

افزایش دقت و سرعت پیش بینی نتایج آنژیوگرافی با استفاده از ترکیب سیستم استنتاج عصبی-فازی و الگوریتم بهینه سازی ازدحام ذرات بر اساس داده های شهريور ماه سال ۱۳۹۲ بیمارستان کوثر شیراز

سیدسعید آیت^{۱*}

(۱) گروه علمی مهندسی کامپیوتر و فناوری اطلاعات، دانشکده مهندسی کامپیوتر، دانشگاه پیام نور، تهران، ایران

تاریخ پذیرش: ۱۳۹۶/۶/۵

تاریخ دریافت: ۱۳۹۵/۱۲/۱۴

چکیده

مقدمه: امروزه استفاده از یافته های هوش مصنوعی و داده کاوی برای کمک به پیش بینی زود هنگام بیماری عروق کرونری قلب مورد توجه پزشکان قرار گرفته است. هدف از این مقاله افزایش دقت و سرعت پیش بینی نتایج آنژیوگرافی با سیستم استنتاج فازی و الگوریتم بهینه سازی ازدحام ذرات است.

مواد و روش ها: در این مقاله سیستم جدیدی با ترکیب استنتاج فازی و الگوریتم بهینه سازی ازدحام ذرات پیشنهاد و با نرم افزار MATLAB نسخه ۲۰۱۵ (۸/۵/۰/۱۹۷۶۱۳) شبیه سازی گردیده است. جامعه آماری این پژوهش شامل ۱۵۲ رکورد از اطلاعات پایگاه داده واقعی افرادی بود که در شهريورماه سال ۱۳۹۲ شمسی در بیمارستان کوثر شیراز تحت آنژیوگرافی عروق کرونری قرار گرفته بودند. داده های جمع آوری شده با نرم افزار اکسل نسخه ۲۰۱۰ آنالیز شده و پارامترهای مورد نیاز سیستم پیشنهادی محاسبه گردید.

یافته های پژوهش: داده ها به ۲۰ دسته، شامل داده های آموزش و آزمون متفاوت، به صورت تصادفی از کل مجموعه داده تقسیم شدند. در هر دسته، ۸۵ درصد برای مرحله آموزش و ۱۵ درصد باقیمانده برای مرحله آزمون در نظر گرفته شد و شبیه سازی برای هر دسته داده به طور جداگانه صورت گرفت. نتایج حاصل بر اساس شاخص های حساسیت، اختصاصیت، دقت و صحت در دسته بندی افراد، به طور میانگین به ترتیب معادل اعداد ۰/۸۴۲۲، ۰/۹۱۹۲، ۰/۸۵۵۴ و ۰/۸۸۸۸ بوده است و در بهترین حالت معادل عدد ۱ به دست آمده است.

بحث و نتیجه گیری: نتایج نشان می دهد سیستم پیشنهادی عملکرد مناسبی در پیش بینی نتایج آنژیوگرافی دارد و می تواند به منظور دسته بندی افراد به دو کلاس نرمال و بیمار استفاده شود. به کارگیری سیستم عصبی-فازی و ترکیب آن با الگوریتم بهینه سازی ازدحام ذرات موجب بهبود سرعت و دقت در این مطالعه شده است.

واژه های کلیدی: الگوریتم بهینه سازی ازدحام ذرات، بیماری عروق کرونری، سیستم استنتاج عصبی-فازی

* نویسنده مسئول: گروه علمی مهندسی کامپیوتر و فناوری اطلاعات، دانشکده مهندسی کامپیوتر، دانشگاه پیام نور، تهران، ایران

Email: dr.ayat@pnu.ac.ir

Copyright © 2018 Journal of Ilam University of Medical Science. This is an open-access article distributed under the terms of the Creative Commons Attribution international 4.0 International License (<https://creativecommons.org/licenses/by-nc/4.0/>) which permits copy and redistribute the material, in any medium or format, provided the original work is properly cited.

مقدمه

در سال‌های اخیر روش‌های هوش مصنوعی از جمله روش‌های یادگیری ماشین، روش‌های داده کاوی و شبکه‌های عصبی مصنوعی به طور گسترده در مسائل دسته بندی، پیش بینی و تشخیص به کار برده شده اند. از جمله کاربردهایی که در مسائل پزشکی مورد توجه قرار گرفته پیش بینی با ابزارهای داده کاوی و تشخیص زودهنگام بیماری‌ها است. بیماری عروق کرونری قلب از جمله بیماری‌هایی است که حیات افراد را به مخاطره می‌اندازد. به گزارش انجمن قلب آمریکا در سال ۲۰۱۶-۲۰۱۵ از هر سه مرگ و میر در ایالت متحده یکی از آن‌ها به علت بیماری قلبی است (۱).

با توجه به اهمیت موضوع و تشخیص زودهنگام این بیماری با کمک ابزارهای داده کاوی می‌توان با پیش‌آگهی به بیماران و اقدامات لازم توسط پزشکان از مرگ و میر افراد جلوگیری کرد پس طراحی سیستم‌های هوشمند که در تشخیص زودهنگام و افزایش دقت به پزشک یاری رسانند ضروری است.

از نظر پزشکی راه‌های مختلفی برای تشخیص CAD وجود دارد از جمله تست ورزش، اکوکاردیوگرام، اسکن هسته ای قلب و آنژیوگرافی. آنژیوگرافی متداول ترین راه تشخیص بیماری قلبی است؛ اما این روش تشخیصی برای بیماران عوارض و خطراتی را به دنبال دارد. به علاوه بسیاری از افراد با این روش تشخیصی پس از آنژیوگرافی از لحاظ گرفتگی عروق کرونری سالم تشخیص داده می‌شوند که علاوه بر آسیب‌های احتمالی هزینه‌های مالی را نیز برای این افراد به دنبال دارد. به نقل از ادیبی و همکاران (۲) هزینه درمان این بیماران به علت پیشرفت تکنولوژی در تشخیص و درمان روبه افزایش است، از سوی دیگر با افزوده شدن جمعیت افراد سالمند در جامعه ایران روزبه‌روز بر تعداد موارد CAD افزوده می‌شود که این امر می‌تواند موجب تحمیل هزینه به سیستم بهداشتی کشور باشد.

