینه پیش‌بینی بروز عوارض در بیماران دیابتی انجام‌شده‌اند. تحقیق‌ها نشان‌داده‌اند که از ۸۰ درصد عوارض مزمن دیابت نوع ۲ می‌توان با شناسایی‌های اولیه افراد در معرض خطر جلوگیری‌کرد یا آنها را به‌تعویق‌انداخت؛برای نمونه، *هوان‌کو* و همکاران با استفاده از دسته‌بندی ماشین بردار پشتیبانی (SVM) و با روش انتخاب ویژگی و تجسم‌سازی، وجود نروپاتی در بیماران دیابتی را پیش‌بینی‌کرده‌اند(۱۳). *سجادی* و همکاران با استفاده از روش‌های خوشه‌بندی در داده‌کاوی، عوامل خطرساز بروز عوارض قلبی در بیماران دیابتی را شناسایی‌کرده‌اند؛ این عوامل عبارت‌اند از: افزایش فشار خون، افزایش شاخص توده بدنی و اختلال چربی‌های خون(۱٤). *پارتیبان* و همکاران در سال ۲۰۱۱ با استفاده از شبکه بیزین، احتمال بروز مشکلات قلبی را در بیماران دیابتی پیش‌بینی‌کرده‌اند و برای انجام این عمل از مؤلفه‌هایی مانند سن، جنسیت، فشارخون و میزان قند خون استفاده‌کرده‌اند؛ دقت مدل به‌دست‌آمده، ۷٤ درصد بود(۱۵). *پارتیبان* و همکاران در سال ۲۰۱۲ با استفاده از ماشین بردار پشتیبانی، مدلی برای پیش‌بینی احتمال بروز مشکلات قلبی در بیماران دیابتی با دقت مدل ۹٤/٦۰ درصد ایجادکردند(۱٦). *سدهی* و همکاران(۱۷) با استفاده از روش شبکه‌های عصبی مصنوعی، مدلی برای پیش‌بینی توأم سندروم متابولیک و مقاومت به انسولین طراحی‌کرده‌اند؛ متغیرهای دموگرافیک، سابقه بیماری قلبی- عروقی، نمایه توده بدنی، LDL,HDL، تری‌گلیسرید، قند خون ناشتا و۲ساعتی، سیگار، فشار خون سیستولیک، دیاستولیک و دور کمر مورد تحلیل قرارگرفته‌اند. مدلی با استفاده از نرم‌افزار MATLAB براساس الگوریتم‌هایSCG، OSS وRP، به‌ترتیب با صحت پیش‌بینی ۷۸، ۷٦ و ۷٦ برای داده‌های آزمون و ۷۸/۳۷، ۷٤/۳۲ و ۷۵/٦۷ درصد برای داده‌های اعتبارسنجی به‌منظور پیش‌بینی سندروم متابولیک و شاخص HOMA-IR طراحی‌کرده‌اند.

هدف از انجام این تحقیق، بررسی علت بروز عارضه سکته قلبی در بیماران دیابتی است. در این تحقیق با استفاده از روش‌های درخت تصمیم، قوانینی برای تشخیص سکته قلبی در بیماران دیابتی ارائه‌شده‌اند. لازم به یادآوری است که ویژگی‌های مورد استفاده در روش پیشنهادی ما، ویژگی‌های بیماران دیابتی هستند و شاخص‌های مستقیم بیماری‌های قلبی بررسی‌نشده‌اند.

روش کار

روش‌هایی مختلف برای پیاده‌سازی و اجرای طرح‌های داده‌کاوی وجوددارند. یکی از روش‌های بسیار قوی، متدولوژی CRISP (Cross Industry Process For Data Mining) است(۱۸). در این مقاله، مدل پیشنهادی براساس CRISP ارائه‌شده‌است و چهار مرحله اصلی

شناخت سیستم، شناخت داده‌ها و آماده‌سازی آنها، مدل‌سازی و ارزیابی و توسعه را دربرمی‌گیرد؛ هریک از این فازها خود شامل زیربخش‌هایی می‌شوند. حرکت رو به جلو و عقب میان فازهای مختلف، نیازاست، زیرا ورودی هر فاز به خروجی فاز مرحله پیشین، وابسته است؛ هریک از این چهار فاز در شکل ۲ نشان‌داده‌شده‌اند.

شکل ۲. مدل پیشنهادی

در ادامه به بررسی هریک از فازهای این مدل پیشنهادی متناسب با مطالعه موردی بیماری دیابت نوع ۲ می‌پردازیم.

