

Application of Artificial Neural Network for Assessing Coronary Artery Disease

Reza Ali Mohammadpour Tahamtan¹,
Mohammad Hadi Esmaili²,
Ali Ghaemian³,
Javad Esmaili⁴

¹ Health Sciences Research Center, Department of Bio Statistics, Faculty of Health, Mazandaran University of Medical Sciences, Sari, Iran

² MSc Student of Biostatistics, Student Research Committee, Faculty of Health, Mazandaran University of Medical Sciences, Sari, Iran

³ Department of Cardiology, Faculty of Medicine, Mazandaran University of Medical Sciences, Sari, Iran

⁴ Department of Computer, Babol Tabari University, Babol, Iran

(Received July 29, 2011 ; Accepted November 15, 2011)

Abstract

Background and purpose: Since the human health is an essential issue in medical sciences, accurate predicting the individual's disease status is of great importance. Therefore, predicting with models minimum error and maximum certainty should be used. This study used artificial neural network model for predicting coronary artery disease (CAD) because it is more precise compared to other models.

Materials and methods: Multilayer perceptron (MLP) with post propagation error algorithm (EBP) for assessing the coronary artery disease was implemented on 150 patients admitted to the Mazandaran Heart Center, Sari. Then, based on the 80% of the available data, an artificial neural network with NN (14, 12, 1), sigmoid transfer function and 1500 epochs were designed and trained. The data were fed into Excel program and then softwares for artificial neural network designing such as Python-Neural Network were employed.

Results: Mean square of the error in training step was decreased to the level of 0.0238 and sensitivity and specificity rates obtained were 0.96 and 1. In the end, the model correctly categorized some healthy individuals who did not require angiography and the treatment related to coronary artery diseases.

Conclusion: Due to the high specificity index, this model prevents side effects of angiography in patients who do not require such interventions. Moreover, due to high sensitivity, it can diagnose the patients who really need such diagnostic measures.

Key words: Coronary artery disease, artificial neural network, multilayer perceptron

J Mazand Univ Med Sci 2012; 22(86): 9-17 (Persian).

کاربرد شبکه عصبی مصنوعی جهت ارزیابی بیماری عروق کرونری قلب

رضاعلی محمدپور تهمتن^۱محمدهادی اسماعیلی^۲علی قائمیان^۳جواد اسمعیلی^۴

چکیده

سابقه و هدف: از آنجایی که پیش‌بینی صحیح وضعیت بیماری افراد از اهمیت زیادی برخوردار است، لذا برای این پیش‌بینی بایستی از آن دسته مدل‌هایی استفاده کرد که دارای حداقل خطا و حداکثر اطمینان باشد. لذا در این مطالعه از روش شبکه عصبی مصنوعی که روش قوی‌تری نسبت به روش‌های موجود است جهت ارزیابی بسته‌بودن یا نبودن عروق کرونری قلب استفاده شد.

مواد و روش‌ها: در این تحقیق از شبکه عصبی مصنوعی پرسپترون چند لایه با الگوریتم پس‌انتشار خطا جهت ارزیابی وضعیت بیماری عروق کرونری قلب در بین ۱۵۰ نفر از بیماران مرکز فوق تخصصی قلب مازندران استفاده شد. سپس شبکه عصبی مصنوعی با ساختار (۱-۱۲-۱۴) NN، تابع انتقال سیگموئید و ۱۵۰۰ سیکل آموزشی بر اساس ۸۰ درصد داده‌های موجود طراحی و آموزش داده شد. برای طراحی شبکه عصبی مصنوعی از نرم افزار Pythia-Neural Network استفاده شد.

یافته‌ها: میانگین مربعات خطای مشاهده شده در مرحله تست به مقدار ۰/۰۲۳۸ کاهش یافت و حساسیت و ویژگی به ترتیب ۰/۹۶ و ۱ به دست آمد. در نهایت مدل به دست آمده، افراد سالمی که نیاز به آنژیوگرافی و درمان‌های مربوط به عروق کرونری قلب نداشتند را به درستی طبقه‌بندی کرد.

استنتاج: این روش به علت ویژگی بالا می‌تواند از عوارض و آسیب‌های احتمالی آنژیوگرافی در بیمارانی که نیاز به آن ندارند را جلوگیری نماید. از طرف دیگر می‌تواند به علت حساسیت بالا در بیمارانی که به‌طور واقعی به این اقدامات تشخیصی و درمانی نیاز دارند را جدا نماید.

واژه‌های کلیدی: بیماری عروق کرونری قلب، شبکه عصبی مصنوعی، پرسپترون چند لایه

مقدمه

برای پیشگویی و تحلیل طبقه‌بندی، مدل‌های آماری زیادی ارائه شده است (۱). شبکه عصبی مصنوعی غیرپارامتری برای طبقه‌بندی است که در حیطه پزشکی

(ANN: Artificial Neural Network) یک روش برای پیشگویی و تحلیل طبقه‌بندی، مدل‌های آماری زیادی ارائه شده است (۱). شبکه عصبی مصنوعی

این مقاله حاصل طرح تحقیقاتی شماره ۱۳۸-۸۹ است که توسط معاونت تحقیقات و فناوری دانشگاه علوم پزشکی مازندران تامین شده است.