مطالعات نشان می‌دهد روش‌های متفاوتی برای تشخیص زودهنگام بیماری قلبی به کار رفته است. به عنوان مثال در (۳) یک روش جدید برای تشخیص بیماری عروق کرونری (CAD: Coronary Artery

(Disease) با استفاده از سیگنال‌های قلبی و تجزیه FAWT ارائه شده است و در بهترین حالت صحت دسته بندی را ۱۰۰ درصد گزارش کرده است. در مطالعه ای دیگر (۴) به تشخیص خودکار CAD با استفاده از سیگنال‌های نوار قلب (ECG) پرداختند و بیشترین دقت را ۹۹/۶۰ درصد گزارش کردند. هم چنین در (۵) با استفاده از شبکه عصبی مصنوعی پرسپترون (MLP: Multi-Layer Perceptron) و شبکه عصبی مصنوعی (neural network) و بهینه سازی با استفاده از الگوریتم ژنتیک به تشخیص این بیماری از روی سیگنال‌های ECG پرداختند و صحت و میانگین دقت طبقه بندی را به ترتیب ۹۶/۹۳ درصد و ۹۶/۹۲ درصد گزارش کردند. در مطالعه ای دیگر (۶) یک سیستم خبره فازی با استفاده از الگوریتم بهینه سازی ازدحام ذرات و به کار گیری درخت تصمیم برای انتخاب ویژگی استفاده شده است و صحت طبقه بندی را ۹۳/۲۷ درصد به دست آوردند. در (۷) یک بررسی کلی بر روش‌های پیاده سازی شده بر بیماری‌های قلب از سال ۲۰۰۵ تا ۲۰۱۳ انجام شده است و نتیجه گرفته است شبکه‌های عصبی در این مورد قوی تر از سایر روش‌های عمل کرده اند و اکثراً به دقت بالای ۹۰ درصد رسیده اند. در (۸) از الگوریتم‌های مختلف داده کاوی نظیر J48، نایو بیز، CART، REPTREE و شبکه بیزی برای پیش بینی بیماری قلبی استفاده کرده است و صحت پیش بینی را ۹۹ درصد گزارش کرده است. در (۹) با استفاده از روش استخراج غیرخطی HOS در سیگنال‌های ECG استفاده کرده است و صحت، حساسیت و اختصاصیت را به ترتیب ۹۸/۱۷ درصد، ۹۴/۵۷ درصد و ۹۹/۳۴ درصد به دست آورده است.

هدف از این مطالعه طراحی یک سیستم استنتاج عصبی-فازی (ANFIS: Adaptive neuro fuzzy inference system) با به کار گیری الگوریتم بهینه سازی ازدحام ذرات در آموزش ANFIS، است که بر اساس فاکتورهای ورودی نتایج آنژیوگرافی (سالم-بیمار) را پیش بینی کند.

مواد و روش ها

مجموعه داده مورد استفاده در این مقاله مطابق با منبع (۲۱)، ۱۵۲ نمونه از افرادی هستند که در شهریور ماه سال ۱۳۹۲ تحت آنژیوگرافی عروق کرنری قرار گرفتند. در (۲۱) آمده است این تعداد بر اساس فرمول مربوطه و تقسیم تعداد نرون های لایه مخفی در شبکه عصبی پرسپترون بر میزان خطای ۰/۱ محاسبه شده است. این تعداد به صورت تصادفی انتخاب شد و پرسش نامه حاوی اطلاعات دموگرافیک بیماری (جدول شماره ۱)، تست های تشخیصی و نتیجه آنژیوگرافی موجود در پرونده برای آن ها تکمیل گردید

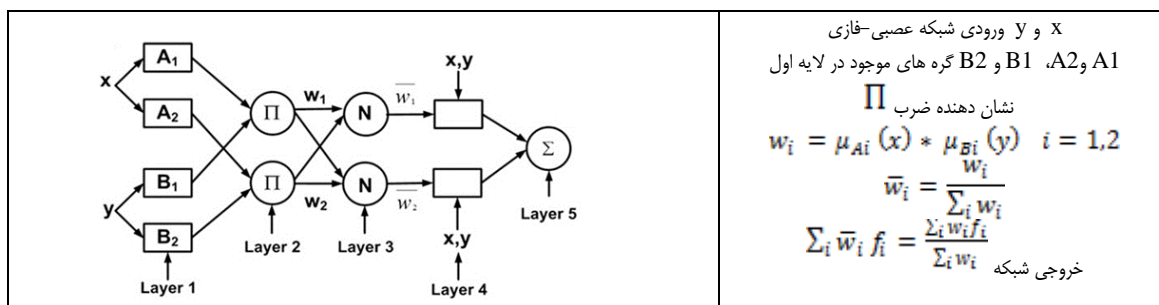
و داده های جمع آوری شده در نرم افزار Excell vol.2010 وارد شد. از ۱۳ فاکتور تشخیصی برای این بیماری استفاده گردید که به دو دسته پیوسته و گسسته تقسیم شد. متغیرهای پیوسته شامل سن، کراتینین، کلسترول تام، تری گلیسیرید، کسر تخلیه و متغیرهای گسسته شامل جنس، سیگاری بودن، سابقه فشارخون بالا، سابقه دیابت، سابقه خانوادگی بیماری قلبی، سابقه سکته قلبی، نتیجه تست ورزش غیر نرمال و نتیجه اکو بود. فاکتورهای تشخیصی پس از نرمال سازی مطابق جدول شماره ۱ به عنوان ورودی سیستم طراحی شده در نظر گرفته شد.

جدول شماره ۱. متغیرها و مقادیر نرمال شده جهت ورودی شبکه عصبی-فازی

متغیرها	توضیحات
جنس	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 سکته قلبی	دارد=۱ ندارد=۰
نتیجه تست ورزش	نرمال=۰ غیر نرمال=۱
نتیجه اکو	نرمال=۰ غیر نرمال=۱
سن	۱۰۰/سال
کراتینین	۱۰/عدد
کلسترول	۱۰۰۰/عدد
تری گلیسیرید	۱۰۰۰/عدد
کسر تخلیه	۱۰۰/عدد

می دهد (۱۰). معماری ANFIS، معماری یک شبکه تطبیقی است که از الگوریتم یادگیری با نظارت استفاده می کند که دارای یک تابع، مشابه سیستم فازی تاکاگی-سوگنو است. معماری ANFIS دارای ۵ لایه است.