شناخت سیستم

در این فاز به شناخت سیستم مورد نظر پرداخته‌می‌شود و سپس اهداف مدنظر و عوامل موفقیت کلیدی سیستم تعیین‌شده، دوباره بازنگری‌می‌شود. یکی از شایع‌ترین بیماری‌های متابولیسم، دیابت است که با سطوح بالای قند خون و اختلال متابولیسم کربوهیدرات، چربی و پروتئین مشخص می‌شود و با فقدان مطلق یا نسبی انسولین همراه است. افزایش مزمن قند خون در درازمدت صدمه‌رسانی به ارگان‌های مختلف حیاتی ازجمله سیستم قلبی–عروقی، چشم‌ها، کلیه‌ها و سیستم عصبی و درنهایت، اختلال در کارکرد آنها را درپی‌دارد(۱۹). علل بروز دیابت نامشخص‌اند؛ بااین‌حال به‌نظرمی‌رسد، عوامل ارثی و عوامل محیطی مؤثرند. عوامل خطر ابتلا به دیابت نوع ۲ عبارت‌اند از: سن بالاتر از ۴۵ سال، اضافه وزن، داشتن پدر و مادر یا خواهر و برادر مبتلا به دیابت (وراثت خانوادگی)، داشتن فشار خون بالا (۱۴۰/۹۰ یا بالاتر)، داشتن کلسترول بالا (HDL ۳۵ یا کمتر و تری‌گلیسرید ۲۵۰ یا بالاتر) و استرس زیاد (۲۰).

با توجه به رشد روزافزون بیماری دیابت و عدم وجود درمان قطعی برای این بیماری و تأثیرها و عوارضی شدید که روی اعضای حیاتی بدن در درازمدت برجای‌می‌گذارد، بررسی داده‌های جمع‌آوری‌شده درخصوص این بیماری می‌تواند مفید باشد. دیابت، سومین علت مرگ‌ومیر در جهان و مرگ‌ومیر ناشی از بیماری‌های قلبی، اولین دلیل مرگ‌ومیر بر اثر بیماری در جهان معرفی‌شده‌اند. سکته‌های قلبی با پیشگیری از

عوامل خطرزا قابل‌کنترل است. با توجه به اینکه سکته قلبی از عوارض بسیار شایع در بیماری دیابت است، پیداکردن روشی برای شناسایی علت بروز این عارضه در بیماران دیابتی و کنترل این ویژگی‌ها می‌تواند در کاهش سکته قلبی در بیماران، بسیار مؤثر باشد.

شناخت داده‌ها و آماده‌سازی آنها

در این فاز به جمع‌آوری داده‌های اولیه، توصیف داده‌ها، بازرسی و بررسی داده‌ها و اعتبارسنجی کیفیت داده‌ها می‌پردازیم. اطلاعات این تحقیق از یک مرکز درمان دیابت در شمال ایران جمع‌آوری‌شده‌اند. اطلاعات پرونده‌ها به سال ۱۳۸۸ مربوط‌اند. ۸۵٦ رکورد اولیه از بیماران وجودداشت که پس از پالایش و حذف رکورهایی که اطلاعات اصلی آنها وجودنداشت، به ۲۵۲ رکورد نهایی می‌رسیم. میانگین سن بیماران ۵۳ سال و ۳۰ درصد آنها مرد و مابقی زن هستند. ۷۰ درصد بیماران دارای سابقه خانوادگی در دیابت هستند. ویژگی‌های آزمایشگاهی بیماران در این مرحله بررسی و شناسایی‌شدند.

در مهم‌ترین گام تحقیق (آماده‌سازی داده‌ها یا پیش‌پردازش داده‌ها) به بررسی پرونده بیماران پرداخته‌شده‌است. در جهان واقعی، داده همیشه کامل نیست و درخصوص اطلاعات پزشکی، این موضوع همیشه درست است. برای حذف تعدادی از تناقض‌ها و داده‌های ناقص درباره داده‌ها از پردازش داده استفاده‌شده‌است. *چین* و همکاران و *هن* و همکاران در بسیاری از روش‌های پردازش داده را ارائه‌کرده‌اند (۱۸و۲۱). در این تحقیق مواردی که ارزش ۰ (صفر) برای ویژگی‌های فشار خون و (Fasting blood glucose) FBS، (2 Hour Post Prandial Blood) 2HDD-BS، Sugar، (Triglycerides) TG و BMI داشتند، حذف شده‌اند. *وایتن* و همکاران در ثابت‌کردند که حذف عاقلانه، روشی کارآمد به‌جای جایگزین‌کردن ارزش‌ها با روش‌هایی مانند میانگین، انتساب تصادفی، انتساب رگرسیون و مدل‌های بیزی است(۲۲).

بعضی از اطلاعات موجود در پرونده، مانند نام و نام‌خانوادگی، شماره پرونده بیمار و نشانی حذف‌شدند؛ در مرحله بعدی، پرونده بیمارانی را که فقط یک‌بار مراجعه‌داشته‌اند، کنارگذاشتیم زیرا اطلاعاتی کامل از آزمایش‌ها و عوارض آنها دردسترس نبود.

