

بررسی تأثیر پارامترهای پیوسته در تشخیص بیماری عروق کرونر قلبی

با استفاده از شبکه‌های عصبی مصنوعی

ایمان ذباج^{۱*}، مجید حسن‌زاده^۲، زهرا کوهجانی^۳

۱- گروه کامپیوتر، دانشگاه آزاد اسلامی تهران شمال، تهران، ایران

۲- گروه پرستاری، دانشگاه علوم پزشکی تربت‌حیدریه، تربت‌حیدریه، ایران

۳- دانشجوی کامپیوتر، دانشگاه تربت‌حیدریه، تربت‌حیدریه، ایران

چکیده

زمینه و هدف: بیماری عروق کرونری قلب، از شایع‌ترین بیماری‌ها در جوامع مختلف است. بهترین روش ارزیابی بیماری کرونر قلبی آنژیوگرافی است. مطالعه حاضر با هدف بررسی تأثیر پارامترهای بیماری با استفاده از روش‌های هوشمند به منظور پیشگویی وضعیت عروق کرونری قلب انجام شده است.

روش‌ها: این مطالعه از نوع تحلیلی بوده و پایگاه داده آن شامل ۲۰۰ رکورد از نوع غیر قابل انتساب می‌باشد. در این پژوهش از شبکه‌های عصبی مختلف MLP و LVQ و BR به منظور پیش‌بینی بسته بودن یا نبودن عروق کرونری قلب استفاده شده است. همچنین اهمیت تأثیر ریسک فاکتورهای پیوسته بیماری کرونر قلب مورد بررسی قرار گرفته است.

نتایج: مهم‌ترین معیارهای سیستم‌های تشخیص بیماری، دو شاخص ویژگی (Specificity) و حساسیت (Sensitivity) می‌باشند. در این مطالعه، این دو شاخص در مرحله تست و آزمون مورد محاسبه قرار گرفتند. بهترین صحت مدل مربوط به شبکه عصبی پرسپترون چندلایه با قانون پس انتشار خطا و معادل ۸۸ درصد بوده است. همچنین مشاهده شد که حذف پارامترهای گسسته در سرعت همگرایی شبکه عصبی تأثیر مثبت دارد و می‌تواند دقت پیش‌بینی را تا ۸۵ درصد ارتقاء بخشد.

نتیجه‌گیری: آنژیوگرافی یک روش تهاجمی است و علاوه بر هزینه گران آن همراه با ریسک‌هایی چون مرگ، سکته قلبی و سکته مغزی است. بنابراین باید از روش‌های غیر تهاجمی استفاده شود که پیش‌بینی بر اساس آن‌ها دارای کمترین خطا و بیشترین اطمینان باشد. استفاده از روش‌های نوین داده‌کاوی می‌تواند به کاهش این عوارض کمک کند.

کلمات کلیدی: عروق کرونری قلب، شبکه عصبی مصنوعی، پارامترهای پیوسته کرونر قلبی.

*آدرس نویسنده مسئول: دانشگاه آزاد اسلامی واحد تربت‌حیدریه، تربت‌حیدریه، ایران

آدرس پست الکترونیک: imanzabbah@gmail.com

مقدمه

شایع‌ترین بیماری قلبی، بیماری عروق کرونری^۱ می‌باشد. روش‌های مختلفی برای تشخیص این بیماری از قبیل تست ورزش، اکوکاردیوگرام و اسکن هسته‌ای قلب وجود دارد ولی در حال حاضر بهترین روش تشخیص بیماری آنژیوگرافی است (۱).

به‌نظر می‌رسد بیماری عروق کرونر قلب نتیجه همگرایی تعدادی از عوامل خطر مرتبط با این بیماری است (۳). تحلیل‌های آماری نشان می‌دهد که میزان اهمیت این متغیرهای بالینی در تشخیص بیماری از ضرایب یکسانی برخوردار نیستند. اخیراً روش‌های داده‌کاوی جهت کشف الگوها در تشخیص بیماری‌ها مورد توجه بسیاری از محققین قرار گرفته است. از جمله این روش‌ها، درخت‌های تصمیم‌گیر، ماشین بردار، دسته‌بندی کننده بیزین، نزدیک‌ترین همسایه، الگوریتم‌های ژنتیک و شبکه‌های عصبی است که در این بین شبکه‌های عصبی مصنوعی از اهمیت ویژه‌ای برخوردار است. در شبکه عصبی مصنوعی^۲ از ساختار توده‌ای مغز انسان الگوبرداری می‌شود.

برخی محققان قدرت تشخیص و دقت پیشگویی مدل شبکه‌های عصبی مصنوعی را نسبت به مدل‌های کلاسیک آماری بیشتر می‌دانند (۴، ۵). همچنین سه تکنیک رگرسیون لجستیک و درخت تصمیم‌گیر و شبکه عصبی برای این منظور استفاده شده است که در نهایت، در بهترین حالت و با کمک شبکه عصبی پرسپترون چند لایه با دقت ۷۵ درصد عمل پیش‌بینی کرونر قلبی را انجام می‌دهد (۶). در یک پژوهش با عنوان کاربرد شبکه عصبی مصنوعی در تعیین پیش‌بینی کننده‌های مهم مرگ‌ومیر درون بیمارستانی پس از جراحی قلب باز و مقایسه آن با مدل رگرسیون لجستیک در سال ۲۰۰۴ از یک شبکه عصبی مصنوعی با ۱۸ نرون ورودی، ۴ نرون مخفی و ۲ نرون خروجی با الگوریتم پس انتشار خطا استفاده کرده‌اند. در این مطالعه برای نشان دادن دقت نتایج از دو شاخص حساسیت و ویژگی استفاده شده است. که در آن حساسیت و ویژگی در گروه آموزش برابر ۱۰۰ درصد و در دو گروه آزمایش به ترتیب برابر ۹۹/۳۳ درصد و ۱۰۰ درصد به دست آمد (۷). بدیهی است که صحت عملکرد شبکه عصبی بایستی بر روی داده‌های آزمون سنجیده شود و داده‌های