E-mail: HadiEsmaili@yahoo.com

مؤلف مسئول: محمد هادی اسماعیلی - ساری: کیلومتر ۱۸ جاده خزر آباد، مجتمع دانشگاهی پیام‌اعظم، دانشکده بهداشت

۱. مرکز تحقیقات علوم بهداشتی، گروه آمار زیستی و اپیدمیولوژی، دانشکده بهداشت، دانشگاه علوم پزشکی مازندران

۲. دانشجوی کارشناس ارشد آمار، کمیته تحقیقات دانشجویی، دانشکده بهداشت، دانشگاه علوم پزشکی مازندران

۳. گروه قلب، دانشکده پزشکی، دانشگاه علوم پزشکی مازندران

۴. گروه کامپیوتر، دانشگاه طبری بابل

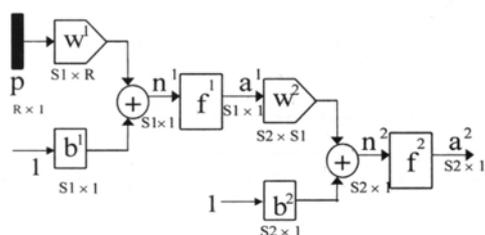
تاریخ دریافت: ۸۹/۱۱/۱۰ تاریخ ارجاع جهت اصلاحات: ۹۰/۳/۱۱ تاریخ تصویب: ۹۰/۸/۱۵

استفاده می‌شود مثل مدل‌سازی رگرسیونی و پیش‌بینی، سری‌های زمانی، تحلیل خوشه‌ای و تحلیل ممیزی، بررسی مسائل تصمیم آماری، کنترل فرایند و برآورد توزیع شرطی می‌تواند مورد استفاده قرار گیرد (۲،۱).

از قرن نوزدهم به‌طور همزمان اما جداگانه، از سوئی نروفیز یولوژیست‌ها سعی کردند سامانه یادگیری و تجزیه و تحلیل مغز را کشف کنند و از سوی دیگر ریاضیدانان تلاش کردند تا مدل ریاضی سازند که قابلیت فراگیری و تجزیه و تحلیل عمومی مسائل را دارا باشد. اولین کوشش‌ها در شبیه‌سازی با استفاده از یک مدل منطقی توسط مک کلوک و والتر پیتز انجام شد که امروزه بلوک اصلی سازنده اکثر شبکه‌های عصبی مصنوعی است. این مدل فرضیه‌هایی در مورد عملکرد نرون‌ها ارائه می‌کند. در سال ۱۹۵۸ شبکه پرسپترون توسط روزنبلات معرفی گردید. وریاس در سال ۱۹۷۴ شیوه آموزش پس انتشار خطا را ایجاد کرد که یک شبکه پرسپترون چندلایه البته با قوانین نیرومندتر آموزشی بود (۳).

طراحی شبکه عصبی دارای دو جنبه اصلی معماری و الگوریتم یادگیری است.

معماری: شبکه عصبی مورد نظر دارای ساختار پرسپترون چندلایه (MLP) می‌باشد که در مقایسه با سایر روش‌ها بهتر عمل می‌کند (۷). ساختار MLP یک ترکیب استاندارد از ورودی‌ها، واحدهای عصبی خطی و غیر خطی و خروجی‌ها می‌باشد. تصویر شماره ۱ ساختار شبکه عصبی MLP دو لایه (با یک لایه مخفی) با یک ورودی به نام I و یک خروجی به نام S را نشان می‌دهد.



تصویر شماره ۱: ساختار شبکه عصبی MLP با یک لایه مخفی

براساس متغیرهای ورودی نسبت به طبقه‌بندی افراد به بیمار یا سالم اقدام می‌کند. طبقه‌بندی و پیشگویی وضعیت بیمار بر اساس عوامل خطر یکی از کاربردهای شبکه‌های عصبی مصنوعی است (۲).

در شبکه عصبی مصنوعی از ساختار درهم و توده‌ای مغز انسان الهام گرفته شده است. میلیاردها سلول عصبی (نرون) از طریق ارتباطاتی که با یکدیگر دارند (سیناپس‌ها) یک شبکه عصبی بیولوژیکی در مغز انسان را تشکیل می‌دهند که به فعالیت‌های انسان از جمله خواندن، ادراک، گفتگو، تنفس، حرکت، تشخیص صدا، تشخیص چهره، همچنین حل مسائل و ذخیره‌سازی اطلاعات و ... اختصاص دارد. ANN در واقع بخشی از عملکرد مغز را شبیه‌سازی می‌کنند (۲،۱). شبکه عصبی مصنوعی در حل مسائلی که دارای راه حل الگوریتمی نیستند یا مسائلی که راه حل الگوریتمی بسیار پیچیده‌ای دارند و نیز مسائلی که برای انسان‌ها آسان، اما برای کامپیوترهای رایج دشوار هستند مانند تشخیص تصاویر و پیش‌بینی‌ها بر پایه دانش گذشته، به خوبی مورد استفاده قرار گرفته است (۳).