بعضی از فیلدها به‌تنهایی اهمیتی‌نداشتند (مانند BUN (Blood urea) و CR (Chromium))؛ اگر این نسبت، میان ۱۰ تا ۲۰ باشد، نرمال و بیشتر از ۲۰ معنی خون‌ریزی گوارشی یا انسداد دستگاه ادرار است؛ نسبت این فیلدها نشان‌دهندهٔ احتمال وجود عارضه کلیوی است و یا قد و وزن که به‌تنهایی اهمیتی‌ندارند، بلکه شاخص BMI آنها تاثیرگذار است؛ درنتیجه، این فیلدها حذف‌شدند و به‌جای آنها از شاخص‌های مرتبط استفاده‌شده‌است. شاخص BMI به این صورت محاسبه‌می‌شود:

$$BMI= Weight(kg) / (Height(cm))^2$$

متغیرهای کلسترول، لیپوپروتئین با چگالی بالا، لیپوپروتئین با چگالی پایین، فشار خون دیاستولیک، فشار خون سیستولیک، تری‌گلیسرید، شاخص توده بدنی، قند خون ناشتا، قند خون ۲ ساعت پس از غذا و اوره به کراتینین که دارای ارزش‌های عددی به‌صورت دامنه‌ای بودند، براساس منابع و سایت‌های معتبر علمی و پزشکی و تأیید پزشک متخصص به‌صورت کدبندی‌شده استفاده‌شده‌اند.

درنتیجه، پس از پالایش داده‌ها به رکوردهایی با مشخصات جدول ۱ رسیدیم.

جدول ۱. داده‌ها و ارزش‌های مربوط پس از پیش‌پردازش

ویژگی	علامت استفاده‌شده و مقیاس محاسبه	ارزش	نوع
سن براساس سال	Age	کمی گسسته	فاصله‌ای
جنسیت	Sex	زن=0 ;مرد =1	اسمی
شاخص توده بدنی	BMI index	1= ;کمبود وزن و لاغری)کمتراز ۱۸/۵ 2=(وزن طبیعی)میان ۱۸/۵ و ۲۴/۹ 3=(اضافه وزن)میان ۲۵ تا ۲۹/۹ 4=(چاق)بیشتراز ۳۰	فاصله‌ای
قند خون ناشتا	Fbs(Fasting blood sugar in mg/dl)	1=70-100; 2=101-126; 3= more than>= 127	فاصله‌ای
قند خون ۲ ساعت پس از غذا	2hpp-bs(2 Hour PostPrandial - blood sugar in mg/dL)	1; Normal <=140; 2; Hidden Diabetes 140-199; 3; Diabetes >=200	فاصله‌ای
کلسترول	Chol(Serum cholesterol in mg)	1= optimal <= 200; 2=between200-239; 3= high above240	فاصله‌ای
لیپوپروتئین با چگالی بالا	HDL(high-density lipoprotein in mg/dL)	1= best>=60; 2= poor(HDL<= 40 and sex=1) or (HDL<= 50 and sex=0); 3= better level(between 40-59 for men and 50-59 for women)	فاصله‌ای
لیپو پروتئین با چگالی پایین	LDL(low-density lipoprotein in mg/dL)	1= optimal<=100; 2= near optimal100-129; 3= border line high130-159; 4= high160-189; 5= very high>=190	فاصله‌ای
تری‌گلیسرید	Trig(Triglyceride in mg/dl)	1=less than 150;normal 2=150-199; Slightly above normal 3= 200-499; high 4= >= 500; Very high	فاصله‌ای
اوره به کراتینبن	Bun/cr (blood urea nitrogen (BUN) (mg/dL) / serum creatinine (mg/dL)	1= normal(after the kidney) =>10 and <=20 2= Prerenal (before the kidney) >20 3= Internal (within kidney) <10	فاصله‌ای
سابقه خانوادگی دیابت	Family history Dm(Diabetes mellitus)	سابقه خانوادگی نوع ۱ و ۲ دیابت دارد=1 سابقه خانوادگی دیابت ندارد =0	اسمی
سایقه فشار خون	Hyp(Hypertension in mmHg)	بلی=1 خیر =0	اسمی
اختلال چربی خون	Dislip(Dyslipidemia)	بلی=1 خیر = 0	اسمی
سیگاری	Smoking(Smoker or not)	سیگاری =1 غیر سیگاری =0	اسمی
فشار خون سیستولیک	Sys bp(Systolic blood pressure Mm/Hg)	1=hypotension =<90; 2=desirable=90-119; 3=borderlinehypertension=120-139; 4=hypertension >=140	فاصله‌ای
فشار خون دیاستولیک	Diabp(Diastolic blood pressure Mm/Hg)	1= hypotension <60=; 2=desirable =61-79; 3=border line hypertension =80-89; 4= hypertension >=90	فاصله‌ای
میزان فعالیت بدنی	Sport	1= more than 3 days per week 2= less than 3 days per week 3= more than 30 minutes per day 4= daily	رتبه‌ای
میزان تحصیلات	Education Level	;2= diploma 1= university 3= pre high school; 4= not educated	رتبه‌ای
سکته قلبی	Heart failure	1= yes 0= no	اسمی