آزمایش نمی‌تواند ملاک دقیق عملکرد شبکه عصبی باشد. لذا در مطالعه پژوهشی مذکور حساسیت مربوط به داده‌های آزمایش مورد قبول است نه داده‌های آموزش، چرا که شبکه عصبی روی داده‌های آزمایش تعلیم داده شده است و انتظار دقت ۱۰۰ درصد دور از دسترس نیست. در برخی تحقیقات نتایج حاصل شده از روش‌های نوین نظیر شبکه عصبی بر روش‌های کلاسیک همچون رگرسیون دیده شده است، به طور مثال در مطالعه متاآنالیزی که سارجنت^۳ در ۲۸ مورد انجام داده بود مشاهده نمود که در ۳۶ درصد موارد شبکه عصبی مصنوعی بهتر و در ۱۴ مورد نتایج استفاده از رگرسیون بهتر و همچنین در ۵۰ درصد موارد عملکرد هر دو مورد شبیه هم بوده است. در این مطالعه از ۲۰ پایگاه داده متفاوت و از بیماری‌های مختلف استفاده شده است که تعداد نمونه‌ها بین ۲۰۰ تا ۲۰۰۰ مورد بوده است با توجه به نوع پایگاه داده شبکه‌های عصبی مختلف با ۵ الی ۲۰ ورودی آموزش داده شده است (۸). بررسی متاآنالیزی که دریسیتل^۴ در جمع‌بندی ۷۲ مطالعه انجام داده بود، مشاهده نمود در ۱۸ درصد موارد شبکه عصبی مصنوعی بهتر، در ۱ درصد موارد روش‌های رگرسیون لجستیک بهتر و در ۴۲ درصد موارد شبیه هم عمل کرده‌اند. در ضمن ۳۹ درصد موارد مقالات آزمون‌های آماری در اختیار نبود بنابراین نادیده گرفته شدند (۹). نتیجه دو مطالعه متاآنالیزی فوق نشان می‌دهد که استفاده از روش‌های نوین داده‌کاوی به‌خصوص شبکه عصبی مصنوعی در مجموع صحت عملکرد بهتری در مقایسه با روش‌های رگرسیون خطی دارد. در عین حال آقای سارجنت پیشنهاد می‌دهد که روش‌های رگرسیونی نباید به طور کامل در تشخیص بیماری‌ها حذف شود. همچنین از شبکه عصبی مصنوعی در مقایسه با دیگر روش‌های آماری از جمله رگرسیون لجستیک برای پیش‌بینی عروق کرونری قلب با کمک منحنی راک^۵ استفاده شد. در منحنی ROC حساسیت در مقابل ویژگی رسم می‌شود که نتایج مبتنی بر بیشتر بودن سطح زیر نمودار ROC در شبکه می‌باشد (۱۰).

کولاک^۶ و همکاران با استفاده از مدل‌های مختلف شبکه‌های عصبی مصنوعی و الگوریتم مختلف یادگیری به پیش‌بینی بیماری عروق کرونر قلب پرداختند و صحت تشخیصی ۸۱

³ - Sargent et al

⁴ - Dreiseitl

⁵ - Receiver Operating Characteristic (ROK)

⁶ - Colak

¹ - CAD: Coronary Artery Disease

² - ANN: Artificial Neural Network

آموزش شبکه عصبی می‌تواند با ناظر^۲ و یا بدون ناظر^۳ باشد. شبکه عصبی بسته به ساختار درونی‌اش در برخورد با مسائل مختلف، عملکرد متفاوتی دارد. لذا انتخاب ساختار شبکه متناسب با مقاله مورد بررسی از اهمیت بسیار بالایی برخوردار است (۱۶). مطالعه حاضر، با هدف مدل‌سازی هوشمند تشخیص بیماری عروق کرونر قلب با استفاده از شبکه‌های عصبی با ناظر و بدون ناظر و نیز بررسی اهمیت تأثیر علایم پیوسته^۴ بیماری نسبت به علایم گسسته^۵ بر روی بیماران انجام گردیده است. ابزار مورد استفاده پرسش‌نامه محقق ساخته است که حاوی اطلاعات دموگرافیک، بیماری، تست‌های تشخیصی و نتیجه است (جدول ۱). از بین این اطلاعات موارد کسر تخلیه، تری‌گلیسیرید، کلسترول، کراتینین و سن به صورت عددی هستند که می‌توانند مقادیر پیوسته‌ای داشته باشند و سایر پارامترها مانند جنسیت فقط به صورت گسسته یعنی صفر و یک مقداردهی می‌شوند.

روش‌ها

در این مطالعه از داده‌های موجود^۶ استفاده شده است. بدین منظور تعداد ۲۷۸ پرونده مربوط به بیماران مراجعه‌کننده به مرکز تخصصی قلب شهرستان تربت‌حیدریه مورد بررسی و مطالعه قرار گرفت. از آنجایی که اطلاعات ۲۰۰ نفر از مراجعین به صورت کامل ثبت شده بود، لذا همین تعداد از پرونده‌ها برای استخراج اطلاعات بیماران مورد استفاده قرار گرفت. به تشخیص پزشک متخصص مرکز از بین این افراد تنها تعداد ۱۹ نفر سالم و ۱۸۱ نفر مبتلا به بیماری عروق کرونر قلب تشخیص داده شده بودند. داده‌ها در بازه زمانی مهر و آبان‌ماه سال ۱۳۹۴ توسط محققین جمع‌آوری گردید. متغیرهای استخراج‌شده از پرونده‌های پزشکی حاوی اطلاعات دموگرافیک بیماری، تست‌های تشخیصی و نتیجه آنژیوگرافی بودند که بر اساس نظر متخصصین قلب و عروق و نیز مطالعات مختلف تعیین شده است (۱۱-۱۳). این داده‌ها از طریق نرم‌افزارهای Excel و SPSS به صورت داده‌های غیر قابل انتساب، ثبت و مورد تحلیل قرار گرفت. متغیرهای مستقل در این مطالعه شامل جنسیت، مصرف سیگار، فشارخون بالا، دیابت، سابقه خانوادگی بیماری قلبی، سابقه سکته قلبی، نتیجه تست ورزش، نتیجه اکو،

