مقاله پژوهشی

مجله انفورماتیک سلامت و زیست پزشکی
مرکز تحقیقات انفورماتیک پزشکی
دوره پنجم شماره دوم. ص۲۷۴-۲۸۵، ۱۳۹۷

# تشخیص بیماری عروق کرونر قلب با استفاده از روش ترکیب خبره‌ها

**مجید حسن زاده[۱]، ایمان ذباح[۲]*، کامران لایقی[۳]**

• دریافت مقاله: ۹۶/۵/۲۲ • پذیرش مقاله: ۹۶/۹/۵

**مقدمه:** بیماری عروق کرونر قلب، شایع‌ترین بیماری قلبی است و از علل اصلی مرگ در زنان و مردان است. این مطالعه با هدف پیش‌بینی وضعیت این بیماری با استفاده از روش ترکیب شبکه‌های عصبی (ترکیب خبره‌ها) انجام شد.

**روش:** این تحقیق از نوع تشخیصی و بر روی ۲۰۰ نفر از مراجعین به مرکز تخصصی قلب و عروق شهرستان تربت‌حیدریه انجام شد. پرونده مراجعین حاوی اطلاعات دموگرافیک بیماران شامل ۱۳ ریسک فاکتور بود. تولید مدل پیش‌بینی بیماری عروق کرونر قلب بر اساس شبکه‌های عصبی پرسپترون چندلایه و سپس جمع‌بندی نظرات آن‌ها انجام شد.

**نتایج:** در ابتدا از یک شبکه عصبی پرسپترون چندلایه با الگوریتم پس انتشار خطا استفاده گردید. بهترین معماری توانست با دقت ۷۱/۷٪ بسته بودن عروق کرونر قلب را پیش‌بینی کند. سپس با افزایش تعداد شبکه‌ها و تعلیم آن‌ها، ترکیب نتایج با یکدیگر انجام شد. ترکیب خبره‌ها با روش خطی رأی اکثریت و غیرخطی شبکه عصبی راه‌گاهی انجام و دقت پیش‌بینی به ترتیب ۷۵/۸٪ و ۷۸/۳٪ به دست آمد.

**نتیجه‌گیری:** آنژیوگرافی یک روش تهاجمی و همراه با ریسک‌هایی مانند سکته قلبی و مغزی است؛ لذا باید از روش‌های غیرتهاجمی در تشخیص عروق کرونر قلب استفاده کرد. در این مطالعه با افزایش تعداد یادگیرها و سپس ترکیب غیرخطی آن‌ها دقت تشخیص افزایش یافت.

**کلید واژه‌ها:** بیماری عروق کرونر قلب، شبکه عصبی مصنوعی، ترکیب خبره‌ها

**•ارجاع:** حسن زاده مجید، ذباح ایمان، لایقی کامران. تشخیص بیماری عروق کرونر قلب با استفاده از روش ترکیب خبره‌ها. مجله انفورماتیک سلامت و زیست پزشکی ۱۳۹۷؛ ۵(۲): ۲۷۴-۲۸۵.

۱. دکتری مدیریت آموزش عالی، استادیار گروه پرستاری، دانشگاه علوم پزشکی تربت حیدریه، تربت حیدریه، ایران
۲. دانشجوی دکتری کامپیوتر، دانشکده برق و کامپیوتر، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران
۳. دکتری کامپیوتر، استادیار گروه کامپیوتر، دانشکده برق و کامپیوتر، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران

*** نویسنده مسئول:** خراسان رضوی، تربت حیدریه، دانشگاه آزاد اسلامی تربت حیدریه

**• شماره تماس:** ۰۹۱۵۹۳۱۱۰۵۰

**• Email:** imanz.zabbah@iaut.ac.ir

[ Downloaded from jhbmi.ir on 2026-02-22 ]

## مقدمه

با توجه به گزارش انجمن قلب آمریکا، بیش از دوازده میلیون آمریکایی از بیماری عروق کرونر قلب ( Coronary Artery Disease) رنج می‌برند و هرساله بیش از پانصد هزار نفر از حمله قلبی ناشی از این بیماری می‌میرند [۱]. در ایران نیز بر اساس اطلاعات حاصل از یک مطالعه اپیدمیولوژیک که به بررسی علت مرگ‌ومیر در سال ۱۳۸۸ پرداخته است از بین ۳۲۱۵۷۰ فوتی، تعداد ۸۲۳۰۷ مورد ناشی از بیماری عروق کرونر قلبی بوده است که این عدد معادل ۲۵/۶ درصد عامل منجر به مرگ براثر این بیماری را نشان می‌دهد [۲]. متخصصان قلب و عروق، عوامل جسمانی شناخته شده‌ای از فشارخون بالا، سطح بالای کلسترول مضر، بیماری دیابت، کمبود فعالیت بدنی، چاقی و وراثت را با بروز بیماری عروق مرتبط می‌دانند؛ باوجوداین شواهد حاکی از آن است که این موارد حداکثر ۵۰ درصد از بروز این بیماری را پیش‌بینی می‌کنند و عوامل جسمانی فوق به‌تنهایی قادر به تبیین بروز و نیز تداوم بیماری کرونر قلب نیستند [۳]. بهترین روش ارزیابی بیماری کرونر قلبی، آنژیوگرافی است. از این روش به‌عنوان استاندارد طلایی برای تشخیص بیماری کرونر قلبی استفاده می‌شود [۴]. آنژیوگرافی یک روش تهاجمی است و علاوه بر هزینه گران آن همراه با ریسک‌هایی چون مرگ و سکته قلبی و مغزی است. به‌عنوان نمونه در مطالعه میر محمدصادقی و همکاران با عنوان بررسی بروز عوامل خطر سکته مغزی بعد از جراحی بای پس عروق کرونر قلب، از تعداد ۱۳۸۶ بیماری که تحت عمل جراحی قرارگرفته بودند، ۱/۴٪ از بیماران پس از عمل جراحی در بیمارستان دچار عارضه سکته مغزی شدند [۳]؛ بنابراین باید از روش‌های غیرتهاجمی استفاده شود که پیش‌بینی بر اساس آن‌ها دارای کمترین خطا و بیشترین اطمینان باشد.