مدل‌سازی و ارزیابی

روش‌های داده‌کاوی بسیاری برای مدل‌سازی وجوددارند. در این فاز با استفاده از روش‌های مختلف داده‌کاوی به پیداکردن مدل و الگوی بهینه می‌پردازیم. یکی از روش‌های متداول، دسته‌بندی درخت تصمیم است. درخت تصمیم، توصیفی صریح از شاخه‌زنی با استفاده از الگوریتم است. از روش درخت طبقه‌بندی استفاده‌شده تا بهترین نسبت میان فیلدهای مختلف به‌دست‌آید؛ این درخت، ساختاری شبیه به فلوچارت دارد که بالاترین گره، ریشه درخت است و هر شاخه بیانگر خروجی‌های آزمایش بوده، گره‌های برگ، دسته یا توزیع دسته‌ها را نمایش می‌دهند (۱۸و۲۳).

قوانین ایجادشده توسط درخت تصمیم به‌صورت «اگر» و«آنگاه» بیان‌می‌شوند؛ در این مرحله، درخت‌های تصمیم C5.0 ،C&R ،QUEST،CHAID و شبکه عصبی مورد آزمایش قرارگرفته‌اند. از الگوریتم‌های پرکاربرد درخت تصمیم، الگوریتم C&R است؛ این درخت از دسته‌بندی و رگرسیون برای پیش‌بینی استفاده‌می‌کند. هر گره ابتدا فیلدهای ورودی را برای یافتن بهترین تجزیه آزمایش‌می‌کند تا شاخص ناخالصی حاصل از تجزیه کمترین مقدار باشد. تمام تجزیه‌ها دودویی هستند و تا زمانی ادامه‌می‌یابند که یکی از معیارهای توقف برآورده شود. درک مدل‌های این درخت و تفسیر قوانین استخراج‌شده نسبت‌به سایر مدل‌ها ساده‌تر است. برای آموزش درخت تصمیم مدل C&R، یک متغییر طبقه‌ای باید فیلد خروجی باشد و یک یا تعداد بیشتری فیلد ورودی وجودداشته‌باشند(۲٤).

پس از مدلسازی باید به ارزیابی نتایج حاصل از مدلسازی پرداخت. نتایج ارزیابی باعث بهبود مدل شده، مدل را قابل‌استفاده‌می‌کنند. برای بررسی صحت مدل، ابتدا لازم است داده‌های موجود را به سه بخش آموزش، آزمایش و اعتبارسنجی تقسیم‌کنیم؛ داده‌های بخش آموزش، درخت را تولیدمی‌کنند و داده‌های بخش آزمایش با کمک تعدادی رکورد، درخت تولیدشده را آزمایش و برچسب مربوط به رکوردهای یادشده را تعیین‌می‌کنند؛ داده‌های بخش اعتبارسنجی نیز صحت مدل تولیدشده را بررسی‌می‌کنند. شاخص‌هایی مختلف برای ارزیابی صحت روش‌های دسته‌بندی وجوددارند که می‌توان حساسیت (Sensitivity)، شفافیت (Specificity)، دقت (Precision) و صحت (Accuracy) را نام‌برد. میزان صحت یک روش دسته‌بندی روی مجموعه داده‌های آموزشی، درصد مشاهداتی از مجموعه آموزش است که به‌درستی، توسط روش مورد استفاده دسته‌بندی‌شده‌است؛ برای محاسبه این شاخص از داده‌های آزمون استفاده‌می‌شود؛ همچنین می‌توان نرخ خطا (Error Rate) یا دسته‌بندی نادرست (Misclassification rate) را براساس شاخص صحت محاسبه‌کرد(۱۸و۲۷).

$$\text{نرخ خطا} = 1 - \text{صحت} \quad (۲)$$

برای محاسبه میزان صحت مدل می‌توان ماتریس اغتشاش (Confusion Matrix) را به‌کاربرد؛ این ماتریس، ابزاری مفید برای تحلیل چگونگی عملکرد روش دسته‌بندی در تشخیص داده‌ها یا مشاهدات دسته‌های مختلف است؛ اگر داده‌ها در M دسته قرارگرفته‌باشند، یک ماتریس دسته‌بندی جدولی با حداقل اندازه M*M است. حالت مطلوب، این است که بیشتر داده‌های مرتبط به مشاهدات، روی قطر اصلی ماتریس قرارگرفته‌باشند و سایر مقادیر ماتریس ۰ (صفر) یا نزدیک به ۰ باشند(۱۸و۲٤).