درصد دست یافتند و نشان دادند که این روش‌ها می‌تواند برای پیش‌بینی بیماری‌های قلبی بدون استفاده از روش‌های تشخیصی تهاجمی به عنوان یک پیش‌آگهی در تصمیم‌گیری‌های بالینی به کارگرفته شود (۱۱). سدهای^۱ و همکاران از مدل شبکه عصبی مصنوعی سه لایه به تعداد ۱۵ گره در لایه ورودی برای پیش‌بینی پاسخ‌های دو متغیره آمیخته در مطالعه قند و لیپید تهران استفاده کردند. بعد از برازش مدل‌های مختلف شبکه عصبی مصنوعی، صحت پیش‌بینی ۸۷/۳۷ درصد به عنوان بهترین پیش‌بینی توأم گزارش گردید (۱۲). در پژوهش دیگری کاربرد شبکه عصبی مصنوعی جهت ارزیابی بیماری عروق کرونری قلب از شبکه عصبی مصنوعی با الگوریتم پس انتشار با ساختار استفاده و صحت و ویژگی بالایی را نشان داده است (۱۳). در مطالعه دیگری با عنوان ارایه یک سیستم هوشمند در تشخیص بیماری عروق کرونری قلب با استفاده از شبکه عصبی احتمالی در یک جامعه آماری ۱۵۲ نفری استفاده شده است (۱۴). در تحقیقات دیگر که مدل‌های به‌دست‌آمده تنها مبتنی بر عوامل خطر بیماری عروق کرونر می‌باشند، به علت تفاوت در عوامل خطر مورد استفاده، مدل‌هایی با دقت متفاوت گزارش داده‌اند. در تحقیق حاضر نیز محدودیت در استفاده از عوامل خطر ممکن است باعث کم شدن دقت مدل نسبت به تحقیقاتی شود که در آن‌ها خطرهای احتمالی برای بیماران پذیرفته شده و عامل وقت صرف نظر شده‌است. اما مسأله‌ای که حائز اهمیت می‌باشد این است که در این تحقیق و دیگر تحقیقات مورد بررسی، میزان ویژگی مدل‌ها کمتر از حساسیت می‌باشد و این بدین معنی است که مدل در تشخیص افراد بیمار نسبت به تشخیص افراد سالم تواناتر است (۱۵).

شبکه عصبی مصنوعی در حل مسائل پیچیده که فاقد الگوریتم هستند یا حل آن‌ها برای کامپیوترهای رایج دشوار است؛ مانند تشخیص تصاویر به‌خوبی عمل کرده‌اند. شبکه عصبی هیچ فرض اولیه‌ای بر توزیع داده‌ها تحمیل نمی‌کند، ضمن اینکه هیچ محدودیتی نیز برای شکل تابعی رابطه بین متغیرهای مستقل و وابسته در نظر نمی‌گیرد. در عوض، شبکه عصبی این رابطه تابعی را که می‌تواند خطی یا غیرخطی باشد کشف می‌کند.

² - Supervised Learning

³ - Unsupervised Learning

⁴ - Continuous

⁵ - Discrete

⁶ - Existing data

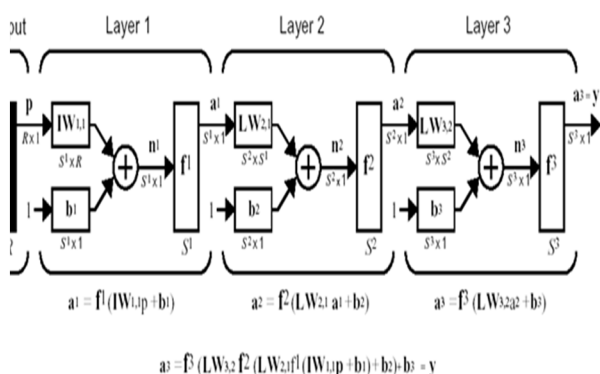
¹ - Sedehi

همان‌طور که جداول ۲ و ۳ نشان می‌دهد، می‌توان متغیرهای بیماری را به دو دسته گسسته و پیوسته تقسیم کرد. در این بین پارامتر جنسیت، دخانیات، فشار خون بالا، دیابت، سابقه خانوادگی، سابقه حمله قلبی، تست ورزش و اکو از نوع گسسته و ۵ پارامتر سن، کراتینین، تری‌گلیسرید و کسر تخلیه دارای مقادیر پیوسته هستند.

جدول ۳- آماره‌های توصیفی مربوط به متغیرهای کمی

متغیر	انحراف معیار ± میانگین
سن	۵۴ ± ۱۴/۷۲
کراتینین	۰/۲۹ ± ۰/۹۹
کلسترول	۱۹۲/۹۸ ± ۴۰/۲۹
تری‌گلیسرید	۱۶۴/۶ ± ۸۳/۰
کسر تخلیه	۶۷/۵ ± ۱۲/۶

بررسی شبکه عصبی MLP: یکی از شبکه‌های عصبی پرکاربرد شبکه عصبی چند لایه پیشخور می‌باشد. ساختار شبکه MLP دارای تعدادی گره با تابع محرک مشخص می‌باشد که در لایه‌های مجزا قرار دارند. هر گره به وسیله ضرایب وزنی خود، خروجی تمامی گره‌های لایه‌های قبلی را جمع کرده و از طریق تابع فعالیت به لایه بعدی ارسال می‌کند. شبکه عصبی MLP دارای یک لایه ورودی، یک لایه خروجی و حداقل یک لایه پنهانی است. تعداد گره‌ها بستگی به ساختار شبکه دارد. در شکل ذیل یک شبکه عصبی سه لایه با S_i نرون در هر لایه و بردار ورودی P با r عضو نشان می‌دهد.



شکل ۱- ساختار شبکه عصبی سه لایه

در طی فرآیند یادگیری شبکه عصبی، مقادیر وزن و بایاس به‌طور متوالی اصلاح می‌شوند تا خروجی شبکه عصبی با مقادیر هدف با قبول خطای اندک منطبق شود. در یک شبکه MLP با یک لایه پنهانی مقدار خروجی \hat{Y} از رابطه ۱ به دست می‌آید.

$$Y^{\wedge} = Q_2(b_0 \sum_{j=0}^M w_j Q_1(b_{j0} + \sum_{s=1}^P X_{is} W_{js})) \quad (1)$$

$i = 1, 2, 3, \dots, n$

سن، کراتینین، کلسترول، تری‌گلیسرید و کسر تخلیه هستند. متغیرهای ورودی براساس جدول ۱ به شبکه عصبی اعمال گردید. برای انجام تحلیل، از شبکه عصبی پرسپترون چند لایه با الگوریتم یادگیری LM، شبکه عصبی LVQ و شبکه عصبی بیزین با استفاده از نرم‌افزار متلب ۲۰۱۳ استفاده گردید.