سیستم استنتاج عصبی-فازی: ANFIS یک کلاس از شبکه های تطبیقی است که از نظر عملکرد معادل سیستم استنتاج فازی است. در واقع ترکیبی از شبکه عصبی با سیستم استنتاج فازی است که قالبی قدرتمند برای حل مسائل دسته بندی ارائه



شکل شماره ۱. معماری شبکه عصبی-فازی (۱۱)

الگوریتم بهینه سازی ازدحام ذرات: الگوریتم بهینه سازی ازدحام ذرات (PSO: Particle Swarm Optimization) یک الگوریتم جستجوی مبتنی بر جمعیت است که رفتار اجتماعی دسته پرندگان را شبیه سازی می‌کند. در PSO موجودات ذره نامیده می‌شوند که در فضای چندبعدی جستجو حرکت می‌کنند. تغییرات یک ذره در ازدحام تحت تاثیر تجربیات خود و یا دانش همسایگانش است. یکی از اولین کاربردهای این الگوریتم برای آموزش شبکه عصبی پیشرو (FFNN) بوده است. از آن پس تحقیقات بی شماری برای بررسی توانایی های بهینه سازی ازدحام ذرات به عنوان یک الگوریتم آموزشی برای معماری های مختلف شبکه های عصبی انجام پذیرفت. الگوریتم بهینه سازی ازدحام ذرات به طور گسترده در پیش بینی و تشخیص بیماری ها و دیگر مسائل بهینه سازی به کار رفته است (۲۰-۱۲).

برای شبیه سازی روش پیشنهادی در این مطالعه از نرم افزار MATLAB استفاده شد و از ۸۵ درصد داده ها برای مرحله آموزش و ۱۵ درصد باقیمانده برای مرحله آزمون استفاده شد. نحوه انتخاب این میزان داده برای مراحل آموزش و آزمون به صورت تصادفی از کل داده های موجود در هر بار شبیه سازی بود. از ۱۳ متغیر بالینی نشان داده شده در جدول شماره ۱ جهت ورودی سیستم استفاده شد که برای این منظور از ماتریسی شامل ۱۳ سطر (۱۳ متغیر بالینی) و به تعداد داده های تصادفی انتخاب شده ستون برای مرحله آموزش و ماتریس دیگری با دو سطر (وضعیت نرمال=۰ و بیمار=۱) و به تعداد داده های تصادفی انتخاب شده ستون به عنوان ماتریس هدف در مرحله آموزش استفاده شد. از نمونه های باقیمانده با ساختاری مشابه مرحله آموزش برای مرحله آزمون استفاده شد. نحوه شبیه سازی به این صورت بود که ابتدا یک ساختار ANFIS همان طور که در جدول شماره ۲ نشان داده شده، ایجاد شد. از آن جا که فرآیند آموزش این شبکه فرآیند پیچیده ای است به منظور بهینه سازی فرآیند آموزش از الگوریتم بهینه سازی ازدحام ذرات استفاده شد. برای شبیه سازی های این مقاله پارامترهای PSO شامل تعداد جمعیت (Swarm size) و ماکزیمم تعداد

اولین و چهارمین لایه شامل گره های تطبیقی است. در حالی که دیگر لایه ها شامل گره های ثابت هستند. هر لایه به صورت زیر توصیف می شود (۱۱):
لایه اول: هر گره در این لایه با یک پارامتر تابع مطابقت دارد. خروجی هر گره یک درجه از مقدار تابع عضویت است که به وسیله ورودی توابع عضویت داده می شود.

لایه دو: گره ها در این لایه ثابت یا غیر تطبیقی هستند که با دایره و برچسب II مشخص شده است. گره خروجی نتیجه ضرب سیگنال های ورودی به آن گره است و به گره بعدی تحویل داده می شود. هر گره در این لایه نشان دهنده قدرت شلیک برای هر قانون است.

$$O_{2i} = w_i = \mu_{Ai}(x) * \mu_{Bi}(y) \quad i = 1, 2 \quad (1)$$

لایه سه: گره ها در این لایه نیز ثابت یا غیر تطبیقی هستند که با دایره و برچسب N نشان داده شده است. هر گره در این لایه به صورت نسبت قدرت شلیک قانون i-ام به مجموع قدرت شلیک تمام قوانین محاسبه می شود. این نتیجه به عنوان قدرت شلیک نرمال شناخته شده است.

$$O_{3i} = \bar{w}_i = \frac{w_i}{\sum_i w_i} \quad (2)$$

لایه چهار: هر گره در این لایه، یک گره انطباقی است با یک خروجی که به صورت زیر تعریف می شود:

$$O_{4i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (3)$$

که \bar{w}_i قدرت شلیک نرمال شده از لایه قبلی (لایه سوم) است و $(p_i x + q_i y + r_i)$ یک پارامتر در گره است. پارامترها در این لایه به پارامترهای نتیجه اشاره دارند.

لایه پنج: گره تنها در این لایه که با دایره و برچسب Σ مشخص شده است، یک گره ثابت یا غیر تطبیقی است که مجموع تمام سیگنال های دریافتی از لایه قبل است و با فرمول ۴ نمایش داده شده است.

$$O_{5i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (4)$$

تکرارها (Maximum Number of Iterations)، به ترتیب با اعداد ۲۵ و ۱۰۰۰ مقداردهی شد.

جدول شماره ۲. ساختار سیستم استنتاج عصبی-فازی ایجادشده

نوع سیستم فازی	الگوریتم	نوع توابع عضویت ورودی	نوع توابع عضویت خروجی
سوگنو	FCM	gaussmf	Linear

یافته های پژوهش

برای ایجاد یک دید کلی متغیرها به دو دسته کمی و کیفی تقسیم شدند جدول شماره ۳ شاخص های آمار توصیفی مربوط به متغیرهای کمی و کیفی برای سه حالت کل افراد، افراد طبیعی و بیمار را نشان می دهد و مقادیر به دست آمده با نرم افزار Excell را نشان می دهد.