مطالعات مختلف انجام‌شده نشان می‌دهد که بیماری عروق کرونر قلب نتیجه همگرایی تعدادی از ریسک فاکتورهای این بیماری است [۵]. اخیراً تکنیک‌های داده‌کاوی ( Data mining) جهت کشف الگوها در تشخیص بیماری‌ها موردتوجه بسیاری از محققین قرار گرفته است [۶]. ازجمله می‌توان به درخت‌های تصمیم‌گیر، ماشین بردار، دسته‌بندی کننده بیزین، نزدیک‌ترین همسایه، الگوریتم‌های ژنتیک و شبکه‌های عصبی اشاره کرد. از بین روش‌های فوق، شبکه‌های عصبی مصنوعی به‌طور وسیع‌تری در زمینه‌های مختلف پزشکی مورد استفاده قرار گرفته‌اند [۷]. نشاطی تنها و همکاران در در پژوهش خود یک مدل را با استفاده از تکنیک‌های داده‌کاوی برای پیش‌بینی سکته قلبی طراحی کردند [۸]. Suchithra پژوهشی را باهدف ساخت یک سیستم ویژه (کارآمد) با طبقه‌بندی کننده کاملاً خودکار برای تشخیص وجود بیماری ایسکمی قلب با استفاده از تکنیک‌های هوش مصنوعی انجام داد [۹]. عموماً در بیشتر مطالعات، قدرت تشخیصی و دقت پیشگویی برای مدل شبکه‌های عصبی مصنوعی نسبت به مدل‌های کلاسیک آماری بیشتر گزارش شده است [۵،۱۰،۱۱]. در این خصوص می‌توان به مطالعه Kurt و همکاران اشاره کرد که شامل جامعه آماری ۱۲۴۵ نفری و ۸ فاکتور بالینی بیماری کرونر قلبی بود. در این مطالعه از سه تکنیک رگرسیون لجستیک، درخت تصمیم‌گیر و شبکه عصبی استفاده شده است. با استفاده از شبکه عصبی پرسپترون چندلایه با دقت ۷۵٪ عمل پیش‌بینی کرونر قلبی را انجام داده است. که نسبت به دو روش دیگر عملکرد بهتری دارد [۱۲]. استفاده از یک شبکه عصبی پرسپترون چندلایه جهت ارزیابی بیماری عروق کرونر قلبی در مطالعه محمدپور و همکاران با یک جامعه آماری ۱۵۰ نفری از بین بیماران مرکز فوق تخصصی قلب مازندران نشان می‌دهد که با یک دقت قابل‌قبول می‌توان بسته و یا باز بودن عروق کرونر قلب را پیش‌بینی کرد [۱۱]. در مطالعه انجام‌شده توسط خسروانیان و آیت در یک جامعه آماری ۱۵۲ نفری نشان داده شد که شبکه‌های عصبی احتمالی بهتر و قوی‌تر از سایر شبکه-های عصبی در تشخیص بیماری عمل کرده‌اند [۱۳]. مطالعه متاآنالیزی که توسط Sargent روی ۲۸ موردتحقیق انجام شد، نشان می‌دهد که در ۳۶٪ از موارد روش شبکه‌های عصبی بهتر از روش رگرسیونی عمل می‌کنند و در ۱۴٪ ضعیف‌تر از رگرسیونی عمل می‌کنند. همچنین در ۵۰٪ مواقع این دو روش مشابه یکدیگرند [۱۴]. در برخی از تحقیقاتی که از مجموعه داده موجود در مخزن یادگیری ماشین دانشگاه ایروین کالیفرنیا استفاده شده است، مدل‌هایی با دقت بالا به‌دست‌آمده که علت آن استفاده از نتایج معاینات فیزیکی، الکتروکاردیوگرافی، تصویربرداری و استرس تست علاوه بر ریسک فاکتورهای بیماری عروق کرونر می‌باشد [۱۵]؛ لذا به علت تفاوت در ریسک فاکتورهای مورداستفاده، مدل‌هایی با دقت متفاوت گزارش شده‌اند [۱۱،۱۳].

توجه بیشتر به فاکتورهای بالینی بیماری کرونر قلب و تحلیل تأثیر آن در تشخیص بیماری موجب خواهد شد از عوارض و آسیب‌های احتمالی آنژیوگرافی و درمان‌های مربوط به عروق

[ Downloaded from jhbmi.ir on 2026-02-22 ]

کرونری قلب برای بیمارانی که نیاز به آن ندارند جلوگیری کند و در هزینه آزمون تشخیصی برای این افراد صرفه‌جویی شود؛ لذا این مطالعه، باهدف تعیین بسته بودن یا نبودن عروق کرونری قلب انجام شد که برای رسیدن به این هدف از روش جامع‌تری به نام ترکیب شبکه‌های عصبی مصنوعی یا همان ترکیب خبره‌ها استفاده شد. افزایش خبره‌ها منجر به تخصصی شدن وظیفه آن‌ها شده و ضمن تمرکز شبکه به توزیع خطا حول هدف کمک خواهد کرد و در نهایت موجب افزایش صحت عملکرد سیستم تصمیم‌گیر می‌شود؛ لذا با ترکیب نظرات آن‌ها حصول نتیجه‌ای دقیق‌تر صورت گرفت.

## روش

تحقیق حاضر یک مطالعه تشخیصی است که بر اساس متغیرهای ورودی به پیشگویی وضعیت عروق کرونری قلب پرداخت. جامعه آماری این پژوهش از مرکز تخصصی قلب شهرستان تربت‌حیدریه (دکتر حامد رضا جعفر زاده) و در مهرماه و آبان ماه ۱۳۹۴ توسط محققین طرح جمع‌آوری شد. این داده‌ها از نوع غیرقابل انتساب می‌باشد. جمع‌آوری داده از روی پرونده بیماران که به‌صورت سنتی ثبت شده بود، انجام گردید. تعداد پرونده‌های اولیه که حاوی اطلاعات دموگرافیک بیماری، تست‌های تشخیصی و نتیجه آنژیوگرافی موجود بوده ۲۳۱ پرونده بود که از این تعداد حدود ۳۱ مورد به دلیل نقص در پرونده و یا عدم مراجعه بیمار و به کمک پزشک متخصص ناقص تشخیص داده شد و به‌عنوان داده‌های گمشده حذف گردیدند؛ لذا پس از پالایش، داده‌ها قابل‌استفاده به ۲۰۰ مورد تقلیل پیدا کرد. این اطلاعات شامل ۱۳ متغیر بالینی جنسیت، مصرف سیگار، فشارخون بالا، دیابت، سابقه خانوادگی، سابقه سکته قلبی، نتیجه تست ورزش، نتیجه تست اکو، سن، کراتینین، کلسترول، تری گلیسرید و کسر تخلیه می‌باشد (جدول ۱).