جدول ۱- مجموعه ریسک فاکتورهای بیماری کرونر قلب

متغیرها	توضیحات
جنسیت	زن=۱، مرد=۰
مصرف سیگار	دارد=۱، ندارد=۰
فشارخون بالا	دارد=۱، ندارد=۰
دیابت	دارد=۱، ندارد=۰
سابقه خانوادگی بیماری قلبی	دارد=۱، ندارد=۰
سابقه سکنه قلبی	دارد=۱، ندارد=۰
نتیجه تست ورزش	نرمال=۱، غیر نرمال=۰
نتیجه اکو	نرمال=۱، غیر نرمال=۰
سن	سال/۱۰۰
کراتینین	عدد/۳/۵
کلسترول	عدد/۱۰۰۰
تری‌گلیسرید	عدد/۱۰۰۰
کسر تخلیه	عدد/۱۰۰

برای ایجاد یک دید کلی متغیرها به دو دسته کمی و کیفی تقسیم شدند. جداول ۲ و ۳ آماره‌های توصیفی مربوط به متغیرهای کیفی را نشان می‌دهد. در مجموع از ۲۰۰ نفر بیمار ۴۳ درصد مرد و ۵۷ درصد زن بودند.

جدول ۲- آماره‌های توصیفی مربوط به متغیرهای کیفی

متغیر	درصد
جنسیت	مرد ۴۳
دخانیات	سیگاری ۸۸/۹
فشار خون بالا	غیر سیگاری ۱۲/۱
دیابت	دارند ۶۱
سابقه خانوادگی	ندارند ۳۹
سابقه حمله قلبی	دارند ۷۲
تست ورزش	ندارند ۲۸
اکو	دارند ۷۶
	نرمال ۲۴
	غیر نرمال ۷۶
	سالم ۸۵
	بیمار ۱۴/۵

همانطور که در شکل مشاهده می‌شود این شبکه در ساختار خود دارای دو لایه است که هر نرون در لایه اول با یادگیری یک بردار اولیه قسمتی از فضای ورودی را طبقه‌بندی می‌کند. اغلب چند نرون به یک کلاس تخصیص می‌یابند و سپس در لایه دوم هر کلاس به یک نرون تخصیص داده می‌شود. از لایه دوم شبکه LVQ برای ترکیب زیر کلاس‌ها به یک کلاس واحد استفاده می‌شود. فرض شده است که یک قانون یادگیری مطلوب برای شبکه LVQ باید معادله دیفرانسیل را از رابطه ۲ در فضای پیوسته تأمین نماید.

$$\frac{dm_i}{dt} = a_t u_i(x)(x - m_i) \quad (2)$$


یا در فضای گسسته داریم:

$$\Delta m_i = a_t u_t(x)(x - m_i) \quad (3)$$

که در رابطه ۳، X بردار ورودی، m_i بردار حافظه نرون i می‌باشد. $u_i(x)$ مقدار خروجی نرون i است در جایی که X لایه ورودی ارائه شده است. فرمول ذیل به نرخ یادگیری تمپورال اشاره دارد.

$$a_t = a \left(\frac{1-t}{T} \right) \quad (4)$$

بررسی شبکه عصبی بیزین: این روش یکی از روش‌های سیستم پشتیبان تصمیم‌گیری می‌باشد که ابزار قدرتمندی در مدل‌سازی شبکه‌ای از احتمالات است. نکته بسیار مهم در روش شبکه بیزین این است که این روش به اطلاعات دقیق و تاریخیچه یک واقعیت نیاز ندارد بلکه می‌تواند با اطلاعات ناقص و غیر دقیق به نتایج بسیار قانع‌کننده‌ای دست یابد. شکل ۳ یک نمونه از این شبکه را نشان می‌دهد.

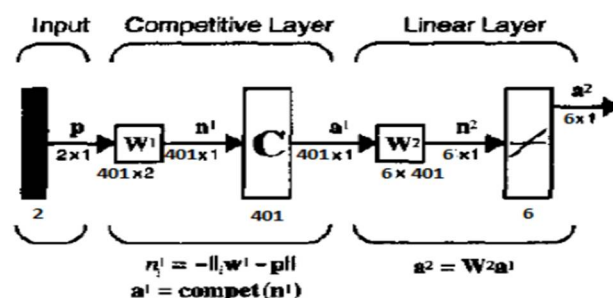


شکل ۳- شبکه بیزین

الگوریتم بیزین به طور خودکار مقادیری مناسب برای پارامترهای تابع قرار می‌دهد؛ مزیت این الگوریتم در این است که اندازه شبکه بر روی نتایج آن تأثیر اندکی خواهد گذاشت. در این قالب فرض می‌شود که وزن‌ها و بایاس‌ها، متغیرهای تصادفی با توزیع مشخص بوده و نیز پارامترهای احتمالی

در این فرمول n تعداد الگوها، M تعداد گره‌های لایه میانی، p تعداد گره‌های لایه ورودی، W_{js} وزن مربوط به ورودی X_{is} در گره j ، W_j وزن مربوط به گره j از لایه میانی و لایه خروجی و b_{j0} و b_0 به ترتیب مقادیر بایاس گره‌های لایه میانی و لایه خروجی و φ_1 و φ_2 به ترتیب توابع محرک لایه خروجی و لایه میانی شبکه می‌باشد. این شبکه عصبی از یک واحد محاسباتی به نام پرسپترون ساخته می‌شود. یک پرسپترون، برداری از ورودی‌ها را می‌گیرد و یک ترکیب خطی از ورودی‌ها را محاسبه می‌کند. اگر حاصل از یک مقدار آستانه بیشتر شد خروجی برابر یک، در غیر این صورت صفر خواهد شد (۱۱).

بررسی شبکه عصبی LVQ: از جمله الگوریتم‌های شبکه عصبی که برای حل مسئله کلاس‌بندی استفاده می‌شود، الگوریتم یادگیری تعیین بردار LVQ می‌باشد. شبکه LVQ یک شبکه ترکیبی است که به هر دو شیوه با ناظر و بدون ناظر آموزش می‌بیند. هدف از کلاس‌بندی این است که داده‌ها را براساس معیارها به دسته‌هایی تقسیم‌بندی کرده و به آن برچسب می‌دهد. مثلاً در تشخیص بیماری افراد به دو کلاس سالم و بیمار تقسیم می‌شود. همچنین این شبکه دارای دو لایه است که هر نرون آن در لایه اول قسمتی از ورودی را بر اساس یادگیری بردار اولیه طبقه‌بندی می‌کند. گاهی اوقات چند نرون به یک کلاس داده می‌شود و سپس در لایه دوم به ازای هر کلاس یک نرون وجود دارد. تعداد نرون‌ها با تعداد کلاس‌ها برابر است و از لایه دوم برای ترکیب زیر کلاس‌ها به یک کلاس واحد استفاده می‌شود. آموزش شبکه LVQ به این صورت است که بردارهای الگو مقاردهی اولیه می‌شوند سپس یک ورودی اعمال می‌شود و نزدیک‌ترین بردار الگو انتخاب می‌شود. در صورت درست بودن الگو به بردار ورودی نزدیک می‌شود و در صورتی که درست نباشد از بردار ورودی دور می‌شود (۱۶).