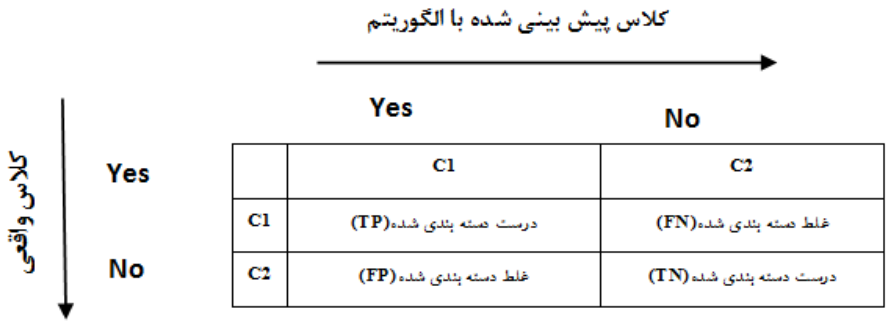

شکل۳. ماتریس اغتشاش

$$\text{حساسیت} = \frac{\text{تعداد داده های برچسب مثبتی که درست دسته بندی شده اند}}{\text{کل تعداد داده های مثبت}} = TP/pos \qquad (۳)$$

$$\text{شفافیت} = \frac{\text{تعداد داده های برچسب منفی که درست دسته بندی شده اند}}{\text{کل تعداد داده های منفی}} = \text{TN/neg} \qquad (٤)$$

$$\text{دقت} = \text{TP}/(\text{TP} + \text{FP}) \qquad (٥)$$

$$\text{صحت} = \text{حساسیت}\frac{pos}{(pos+neg)} + \text{شفافیت}\frac{neg}{(pos+neg)} \qquad (٦)$$

توسعه

ساخت مدل، پایان یک طرح نیست و هدف از طرح‌های داده‌کاوی، کشف دانش و استفاده از دانش کشف‌شده در آینده است. دانش کشف‌شده باید سازماندهی‌شده، به شکلی قابل‌استفاده برای دیگران نیز درآید؛ ما در این فاز، علاوه بر تهیه گزارش تلاش‌کردیم تا نشان‌دهیم که میزان تأثیرگذاری مؤلفه‌های مختلف روی سکته قلبی چه میزان است. می‌توان از این دانش برای پیش‌بینی وضعیت بیماران جدید استفاده‌کرده، در جهت کنترل سکته قلبی در بیماران، همگام با دانش کشف‌شده از داده‌های پیشین گام‌برداشت.

یافته‌ها

هدف از داده‌کاوی استخراج دانش از اطلاعات ذخیره‌شده در پایگاه داده و ایجاد شرحی روشن و قابل‌فهم از الگوهاست. از الگوریتم‌های مختلف درخت تصمیم برای پیداکردن بهترین نتیجه استفاده‌شده‌است. در جدول ۲ میزان صحت، دقت، شفافیت و حساسیت را برای درخت‌های تصمیم استفاده‌شده با هم مقایسه‌کرده‌ایم.

جدول۲. مقایسه شاخص‌های دقت، صحت، حساسیت و شفافیت برای درخت‌های تصمیم مورد بررسی

درخت تصمیم	حساسیت	شفافیت	دقت	صحت	نرخ خطا
C5.0	۹۷درصد	۵۸درصد	۹۰درصد	۹۲درصد	۰/۰۸
CHAID	۹۸درصد	۲۰درصد	۸۳درصد	۹۰درصد	۰/۱
QUEST	–	–	–	۸۶درصد	۰/۱۴
NURAL NETWORK	–	–	–	۸۶درصد	۰/۱۴
C&R	۹۶درصد	۶۰درصد	۹۱درصد	۹۴درصد	۰/۰۶

مقادیر حساسیت، شفافیت و دقت برای الگوریتم‌های QUEST و شبکه عصبی به این دلیل که درختی مناسب ایجادنشده‌بود، غیرقابل‌محاسبه است. بهترین نتایج با استفاده از گره درخت C&R به‌دست‌آمده‌اند. با بررسی درخت تصمیم C&R، ویژگی‌های تأثیرگذار بر سکته قلبی در بیمار شناسایی‌شدند که عبارت‌اند از: سابقه فشار خون بالا، شاخص BMI، مقدار کنترل‌نشده برای لیپو پروتئین با چگالی پایین (کلسترول مضر)، بالابودن سن و نداشتن تحرک زیاد. اغلب، مجموعه‌های قوانین، مهم‌ترین اطلاعات مرتبط با درخت تصمیم را دربردارند.

جدول ۳، مجموعه قوانین ایجادشده توسط گره درخت C&R را نمایش‌می‌دهد. معیار اطمینان (Confidence) برای قوانین ایجادشده، ٦٠درصد تعیین‌شده‌است؛ با استفاده از این قوانین، می‌توان ارتباطی میان ویژگی‌های مؤثر بر سکته قلبی بیماران دیابتی را شناسایی و در جهت کنترل این عوامل خطرساز تلاش‌کرد.