**جدول ۱: آماره‌های توصیفی مربوط به متغیرهای کمی و کیفی پرونده‌های مراجعین به مرکز تخصصی قلب و عروق [۱۵]**

| نام متغیر | نوع | درصد | سطح معنی‌داری | نام متغیر | سطح معنی‌داری | میانگین و انحراف معیار Mean±SD |
|---|---|---|---|---|---|---|
| جنسیت | مرد | ٪۴۳ | ۰/۳۷۷ | سن | ۰/۵۸ | ۱۴/۷۲± ۵۴/۹۵۵۰ |
| | زن | ٪۵۷ | | | | |
| دخانیات | سیگاری | ٪۸۸,۹ | ۰/۵۲۳ | کراتینین | ۰/۷۱ | ۰/۲۹± ۰/۹۸۸۰ |
| | غیر سیگاری | ٪۱۲,۱ | | | | |
| فشارخون بالا | دارند | ٪۶۱ | ۰/۳۹۷ | کلسترول میلی‌گرم / دسی لیتر | ۰/۲۲۷ | ۴۰/۲۹± ۱۹۲/۹۸۰۰ |
| | ندارند | ٪۳۹ | | | | |
| دیابت | دارند | ٪۷۲ | ۰/۴۵۳ | تری گلیسرید | ۰/۱۷۷ | ۸۳/۲۴± ۱۴۴/۶۴ |
| | ندارند | ٪۲۸ | | | | |
| سابقه خانوادگی | دارند | ٪۷۶ | ۰/۴۷۲ | کسر تخلیه | ۰/۹۹ | ۱۲/۶۰± ۶۷/۵۸۵۰ |
| | ندارند | ٪۲۴ | | | | |
| سابقه حمله قلبی | دارند | ٪۲ | ۰/۵۳۷ | * Significant at P<۰/۰۱ و N= ۲۰۰ | | |
| | ندارند | ٪۹۸ | | ** متغیرهای جنسیت، دخانیات، فشارخون بالا، دیابت، سابقه خانوادگی، سابقه حمله قلبی، تست ورزش و اکو از نوع کیفی می‌باشند. | | |
| تست ورزش | نرمال | ٪۲۴ | ۰/۴۲۷ | *** متغیرهای سن، کراتینین، کلسترول، تری گلیسرید و کسر تخلیه از نوع کمی می‌باشند. | | |
| | غیر نرمال | ٪۷۶ | | | | |
| تست اکو | سالم | ٪۸۵ | ۰,۵۱۴ | | | |
| | بیمار | ٪۱۴/۵ | | | | |

### بخش اول: طراحی و آموزش شبکه عصبی با در نظر گرفتن کلیه فاکتورهای بالینی

یادگیری شاخص‌ترین ویژگی یک شبکه عصبی است. سیستم‌های یادگیر، سیستم‌هایی هستند که صرفاً با مشاهده عملکردشان، می‌توانند رفتارشان را جهت دستیابی به هدف و مقصدی خاص بهبود بخشند. زمانی پروسه یادگیری موردنیاز است که اطلاعات کامل در مورد کل اهداف موجود نباشد. شبکه‌های عصبی مصنوعی مانند شبکه‌های عصبی برای یادگیری فرآیند به آموزش نیاز دارند. یک شبکه عصبی می‌تواند متشکل از چندلایه باشد. هر لایه ماتریس وزنی، بردار بایاس و

[ Downloaded from jhbmi.ir on 2026-02-22 ]

بردار خروجی مختص خود را دارد. در شکل ۱ یک شبکه عصبی سه لایه با $S^i$ نرون در هر لایه و بردار ورودی P با R عضو را نشان می‌دهد.

**شکل ۱: ساختار شبکه عصبی سه لایه**

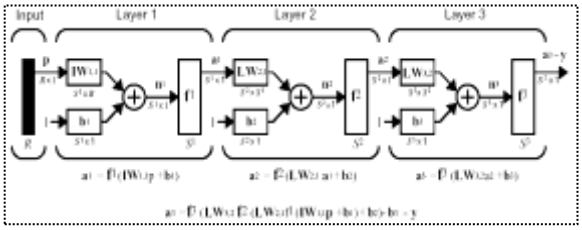


در این مطالعه ابتدا یک شبکه عصبی مصنوعی با ساختار پرسپترون چندلایه مورد استفاده قرار گرفت و کلیه ویژگی‌های تشخیص بیماری کرونر قلب شامل جنسیت، دخانیات، فشارخون بالا، دیابت، سابقه بیماری خانوادگی، سابقه سکته قلبی، تست ورزش، اکو، سن، کلسترول، کراتینین، تری‌گلیسرید و کسر تخلیه به‌عنوان پارامتر ورودی به شبکه اعمال شدند.

انتخاب این روش بر اساس تحقیق Mobley و همکاران در پژوهشی با عنوان پیش‌بینی شریان کرونر به‌وسیله شبکه‌های عصبی مصنوعی که بیش‌ترین شباهت را با این قسمت از تحقیق داشت، انجام گرفت [۱۵]. در این روش ۱۴ ویژگی شامل سن، جنسیت، نژاد، دخانیات، دیابت، فشارخون، شاخص توده بدنی و برخی عوامل خطی دیگر به‌عنوان ورودی به شبکه عصبی پرسپترون چندلایه با ساختار (۱۴-۲۶-۱) اعمال گردید و خروجی شبکه متغیر تنگ بودن یا نبودن شریان کرونر در نظر گرفته شد. در این قسمت از تحقیق حاضر با حذف ویژگی غیرضروری "نژاد" یک شبکه عصبی با ۱۳ ورودی طراحی گردید، فاکتورهای بالینی ورودی شبکه عصبی در جدول ۱ نمایش داده شد. برای انتخاب بهترین مدل پیش‌بینی مدل‌های مختلف شبکه عصبی مصنوعی ۳ لایه (حدود ۳۰ ساختار) مورد بررسی قرار گرفت. برخی از مدل‌های شبکه و نتایج حاصل از آن در جدول ۲ نمایش داده شد. در تمامی شبکه‌های فوق از ۷۰٪ داده‌ها در مرحله آموزش و ۳۰٪ در مرحله آزمون استفاده شد.

**جدول ۲: بررسی معماری‌های مختلف شبکه عصبی با در نظر گرفتن کلیه پارامترهای ورودی بیماری**

| معماری شبکه عصبی ۳ لایه | نوع داده | دقت تشخیص (درصد) |
|---|---|---|
| ۱-۱۳-۱۳ | آموزش | ۸/۶ |
| | تست | ۷۱/۷ |
| ۱-۱۴-۱۳ | آموزش | ۸۶ |
| | تست | ۷۰ |
| ۱-۱۵-۱۳ | آموزش | ۸۸ |
| | تست | ۶۹/۵ |
| ۱-۱۶-۱۳ | آموزش | ۸۰ |
| | تست | ۶۸ |
| ۱-۱۷-۱۳ | آموزش | ۸۵ |
| | تست | ۶۶/۷ |
| ۱-۱۸-۱۳ | آموزش | ۹۵ |
| | تست | ۶۶/۷ |
| ۱-۱۹-۱۳ | آموزش | ۸۲/۹ |
| | تست | ۷۰ |

## بخش دوم: طراحی و آموزش چندین شبکه عصبی به‌عنوان خبره

اگر تعداد شبکه‌های عصبی افزایش یابد، می‌توان با ترکیب آن‌ها به‌دقت بالاتری دست پیدا کرد، به هر یک از این شبکه‌های عصبی یک خبره پایه گفته می‌شود. این تنوع باعث

[ Downloaded from jhbmi.ir on 2026-02-22 ]

می‌شود که نوعی از واریانس در عملکرد سیستم به وجود آمده و در نهایت نتایج بهتری کسب شود. برای این‌که بتوان نتیجه مناسبی از ترکیب خبره‌ها گرفت باید هر یک از شبکه‌های عصبی طراحی‌شده شرایط ذیل را داشته باشد:

الف- هر یک از خبره‌ها به‌تنهایی در حد قابل‌قبولی (و نه کامل) دقیق باشند.