شکل ۲- نمای شماتیک شبکه عصبی LVQ

آشفتگی^۴ برای نمایش دقت‌های به‌دست آمده استفاده شد. ماتریس آشفتگی در سیستم‌های دسته‌بندی و تشخیص بیماری‌ها، برای بررسی میزان موفقیت و کارایی این سیستم‌ها کاربرد دارد. برای نشان دادن دقت شبکه از شاخص حساسیت و ویژگی استفاده شده است. دقت کلاس‌بندی از رابطه ۷ به‌دست می‌آید.

Classification accuracy(N) =

$$\frac{\sum_{i=1}^N \text{calculator}(ni)}{|N|} \quad (7)$$

در این رابطه، N کل نمونه‌هایی است که برای داده تست در نظر گرفته می‌شود. علاوه بر محاسبه دقت شبکه دو کمیت حساسیت^۵ و ویژگی^۶ نیز محاسبه شده است، که از روابط ۸ و ۹ به‌دست می‌آید.

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (8)$$

$$\text{Specificy} = \frac{TN}{FP + TN} \quad (9)$$

در روابط بالا:

TP (True Positive): کل افراد بیماری که بیمار تشخیص داده شدند.

FP (False Positive): کل افرادی بیماری که سالم تشخیص داده شدند.

TN (True Negative): کل افراد سالمی که سالم تشخیص داده شدند.

FN (False Negative): کل افراد سالمی که بیمار تشخیص داده شدند.

طراحی شبکه عصبی MLP: در طراحی این شبکه، از الگوریتم یادگیری لونیگ مارکوات (LM) به دلیل هم‌گرایی سریع‌تر در آموزش شبکه‌های با اندازه متوسط، در پژوهش حاضر استفاده گردید. یک شبکه عصبی MLP می‌تواند شامل معماری‌های مختلف و چند لایه با تعداد نرون‌های مخفی موردنظر در هر لایه باشد. برای نشان دادن دقت از شاخص حساسیت و ویژگی استفاده شده است. انتخاب این روش بر اساس تحقیق آقای

مشخص، با داده و مدل ساختاربندی شده باشند. در روش بیزین برای توزیع وزن‌ها از رابطه ۵ استفاده شده است.

$$y_k = f_{\text{outer}} \left(\sum_{j=1}^M W^{(2)}_{kj} f_{\text{inner}} \left(\sum_{i=1}^d W^{(1)}_{ji} + W^{(1)}_{j0} \right) + W^{(1)}_{k0} \right) \quad (5)$$

وزن‌ها در لایه اول و دوم به ترتیب با $W^{(1)}_{ji}$ و $W^{(2)}_{kj}$ ورودی i و لایه مخفی j و $W^{(2)}_{j0}$ بایاس برای واحد مخفی

z می‌باشد. M تعداد واحدهای مخفی، d تعداد واحد ورودی و k شاخصی برای واحد خروجی است. تابع $f_{\text{outer}}(0)$ خطی است و $f_{\text{inner}}(0)$ تابع تانژانت هایپربولیک است. برای مشخص کردن میزان وزن‌های شبکه با قرار دادن در رابطه ۶ به‌دست می‌آید

$$P(W|D) = \frac{P(D|W)P(w)}{P(D)} \quad (6) \quad (17)$$

$P(w)$ تابع توزیع احتمال در فضای وزنی با فقدان داده است که به صورت تابع اولیه می‌باشد. کمیت $P(W|D)$ تابع احتمالی وزن‌ها است که به عنوان تابع توزیع احتمالی بعد از آموزش داده‌ها دیده می‌شود. $P(D|W)$ تابع توزیع احتمال و $P(D)$ تابع توزیع احتمال ثانویه است.

در مطالعه حاضر از طبقه‌بندی کننده پرسپترون چندلایه^۱ و الگوریتم یادگیری تعیین بردار^۲ و شبکه عصبی بیزین^۳ جهت طبقه‌بندی افراد به دو دسته بیمار و سالم استفاده شد. در ابتدا معماری‌های مختلف شبکه عصبی پرسپترون چندلایه برای کشف بهترین معماری، مورد بررسی قرار گرفت سپس از کلیه ۱۳ پارامتر بالینی بیماران که در جدول ۱ مشخص شده است، جهت آموزش شبکه‌های مختلف عصبی استفاده کرده و نتایج ثبت گردید. در گام بعد با بررسی آماره‌های توصیفی بیماران، پارامترهای پیوسته بیماران را استخراج و با این علائم پیوسته آموزش شبکه عصبی بررسی شد.

طراحی و آموزش شبکه‌های عصبی: در طراحی شبکه‌های عصبی مذکور از دو ماتریس استفاده گردید که ماتریس اول با ۲۰۰ نمونه و ۱۳ ویژگی و ماتریس دوم شامل ۲۰۰ نمونه و دو وضعیت صفر و یک، به ترتیب به معنی سالم و بیمار به عنوان ماتریس هدف مورد استفاده قرار گرفت. همچنین از ماتریس

⁴ - Confusion

⁵ - Sensitivity

⁶ - Specificity

¹ - Multi-Layer Perceptron

² - Learning Vector Quantization


³ - Bayesian

حقیقی (True Positive)، منفی حقیقی (True Negative)، مثبت کاذب (False Positive) و منفی کاذب (False Negative) را نشان می‌دهد. مشاهده می‌شود که پارامتر حساسیت ۸۸ درصد و پارامتر ویژگی ۱۲ درصد می‌باشد. این ماتریس مربوط به ارزیابی کل داده‌ها شامل آزمون و آزمایش می‌باشد.