جدول ۳. قواعد ایجادشده توسط درخت تصمیم C&R

قوانین ایجادشده	دقت و اطمینان
اگر قند خون، ۲ ساعت پس از خوردن غذا در بازه نرمال یا دیابت پنهان باشد، آنگاه بیمار به سکته قلبی، دچار نمی‌شود.	۱/۰
اگر قند خون، ۲ ساعت پس از خوردن غذا در بازه دیابتی باشد و شاخص BMI نشان‌دهنده وزن نرمال یا اضافه وزن باشد ولی سابقه فشارخون نداشته‌باشد، آنگاه بیمار به سکته قلبی، دچار نمی‌شود.	۰/۸۶
اگر قند خون، ۲ ساعت پس از خوردن غذا در بازه دیابتی باشد و بیمار، سابقه فشارخون داشته‌باشد و قند خون ناشتا بیشتر از ۱۲۷ باشد و تری‌گلیسیرید در بازه نرمال یا بالا باشد، آنگاه بیمار به سکته قلبی، دچار نمی‌شود.	۰/۷۴
اگر قند خون، ۲ ساعت پس از خوردن غذا در بازه دیابتی باشد و بیمار، سابقه فشارخون داشته‌باشد و قند خون ناشتا بیشتر از ۱۲۷ باشد ، تری‌گلیسیرید در بازه بالاتر از نرمال یا خیلی بالا و کلسترول بالاتر از ۲۴۰ باشد، آنگاه بیمار به سکته قلبی، دچار نمی‌شود.	۱/۰
اگر قند خون، ۲ ساعت پس از خوردن غذا در بازه دیابتی باشد و بیمار، سابقه فشارخون داشته‌باشد و قند خون ناشتا میان ۷۰ تا ۱۲۶باشد، آنگاه بیمار به سکته قلبی، دچار می‌شود.	۰/۷۳
اگر قند خون، ۲ ساعت پس از خوردن غذا در بازه دیابتی باشد و بیمار، سابقه فشارخون داشته‌باشد و قند خون ناشتا بیشتر از ۱۲۷باشد، تری‌گلیسیرید در بازه بالاتر از نرمال یا خیلی بالا و کلسترول خیلی بالا باشد (بالاتر از ۱۴۰)، آنگاه بیمار به سکته قلبی، دچار می‌شود.	۰/۷۱

مطابق جدول شماره ٤، براساس الگوریتم C&R، مهم‌ترین عوامل مؤثر بر سکته قلبی بیماران دیابتی معرفی‌شده‌اند.

جدول٤. عوامل تأثیرگذار بر سکته قلبی براساس الگوریتمC&R

ویژگی	وزن اهمیت
سابقه فشارخون بالا	۰/۳۶۸
شاخص BMI	۰/۱۹۸
فشارخون سیستولیک	۰/۰۸۱
فشارخون دیاستولیک	۰/۰۸۱
چربی خون با چگالی پایین	۰/۰۸۱
سن	۰/۰۸۱
میزان فعالیت بدنی	۰/۰۸۱
قندخون ناشتا	۰/۰۱۸
کاسترول	۰/۰۱۱

افراد متخصص نیز، ارزیابی قوانین را انجام‌دادند. با توجه به قواعد تولیدشده، مؤلفه‌هایی که بیشترین تأثیر را بر سکته قلبی دارند، شناسایی و تأییدشده‌اند. طبق نظر کارشناسان می‌توان از مدل ایجادشده، نتایج زیر را گرفت. با کنترل میزان قند خون، فشار خون و چاقی می‌توان از سکته قلبی اجتناب‌کرد.

بالابودن قند خون و فشار خون بالا همراه با تری‌گلیسرید و کلسترول بالا، احتمال بروز سکته قلبی را بسیار افزایش می‌دهد. با کم کردن کلسترول و کنترل فشارخون بروز سکته قلبی در بیماران دیابتی را می‌توان کاهش داد.

بحث و نتیجه‌گیری

در این تحقیق با استفاده از الگوریتم‌های داده‌کاوی تلاش‌کردیم که احتمال بروز سکته قلبی در بیماران دیابتی را با بهره‌گیری از ویژگی‌های تشخیص دیابت پیش‌بینی‌کنیم. از میان الگوریتم‌های مورد استفاده، بهترین نتایج از الگوریتم درخت C&R به‌دست‌آمد که دقت مدل آن برابر ۹۱ درصد و صحت مدل ۹٤ درصد است؛ به این معنی که با استفاده از قوانین یافته‌شده، می‌توان احتمال بروز سکته قلبی را در بیمار دیابتی براساس ویژگی‌های دموگرافیک و نتایج آزمایشگاهی بیمار با دقت ۹۱ درصد پیش‌بینی‌کرد. بیشترین مؤلفه‌های تأثیرگذار بر سکته قلبی در بیماران دیابتی، سابقه فشار خون بالا، شاخص BMI، مقدار کنترل‌نشده برای کلسترول مضر، بالابودن سن و نداشتن تحرک زیاد شناخته‌شده‌اند. با استفاده از قوانین ایجادشده، برای یک نمونه جدید با ویژگی‌های مشخص، می‌توان پیش‌بینی‌کرد که «این فرد احتمال‌دارد [در آینده] به سکته قلبی، دچار شود یا خیر؟». با کنترل عوامل تأثیرگذار در هر بیمار، می‌توان امیدوار بود از بروز عارضه تاحدی اجتناب‌کرد و به این صورت، میزان مرگ‌ومیر ناشی از سکته‌های قلبی را تاحدی کاهش‌داد.