ب- هرکدام مکمل دیگری باشند، یعنی نباید مشابه هم بوده و نتیجه یکسانی تولید کنند.

با در نظر گرفتن شرایط فوق طراحی شبکه‌های عصبی مختلف انجام گردید. به‌منظور دستیابی به این هدف طبق تحلیل آماری به کمک نرم‌افزار SPSS 22.0 انجام‌شد و اهمیت ویژگی‌ها در بیماری کرونر قلبی موردبررسی قرار گرفت.

برخی از مطالعات نشان می‌دهد که پارامترهای پیوسته بیماری کرونر قلب در تشخیص بیماری بسیار تأثیرگذارتر از پارامترهای پیوسته هستند [۱۶] و بر اساس آن ۵ شبکه عصبی طراحی و پیاده‌سازی شد. داده‌های جدول۱ نشان می‌دهد که ویژگی‌های "مصرف دخانیات" و " ابتلا به دیابت" بیش‌ترین تأثیر را در ارزیابی کرونر قلبی دارد؛ لذا این ویژگی‌ها به‌عنوان مهم‌ترین پارامترهای ورودی شبکه عصبی در طراحی خبره‌های مختلف مورداستفاده قرار گرفتند و ۵ شبکه عصبی به‌عنوان خبره‌ها به صورتی که در شکل ۲-۱ تا ۲-۵ نشان داده شد، طراحی گردید. شبکه عصبی ششم در شکل ۲-۶ درواقع همان شبکه عصبی راهگاهی (gating network) است که کلیه فاکتورهای بالینی بیماری را به‌عنوان ورودی در نظر می‌گیرد و در بخش اول این مقاله طراحی و تست گردید. تمامی این شبکه‌ها سه لایه (دولایه پنهان) دارند.

پس از طراحی این ۶ شبکه عصبی به‌عنوان خبره‌ها باید بهترین معماری شبکه عصبی موردبررسی قرار می‌گرفت. تعداد لایه‌های شبکه عصبی و تعداد نرون‌ها در لایه‌های مخفی پارامترهای تنظیم شبکه عصبی هستند که می‌توانند در بهبود صحت شبکه عصبی تأثیرگذار باشند؛ لذا برای هر یک از این شبکه‌های عصبی به‌عنوان خبره معماری‌های مختلفی موردبررسی قرار گرفت تا بهترین معماری به دست آید. برخی از این معماری‌ها در جدول ۳ نشان داده شد. که برای خبره‌های ۱ و ۲ و ۴ بهترین معماری مربوط به زمانی است که ۲۰ نرون در لایه مخفی اول و ۲۱ نرون در لایه مخفی دوم است. چراکه در این حالت شبکه‌ها موفق شده‌اند به‌دقت ۷۵٪ روی داده‌های تست و ۸۸٪ روی داده‌های آموزش دست پیدا کنند؛ بنابراین شبکه‌ای با معماری ۱-۲۱-۲۰ انتخاب گردید. همچنین برای خبره‌های ۳ و ۵ معماری ۱-۲۳-۲۰ به همین دلیل انتخاب شدند.

**جدول ۳: معماری‌های مختلف شبکه عصبی (خبرهای مختلف) و میزان عملکرد آن‌ها در مراحل آموزش و تست**

| معماری | خبره ۱ | | خبره ۲ | | خبره ۳ | | خبره ۴ | | خبره ۵ | |
|---|---|---|---|---|---|---|---|---|---|---|
| ۱-۲۱-۲۰ | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست |
| | ۸۸/۶ | ۷۵/۳ | ۸۸/۲ | ۷۵/۹ | ۱۱/۴ | ۲۵ | ۸۸/۳ | ۷۵/۲ | ۱۱/۴ | ۲۵/۵ |
| ۱-۲۲-۲۰ | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست |
| | ۱۵/۷ | ۳۳ | ۳۴/۴ | ۴۰ | ۱۱/۴ | ۲۵ | ۸۷/۹ | ۷۵ | ۱۱/۴ | ۲۵ |
| ۱-۲۳-۲۰ | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست |
| | ۷۵ | ۶۵ | ۷۷/۹ | ۶۳ | ۸۸/۴ | ۷۵/۲ | ۸۸/۶ | ۷۵ | ۸۸/۲ | ۷۵/۶ |
| ۱-۲۴-۲۰ | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست |
| | ۵۰ | ۵۵ | ۳۱/۴ | ۶۱/۷ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۷۵ |
| ۱-۲۵-۲۰ | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست |
| | ۸۴ | ۷۰ | ۸۱/۴ | ۶۱/۷ | ۱۲/۱ | ۲۵ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۷۵ |
| ۱-۲۶-۲۰ | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست |
| | ۲۰ | ۲۶/۷ | ۳۰ | ۲۶/۷ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۷۵ | ۱۱/۴ | ۲۶ |

[ Downloaded from jhbmi.ir on 2026-02-22 ]

جدول ۳: معماری‌های مختلف شبکه عصبی (خبرهای مختلف) و میزان عملکرد آن‌ها در مراحل آموزش و تست(ادامه)

| | | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|
| تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | ۲۰-۲۷-۱ |
| ۷۵ | ۸۸/۶ | ۲۵ | ۱۱/۴ | ۷۵ | ۸۸/۶ | ۶۰ | ۷۹/۳ | ۶۱/۷ | ۷۹/۳ | |
| تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | ۲۰-۲۸-۱ |
| ۷۵ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۵۸/۳ | ۲۷/۱ | ۵۶/۷ | ۵۰/۷ | |
| تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | ۲۰-۲۹-۱ |
| ۷۵ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۶۳/۳ | ۷۷/۹ | ۷۳/۳ | ۷۲/۹ | |
| تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | تست | آموزش | ۲۰-۳۰-۱ |
| ۷۵ | ۸۸/۶ | ۷۵ | ۸۸/۶ | ۲۵ | ۱۱/۴ | ۶۰ | ۷۱/۴ | ۵۸/۳ | ۷۳/۶ | |

**بخش سوم: ترکیب شبکه‌های عصبی (ترکیب خبره‌ها)**

روش‌های مختلفی برای ترکیب خبره‌ها وجود دارد؛ اما به‌طورکلی شامل دو دسته خطی و غیرخطی است. متداول‌ترین روش‌های خطی استفاده از رأی اکثریت ( Majority Voting)، ترکیبات غیرخطی روشی به نام ( Gating Network) است که در آن خروجی هر یک از خبره‌ها به ورودی شبکه نهایی متصل می‌شود.