در بعضی مطالعات ارجحیت روش‌های نوین بر روش‌های کلاسیک همچون رگرسیون ثابت شده است. در مطالعه متا آنالیزی که Sargent با ۲۸ مطالعه انجام داده بود مشاهده نمود در ۳۶ درصد موارد ANN بهتر از روش‌های رگرسیونی، در ۱۴ درصد موارد روش‌های رگرسیونی بهتر از ANN و در ۵۰ درصد موارد این دو روش شبیه هم عمل کردند. در مطالعه متا آنالیزی که Dreiseitl با جمع‌بندی ۷۲ مطالعه انجام داده بود مشاهده نمود در ۱۸ درصد موارد ANN بهتر و در ۱ درصد موارد روش‌های رگرسیون لجستیک بهتر و در ۴۲ درصد موارد، این دو روش شبیه هم عمل کردند. ضمناً در ۳۹ درصد موارد مقالات آزمون‌های آماری کافی نداشتند و لذا این مقالات در نظر گرفته نشدند (۴-۶).

شبکه‌های عصبی مصنوعی به‌عنوان یک شیوه جانشین در مسائلی که به‌طور متداول از روش‌های آماری

خطا) از لایه آخر به لایه اول برگشت داده می‌شوند. در نهایت، با استفاده از اطلاعات به دست آمده از دو مسیر فوق، ماتریس‌های وزن و بردارهای Bias شبکه MLP تنظیم می‌گردد. جهت توقف تکرار الگوریتم EBPL می‌توان از شاخص میانگین مربعات خطا^۱ به صورت زیر استفاده کرد (۸،۲،۱):

$$MSE = \sum_{i=1}^Q (t_i - a_L(p_i))^2 / Q$$

پایه‌سازی شبکه عصبی دارای سه بخش فراهم کردن نمونه‌های آموزشی، فاز آموزش و تست شبکه عصبی است.

شبکه‌های عصبی مصنوعی در حل مسائل مربوط به تشخیص بالینی، آنالیز تصاویر پزشکی، پیش‌بینی بقا و در دامنه وسیعی از زمینه‌های پزشکی شامل انکولوژی، کاردیولوژی و هماتولوژی، مراقبت‌های ویژه، تشخیص از روی تصاویر پزشکی، ناباروری، جراحی و ... به کار رفته است. همچنین برخی از مطالعات از شبکه عصبی مصنوعی در مباحث مختلف مربوط به بیماری عروق کرونری قلب استفاده نمودند (۷، ۱۸-۹). به عنوان نمونه می‌توان به چند مقاله که در زیر آمده است اشاره نمود. در مقاله‌ای که با عنوان کاربرد شبکه عصبی مصنوعی در تعیین پیش‌بینی‌کننده‌های مهم مرگ و میر درون بیمارستانی پس از جراحی قلب باز و مقایسه آن با مدل رگرسیون لجستیک انجام شد، از یک شبکه عصبی مصنوعی دارای ۱۸ نرون ورودی، ۴ نرون مخفی و ۲ نرون خروجی با الگوریتم پس انتشار خطا برای ارزیابی بیمارانی که در بیمارستان دکتر شریعتی تهران تحت عمل جراحی قلب باز قرار گرفته بودند، استفاده گردید. حساسیت و ویژگی در گروه آموزش برابر ۱۰۰ درصد و در گروه آزمایش به ترتیب برابر ۹۹/۳۳ درصد و ۱۰۰ درصد به دست آمد. اما در مدل رگرسیون لجستیک ارائه شده حساسیت و ویژگی به ترتیب برابر ۹۹ درصد و

در شبکه فوق S_1 تعداد نرون‌های لایه مخفی و S_2 تعداد نرون‌های لایه خروجی می‌باشد. چنین شبکه عصبی را به صورت زیر نشان می‌دهند:

$$NN (I - S_1 - S_2)$$

خروجی تمامی واحدهای پردازش، از هر لایه، به عنوان ورودی به تمام واحدهای پردازش لایه بعد داده می‌شوند. واحدهای پردازش در لایه ورودی همگی خطی هستند ولی در لایه‌های مخفی خصوصاً لایه خروجی می‌توان از نرون‌های غیرخطی، با تابع تانژانت هیپربولیک و یا سیگموئید و یا هر تابع غیر خطی پیوسته و مشتق پذیر دیگر استفاده کرد.