پس از بارگذاری داده های آموزشی و ایجاد ساختار اولیه سیستم استنتاج فازی از نوع سوگنو، جهت آموزش سیستم طراحی شده از PSO استفاده شده است و فرآیند آموزش ۱۰۰۰ دور تکرار شده است. پس از اتمام فرآیند آموزش جهت ارزیابی سیستم پیشنهادی داده های آزمون که در مرحله آموزش استفاده نشده بود به کار گرفته شد.

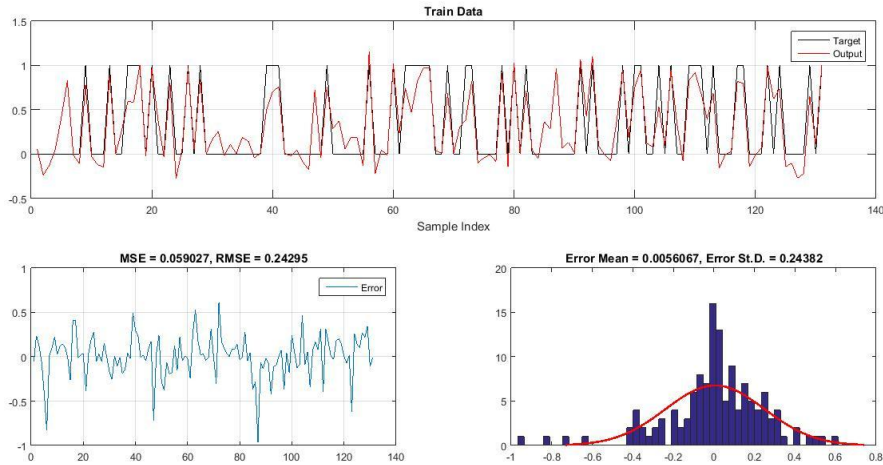
جدول شماره ۳. شاخص های آمار توصیفی مربوط به متغیرهای کمی و کیفی برای سه حالت کل افراد، افراد طبیعی و بیمار

نام متغیر	میانگین (انحراف معیار) کل افراد	میانگین (انحراف معیار) نرمال	میانگین (انحراف معیار) بیماری CAD	سطح معنی داری
سن	(۱۰/۵۲۲) ۵۶/۹۶	(۱۰/۳) ۵۱/۷۹	(۱۰/۳) ۵۹/۴۱	۰/۰۱۶
کراتینین	(۰/۲۴) ۱/۱۶۴	(۰/۱۹) ۱/۰۴۲	(۰/۲۵) ۱/۱۲۲	۰/۰۱۶
کلسترول	(۴۸/۶۷) ۱۶۹/۱۱	(۳۳/۲) ۱۵۰/۱۲	(۵۳/۸) ۱۷۸/۴۱	۰/۶۴۴
تری گلیسیرید	(۱۰/۴۰۵) ۱۳۷	(۱۰/۷) ۹۷/۳۶	(۱۰/۲) ۱۵۵/۴۲	۰/۶۲۸
کسر تخلیه	(۹/۹۸) ۴۹/۱۶	(۷/۹) ۵۴/۲۸	(۹/۵) ۴۶/۶۶	۰/۰۰۱
	فراوانی کل N=۱۵۲	فراوانی (درصد) نرمال N= ۴۹	فراوانی (درصد) بیماری CAD N=۱۰۳	
مرد	۸۹	(۴۰/۸۱) ۲۰	(۶۶/۹۹) ۶۹	
زن	۶۳	(۵۹/۱۸) ۲۹	(۳۳) ۳۴	
مصرف سیگار	۲۱	(۱۲/۲۴) ۶	(۱۴/۵۶) ۱۵	
فشارخون بالا	۶۵	(۳۳/۶۵) ۱۶	(۴۷/۵۷) ۴۹	
دیابت	۵۱	(۱۸/۳۶) ۹	(۴۰/۷۷) ۴۲	
سابقه خانوادگی بیماری قلبی	۳۴	(۲۶/۵۳) ۱۳	(۲۰/۳۸) ۲۱	
سابقه سکنه قلبی	۱۹	(۰) ۰	(۱۸/۴۴) ۱۹	
نتیجه تست ورزش غیر نرمال	۱۰۹	(۴۳/۸۵) ۲۱	(۸۵/۴۳) ۸۸	
نتیجه اکو غیر نرمال	۱۰۶	(۳۶/۷۳) ۱۸	(۸۵/۴۳) ۸۸	


معنی داری داشتند. در مجموع ۴۹ نفر دارای نتیجه آنژیوگرافی نرمال و ۱۰۳ نفر غیر نرمال (۴۰ نفر تنگی یک رگ بود، ۲۲ نفر تنگی دو رگ و ۴۱ نفر تنگی سه رگ بود).

در ابتدای شبیه سازی، داده ها به ۲۰ دسته تصادفی شامل داده های آموزش و آزمون متفاوت تقسیم شدند. سپس روش پیشنهادی برای هر یک از دسته ها به صورت جداگانه اجرا شد. شکل های شماره ۱ و ۲ نتایج حاصل از شبیه سازی سیستم پیشنهادی در بهترین حالت در مرحله آموزش و آزمون را نشان می دهد.

نتایج آماری نشان می دهد مقادیر متغیرهای کمی سن، کراتینین و کسر تخلیه در دو گروه سالم و بیمار تفاوت معنی داری داشته است و مقادیر متغیرهای کلسترول و تری گلیسیرید در دو گروه اختلاف نداشته اند. علت اختلاف نداشتن کلسترول در دو گروه به خاطر عدم وجود HDL و LDL است. اطلاعات مربوط به متغیرهای کیفی نشان می دهد، به جز سیگار و سابقه بیماری بقیه متغیرها مانند جنس، فشارخون بالا، دیابت، سابقه سکنه قلبی، نتیجه تست ورزش و نتیجه اکو کاردیوگرافی با نتیجه آنژیوگرافی ارتباط



شکل شماره ۱. نتایج حاصل از شبیه سازی در مرحله آموزش شبکه عصبی-فازی با الگوریتم PSO در داده های دسته دوم



شکل شماره ۲. نتایج حاصل از شبیه سازی در مرحله آزمون شبکه عصبی-فازی با الگوریتم PSO در داده های دسته دوم

آزمون در بهترین حالت را نشان می دهد. عناصر قطری در ماتریس کانفیوژن نشان دهنده تعداد مواردی است که به درستی طبقه بندی شده است و عناصر غیر قطری تعداد مواردی را نشان می دهد که به درستی طبقه بندی نشده است. هم چنین سطرها نتایج واقعی و ستون ها نتایج پیش بینی شده توسط سیستم پیشنهادی را نشان می دهد.