Confusion Matrix			
Output Class	۷	۰	۱۰۰٪
	۳.۵٪	۰.۰٪	۰.۰٪
	۲۴	۱۶۹	۸۷.۶٪
	۱۲.۰٪	۸۴.۵٪	۱۲.۴٪
	۲۲.۶٪	۱۰۰٪	۸۸.۰٪
	۷۷.۴٪	۰.۰٪	۱۲.۰٪
Target Class			

شکل ۵- ماتریس آشفته‌گی شبکه عصبی MLP

طراحی شبکه عصبی LVQ: در طراحی شبکه عصبی LVQ از الگوریتم SOM برای حل مسأله کلاس‌بندی استفاده گردید. SOM یک شبکه عصبی مبتنی بر رقابت است که توانایی تشخیص خوشه‌ها در داده‌ها را دارد. در این الگوریتم نرون‌ها به سمت نواحی حرکت می‌کنند که در آن تمرکز داده‌ها وجود دارد. این عمل از طریق تغییر وزن ارتباطات صورت می‌گیرد. در پژوهش حاضر، در طراحی شبکه عصبی LVQ از ۸۰ درصد داده‌ها به عنوان داده‌های آموزش و ۱۰ درصد داده‌ها به عنوان داده‌های اعتبارسنجی و ۱۰ درصد داده‌ها به عنوان تست مورد استفاده قرار گرفت. داده‌های آموزش به صورت تصادفی انتخاب شدند. معماری شبکه ایجاد شده در شکل ۶ آمده است.



شکل ۶- بهترین معماری شبکه عصبی LVQ در تشخیص افراد سالم

ماتریس آشفته‌گی مربوط به شبکه عصبی LVQ به دست آمد و مشاهده می‌شود که دقت نهایی دارای حساسیت ۸۴/۵ درصد و


موبلی^۱ در مقاله‌ای با عنوان پیش‌بینی شریان کرونری بوسیله شبکه‌های عصبی مصنوعی که بیشترین شباهت را به این قسمت از تحقیق داشت انجام گرفت (۱۸). در مطالعه ایشان ۱۴ ویژگی شامل سن، جنسیت، نژاد، دخانیات، دیابت، فشار خون، شاخص توده بدنی و برخی عوامل خطی دیگر به عنوان ورودی به شبکه عصبی MLP با ساختار (۱-۲۶-۱۴) اعمال گردید و خروجی شبکه، متغیر تنگ بودن یا نبودن شریان کرونری در نظر گرفته شد که طبق نتایج به دست آمده حساسیت برابر ۱ و ویژگی برابر ۴۷ درصد به دست آمد. پس از طراحی معماری شبکه، ۷۰ درصد داده‌ها جهت آموزش، ۱۵ درصد داده‌ها جهت اعتبارسنجی و ۱۵ درصد داده‌ها جهت تست نتایج تخصیص داده شدند. لذا جهت حصول دقت بیشتر در ارزیابی نتایج حاصله، به طور میانگین در هر طراحی ۱۰ بار آزمایش تکرار شده است و نتایج آن در جدول شماره ۳ ثبت گردید.

جدول ۳- معماری‌های مختلف شبکه عصبی MLP پس از ۱۰

بار آزمایش و ثبت میانگین نتایج

میانگین دقت	معماری
۸۲/۵ درصد	دو لایه با ۱۰ نرون در لایه اول
۸۵ درصد	سه لایه با ۱۰ نرون در لایه اول و ۵ نرون در لایه دوم
۸۸ درصد	چهار لایه با ۱۰ نرون در لایه اول و ۵ نرون در لایه دوم و ۵ نرون در لایه سوم

نتایج نشان می‌دهد که از بین معماری‌های فوق ساختار یک شبکه عصبی با ۱۰ گره در لایه میانی اول، ۵ گره در لایه میانی دوم و ۵ گره در لایه میانی سوم می‌تواند تا ۸۸ درصد به بالاترین دقت رسید. شکل ۴ معماری بهترین نوع شبکه MLP آموزش دیده را نشان می‌دهد.



شکل ۴- بهترین معماری شبکه عصبی MLP با ۳ لایه مخفی

جهت تشخیص افراد سالم

ماتریس آشفته‌گی مربوط به بهترین معماری شبکه MLP در شکل ۵ مشاهده می‌شود. این ماتریس چهار حالت مثبت

¹ - Mobley

اطلاعات پیوسته بودند از جدول ۱ استخراج شدند که در جدول ۴ نمایش داده شده است.

جدول ۴- ریسک فاکتورهای پیوسته بیماری عروق کرونر قلب

پارامترهای پیوسته بیماری عروق کرونر قلب			
سن	کراتینین	کلسترول	تری‌گلیسیرید
کسر تخلیه			

با ۸۰ درصد داده‌ها و ۵ پارامتر ورودی، آموزش شبکه‌های عصبی MLP و LVQ و BR انجام گرفت و از ۱۰ درصد داده‌ها جهت اعتبارسنجی و ۱۰ درصد باقی‌مانده جهت آزمون استفاده گردید. جهت اطمینان از صحت نتایج به‌دست‌آمده، عملیات آموزش شبکه عصبی با ۱۰ بار تکرار برای هر شبکه عصبی و ثبت نتایج میانگین انجام پذیرفت. در این حالت، در بهترین معماری شبکه عصبی پرسپترون چندلایه توانستیم به دقت ۸۵ درصد و شبکه LVQ به دقت ۸۴/۴ درصد و شبکه BR به دقت ۸۲/۵ درصد در مورد شاخص حساسیت دست پیدا کنیم.

نتایج

مطالعه حاضر بر روی داده‌های استخراج شده از پرونده ۲۰۰ نفر از بیماران عروق کرونر قلبی صورت گرفته است. اطلاعات این بیماران توسط محققین از یکی از مراکز تخصصی قلب شهرستان تربت‌حیدریه استخراج و مورد تحلیل قرار گرفته است از این تعداد ۱۷۹ نفر به تشخیص پزشک متخصص، مبتلا به بیماری عروق کرونر قلبی و ۲۱ نفر هم سالم تشخیص داده شده بودند. از آنجایی که شبکه‌های عصبی مصنوعی به عنوان روش نوین در تشخیص بیماری‌ها مورد توجه بسیاری از محققین در سال‌های اخیر قرار گرفته است لذا در این پژوهش به کمک ۳ نوع شبکه عصبی مختلف به تشخیص بیماری عروق کرونر قلب و مدل‌سازی و مقایسه نتایج آن پرداخته شده است. با توجه به اینکه افزودنی پارامترهای ورودی هر بیماری می‌تواند فرآیند همگرا شدن شبکه عصبی را زمان‌بر کند، اقدام به حذف ویژگی‌های گسسته از مجموع عوامل خطر بیماری عروق کرونر قلب گردید و با همان شبکه‌های عصبی قبلی، مدل‌سازی انجام شد. الگوریتم مورد استفاده در این پژوهش به صورت زیر است.

ویژگی ۱۵/۵ درصد می‌باشد. شکل ۷ دقت نهایی شبکه عصبی LVQ را نشان می‌دهد.