الگوریتم یادگیری: شبکه‌های عصبی دارای این توانایی هستند که از گذشته، تجربه و محیط، آموزش بگیرند و در حال یادگیری رفتار خود را بهبود بخشند. شبکه عصبی MLP از روش یادگیری با ناظر^۱ جهت آموزش استفاده می‌کند. در یادگیری با ناظر، مجموعه‌ای از زوج داده‌ها به نام نمونه‌های آموزشی به صورت زیر داده می‌شود:

$$A = (X_i, t_i)$$

در آن X_i ورودی و t_i خروجی مطلوب شبکه برای ورودی X_i است. پس از اعمال ورودی X_i به شبکه عصبی، خروجی واقعی شبکه Y_i با t_i مقایسه شده و سپس خطای یادگیری محاسبه و از آن جهت تنظیم پارامترهای شبکه به گونه‌ای استفاده می‌شود که اگر دفعه بعد به شبکه همان ورودی X_i اعمال شود خروجی شبکه به t_i نزدیک‌تر گردد. الگوریتم یادگیری مورد استفاده در شبکه عصبی MLP، الگوریتم یادگیری پس انتشار خطا (EBPL^۲) می‌باشد. در الگوریتم EBPL دو مسیر محاسباتی وجود دارد. مسیر رفت که در آن توابع محرک، روی تک تک نرون‌ها عمل می‌کند. مسیر برگشت که در این مسیر بردارهای حساسیت (بردارهای

1. Supervised Learning
2. Error Back Propagation Learning

۹۰ درصد به دست آمد که با مقایسه آن با حساسیت و ویژگی شبکه عصبی مشخص می‌شود که شبکه عصبی در حل مسائل از مدل رگرسیون لجستیک توانا تر می‌باشد (۱۹).

در مقاله‌ای دیگر به مقایسه شبکه عصبی مصنوعی با دیگر روش‌های آماری از جمله رگرسیون لجستیک برای پیش‌بینی بیماری عروق کرونری پرداخته شد. این مقایسه بر اساس منحنی ROC انجام گرفته بود و نتایج مبنی بر بیشتر بودن سطح زیر منحنی ROC در شبکه عصبی مصنوعی بود که نشان دهنده برتری شبکه عصبی مصنوعی در حل این گونه مسائل می‌باشد (۷).

در مقاله‌ای که با هدف مقایسه مدل شبکه عصبی مصنوعی و رگرسیون کاکس در پیش‌بینی بقای بیماران مبتلا به سرطان معده انجام شده بود، شبکه عصبی مصنوعی نسبت به مدل رگرسیون کاکس پیش‌بینی بهتری برای بقای بیماران داشت و به کارگیری شبکه عصبی مصنوعی در زمینه‌های پیش‌بینی بقا پیشنهاد شد (۲۰).

در مقاله دیگری که با عنوان تعیین عوامل موثر بر بقای بیماران مبتلا به سرطان معده با استفاده از شبکه عصبی مصنوعی انجام شده بود، شبکه عصبی مصنوعی توانست ۸۲/۶ درصد پیش‌بینی صحیح داشته باشد در حالی که این میزان برای مدل رگرسیون وایبل ۷۵/۷ درصد بوده است. این مطالعه نیز نشان داد که شبکه عصبی مصنوعی توانا تر از مدل رگرسیون وایبل می‌باشد (۲۱).

مدل مناسب برای تحلیل داده‌های پزشکی، تابع شرایط گوناگونی می‌باشد که استفاده از آن‌ها با محدودیت‌ها و مشکلاتی نیز همراه است. از جمله این که فرض‌های اولیه مورد نیاز این مدل‌ها همانند نرمال بودن داده‌ها، تصادفی بودن مقادیر خطا، ثابت بودن واریانس خطا و ... همواره برقرار نیستند. لذا در این موارد نمی‌توان مدل مناسبی بر اساس داده‌های مورد نظر برازش داد.

اگرچه در بیشتر مطالعات، قدرت تشخیصی و دقت پیشگویی برای مدل شبکه‌ها عصبی مصنوعی نسبت به مدل‌های کلاسیک آماری بیشتر گزارش شده است. ولی

در برخی از آن‌ها تفاوتی بین مدل‌ها گزارش نشده است و میزان حساسیت و ویژگی مدل متفاوت اعلام شده است (۲۰-۱۷). هدف این مطالعه تعیین میزان دقت پیشگویی مدل شبکه‌های عصبی مصنوعی در طبقه‌بندی بیماران عروق کرونری از افراد سالم بر اساس نتایج آنژیوگرافی است تا در صورت داشتن قدرت تشخیصی بالا بتوان قبل از انجام آنژیوگرافی بیمار، با استفاده از مدل و از طریق متغیرهای فردی، آزمایشات و نتایج تست‌های غیر تهاجمی مانند تست ورزش و اکوکاردیوگرافی درباره وضعیت بیماری عروق کرونری پیشگویی کرد. این نتیجه از آن جهت دارای اهمیت می‌باشد که می‌تواند از عوارض و آسیب‌های احتمالی آنژیوگرافی و درمان‌های مربوط به عروق کرونری قلب در بیمارانی که نیاز به آن ندارند، جلوگیری کند و از طرفی دیگر در هزینه آزمون تشخیصی برای این افراد صرفه‌جویی خواهد شد.