شکل های شماره ۱ و ۲ بالا نمودار خروجی سیستم در مقابل تابع هدف در مراحل آموزش و آزمون را نشان می دهد. مشاهده می شود که سیستم طراحی شده در این دسته داده عکس العمل مناسبی داشته است. نمودارهای پایین نمودارهای خطا و هیستوگرام خطاها بر اساس پارامترهای MSE، RMSE، میانگین خطا و انحراف معیار خطا را نشان می دهد. جدول شماره ۴ ماتریس کانفیوژن به دست آمده در مرحله

جدول شماره ۴. ماتریس کانفیوژن سیستم پیشنهادی در مرحله آزمون داده های دسته دوم

	نتیجه پیش بینی غیر نرمال	نتیجه پیش بینی نرمال
نتیجه آنژیوگرافی غیر نرمال	۱۵	۰
نتیجه آنژیوگرافی نرمال	۰	۶

$$= \frac{TN}{FP+TN} \text{ اختصاصیت} \quad (2)$$

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

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

خروجی سیستم پیشنهادی برای هریک از دسته ها بر اساس شاخص های حساسیت، اختصاصیت، دقت و صحت در جدول شماره ۵ نشان داده شده است.

تحلیل های ماتریس کانفیوژن در دسته بندی و تشخیص بیماران منجر به چهار حالت مثبت حقیقی (TP)، منفی حقیقی (TN)، مثبت کاذب (FP) و منفی کاذب (FN) می شود. از نتایج ماتریس کانفیوژن چهار شاخص حساسیت، اختصاصیت و دقت و صحت به صورت زیر به دست می آید که برای تحلیل عملکرد سیستم های دسته بندی استفاده می شود.


$$= \frac{TP}{TP+FN} \text{ حساسیت} \quad (1)$$

جدول شماره ۵. شاخص های عملکردی سیستم پیشنهادی در هر دسته داده


تعداد داده های مرحله آموزش	تعداد داده های مرحله آزمون	حساسیت	اختصاصیت	دقت	صحت
۱۲۶	۲۶	۱	۰/۹۴۴۴	۰/۸۸۸۹	۰/۹۶۱۵
۱۳۱	۲۱	۱	۱	۱	۱
۱۲۸	۲۴	۰/۷۵۰۰	۰/۹۱۶۷	۰/۹۰۰۰	۰/۸۳۳۳
۱۳۳	۱۹	۰/۵۵۵۶	۱	۱	۰/۷۸۹۵
۱۳۳	۱۹	۱	۱	۱	۱
۱۲۴	۲۸	۰/۷۰۰۰	۰/۹۴۴۴	۰/۸۷۵۰	۰/۸۵۷۱
۱۲۸	۲۴	۱	۰/۸۶۶۷	۰/۸۱۸۲	۰/۹۱۶۷
۱۳۱	۲۱	۱	۰/۸۵۷۱	۰/۷۷۷۸	۰/۹۰۴۸
۱۳۰	۲۲	۰/۷۱۴۳	۱	۱	۰/۹۰۹۱
۱۳۰	۲۲	۰/۸۷۵۰	۰/۸۵۷۱	۰/۷۷۷۸	۰/۸۶۳۶
۱۲۸	۲۴	۱	۰/۷۵۰۰	۰/۶۶۶۷	۰/۸۳۳۳
۱۲۸	۲۴	۰/۸۰۰۰	۰/۹۲۸۶	۰/۸۸۸۹	۰/۸۷۵۰
۱۲۹	۲۳	۰/۶۰۰۰	۰/۹۴۴۴	۰/۷۵۰۰	۰/۸۶۹۶
۱۲۹	۲۳	۰/۶۰۰۰	۱	۱	۰/۸۲۶۱
۱۲۲	۳۰	۰/۶۶۶۷	۰/۹۰۴۸	۰/۷۵۰۰	۰/۸۳۳۳
۱۳۲	۲۰	۰/۸۷۵۰	۰/۹۱۶۷	۰/۸۷۵۰	۰/۹۰۰۰
۱۳۰	۲۲	۰/۸۳۳۳	۰/۸۱۲۵	۰/۶۲۵۰	۰/۸۱۸۲
۱۳۲	۲۰	۱	۰/۸۵۷۱	۰/۷۵۰۰	۰/۹۰۰۰
۱۲۸	۲۴	۱	۰/۹۳۷۵	۰/۸۸۸۹	۰/۹۵۸۳
۱۲۵	۲۷	۰/۸۷۵۰	۰/۹۴۷۴	۰/۸۷۵۰	۰/۹۲۵۹

حساسیت، اختصاصیت، دقت و صحت در دسته بندی افراد به دو دسته سالم و بیمار، به طور میانگین به ترتیب معادل اعداد ۰/۸۴۲۲، ۰/۹۱۹۲، ۰/۸۵۵۴ و ۰/۸۸۸۸ بوده است. شکل های شماره ۳، ۴ و ۵ شاخص های حاصل از ۲۰ مرتبه شبیه سازی بر دسته داده های مختلف را نشان می دهد.


همان طور که در جدول شماره ۵ مشاهده می شود سیستم پیشنهادی در داده های دسته دوم و دسته پنجم بهترین عملکرد را داشته است و بر روی مجموعه داده های به کار رفته در این مقاله شاخص های حساسیت، اختصاصیت، دقت و صحت در این دو دسته داده معادل عدد یک به دست آمده است. نتایج حاصل از ۲۰ مرتبه شبیه سازی بر اساس شاخص های




شکل شماره ۳. شاخص حساسیت در اجرای ۲۰ دسته داده در دسته بندی نتایج آنژیوگرافی



شکل شماره ۴. شاخص اختصاصیت در اجرای ۲۰ دسته داده در دسته بندی نتایج آنژیوگرافی



شکل شماره ۵. شاخص دقت در اجرای ۲۰ دسته داده در دسته بندی نتایج آنژیوگرافی



شکل شماره ۶. شاخص صحت در اجرای ۲۰ دسته داده در دسته بندی نتایج آنژیوگرافی

همان طور که در جدول شماره ۶ مشاهده می شود روش پیشنهادی در این مطالعه شاخص های عملکردی را بهبود داده است.