**ترکیب خبره‌ها در تشخیص کرونر قلب به روش خطی**

یکی از متداول‌ترین روش‌های ترکیب به‌صورت خطی روش رأی اکثریت است. انگیزه اصلی این کار در اینجا است که هنگام طراحی یک سیستم خبره انتخاب‌های فراوانی وجود دارد مانند نحوه نمایش، پارامترهای خبره، داده‌های آموزشی و غیره. اگر از نتیجه چند دسته‌بندی کننده به‌صورت زیر استفاده شود:

$$f_{com} = vote(f_1, f_2, f_3, f_4 f_5, f_6)$$

که $f_1$ تا $f_6$ همان شش خبره طراحی‌شده می‌باشند. برای این که بتوان نتیجه مناسبی از ترکیب خبره‌ها گرفت، باید هر یک به تنهایی در حد قابل‌قبولی دقیق باشند، البته نیازی به بسیار دقیق بودن آن‌ها نیست و کافی است هرکدام مکمل دیگری عمل کنند. به این معنا که همگی نباید مشابه هم بوده و نتیجه یکسانی تولید کنند. با توجه به این که در تحقیق حاضر دو کلاس از افراد بیمار و سالم است، لذا روش رأی اکثریت قابل استفاده است.

**ترکیب خبره‌ها در تشخیص کرونر قلب به روش غیرخطی و خطی**

در این روش وزن‌های مورداستفاده برای رأی‌گیری بر اساس ورودی‌ها تغییر می‌کنند و ثابت نیستند. خروجی خبره‌ها توسط یک شبکه نهایی به‌صورت غیرخطی باهم ترکیب می‌شوند. شبکه راهگاهی همزمان با یادگیری هر یک از خبره‌ها یاد می‌گیرد که چه وزنی به هر خبره اختصاص داده شود تا خطا کم شود. این کار باعث تجزیه فضای ورودی بین خبره‌ها می‌شود. شبکه Gating معمولاً از روش Softmax استفاده می‌کند تا مجموع وزن‌ها یک شود [۱۱].

[ Downloaded from jhbmi.ir on 2026-02-22 ]