Output Class	۰	۰	NaN%
	۰.۰%	۰.۰%	NaN%
	۲۱	۱۶۹	۸۴.۵%
	۱۵.۵%	۸۴.۵%	۱۵.۵%
	۰.۰%	۱۰۰%	۸۴.۵%
	۱۰۰%	۰.۰%	۱۵.۵%
Target Class			


شکل ۷- ماتریس آشفتگی شبکه عصبی LVQ

طراحی شبکه عصبی BR: در طراحی این شبکه، ابتدا مجموعه داده‌ها در نظر گرفته شده و با توجه به ماهیت الگوریتم‌ها، داده‌ها به دو دسته تقسیم می‌شود و عملیات پیش پردازش و گسسته‌سازی صورت می‌گیرد. ماتریس آشفتگی مربوطه در شکل ۸ نشان می‌دهد که شبکه عصبی به دقت حساسیت درصد و ویژگی ۱۶ درصد رسیده است.

Output Class	۱	۲	۳۳.۳%
	۰.۵%	۱.۰%	۶۶.۷%
	۳۰	۱۶۷	۸۴.۸%
	۱۵.۰%	۸۳.۵%	۱۵.۲%
	۳.۲%	۹۸.۸%	۸۴.۵%
	۹۶.۸%	۱.۲%	۱۶.۰%
Target Class			

شکل ۸- ماتریس آشفتگی شبکه عصبی BR

معماری شبکه بیزین ایجاد شده در نرم‌افزار متلب شامل ۱۰ نرون در لایه مخفی خود می‌باشد. شکل ۹ معماری شبکه عصبی BR را نشان می‌دهد.



شکل ۹- معماری شبکه عصبی BR

بررسی تأثیر پارامترهای پیوسته: در این قسمت از مجموع ۱۳ پارامتر بالینی اخذ شده از بیماران، ۵ پارامتری که حاوی

حذف پارامترهای گسسته از فرآیند تشخیص بیماری، تأثیر قابل توجهی در نتایج ندارد. از آنجایی که کاهش پارامترهای ورودی شبکه عصبی می‌تواند فرآیند همگرا شدن شبکه را تسریع کند، لذا باتوجه به این که زمان اهمیت بیشتری نسبت به دقت پیدا می‌کند حذف برخی از پارامترها می‌تواند در تحلیل سریع‌تر نتیجه تشخیص بیماری عروق کرونر قلب کمک کند. نتایج نشان می‌دهد که حذف پارامترهای گسسته از فرآیند کلاس-بندی بیماری و با استفاده از شبکه MLP تنها موجب کاهش ۳ درصد دقت در پیش‌بینی نتیجه می‌شود.

نتیجه‌گیری

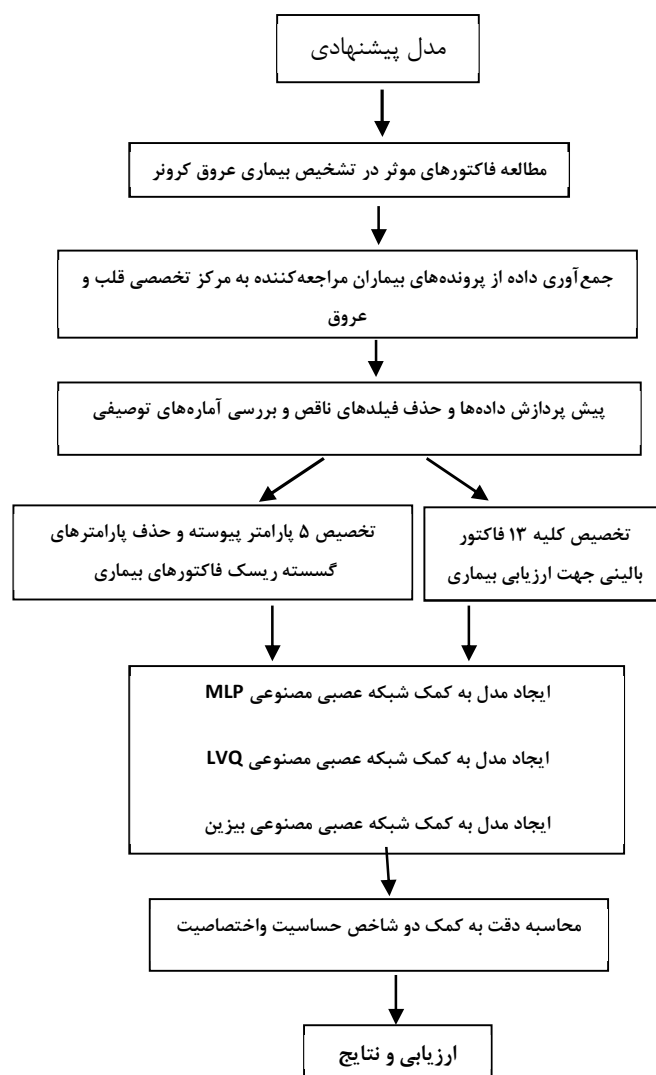
آنژیوگرافی یک روش تهاجمی است و علاوه بر هزینه گران آن همراه با ریسک‌هایی چون مرگ، سکته قلبی و سکته مغزی است. بنابراین باید از روش‌های غیر تهاجمی استفاده شود که پیش‌بینی بر اساس آن‌ها دارای کمترین خطا و بیشترین اطمینان باشد. استفاده از روش‌های نوین داده‌کاوی می‌تواند به کاهش این عوارض کمک کند. جدول ۵ نتایج ارزیابی این پژوهش را نشان می‌دهد.

جدول ۵- نتایج ارزیابی

نوع شبکه عصبی		امال کلیه پارامترهای بالینی		امال پارامترهای پیوسته	
ویژگی (درصد)	حساسیت (درصد)	ویژگی (درصد)	حساسیت (درصد)	ویژگی (درصد)	حساسیت (درصد)
۸۸	۱۲	۸۵	۱۵	۸۵	۱۵
۸۴/۵	۱۵/۵	۸۴/۴	۱۵/۶	۸۴	۱۶
۸۴	۱۶	۸۲/۵	۱۷/۵		

تشکر و قدردانی

این مطالعه در قالب طرح تحقیقاتی مصوب به شماره A-10-1289-1 و با حمایت معاونت محترم پژوهشی دانشگاه علوم پزشکی تربت‌حیدریه انجام شده است.