جدول شماره ۶. مقایسه روش های پیاده سازی شده در تشخیص CAD بر مجموعه داده بیمارستان کوثر

سال	دقت	اختصاصیت	صحت	حساسیت	روش	مجموعه داده	نویسندگان
۲۰۱۵	۰/۹۳۴۰	۰/۹۴	-	۱	شبکه عصبی احتمالی	بیمارستان کوثر	خسروانیان و همکاران (۲۱)
۲۰۱۵	۰/۸۰	۰/۸۸	-	۱	شبکه عصبی پرسپترون	بیمارستان کوثر	خسروانیان و همکاران (۲۲)
۲۰۱۴	-	۰/۸۸	-	۱	شبکه عصبی- فازی	بیمارستان کوثر	خسروانیان و همکاران (۲۳)
۲۰۱۷	۱	۱	۱	۱	شبکه عصبی- فازی با الگوریتم بهینه سازی ازدحام ذرات در بهترین حالت	بیمارستان کوثر	پژوهش حاضر

بحث و نتیجه گیری

این مطالعه با سایر تحقیقات انجام شده، ابتدا به مواردی اشاره می شود که بر روی این مجموعه داده و با روش های متفاوت با این مقاله انجام شده است. در (۲۱) از شبکه عصبی احتمالی به منظور پیش بینی بیماری عروق کرنری استفاده شد و پس از پیاده سازی در نرم افزار MATLAB شاخص های اختصاصیت، حساسیت و دقت به ترتیب ۰/۹۴، ۱ و ۰/۹۳۴۰ به دست آمد. در (۲۲) شبکه عصبی پرسپترون بر روی این مجموعه داده پیاده سازی شد و شاخص های اختصاصیت، حساسیت و دقت به ترتیب معادل ۰/۸۸، ۱ و ۰/۸۰ به دست آمد. در (۲۳) یک سیستم خبره فازی جهت تشخیص بیماری عروق کرنری به کار برده شد و شاخص های حساسیت و اختصاصیت را معادل اعداد ۰/۸۸ و ۱ گزارش کردند.

مطالعات بسیاری با روش های هوش مصنوعی در تشخیص CAD انجام شده است به عنوان نمونه عرب اسدی و همکاران از شبکه عصبی برای تشخیص این

در شبیه سازی سیستم پیشنهادی در این مطالعه، استفاده از الگوریتم فرا ابتکاری در آموزش ANFIS موجب افزایش سرعت در فرآیند آموزش شد. آموزش ساختار سیستم استنتاج عصبی-فازی بر روی این مجموعه داده با استفاده از جعبه ابزار موجود در نرم افزار MATLAB نشان داد فرآیند آموزش برای هر دور بسیار کند و وقت گیر است لذا از الگوریتم فرا ابتکاری برای بهینه سازی فرآیند آموزش استفاده شد و توانستیم سیستم طراحی شده را با سرعت مناسبی در ۱۰۰۰ دور آموزش دهیم. استفاده از الگوریتم فرا ابتکاری علاوه بر افزایش سرعت، شاخص های عملکردی سیستم طراحی شده را نیز بهبود داده است. از دلایل بالا بودن شاخص های عملکردی این مطالعه بر روی مجموعه داده ذکر شده می توان به نرمال کردن داده های ورودی و استفاده از الگوریتم PSO در آموزش شبکه عصبی-فازی اشاره کرد. در مقایسه نتایج

یکسان با این پژوهش داشت انجام شد. در آینده قصد داریم دیگر روش های تشخیصی بیماری CAD را بر این مجموعه داده شبیه سازی کنیم و نتایج را ارزیابی کنیم تا مقایسه جامع تری، داشته باشیم.

با توجه به گسترش کاربرد روش های فرا ابتکاری و الگوریتم های داده کاوی استفاده از شبکه عصبی به تنهایی مانند آن چه در منابع (۲۳-۲۱) آمده است مناسب نیست. ضمن این که در روش به کار گرفته شده در منبع (۲۳) فرآیند آموزش برای حجم داده کم این مجموعه داده که ۱۵۲ نمونه بود بسیار زمان بر است و با افزایش حجم مجموعه داده عملاً این روش به خاطر کندی بیش از حد، کاربرد ندارد. در این تحقیق سعی شد با این چالش در شبکه عصبی-فازی مقابله شود. لازم به ذکر است که روش پیشنهادی در این مقاله از نظر سرعت از روش مطرح شده در (۲۱) ضعیف تر بوده است چرا که در شبکه عصبی احتمالی فرآیند آموزش شامل یک مرحله است و نیاز به تکرار دوره های آموزشی نیست حال آن که استفاده از الگوریتم بهینه سازی ازدحام ذرات در فرآیند آموزش نیازمند انتخاب جمعیت جدید و تکرار در هر مرحله برای رسیدن به نقطه بهینه است که زمان بیشتری را می طلبد اما بالا رفتن شاخص های عملکردی در تشخیص بیماری قلبی که بسیار حساس است و با حیات انسان ارتباط تنگاتنگی دارد می تواند این مورد را پوشش دهد. در روش مطرح شده در (۲۲) مهم ترین مسئله ای که در شبکه عصبی پرسپترون وجود دارد انتخاب تعداد نرون در لایه مخفی است که می تواند بر نتیجه تاثیرگذار باشد حال آن که در منبع ذکر شده، شبکه برای داده های ثابت در مرحله آموزش و آزمون طراحی شده است و تعداد نرون لایه مخفی ثابت در نظر گرفته شده است در حالی که انتخاب دسته های مختلف داده برای مرحله آموزش و آزمون و انتخاب تعداد نرون مختلف در لایه مخفی می تواند موجب ارزیابی کامل تری از این روش ارائه دهد. روش پیشنهادی مطرح شده در مقاله حاضر در ده دسته داده مختلف شبیه سازی و ارزیابی شده است که نقطه قوت آن در مقایسه با (۲۲) است.