مواد و روش‌ها

تحقیق حاضر یک مطالعه تشخیصی است که بر اساس متغیرهای ورودی، به پیشگویی وضعیت تنگی عروق کرونری می‌پردازد. جامعه آماری بیمارانی هستند که در مرکز قلب ساری تحت آنژیوگرافی عروق کرونری قرار گرفتند. تعداد نمونه بر اساس فرمول مربوطه و تقسیم تعداد نرون‌های لایه مخفی بر میزان خطای ۰/۱، حداقل ۱۲۰ محاسبه شد. لذا تعداد ۱۵۰ نفر از افراد فوق در سال ۱۳۸۹ به صورت تصادفی به عنوان نمونه انتخاب و پرسشنامه حاوی اطلاعات دموگرافیک، بیماری، تست‌های تشخیصی و نتیجه آنژیوگرافی موجود در پرونده برای آن‌ها تکمیل گردید.

ابتدا این داده‌ها را در نرم‌افزار Excel وارد شده سپس از نرم‌افزارهای مربوط به طراحی شبکه عصبی مصنوعی نظیر Pythia-Neural Network استفاده شد. نحوه استفاده از این داده‌ها بدین صورت است که ۸۰ درصد جهت آموزش شبکه عصبی مصنوعی طراحی

شده و مابقی آن جهت تست این شبکه بود. برای مقایسه اولیه بین دو گروهی که نتیجه آنژیوگرافی آن‌ها طبیعی گزارش شده و گروهی که حداقل یکی از رگ‌های آن‌ها بالای ۵۰ درصد بسته بوده است از آزمون‌های t-test و Chi-square و نرم‌افزار SPSS استفاده شد.

نتیجه اکوکاردیوگرافی با نتیجه آنژیوگرافی ارتباط معنی‌داری داشتند.

در مجموع ۴۴ نفر دارای نتیجه آنژیوگرافی طبیعی و ۱۰۶ نفر غیر طبیعی (۳۶ نفر یک رگ تنگ، ۲۶ نفر ۲ رگ تنگ و ۴۴ نفر ۳ رگ تنگ داشتند) بودند.

یافته‌ها

فراهم کردن نمونه‌های آموزشی

ابتدا برای این که یک دید کلی از متغیر مربوطه پیدا شود آزمون آماری برای متغیرهای کمی و کیفی انجام شد. همان‌طور که در جدول شماره ۱ مشاهده می‌شود، میانگین و انحراف معیار متغیرهای کمی مانند سن، کراتینین و کسر تخلیه در دو گروه سالم و بیمار اختلاف معنی‌دار داشتند ولی شاخص توده بدنی، کلسترول و تری‌گلیسیرید بین دو گروه اختلاف معنی‌داری نداشتند. اطلاعات مربوط به متغیرهای کیفی نشان می‌دهد که بجز سیگار و سابقه بیماری بقیه متغیرها مانند جنس، فشارخون بالا، دیابت، سابقه MI، نتیجه تست ورزش و

فاز آموزش شبکه عصبی

در این فاز از ۱۲۰ نمونه (۸۰ درصد)، جهت آموزش شبکه عصبی مصنوعی استفاده شد. بعد از پیاده‌سازی شبکه عصبی پرسپترون چندلایه (MLP) با الگوریتم پس انتشار خطا (EBPL) در نرم‌افزار Pythia-Neural Network و بعد از عوض کردن تعداد لایه‌ها و نرون‌ها شبکه MLP و مشاهده خطای آن، بهترین ساختار به دست آمد که ساختاری NN(14-12-1) با ۱۵۰۰ سیکل آموزشی بود. این بدان معنی می‌باشد که شبکه MLP دارای ۱۴ متغیر برای لایه ورودی، ۱ متغیر برای لایه خروجی و ۱۲ نرون برای لایه میانی (مخفی) است و در مرحله آموزش ۱۵۰۰ بار فرایند یادگیری

جدول شماره ۱: شاخص‌های آمار توصیفی مربوط به متغیرهای کمی و کیفی برای سه حالت کل افراد، افراد طبیعی و بیمار