در ادامه، نتایج کار خود را با کارهای مشابه در این حوزه در جدول ۵ مقایسه‌کرده‌ایم.

جدول۵. مقایسه نتایج کار با کارهای انجام‌شده پیشین

نویسندگان و سال ارائه	روش انتخابی	تأثیرگذارترین ویژگی‌ها	صحت مدل	دقت مدل	ارائه قوانین
سجادی و همکاران (۲۰۰۵)	خوشه‌بندی	افزایش فشار خون، افزایش شاخص توده بدنی و اختلال چربی‌های خون	–	–	☒
پارتیبان و همکاران (۲۰۱۱)	شبکه بیزین	سن، جنسیت، فشار خون و میزان قند خون	۷۴ درصد	۷۱ درصد	☒
پارتیبان و همکاران (۲۰۱۲)	ماشین بردار پشتیبانی(svm)	مشخص نشده‌است	۹۴/۶۰ درصد	۹۴/۰۶ درصد	☒
مدل انتخابی ما	C&R	فشار خون بالا، شاخص BMI، مقدار کنترل‌نشده برای کلسترول مضر، بالابودن سن و نداشتن تحرک زیاد	۹۴ درصد	۹۱ درصد	✓

با مرور کارهای پیشین در این زمینه، مؤلفه‌های شناخته‌شده تأثیرگذار بر سکته قلبی تحقیق‌های انجام‌شده با ویژگی‌های یافته‌شده توسط کار ما منطبق هستند. ویژگی‌های سن، فشار خون بالا، افزایش شاخص توده بدنی در هر سه مورد، مطالعاتی انجام‌شده، به‌عنوان عواملی با بیشترین تأثیرگذاری شناخته‌شده‌اند. ویژگی‌هایی مانند افزایش شاخص توده بدنی و فشار خون بالا را می‌توان با رژیم‌های غذایی و انجام حرکات

ورزشی و فعالیت‌های بدنی، تاحدودی کنترل‌کرد. با تغییر سبک زندگی و عادات غذایی، می‌توان تا اندازه زیادی به کاهش ابتلا به دیابت و بروز سکته قلبی به‌عنوان عارضه‌ای از آن (با توجه به نتایج این پژوهش)، امیدوار بود.

سپاس و قدردانی

این مطالعه با همکاری پزشکان و کارکنان محترم مرکز دیابت گرگان، زیر نظر دانشگاه علوم پزشکی استان گلستان انجام‌شده‌است، محققان بر خود لازم می‌دانند تا از مساعدت و همکاری یکایک این عزیزان تشکر و قدردانی کنند.