شکل ۱۰- الگوریتم پیشنهادی

بحث

در پژوهش حاضر، به منظور پیش‌بینی عروق کرونر قلب از تکنیک قدرتمند شبکه عصبی مصنوعی استفاده شد و شبکه‌های عصبی نظارت شده و غیر نظارت شده مورد ارزیابی قرار گرفتند. طبق نتایج مندرج در جدول شماره ۵ بین شبکه‌های عصبی مختلف، شبکه عصبی پس انتشار خطا با الگوریتم LM و با میانگین مربعات خطا، بیشترین دقت را در تشخیص بیماری عروق کرونر قلب داشت. همچنین این مطالعه نشان داد که

References

- 1- Thom T, Haase N, Rosamond W, Howard VJ, Rumsfeld J, Manolio T, Et Al. Heart Disease And Stroke Statistics--2006 Update: A Report From The American Heart Association Statistics Committee And Stroke Statistics Subcommittee. *Circulation*. 2006;113(6):E85.
- 2- Crawford MH. *Current Diagnosis & Treatment In Cardiology*. Lange Medical Books/Mcgraw-Hill; 2003.
- 3- Falk CT. Risk Factors For Coronary Artery Disease And The Use Of Neural Networks To Predict The Presence Or Absence Of High Blood Pressure. *BMC Genet*. 2003;4(1):S67.
- 4- Itchhaporia D, Snow PB, Almassy RJ, Oetgen WJ. Artificial Neural Networks: Current Status In Cardiovascular Medicine. *J Am Coll Cardiol*. 1996;28(2):515–21.
- 5- Catalano PJ, Ryan LM. Bivariate Latent Variable Models For Clustered Discrete And Continuous Outcomes. *J Am Stat Assoc*. 1992;87(419):651–8.
- 6- Kurt I, Ture M, Kurum AT. Comparing Performances Of Logistic Regression, Classification And Regression Tree, And Neural Networks For Predicting Coronary Artery Disease. *Expert Syst Appl*. 2008;34(1):366–74.
- 7- Biglarian A, Bababee Gr, Azmie R. Application Of Artificial Neural Network Model In Determining Important Predictors Of In-Hospital Mortality After Coronaryartery Bypass Graft Surgery, And It's Comparison With Logistic Regression Model. 2004; 7(1):23-29.
- 8- Sargent DJ. Comparison Of Artificial Neural Networks With Other Statistical Approaches. *Cancer*. 2001;91(S8):1636–42.
- 9- Dreiseitl S, Ohno-Machado L. Logistic Regression And Artificial Neural Network Classification Models: A Methodology Review. *J Biomed Inform*. 2002;35(5):352–9.
- 10- Ohno-Machado L, Musen MA. Sequential Versus Standard Neural Networks For Pattern Recognition: An Example Using The Domain Of Coronary Heart Disease. *Comput Biol Med*. 1997;27(4):267–81.
- 11- Colak MC, Colak C, Kocaturk H, Sagioglu S, Barutcu I. Predicting Coronary Artery Disease Using Different Artificial Neural Network Models/Koroner Arter Hastaliginin Degisik Yapay Sinir Agi Modelleri Lie Tahmini. *Anatol J Cardiol (Anadolu Kardiyol Dergisi)*. 2008;8(4):249–55.
- 12- Sedehi M. Design Of Artificial Neural Network For Modeling Of Bivariate Mixed Responses And Its Application In Medical Data. Present Degree Phd Biostat Tarbiat Modares Univ. 2010;
- 13- Ghaemian A, Esmacili J. Application Of Artificial Neural Network For Assessing Coronary Artery Disease. *J Maz Univ Med Sci*. 2012;21(86):9–17.
- 14- Khosravanian A AS. Presenting An Intelligent System For Diagnosis Of Coronary Heart Disease By Using Probabilistic Neural Network. *Heal Inf Manag*. 2015;12:13.
- 15- Samadi S, Nazifi M, Abbaspour S. Estimating The Duration Of Treatment And Hospitalization Costs Using Neural Network Approach. *Heal Inf Manag*. 2012;(0):518.
- 16- Melin P, Amezcua J, Valdez F, Castillo O. A New Neural Network Model Based On The LVQ Algorithm For Multi-Class Classification Of Arrhythmias. *Inf Sci (Ny)*. 2014;279:483–97.
- 17- Marwala T. Bayesian Training Of Neural Networks Using Genetic Programming. *Pattern Recognit Lett*. 2007;28(12):1452–8.
- 18- Mobley BA, Schechter E, Moore WE, Mckee PA, Eichner JE. Neural Network Predictions Of Significant Coronary Artery Stenosis In Men. *Artif Intell Med*. 2005;34(2):151–61.

The Effect of Continuous Parameters on the Diagnosis of Coronary Artery Disease Using Artificial Neural Networks

Iman Zabbah^{*1}, Majid hassanzadeh², Zahra Koohjani³

1- Department of Computer Engineering, Islamic Azad University, Torbat-e-Heydariyeh branch, Torbat-e-Heydariyeh, Iran

2- Department of Nursing, Torbat Heydariyeh University of Medical Sciences, Torbat Heydariyeh, Iran

3- Student of Computer Engineering, Torbat-e-Heydariyeh University, Torbat-e-Heydariyeh, Iran

***Corresponding Address: Islamic Islamic Azad University, Torbat-e-Heydariyeh branch, Torbat-e-Heydariyeh, Iran.**

Email address: imanzabbah@gmail.com

Abstract

Background & Aim: Coronary artery disease is among the common diseases in societies. The best method of assessing coronary artery diseases is through angiography. This study aimed at investigating the effect of disease parameters on the diagnosis of coronary artery disease using artificial neural networks.

Methods: This analytic study included a database of 200 non-attributable records. In this research, different neural networks such as MLP, LVQ and BR were used to predict whether the coronary arteries were blocked or not. In addition, the importance of the continuous risk factors of coronary artery disease was studied.

Results: The most important criteria of the diagnosis systems are the specificity and sensitivity indicators. In this study, these two indicators were calculated in the test. The best accuracy was observed in MLP, with a back-error propagation of 88%. It was also observed that the removal of discrete parameters positively affects neural network convergence speed so that the prediction accuracy could reach 85%.

Conclusion: Angiography is a high-cost invasive procedure with risk factors such as death, stroke and heart attack. Therefore, noninvasive methods should be applied in order to minimize error and maximize reliability to predict the disease. Using data mining methods can decrease the complications of the disease.

Keyword: Coronary Artery Disease, Artificial Neural Network, Continuous Parameters of Coronary Artery