متغیر کمی	میانگین (انحراف معیار) کل افراد	میانگین (انحراف معیار) نرمال	میانگین (انحراف معیار) بیماری CAD	سطح معنی‌داری
سن	۵۸/۷۹ (۱۰/۵۲۲)	۲۲/۶ (۱۰/۳)	۶۰/۱ (۱۰/۳)	۰/۰۱۶
شاخص توده بدنی (BMI)	۲۶/۳۶ (۴/۱)	۲۶/۹ (۳/۹)	۲۶/۱ (۴/۱)	۰/۲۵۴
کراتینین	۰/۹۱ (۰/۲۴)	۰/۸۴ (۰/۱۹)	۰/۹۴ (۰/۲۵)	۰/۰۱۶
کلسترول تام	۱۹۳/۲۷ (۴۸/۶۷)	۱۹۰/۴ (۳۳/۲)	۱۹۴/۵ (۵۳/۸)	۰/۶۴۴
تری‌گلیسیرید	۲۰۲/۲۱ (۱۰۴/۰۵)	۲۰۸/۶ (۱۰/۷)	۱۹۹/۵ (۱۰/۲)	۰/۶۲۸
کسر تخلیه (Ejection fraction)	۴۴/۵۳ (۹/۹۸)	۵۱/۱۳ (۷/۹)	۴۱/۷۹ (۹/۵)	۰/۰۰۱
متغیر کیفی	فراوانی کل (N= ۱۵۰)	فراوانی (درصد) نرمال (N= ۴۴)	فراوانی بیماری CAD (N= ۱۰۶)	سطح معنی‌داری
جنس مرد (درصد)	۶۷	۱۰ (۲۲/۷)	۵۷ (۵۳/۸)	۰/۰۰۱
زن	۸۳	۳۴ (۷۷/۳)	۴۹ (۴۶/۲)	۰/۰۰۶
سیگاری بودن (درصد)	۲۹	۳ (۶/۸)	۲۶ (۲۴/۵)	۰/۰۰۱
سابقه فشارخون بالا	۷۶	۲۳ (۲۹/۵)	۵۳ (۵۹/۴)	۰/۰۰۱
سابقه دیابت (درصد)	۵۰	۷ (۱۵/۹)	۴۳ (۴۵/۸)	۰/۰۰۴
سابقه خانوادگی بیماری عروق کرونری	۳۸	۸ (۱۸/۲)	۳۰ (۲۸/۳)	۰/۱۹۴
سابقه MI (درصد)	۲۱	۱ (۲/۳)	۲۰ (۱۸/۵)	۰/۰۰۸
نتیجه تست ورزش غیر نرمال	۱۱۷	۱۵ (۳۴/۱)	۱۰۲ (۹۶/۲)	۰/۰۰۱
نتیجه اکوی غیر نرمال	۷۶	۱۴ (۳۱/۸)	۶۲ (۵۸/۵)	۰/۰۰۳

1. Mean Squares of Error

جدول شماره ۳: پیشگویی وضعیت عروق کرونر بر حسب نتیجه آنژیوگرافی در فاز تست شبکه

پیشگویی شبکه	نتیجه آنژیوگرافی		جمع
	طبیعی	بیماری CAD	
طبیعی	۵	۰	۵
بیماری CAD	۱	۲۴	۲۵
جمع	۶	۲۴	۳۰

برای درک بهتر نیاز به به دست آوردن حساسیت و ویژگی وجود دارد:

حساسیت عبارت است از نسبت تعداد افراد بیمار تشخیص داده شده توسط شبکه عصبی مصنوعی به کل بیماران که ۲۴۰ تقسیم بر ۲۵ برابر با ۰/۹۶ محاسبه شد. به عبارت دیگر شبکه عصبی مصنوعی طراحی شده ۹۶ درصد از بیماران را به طور صحیح ارزیابی می کند. ویژگی عبارت است از نسبت تعداد سالم تشخیص داده شده توسط شبکه عصبی مصنوعی به کل افراد سالم که ۵ تقسیم بر ۵ برابر با یک محاسبه شد. به عبارت دیگر شبکه عصبی مصنوعی طراحی شده ۱۰۰ درصد افراد سالم را به درستی ارزیابی نموده است.

بحث

شبکه عصبی مصنوعی MLP که در این تحقیق طراحی و مورد استفاده قرار گرفت می تواند بعضی از بیمارانی را که نیازی به آنژیوگرافی و درمان های مربوط به عروق کرونری قلب ندارند را به درستی تشخیص دهد. این نتیجه به دست آمده نیز همسو با دیگر تحقیقات انجام گرفته در جهان می باشد (۷).

Mobley و همکاران مقاله ای با عنوان پیش بینی تنگی شریان کرونری به وسیله شبکه عصبی مصنوعی را منتشر نمودند که بیشترین تطبیق را با موضوع تحقیق حاضر داشت. داده های این تحقیق که از اطلاعات آنژیوگرافی ثبت شده بیماران به دست آمده بود شامل ۱۴ متغیر ورودی (سن، جنس، نژاد، کشیدن سیگار، دیابت، فشارخون، شاخص توده بدنی و برخی عوامل

تکرار شده است. متغیر خروجی براساس نتیجه آنژیوگرافی دو حالتی بود که به صورت طبیعی بودن یا بسته بودن رگ ها تعریف شد. مجموع مربعات خطای مشاهده شده در مرحله آموزش ۰/۰۰۸۹ به دست آمد.

جدول شماره ۲ خروجی شبکه عصبی مصنوعی طراحی شده را در مقایسه با نتیجه آنژیوگرافی نشان می دهد. نتایج حاکی از آن است که ارزیابی شبکه عصبی مصنوعی صحیح بوده است. زیرا افراد بیمار و سالم را بدرستی تشخیص داده است. البته صحیح بودن این مطلب باید در فاز تست آزمایش شود.