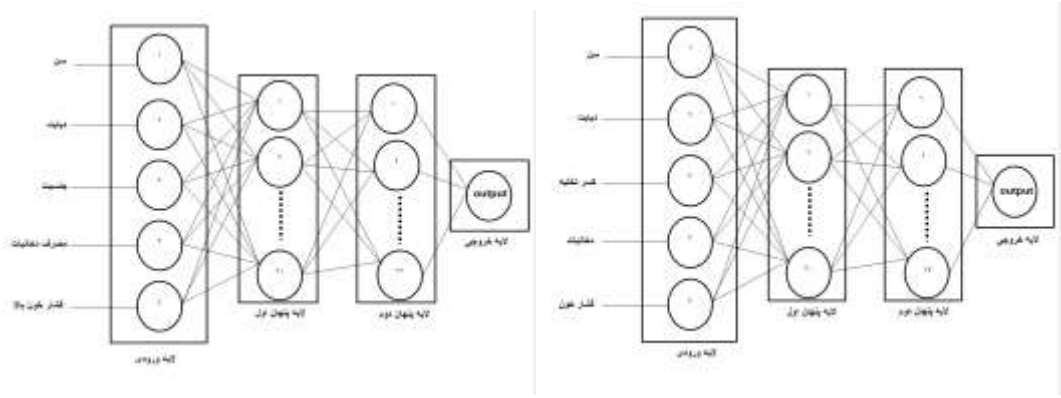

**شکل ۲- ۱ طراحی شبکه عصبی N1 با ورودی‌های**

سن- دیابت- جنسیت- مصرف دخانیات- فشارخون

**شکل ۲-۲ طراحی شبکه عصبی N2 با ورودی‌های**

سن- دیابت- کسر تخلیه- مصرف دخانیات- فشارخون

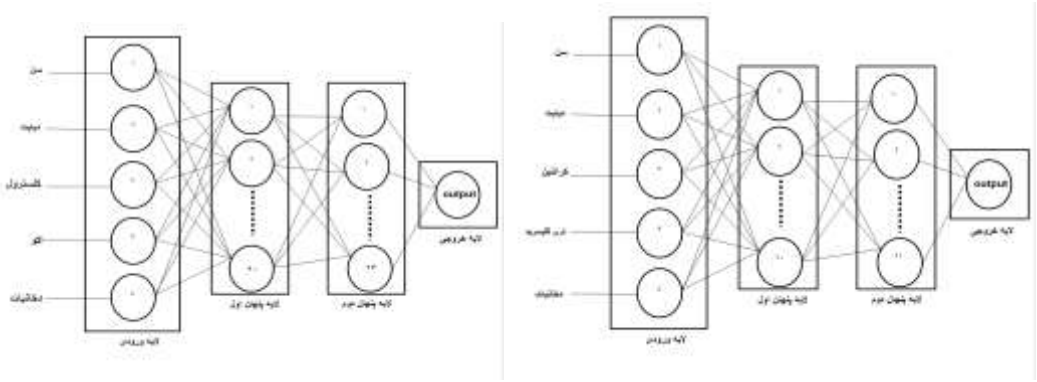

**شکل ۲- ۳ طراحی شبکه عصبی N3 با ورودی‌های**

سن- دیابت- کلسترول- اکو- مصرف دخانیات-

**شکل ۲- ۴ طراحی شبکه عصبی N4 با ورودی‌های**

سن- دیابت- کراتنین- مصرف دخانیات- تری گلیسرید

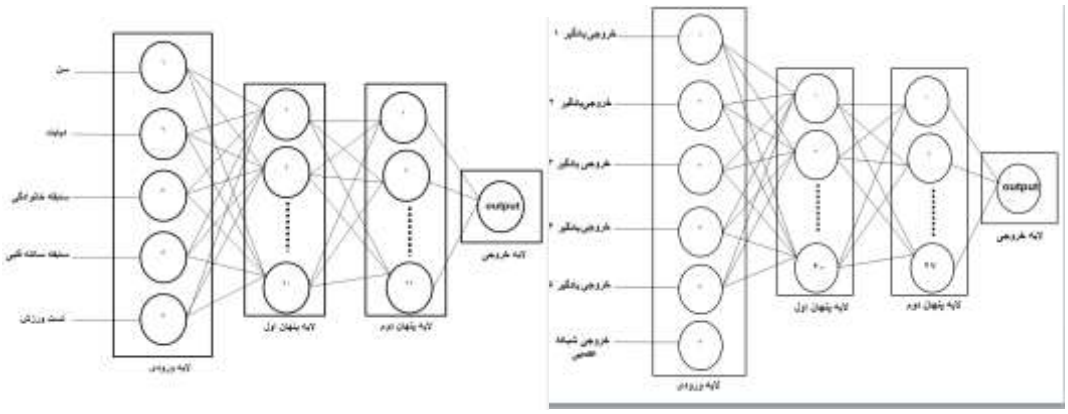

**شکل ۲- ۵ طراحی شبکه عصبی ۵N با ورودی‌های**

سن- دیابت- سابقه خانوادگی- سابقه سکته قلبی- تست ورزش

**شکل ۲- ۶ طراحی شبکه عصبی راهگاهی با ورودی‌های**

۶شبکه عصبی N1تا N6

**شکل ۲: مدل‌سازی شبکه‌های عصبی، با توجه به ریسک فاکتورهای بیماری عروق کرونر قلب**

[ Downloaded from jhbmi.ir on 2026-02-22 ]

## نتایج

در این مطالعه ۲۰۰ مراجعه‌کننده به مرکز تخصصی قلب و عروق جهت تشخیص بیماری کرونر قلبی مورد بررسی قرار گرفتند. از این تعداد ۴۷٪ مرد و ۵۳٪ را زن تشکیل می‌دادند. از میان ریسک فاکتورهای ثبت‌شده در پرونده بیماران ۵ فاکتور آن دارای پارامترهای پیوسته بودند. انتخاب فاکتورهای بالینی ورودی با تحلیل‌های آماری انجام شد.

جدول ۴ مدل‌های مختلف شبکه عصبی بر اساس ریسک فاکتورهای اعمال‌شده و بهترین معماری را نشان می‌دهد.

**جدول ۴: میانگین ۱۰ مرتبه مدل‌سازی بر روی ۶ شبکه عصبی به‌منظور پیش‌بینی بیماری عروق کرونر قلب**

| شماره مدل | ریسک فاکتورها | بهترین معماری شبکه | دقت ارزیابی | دقت تست |
|---|---|---|---|---|
| ۱ | سن –دیابت– جنسیت– مصرف دخانیات–فشارخون | ۵–۲۰–۲۱–۱ | ۸۸٪/۶ | ۷۵٪/۴ |
| ۲ | سن –دیابت– کسر تخلیه– مصرف دخانیات–فشارخون | ۵–۲۰–۲۱–۱ | ۸۸٪/۲ | ۷۵٪/۹ |
| ۳ | سن –دیابت– کلسترول– اکو– مصرف دخانیات | ۵–۲۰–۲۱–۱ | ۸۸٪/۴ | ۷۷٪/۹ |
| ۴ | سن –دیابت– کراتنین– مصرف دخانیات–تری گلیسرید | ۵–۲۰–۲۱–۱ | ۸۸٪/۳ | ۷۵٪/۶ |
| ۵ | سن –دیابت– سابقه خانوادگی –سابقه سکته قلبی – تست ورزش | ۵–۲۰–۲۳–۱ | ۸۴٪/۲ | ۷۴٪/۹ |
| ۶ | کلیه ۱۳ فاکتور | ۱۳–۱۴–۲۶–۱ | ۸۸٪/۲ | ۷۱٪/۷ |

جدول ۵ نتیجه ترکیب خطی به روش رأی اکثریت و شبکه راهگاهی روی داده‌های آموزش و تست را نشان می‌دهد.

**جدول ۵: نتیجه ترکیب نتایج شبکه‌های عصبی در تشخیص کرونر قلبی به دور روش خطی و غیر خطی**

| | آموزش | تست |
|---|---|---|
| روش خطی رأی اکثریت | ۸۶٪/۶ | ۷۵٪/۳ |
| روش غیر خطی راهگاهی | ۸۱٪/۷ | ۷۸٪/۳ |

[ Downloaded from jhbmi.ir on 2026-02-22 ]

جدول ۶ نتیجه تشخیص بیماری عروق کرونر قلب با یک شبکه عصبی با حضور کلیه ریسک فاکتورها و نیز زمانی که از ترکیب شبکه‌های عصبی به روش خطی رأی اکثریت و غیرخطی شبکه راهگاهی استفاده شده است را نشان می‌دهد.

نتایج حاکی از آن است که در استفاده از شبکه‌های عصبی به تنهایی و ترکیب شبکه‌های عصبی به صورت خطی و ترکیب غیرخطی شبکه‌های عصبی، به ترتیب دقت‌های ۷۱/۷٪ و ۷۵٪/۳ و ۷۸/۳٪ قابل حصول است.

**جدول ۶: نتایج تشخیص بیماری کرونر قلب با استفاده از ترکیب شبکه‌های عصبی در روش‌های مختلف روی نمونه‌های تست**

| ترکیب به شبکه عصبی راهگاهی | ترکیب به روش رأی اکثریت | شبکه عصبی بدون ترکیب |
|---|---|---|
| ۷۸/٪۳ | ۷۵٪/۳ | ٪۷۱/۷ |

## بحث و نتیجه‌گیری

نتیجه مطالعه حاکی از آن است که استفاده از چندین شبکه عصبی مصنوعی و ترکیب آن‌ها به روش غیرخطی نسبت به ترکیب خطی و نسبت به زمانی که فقط از یک شبکه عصبی استفاده می‌شود در پیش‌بینی دقیق‌تر بیماری عروق کرونر قلب بهتر است.

در مطالعات مختلف تحت عنوان داده‌کاوی پزشکی، راهکارهای متعددی جهت کشف روابط بین عوامل کرونر قلبی ارائه شده است. استفاده از شبکه‌های عصبی مصنوعی با الگوریتم پس انتشار خطا جهت تشخیص بیماری کرونر قلبی در مطالعات مختلف موردبررسی قرار گرفته است. در این پژوهش سعی شد برای بهبود تشخیص بیماری کرونر قلب از روش‌های مختلف با تأکید بر روش ترکیب خبره‌ها استفاده شود. در اولین مرتبه مدل‌سازی از یک شبکه عصبی پرسپترون چندلایه با الگوریتم پس انتشار خطا استفاده‌شده که با حضور کلیه ۱۳ ریسک فاکتور موجود انجام شد. از شبکه عصبی مصنوعی به‌عنوان یک طبقه‌بندی برای کلاس‌بندی داده‌ها به دو دسته بیمار و سالم استفاده گردید و معماری‌های مختلف شبکه عصبی برای حصول بهترین کلاس‌بندی موردبررسی قرار گرفت که در بهترین حالت نتیجه تشخیص روی داده‌های تست ۷۱/۷٪ به دست آمد.