منابع

1. Neisani TR. Micronutrients are effective in reducing blood pressure in type II diabetic. Iranina's Students New Agency. [cited 2009 sep 24]; Available from (url) : [http://isna.ir/fa/news/8907-13779.166745]
2. World Health Organization(WHO). International Diabetes. The World health report: 2002: Reducing the risks, promoting healthy life. Switzerland: FederationWorld Health Organization; 2002.
3. Al Jarullah, Asma A. Decision tree discovery for the diagnosis of type II diabetes. Innovations in Information Technology (IIT), 2011 International Conference on IEEE. 2011; 303-307.
4. Khajehei M, Etemady F. Data mining and medical research studies .cimsim, Second International Conference on Computational Intelligence, Modelling and Simulation.2010; 119-122.
5. Jayalakshmi T, Santhakumaran A. A Novel classification method for diagnosis of diabetes mellitus using Aartificial neural networks. Data Storage and Data Engineering (DSDE).2010 International Conference on IEEE. 2010; 159-163.
6. Ameri H. Using data mining in diabetes, Master of Science Seminar in Information Technology (Ecommerce), K. N. Toosi University of Technology.2013[Persian]
7. Zayeri F, Sadeghi Nejad R, Noorkojuri H, Bagheri J, Ghazanfari E. Application of classification tree model for determining the effective factors of mortality after coronary bypass surgery in dialysis-independent patients. Daneshvar(medicine) Shahed University. 2012; 98:15-24[Persian]
8. Patil B, Durga T. Association rule for classification of type-2 diabetic patients. In Machine Learning and Computing (ICMLC), 2010 Second International Conference on IEEE. 2010; 330-334.
9. Bagdi R,Patil P. Diagnosis of diabetes using OLAP and data mining integration. International Journal of Computer Science & Communication Networks, 2012; 3: 314-322.
10. Vimala B, Shakouri M, Hoodeh H, Loo, Huck-Soo. Predictions using data mining and case-based reasoning: A case study for retinopathy. International Conference on Information Technology.2012; 63:573-576.
11. Barakat N, Bradley AP. Intelligible support vector machines for diagnosis of diabetes mellitus. Information Technology in Biomedicine, IEEE .2010; 14:1114-1120.
12. Purnami SW, Zain JM, Embong A. A new expert system for diabetes disease diagnosis using modified spline smooth support vector machine. Computational Science and Its Applications–ICCSA 2010. Springer Berlin Heidelberg. 2010; 6019:83-92.
13. Cho BH, Yu H, Kim KW, Kim TH, Kim IY, Kim SI. Application of irregular and unbalanced data to predict diabetic nephropathy using visualization and feature selection methods. Artificial Intelligence in Medicine 2008; 42:37-53.
14. Sajjadi F, Mohammadifard N,Ghaderian N, Alikhasi H,Maghroon M. Clustering of cardiovascular risk factors in diabetic and glucose intolerant cases. The Journal of Qazvin University of Medical Sciences. 2005; 9:35-43.
15. Parthiban G, Rajesh A, Srivatsa SK. Diagnosis of heart disease for diabetic patients using naive bayes method. International Journal of Computer Applications ,2011; 24:0975-8887.
16. Parthiban G, Srivatsa SK. Applying machine learning methods in diagnosing heart disease for diabetic patients. International Journal of Applied Information Systems (IJAIS). 2012; 3:2249-0868.
17. Mehrabi Y, Sedehi M, Kazemnejad A, Joharimajd V, Hadaegh F. Artificial neural network for joint prediction of metabolic syndrome and HOMA-IR.Tehran Lipid and Glucose Study (TLGS) . 2010; 17:29-38[Persian]
18. Han J, Kamber M. chapter 1: Introduction: Data Mining: Concepts and Techniques. 2nd ed., San Francisco: Morgan Kaufman Publisher. 2006.

19. Ahmadi K. Guideline &book review. The internal (endocrine and lung). Tehran: Ahmadi Cultural Institute. 2009 [Persian].
20. Franciosi M, De Berardis G, Rossi MC, Sacco M, Belfiglio M, Pellegrini F and et al. Use of the diabetes risk score for opportunistic screening of undiagnosed diabetes and impaired glucose tolerance the IGLOO (Impaired Glucose Tolerance and Long-Term Outcomes Observational) study. Diabetes Care. 2005; 28:1187-1194.
21. Newman DS, Hettich J,Blake CLS, Merz CJ. UCI Repository of machine learning databases,Irvine, CA: University of California. Department of Information and Computer Science.1998.
22. Chen G, Astebro T. How to deal with missing categorical data: test of a simple Bayesian method. Organizational Research Methods. 2003; 6: 309-327.
23. Alizadeh S, Ghazanfari M, Teimorpour B .Data Mining and Knowledge Discovery, Tehran: Publication of Iran University of Science and Technology .2nd ed. 2011 [Persian].
24. Alizadeh S,Malekmahmodi S. Data Mining and Knowlade Discovery,step by step,tehran: publication of KNTU university.2011[persian].

Daneshvar

Medicine

Identification of influencing factors for heart attack in diabetic patients using C & R algorithm

Hakimeh Ameri[1*], Somayeh Alizadeh[1], Akbar Barzegari[2]

1. Department of Industrial Engineering, KN Toosi University Of Technology, Tehran, Iran
2. Golestan University of Medical Sciences, Gorgan, Iran.

*** E-mail: hameri@mail.kntu.ac.ir**

Abstract

Background and Objective: Cardiovascular disease is the most common cause of death in developed countries and in the whole world, and according to the World Health Organization prediction, will be the major cause of morbidity throughout the world in 2020. According to the recent World Health Organization report from each 20 deaths, one is due to diabetes. Heart disease and heart attack are the most important complications of diabetes. In this study, data mining algorithms were used to predict the risk of heart attack in diabetic patients with acceptable accuracy and identify the factors that affect the incidence of heart attack.

Materials and Methods: The study was performed retrospectively on 856 patients in 2009 from Gorgan diabetic center. Clinical data of patients using data mining methods were analyzed in the SPSS software. To identify the influencing factors on incidence heart attack, classification data mining algorithms were used.

Results: A model with 94 percent accuracy is identified using the C&R decision tree algorithm. According to the C&R Tree hypertension, index BMI, systolic and diastolic blood pressure, LDL, daily activity level and age are identified as the most important factors of heart disease in diabetic patients

Conclusion: With the use of Created rules and identifying effective features and controlling effective factors on diabetic patients, the mortality rate of this complication was somewhat reduced.

Keywords: Data mining, Diabetes, Heart attack, Decision tree algorithm

Scientific-Research Journal of Shahed University 21st Year, No.112
September- October, 2014

Received: 11/06/2014
Last revised: 09/08/2014
Accepted: 13/08/2014