جدول شماره ۲: پیشگویی وضعیت عروق کرونر بر حسب نتیجه آنژیوگرافی در فاز آموزشی شبکه

پیشگویی شبکه	نتیجه آنژیوگرافی		جمع
	طبیعی	بیماری CAD	
طبیعی	۳۹	۰	۳۹
بیماری CAD	۰	۸۱	۸۱
جمع	۳۹	۸۱	۱۲۰

فاز تست شبکه عصبی

۳۰ نمونه (۲۰ درصد)، جهت تست شبکه عصبی مصنوعی استفاده شد.

در این فاز نیز از شبکه عصبی پرسپترون چند لایه (MLP) با الگوریتم پس انتشار خطا (EBPL) با ساختار NN (14-12-1) و ۱۵۰۰ سیکل آموزشی استفاده شد.

مجموع مربعات خطای مشاهده شده در مرحله تست ۰/۰۲۳۸ به دست آمده است.

جدول شماره ۳ خروجی مرحله تست شبکه عصبی مصنوعی را در مقایسه با نتایج واقعی نشان می دهد. نتایج حاکی از آن است از ۳۰ نمونه آموزشی که در فاز تست مورد استفاده قرار گرفت ۵ نفر سالم و ۲۵ نفر بیمار بودند، ولی شبکه عصبی مصنوعی ۶ نفر را سالم و ۲۴ نفر را بیمار تشخیص داده بود. این بدان معنی می باشد که شبکه عصبی مصنوعی یک نفر بیمار را به اشتباه سالم تشخیص داده است.

NN(14-12-1) را با توجه به کوچک بودن مجموع مربعات خطای آن در نظر گرفتیم. در نهایت توانستیم حساسیت و ویژگی بالایی (حساسیت ۰/۹۶ و ویژگی برابر یک) را به دست آوریم؛ در صورتی که مطالعه قبلی نتوانسته بود هر دو میزان را در حد بالا به دست آورد.

این نتیجه بسیار مهم می باشد زیرا از عوارض و آسیب های احتمالی آنژیوگرافی برای بیمارانی که نیاز به آن ندارند جلوگیری می شود. از طرف دیگر می تواند بیمارانی را که به طور واقعی به این اقدامات تشخیصی و درمانی نیاز دارند در سریع ترین زمان و بیشترین دقت مشخص نماید. حتی در آینده می توان با تکیه بر تعداد داده های بیشتر آموزشی از مراکز فوق تخصصی قلب در سراسر کشور به صورت چند مرکزی یک شبکه عصبی مصنوعی جامع تری پیاده سازی نمود تا در کنار آنژیوگرافی بتواند به افراد بیمار و غیر بیمار مراجعه کننده کمک نماید. یعنی ابتدا با استفاده از شبکه عصبی مصنوعی MLP و با توجه به این که ویژگی برابر یک به دست آمده است افراد سالم را از بیمار جدا نموده و سپس آنژیوگرافی را برای افراد بیمار جهت یافتن تعداد رگ های بسته به کار گرفت.

سپاسگزاری

از معاونت محترم پژوهشی دانشگاه علوم پزشکی مازندران و همه کسانی که در جمع آوری داده های این تحقیق کمک نموده اند به ویژه آقای زلیکانی تشکر می نمایم. این مقاله حاصل پایان نامه دانشجویی کارشناسی ارشد آمار آقای محمدای اسماعیلی می باشد.

References

1. Dunne RA, Wiley J, Inc S. A Statistical Approach to Neural Networks for Pattern Recognition. New Jersey: John Wiley & Sons Inc; 2007.
2. Livingstone DJ, Totowa NJ. Artificial Neural

خطر دیگر) و متغیر خروجی تنگ بودن یا نبودن شریان کرونری بوده است. نتایج این تحقیق که از شبکه عصبی مصنوعی MLP با ساختار NN(14-26-1) استفاده کرده بود در بهترین حالت حساسیت را برابر یک و ویژگی را برابر ۰/۴۷ گزارش کرده بود (۱۵). Sagiroglu و همکارانش در ترکیه نیز نشان دادند که MLP بهتر از روش های دیگر الگوریتم های آموزشی عمل می کند (۲۲).

در مطالعه حاضر نیز سعی بر آن بود که نتایج پیشگویی بهبود داده شود، لذا تغییرات اساسی در متغیرهای ورودی داده شد. به عنوان مثال با حذف متغیر ورودی نژاد و همچنین با اضافه نمودن متغیرهای ورودی مفیدتری چون تست ورزش، نتیجه اکو، کسر تخلیه بیمار به لیست متغیرهای ورودی و همچنین ارتباط بهتر این متغیرها با متغیر خروجی، نتایج بهتری حاصل شد. یکی از دلایل بالا بودن حساسیت و ویژگی مدل، متغیرهای انتخابی هستند که در ایجاد بیماری عروق کرونر شناخته شده هستند و براساس مطالعات مختلف با مدل های رگرسیون لجستیک، تحلیل ممیزی به آنها شده است (۲۳).