در مرتبه دوم مدل‌سازی، با توجه به ترتیب اهمیت ریسک فاکتورها به طراحی شبکه‌های عصبی مختلف پرداخته و نتایج آن‌ها با یکدیگر ترکیب گردید. اثبات شده است که ترکیب خبره‌های مستقل‌تر باعث افزایش نرخ بازشناسی می‌شود [۱۷]. دو روش مناسب که در این مطالعه نیز مورداستفاده قرار گرفتند Majority voting و gating network می‌باشد [۱۸].

در مطالعه محمودی و همکاران برای پیش‌بینی بیماری عروق کرونر از تکنیک قدرتمند شبکه‌های عصبی استفاده گردید که مدل نهایی به‌دست‌آمده دارای دقت ۷۴/۱۹ درصد و توانست با درصد بالایی بیماران را تشخیص داده و تعداد ۲۷۱ نفر از ۸۱۵ فردی که فاقد بیماری عروق کرونر بودند را مشخص نماید [۱۹]. در تحقیقات دیگری که مدل‌های به‌دست‌آمده تنها مبتنی بر ریسک فاکتورهای بیماری عروق کرونر می‌باشند، به علت تفاوت در ریسک فاکتورهای مورداستفاده مدل‌هایی با دقت متفاوت گزارش شده است [۱۲،۲۰]. در بررسی انجام‌شده توسط Jyoti جهت پیش‌بینی ابتلا به بیماری قلبی مدل ارائه شده توسط درخت تصمیم دارای میزان دقت ۸۳ درصد می‌باشد [۱۲]. این در حالی است که درخت تصمیم ارائه شده در این مطالعه از دقت بالاتری برخوردار بوده است. در مطالعه محمد پور و همکاران به کاربرد شبکه عصبی در ارزیابی بیماری عروق کرونر قلب پرداخته و حساسیت مدل به‌دست‌آمده ۳۲٪ به دست آمد، که نشان از توان بالای این مدل در تشخیص سریع‌تر بیمارانی است که نیازمند اقدامات تشخیصی و درمانی هستند. حساسیت بالای مدل ارائه‌شده در این مطالعه را می‌توان به‌کارگیری متغیرهای مفیدی چون نتیجه تست ورزش و نتیجه اکو و همچنین تعیین تعداد نرون‌های کمتر در لایه میانی شبکه عصبی می‌باشد [۱۱]. در مطالعه‌ای که به مقایسه عملکرد شبکه‌های عصبی پرسپترون چندلایه و با تابع مبتنی بر شعاع در سیستم‌های تصمیم‌یار بالینی برای تفکیک در بیماری نارسایی قلبی و انسداد مزمن ریه پرداخته‌شده است، مدل شبکه عصبی با حساسیت ۳۳٪ به‌عنوان مدل برتر جهت ایجاد تمایز در تشخیص بیماران مبتلابه نارسایی قلبی و انسداد مزمن ریه معرفی شده است [۲۱]. استفاده از ترکیب خبرها در تشخیص سایر بیماری‌ها نیز نتایج خوبی به همراه داشته است [۲۲]. در برخی از تحقیقات بررسی‌شده، از آنالیز منحنی‌های راک برای ارزیابی مدل به‌دست آمده، استفاده شده است و در برخی دیگر ملاک ارزیابی، دقت مدل در مجموعه داده آزمایش بوده است [۲۳]؛ اگرچه در برخی از پژوهش‌ها به علت عملکرد بهتر شبکه‌های عصبی روی داده‌های آموزش، ملاک ارزیابی داده‌های آموزش قرارگرفته‌اند، لیکن در پژوهش حاضر ملاک دقت عملکرد روی مجموعه داده‌های آزمون (داده‌های تست) بود.

[ Downloaded from jhbmi.ir on 2026-02-22 ]

در مطالعه حاضر علت بهبود نتیجه را می‌توان این‌گونه توصیف کرد که؛ اگرچه هریک از شبکه‌های عصبی می‌توانند به‌تنهایی به پیش‌بینی بیماری عروق کرونر قلب بپردازند؛ اما وقتی تعداد ورودی‌های این شبکه‌ها که شامل ویژگی‌های بیماری کرونر است کاهش یابد باعث تمرکز بیشتر شبکه و درنتیجه افزایش دقت طبقه‌بندی می‌شود. به‌این‌ترتیب برای هر طبقه‌بندی پایه، توزیع نمونه‌های ورودی برای آموزش در جهتی تغییر داده می‌شود که طبقه‌بندی‌ها بر روی نمونه‌ها سخت‌تر متمرکز شوند و درنهایت هر یک از شبکه‌ها بهتر تعلیم داده شوند.

تکنیک‌های داده‌کاوی می‌تواند به‌عنوان دستیار پزشک در تشخیص بیماری‌های خاص جهت پیش‌گویی امکان ابتلای افراد به بیماری‌ها استفاده شوند. مدل ارائه‌شده در این مطالعه می‌تواند در برنامه‌های غربالگری جهت شناسایی افراد در معرض خطر استفاده شود. یکی از مهم‌ترین محدودیت‌های محققین این حوزه عدم وجود دیتای بومی است و ازآنجایی‌که بسیاری از تحقیقات پزشکی مبتنی بر کاوش داده است، اهمیت ثبت داده‌های صحیح بسیار مشهود است. محدودیت دیگر عدم وجود داده‌های کافی مربوط به افراد سالم است چراکه در بیشتر داده‌های ثبتی تعداد نمونه‌های افراد سالم نسبت به بیمار بسیار کمتر است. وجود این عدم تقارن می‌تواند منجر به عدم یادگیری کامل یادگیرها شده و دقت تشخیص را کاهش دهد. پیشنهاد می‌شود که این مدل با مجموعه داده‌های بیشتر تست شود و اطلاعات افراد سالم بیش‌تری نیز به مجموعه اضافه گردد و با نصب در مراکز درمانی به‌صورت آزمایشی به‌عنوان دستیار پزشک مورداستفاده قرار بگیرد تا سرانجام با تغییرات ضروری و رسیدن به سطح مطلوب دقت، در انتخاب مدلی جامع و مناسب جهت پیش‌بینی بیماری عروق کرونر قلبی مؤثر واقع شود.

## تشکر و قدردانی

نویسندگان برخود لازم می‌دانند که از شورای محترم پژوهشی دانشگاه علوم پزشکی شهرستان تربت‌حیدریه به‌واسطه حمایت از طرح پژوهشی به شماره A-10-1289-1 کمال تشکر را داشته باشند. همچنین بدین‌وسیله از همکاری دکتر حامد رضا جعفر زاده متخصص قلب و عروق کمال تشکر را دارد.

## تضاد منافع

بدین‌وسیله نویسندگان تصریح می‌نمایند که هیچ‌گونه تضاد منافعی در خصوص پژوهش حاضر وجود ندارد.