بیماری استفاده کردند و برای تنظیم وزن های شبکه عصبی الگوریتم ژنتیک را به کار بردند و شاخص های صحت، حساسیت و اختصاصیت را به ترتیب ۹۳/۸۵ درصد، ۹۷ درصد و ۹۲ درصد گزارش کردند (۲۴). در (۲۵) یک مدل طبقه بندی برای تشخیص تنگی عروق کرونری پیشنهاد کردند و نرخ صحت را برای هر یک از عروق کرونری ۸۶/۱۴ درصد، ۸۳/۱۷ درصد و ۸۳/۵۰ درصد به دست آوردند. Babaoglu و همکاران ماشین بردار پشتیبان را برای تشخیص CAD به کار بردند آن ها مقایسه ای بین مدل انتخاب ویژگی با استفاده از الگوریتم بهینه سازی ازدحام ذرات باینری (BPSO) و الگوریتم ژنتیک (GA) انجام دادند نتایج مقایسه آن ها نشان داد انتخاب ویژگی به وسیله BPSO موفق تر عمل کرده است (۲۶). در (۲۷) رویکرد جدیدی از ترکیب K-NN و الگوریتم ژنتیک پیشنهاد شده است و روش پیشنهادی بر ۷ مجموعه داده موجود در UCI ارزیابی شده است آن ها ادعا کردند به بالاترین دقت نسبت به دیگر روش های پیاده سازی شده دست یافتند. Muthukaruppan و همکاران یک سیستم خبره فازی با استفاده از PSO طراحی کردند و بر مجموعه داده Cleveland and Hungarian Heart Disease روش خود را پیاده سازی کردند و به دقت ۹۳/۲۷ درصد رسیدند (۲۸). در مطالعه ای دیگر یک سیستم خبره فازی تکاملی با استفاده از الگوریتم ژنتیک و درخت تصمیم طراحی شد و شاخص های حساسیت، اختصاصیت و صحت را به ترتیب ۹۴/۹۸ درصد، ۸۰/۴۹ درصد و ۸۸/۷۹ درصد گزارش کردند (۲۹). در مطالعه ای دیگر با ادغام روش های SVM، Random Forest و Naive Bayes سیستمی برای پیش بینی بیماری CAD طراحی کردند و برای بهینه سازی خروجی از PCA و Firefly استفاده کردند نتایج مطالعه آن ها کارآمدی روش پیشنهادی را تأیید کرد (۳۰).

در این مطالعه از روشی جدید برای تشخیص CAD استفاده شد و روش پیشنهادی بر مجموعه داده بیمارستان کوثر ارزیابی شد. به منظور مقایسه نتایج این مطالعه با موارد ذکر شده از آن جا که مجموعه داده ها متفاوت است مقایسه با (۲۱-۲۳) که مجموعه داده

دقت مشخص نماید. پیشنهاد می شود در پژوهش های آتی از دیگر الگوریتم های فرا ابتکاری جهت آموزش ANFIS استفاده شود و نتایج حاصل با نتایج به دست آمده از این مطالعه مقایسه شود.

سیاسگزاری

بدین وسیله از سرکار خانم آسیه خسروانیان دانشجوی دکتری هوش مصنوعی دانشگاه سمنان که ما را در انجام این تحقیق یاری نمودند هم چنین حمایت های معاونت پژوهشی دانشگاه پیام نور صمیمانه تشکر می گردد.

References

1. American heart association heart disease and stroke statistics. Rep Am Heart Asso016.
2. Adibi A, Sadeghi M, Ahmadi A. [Evaluation of Association between ultrasonographic carotid int with severity of angiographic coronary artery involvement in contrast to control group in angina pectoris patients]. J Isfahan Med Sch 2011; 87: 89-95. (Persian)
3. Kumar M, Pachori RB, Acharya UR. An efficient automated technique for CAD diagnosis using flexible analytic wavelet transform and entropy features extracted from HRV signals. Exp Sys 2016; 63: 165-72. doi: 10.1016/j.eswa.2016.06.038
4. Kumar M, Pachori RB, Acharya UR. Characterization of coronary artery disease using flexible analytic wavelet transform applied on ECG signals. Biomed Sig Proce Cont 2017; 31: 301-308. doi: 10.1016/j.bspc.2016.08.018
5. Kumari VS, Kumar R, Rajesh P. Optimization of multi-layer perceptron neural network using genetic algorithm for arrhythmia classification. Communications 2015; 3: 150-7.
6. Muthukaruppan S, Er MJ. A hybrid particle swarm optimization based fuzzy expert system for the diagnosis of coronary artery disease. Exp Sys 2012; 39: 1657-65. doi: 10.1016/j.eswa.2012.04.036
7. Gayathri P, Jaisankar N. Comprehensive study of heart disease diagnosis using data mining and soft comput techniques. IJET 2013; 5: 2947-58.

در این مطالعه یک سیستم استنتاج عصبی-فازی مبتنی بر PSO طراحی شد و بر روی داده های جمع آوری شده از بیماران که در بیمارستان کوثر شیراز تحت آنژیوگرافی عروق کرونری قرار گرفتند ارزیابی شد. نتایج شبیه سازی نشان داد سیستم طراحی شده با دقت مناسبی به پیش بینی نتایج آنژیوگرافی پرداخته است. این نتیجه بسیار حائز اهمیت است زیرا از عوارض و آسیب های ناشی از آنژیوگرافی برای بیماران که به آن نیاز ندارند جلوگیری می شود هم چنین می تواند بیماران را که واقعاً به این اقدامات تشخیصی نیاز دارند در سریع ترین زمان و بیشترین

8. Masethe HD, Masethe MA. Prediction of heart disease using classification algorithms. Proce World Cong Eng Comput Sci2014; 4:33-9.
9. Acharya UR, et al. Application of higher-order spectra for the characterization of Coronary artery disease using electrocardiogram signals. Biomed Signal Process Control 2017; 31: 31-43. doi: 10.1016/j.bspc.2016.07.003
10. Shaabani M.E, Baniroostam T, Hedayati A. Implementation of neuro fuzzy system for diagnosis of multiple sclerosis. IJCSN 2016; 5: 157-64.
11. Suparta W, Alhasa K.M. Modeling of Tropospheric Delays Using ANFIS. Springer; 2016.
12. Gunasundaria S, Janakiramana S, Meenambal S. Velocity bounded boolean particle swarm optimization for improved feature selection in liver and kidney disease diagnosis. Exp Sys2016; 56: 28-47. doi: 10.1016/j.eswa.2016.02.042
13. Jiji GW, DuraiRajb PJ. Content based image retrieval techniques for the analysis of dermatological lesions using particle swarm optimization technique. Appl Soft Comput 2015; 30: 650-62. doi: 10.1016/j.asoc.2015.01.058
14. Guraksin GE, Hakli H, Uguzb H. Support vector machines classification based on particle swarm optimization for bone age determination. Appl Soft Comput 2014; 24: 597-602.
15. Wen L, Wanga X, Wu Z, Zhou M, Jinb J. S. A novel statistical cerebrovascular