در قسمت ساختار شبکه عصبی مصنوعی به کار گرفته شده در تحقیق بالا، NN(14-26-1)، تعداد نرون های لایه میانی ۲۶ در نظر گرفته شده است. این تعداد زیاد نرون های لایه میانی ممکن است شبکه عصبی مصنوعی را با مشکلاتی نظیر افزایش زمان آموزش شبکه مواجه کند و همچنین ممکن است شبکه نظام بی اهمیت داده های آموزشی را یاد بگیرد و در حل مسائل ضعیف عمل نماید. لذا ما با توجه به این نکته مهم، بهترین ساختار شبکه عصبی مصنوعی MLP یعنی

- Networks Methods and Application. 1th ed. Totowa, NJ: Hummana Press; 2008.
3. Zini G, d'Onofrio G, Neural network in hematopoietic malignancies. Clin Chim Acta 2003; 333(2): 195-201.

4. Sargent DJ. Comparison of artificial neural networks with other statistical approaches: results from medical data sets. *Cancer* 2001; 91(8 Suppl): 1636-1642.
5. Dreiseitl S, Ohno-Machado L. Logistic regression and artificial neural network classification models: a methodology review. *J Biomed Inform* 2002; 35(5-6): 352-359.
6. Song JH, Venkatesh SS, Conant EA, Arger PH, Sehgal CM. Comparative analysis of logistic regression and artificial neural network for computer-aided diagnosis of breast masses. *Acad Radiol* 2005; 12(4): 487-495.
7. 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): 366-374.
8. Menhaj MB. Computational intelligence, fundamentals of neural network. 2nd ed. Tehran: Amir Kabir University Press; 2008 (Persian).
9. George J, Ahmed A, Patnaik M, Adely Y, Levy Y, Harats D, et al. The prediction of coronary atherosclerosis employing artificial neural networks. *Clin Cardiol* 2009; 23(6): 453-456.
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(Suppl 1): S67.
11. Itchhaporia D, Snow PB, Almasy RJ, Oetgen WJ. Artificial neural networks: Current status in cardiovascular medicine. *J Am Coll Cardiol* 1996; 28(2): 515-521.
12. Chong CF, Li YC, Wang TL, Chang H. Stratification of adverse outcomes by preoperative risk factors in coronary artery bypass graft patients: an artificial neural network prediction model. *AMIA Annu Symp Proc* 2003; 160-164.
13. Babaoglu I, Baykan OK, Aygul N, Ozdemir K, Bayrak M. Assessment of exercise stress testing with artificial neural network in determining coronary artery disease and predicting lesion localization. *Expert Syst Appl* 2010; 37(1): 905.
14. 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): 267-281.
15. 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.
16. Dirgenali F, Kara S. Recognition of early phase of atherosclerosis using principles component analysis and artificial neural networks from carotid artery Doppler signals. *Expert Syst Appl* 2006; 31(3): 643-651.
17. Harrison RF, Kennedy R L. Artificial Neural Network Models for Prediction of Acute Coronary Syndromes Using Clinical Data From the Time of Presentation. *Ann Emerg Med* 2005; 46(5): 431-439.
18. Turkoglu I, Arslan A, Ilkay E. An intelligent system for diagnosis of the heart valve diseases with wavelet packet neural networks. *Comput Biol Med* 2003; 33(4): 319-331.
19. Biglarian A, Babae GR, Azmie R. Application of Artificial Neural Network Model in Determining Important Predictors of In-Hospital Mortality After Coronary Artery Bypass Graft Surgery, and it's Comparison with Logistic Regression Model. *Modarres J Med Sci* 2004; 7(1): 23-30.
20. Biglarian A, Hajizadeh E, Kazemnejad A. Comparison of Artificial Neural Network and COX Regression Models in Survival

- Prediction of Gastric Cancer Patients. Koomesh 2010; 11(3): 211-205.
21. Biglarian A, Hajizadeh E, Kazemnejad A, Zayeri F. Determining of prognostic factors in gastric cancer patients using artificial neural networks. Asian Pac J Cancer Prev 2010; 11(2): 533-536.
22. Sağiroglu Ş, Çolak C, Çolak MC, Atıcı MA, Alasulu N. Radial Basis Function Neural Network and Logistic Regression Analysis For Prognostic Classification of Coronary Artery Disease. Ankara Üniv Tıp Fak Mecm 2007; 60(3): 97-102.
23. Mohammadpour Tahamtan RA, Babae GR, Mahmodi M, Memariani A, Mohseni A. Evaluation of Exercise Test Variables in Diagnosis and Prediction of the Severity of Coronary Artery Disease by Fuzzy Discriminant Analysis. J Mazand Univ Med Sci 2002; 11(33): 39-45.