## References

1. Analysis of healthcare quality indicator using data mining and decision support system. Expert Systems with Applications 2003;24(2):167-72.

**1**. Scanlon PJ, Faxon DP, Audet AM, Carabello B, Dehmer GJ, Eagle KA, et al. ACC/AHA guidelines for coronary angiography: executive summary and recommendations. A report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines (Committee on Coronary Angiography) developed in collaboration with the Society for Cardiac Angiography and Interventions. Circulation 1999;99(17):2345-57.

**2.** Amani F, Kazemnejad A, Habibi R, Hajizadeh E. Pattern of mortality trend in Iran during 1970-2009. J Gorgan Univ Med Sci 2011;12(4):85-90. Persian

**3.** Mir Mohammad Sadeghi SM, Hadipour M, Molavi Vardanjani. incidence of postoperative stroke after coronary artery bypass surgery and its risk factors. J Babol Univ Med Sci 2011; 13(3): 74 - 9. Persian

**4.** Samadi S, Nazifi Naeini M, Abbaspour S. Estimating the duration of treatment and hospitalization costs using neural network approach. Health Information Management 2012; 8(7):948- 57. Persian

**5.** Catalano PJ, Ryan LM. Bivariate latent variable models for clustered discrete and continuous outcomes. Journal of the American Statistical Association 1992;87(419):651–8.

**6.** Chae YM, Kim HS, Tark KC, Park HJ, Ho SH.

**7.** Zhang G, Eddy Patuwo BY, Hu M. Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting 1998;14(1):35-62.

**8.** Neshati Tanha A, Soleimani P. Prediction of acute heart attack using logistic regression (case study: a hospital in Iran). Journal of Industrial Engineering 2016;50(1):109-19. Persian

**9.** Suchithra PU. Clinical decision support system for diagnosing heart disease. International Journal of Innovative Research in Computer and Communication Engineering 2014;2(3):121-9.

**10.** 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.

**11.** Mohammadpour RA, Esmaeili MH, Ghaemian A, Esmaeili J. Application of Artificial neural network for assessing coronary artery disease. J Mazandaran Univ Med Sci 2012; 21(86):9-17. Persian

**12.** Kurt I, Ture M, Kurum AT. Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease. Expert Systems with

[ Downloaded from jhbmi.ir on 2026-02-22 ]

Applications 2008;34(1):366-74.
**13.** Khosravanian A, Ayat SS. Presenting an intelligent system for diagnosis of coronary heart disease by using Probabilistic Neural Network. Health Inf Manage 2015; 12(1):3-13. Persian
**14.** Sargent DJ. Comparison of artificial neural networks with other statistical approaches: results from medical data sets. Cancer 2001;91(8 Suppl):1636-42.
**15.** 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.
**16.** Zabbah I, Hassaanzadeh M, Kohjani Z. The effect of continuous parameters on the diagnosis of coronary artery disease using artificial neural networks. Journal of Torbat Heydariyeh University of Medical Sciences 2017; 4(4):29-39. Persian
**17.** Lasota T, Londzin B, Trawiński B, Telec Z, editors. Investigation of Mixture of Experts Applied to Residential Premises Valuation. Berlin, Heidelberg: Springer; 2013.
**18.** Sineglazov V, Chumachenko E, Gorbatyuk V. Using a mixture of experts' approach to solve the forecasting task. Aviation 2014;18(3):129-33.
**19.** Mahmoudi I, Askari Moghadam R, Moazzam MH, Sadeghian S. Prediction model for coronary artery disease using neural networks and feature selection based on classification and regression tree. J Shahrekord Univ Med Sci 2013; 15(5):47-56. Persian
**20.** Mobley BA, Schechter E, Moore WE, McKee PA, Eichner JE. Predictions of coronary artery stenosis by artificial neural network. Artif Intell Med 2000;18(3):187-203.
**21.** 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.
**22.** Zabbah I, Yasrebi Naeini S E, Ramazanpoor Z, Sahragard K. The diagnosis of thyroid diseases using combinati on of neural networks through hierarchical method. Journal of Health and Biomedical Informatics 2017; 4(1) :21-31. Persian

[ Downloaded from jhbmi.ir on 2026-02-22 ]

Original Article

*Journal of Health and Biomedical Informatics*
*Medical Informatics Research Center*
*2018; 5(2): 274-285*

# Diagnosis of Coronary Heart Disease using Mixture of Experts Method

**Hasanzadeh Majid[1], Zabbah Iman[2]*, Layeghi Kamran[3]**

• **Received:** 13 Aug, 2017 • **Accepted:** 26 Nov, 2017

**Introduction:** Coronary Artery Disease (CAD) is one of the most common heart diseases and the main cause of mortality in men and women. This study aimed to predict the disease status using Neural Network compound (mixture of experts).

**Methods:** The present study was a diagnostic study conducted on 200 patients referred to a heart specialty center in Torbat-e-Heydarieh. Patients' files contained their demographic information including13 risk factors. A model for predicting CAD based on multilayer perceptron neural network and mixture of experts was produced.

**Results:** First, we used a neural network of multilayer perceptron with Propagation algorithm by different architectures. The best architecture could predict closed coronary artery with the accuracy of 71.7%. Then, by increasing the number of neural networks and training process, results were combined. Mixture of experts by liner method (majority voting) and nonlinear method (gating network) was applied and the accuracy rates of 75.8 percent and 78.3 percent were respectively obtained.

**Conclusion**: Angiography is an invasive diagnostic procedure with risk factors such as stroke and heart attack. Therefore, non-invasive methods should be used for the diagnosis of CAD. In this study, with increasing the number of learners and their nonlinear mixture, the accuracy of diagnosis was increased.

**Keywords:** Diagnosing Coronary Heart Disease, Artificial Neural Network, Mixture of expert.

• **Citation:** Hasanzadeh M, Zabbah I, Layeghi K. Diagnosis of Coronary Heart Disease using Mixture of Experts Method. Journal of Health and Biomedical Informatics 2018; 5(2): 274-285.

1. Ph.D in Higher Education Management, Assistant Professor, Nursing Dept., Torbat Heydarieh University of Medical Sciences, Torbat Heydarieh, Iran
2. PhD Student in Computer, School of Electrical and Computer, Tehran North Branch, Islamic Azad University, Tehran, Iran.
3. Ph.D. in Computer, Assistant Professor, Department of Computer, North Tehran Branch, Islamic Azad University, Tehran, Iran.

***Correspondence**: Computer Dept., Islamic Azad University of Torbat Heydarieh, Khorasan Razavi, Iran
• **Tel:** 09159311050 • **Email:** imanzabbah@iautorbat.ac.ir

[ Downloaded from jhbmi.ir on 2026-02-22 ]