- segmentation algorithm with particle swarm optimization. *Neurocomputing* 2015; 148: 569-77. doi: 10.1016/j.neucom.2014.07.006
16. Chen KH, Wanga KJ, Wangb KM, Angeliaa MA. Applying particle swarm optimization-based decision tree classifier for cancer classification on gene expression data. *Appl Soft Comput* 2014; 24: 773-80. doi: 10.1016/j.asoc.2014.08.032
17. Lahmiria S. Glioma detection based on multi fractal features of segmented brain MRI by particle swarm optimization techniques. *Biomed Sig Proce Cont* 2017; 31: 148-155. doi: 10.1016/j.bspc.2016.07.008
18. Ramyachitra D, Sofia M, Manikandan P. Interval value based particle swarm optimization algorithm for cancer type specific gene selection and sample classification. *Gen Data* 2015; 5: 46-50. doi: 10.1016/j.gdata.2015.04.027
19. Zenga K, Dong M. A novel cuboid method with particle swarm optimization for real-life noise attenuation from heart sound signals. *Exp Sys* 2014; 41: 6839- 47. doi: 10.1016/j.eswa.2014.05.006
20. Koraa P, Krishna KS. Hybrid firefly and particle swarm optimization algorithm for the detection of bundle branch block. *Int J Card Acad* 2016; 2: 44-8. doi: 10.1016/j.ijcac.2015.12.001
21. Khosravanian A, Ayat S. [Presenting an intelligent system for diagnosis of coronary heart disease by using probabilistic neural network]. *Health Inform Manage* 2015; 12: 3-13. (Persian).
22. Khosravanian A, Ayat S. [Presenting a new method in the angiography results classification by using artificial neural network]. *J Zabol Uni Med Sci Health Serv* 2015; 6: 90-101. (Persian)
23. Khosravanian A, Ayat S. Identification and classification of coronary artery disease patients using neuro fuzzy inference systems. *JMCS* 2014; 13: 136-41.
24. Arabasadi Z, Alizadehsani R, Roshanzamir M, Moosaei H, Yarifard AA. Computer aided decision making for heart disease detection using hybrid neural network-genetic algorithm. *Comput Meth Prog Biomed* 2017; 2: 123-7. doi: 10.1016/j.cmpb.2017.01.004
25. Alizadehsani R, Zangooei MH, Hosseini MJ. Coronary artery disease detection using computational intelligence methods. *Knowl Based Sys* 2016; 109: 187-97. doi: 10.1016/j.knosys.2016.07.004
26. Babaoglu I, Findik O, Ulker E. A comparison of feature selection models utilizing binary particle swarm optimization and genetic algorithm in determining coronary artery disease using support vector machine. *Exp Sys* 2010; 37: 3177-83. doi: 10.1016/j.eswa.2009.09.064
27. Jabbar MA, Deekshatulua BL, Chandra P. classification of heart disease using k-nearest neighbor and genetic algorithm. *Proce Technol* 2013; 10: 85-94.
28. Muthukaruppan S, Er MJ. A hybrid particle swarm optimization based fuzzy expert system for the diagnosis of coronary artery disease. *Exp Sys* 2012; 39: 11657-5. doi: 10.1016/j.eswa.2012.04.036
29. Devi Y.N, Anto S. An Evolutionary-Fuzzy Expert System for the Diagnosis of Coronary Artery Disease. *IJAR CET* 2014; 3: 1474-84.
30. Deepthi S, Ravikumar A. Computation methods for the diagnosis and prognosis of heart disease. *Int J Eng Res Appl* 2014; 95: 5-9.

Increasing the Speed and Precision of Prediction of the Results of Angiography by Using Combination of Adaptive Neuro-Fuzzy Inference System and Particle Swarm Optimization Algorithm based on Data from Kowsar Hospital of Shiraz

Ayat S¹*

(Received: March 4, 2017

Accepted: August 27, 2017)

Abstract

Introduction: With regards to the importance of early prognosis of coronary artery diseases, in recent years the use of the latest artificial intelligence and data mining findings is considered to assist physicians. The purpose of this study was to increase the precision and prediction speed for the results of angiography by using a combination of fuzzy inference systems and particle swarm optimization algorithm.

Materials & Methods: A new system consisting of a combination of fuzzy inferences and particle swarm optimization algorithm was proposed and simulated by MATLAB software R2015a (8.5.0.197613). The samples consisted of 152 patients who were randomly selected from those undergone coronary artery angiographies in Kowsar Hospital of Shiraz, Iran, in August 2013. The data were then analyzed by Excel 2010 and the essential parameters of the proposed system were extracted.

Findings: The data were then randomly divided into 20 groups for training and testing. These groups were selected

randomly in a manner that 85% of the data were used for training and 15% for testing, and each group was simulated individually. The results of the simulation after 20 rounds of simulation with different training and testing data in system performance indicators displayed that the average of sensitivity, specificity, precision, and accuracy was 0.8422, 0.9192, 0.8554, and 0.8888, respectively, and it was equal to 1 in the most optimal situations.

Discussion & Conclusions: High performance indicators prove that the proposed system has a satisfactory performance in predicting the results of angiography and classifying them into two classes of normal and patient. In fact, in this study, prediction speed and precision were improved by using the proposed system, which was based on neuro-fuzzy inference system in combination with particle swarm optimization meta-heuristic algorithm.

Keywords: Particle swarm optimization, Coronary artery disease, Adaptive neuro-fuzzy inference system

1. Dept of Computer Engineering and Information Technology, Faculty of Computer Engineering, Payame Noor University, Tehran, Iran

** Corresponding author Email: dr.ayat@pnu.ac.ir*