

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 Comared to after 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 Pythia-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^۱

محمدهادی اسماعیلی^۲

علی قائمیان^۳

جواد 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 پس انتشار 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 (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 (ANN: Artificial Neural Network) یک روش

آماري زیادی ارائه شده است (۱). شبکه عصبی مصنوعی غیر پارامتری برای طبقه‌بندی است که در حیطه پزشکی

غیر پارامتری برای طبقه‌بندی است که در حیطه پزشکی

غیر پارامتری برای طبقه‌بندی است که در حیطه پزشکی

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 می شود مثل مدل سازی رگرسیونی و پیش بینی، سری های زمانی، تحلیل خوشه ای و تحلیل ممیزی، بررسی مسائل تصمیم آماری، کنترل فرایند و برآورد توزیع شرطی می تواند مورد استفاده قرار گیرد (۲،۱).

از قرن نوزدهم به طور همزمان اما جداگانه، از سویی نروفیزیولوژیست ها 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 کوشش ها در شبیه سازی با استفاده از یک مدل منطقی توسط مک کلوک و والتر پیتز انجام شد که امروزه بلوک اصلی سازنده اکثر شبکه های عصبی مصنوعی است. این مدل فرضیه هایی در مورد عملکرد نرون ها ارائه می کند. در سال ۱۹۵۸ شبکه پرسپترون توسط روزنبلات معرفی گردید. ورباس 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) می باشد که در مقایسه با سایر روش ها بهتر عمل می کند (۷). ساختار MLP یک ترکیب استاندارد از ورودی ها، واحدهای عصبی خطی و غیر خطی و خروجی ها می باشد. 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 می دهد.



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

براساس متغیرهای ورودی نسبت به طبقه بندی افراد به بیمار یا سالم اقدام می کند. طبقه بندی و پیشگویی وضعیت بیمار بر اساس عوامل خطر یکی از کاربردهای شبکه های عصبی مصنوعی است (۲).

در شبکه عصبی مصنوعی از ساختار درهم و توده ای مغز انسان الهام گرفته شده است. میلیاردها سلول عصبی (نرون) از طریق ارتباطاتی که با یکدیگر دارند (سیناپس ها) یک شبکه عصبی بیولوژیکی در مغز انسان را تشکیل می دهند که به فعالیت های انسان از جمله خواندن، ادراک، گفتگو، تنفس، حرکت، تشخیص صدا، تشخیص چهره، همچنین حل مسائل و ذخیره سازی اطلاعات و ... اختصاص دارد. ANN در واقع بخشی از عملکرد مغز را شبیه سازی می کنند (۲،۱). شبکه عصبی مصنوعی در حل مسائلی که دارای راه حل الگوریتمی نیستند یا مسائلی که راه حل الگوریتمی بسیار پیچیده ای دارند و نیز مسائلی که برای انسان ها آسان، اما برای کامپیوترهای رایج دشوار هستند مانند تشخیص تصاویر و پیش بینی ها بر پایه دانش گذشته، به خوبی مورد استفاده قرار گرفته است (۳).

در بعضی مطالعات ارجحیت روش های نوین بر روش های 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 روش های رگرسیونی، در ۱۴ درصد موارد روش های رگرسیونی بهتر از ANN و در ۵۰ درصد موارد این دو روش شبیه هم عمل کردند. در مطالعه متا آنالیزی که Dreiseitl با جمع بندی ۷۲ مطالعه انجام داده بود مشاهده نمود در ۱۸ درصد موارد ANN بهتر و در ۱ درصد موارد روش های رگرسیون لجستیک بهتر و در ۴۲ درصد موارد، این دو روش شبیه هم عمل کردند. ضمناً در ۳۹ درصد موارد مقالات آزمون های آماری کافی نداشتند و لذا این مقالات در نظر گرفته نشدند (۴-۶).

شبکه های عصبی مصنوعی به عنوان یک شیوه جانشین در مسائلی که به طور متداول از روش های آماری

در شبکه فوق S_1 تعداد نرون های لایه مخفی و S_2 تعداد نرون های لایه خروجی می باشد. چنین شبکه عصبی را به صورت زیر نشان می دهند:

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

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

الگوریتم یادگیری: شبکه های 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 می کند. در یادگیری با ناظر، مجموعه ای از زوج داده ها به نام نمونه های آموزشی به صورت زیر داده می شود:

$$A = (X_i, t_i)$$

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 گونه ای استفاده می شود که اگر دفعه بعد به شبکه همان ورودی X_i اعمال شود خروجی شبکه به t_i نزدیک تر گردد. الگوریتم یادگیری مورد استفاده در شبکه عصبی MLP، الگوریتم یادگیری پس انتشار خطا ($EBPL^2$) می باشد. در الگوریتم EBPL دو مسیر محاسباتی وجود دارد. مسیر رفت که در آن توابع محرک، روی تک تک نرون ها عمل می کند. مسیر برگشت که در این مسیر بردارهای حساسیت (بردارهای

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

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

پایه سازی شبکه عصبی دارای سه بخش فراهم کردن نمونه های آموزشی، فاز آموزش و تست شبکه عصبی است.

شبکه های عصبی مصنوعی در حل مسائل مربوط به تشخیص بالینی، آنالیز تصاویر پزشکی، پیش بینی بقا و در دامنه وسیعی از زمینه های پزشکی شامل انکولوژی، کاردیولوژی و هماتولوژی، مراقبت های 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، ۹-۱۸). به عنوان نمونه می توان به چند مقاله که در زیر آمده است اشاره نمود. در مقاله ای که با عنوان کاربرد شبکه عصبی مصنوعی در تعیین پیش بینی کننده های 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

1. Supervised Learning

2. Error Back Propagation Learning

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

در مقاله ای دیگر به مقایسه شبکه عصبی مصنوعی با دیگر روش های آماری از جمله رگرسیون لجستیک برای پیش بینی 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 می باشد (۷).

در مقاله ای که با هدف مقایسه مدل شبکه عصبی مصنوعی و رگرسیون کاکس در پیش بینی بقای بیماران مبتلا به سرطان معده انجام شده بود، شبکه عصبی مصنوعی نسبت به مدل رگرسیون کاکس پیش بینی بهتری برای بقای بیماران داشت و به کارگیری شبکه عصبی مصنوعی در زمینه های پیش بینی 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 پیش بینی 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 می باشد (۲۱).

مدل مناسب برای تحلیل داده های پزشکی، تابع شرایط گوناگونی می باشد که استفاده از آن ها با محدودیت ها و مشکلاتی نیز همراه است. از جمله این که فرض های اولیه مورد نیاز این مدل ها همانند نرمال بودن داده ها، تصادفی بودن مقادیر خطا، ثابت بودن واریانس خطا و ... همواره برقرار نیستند. لذا در این موارد نمی توان مدل مناسبی بر اساس داده های مورد نظر برازش داد.

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

در برخی از آن ها تفاوتی بین مدل ها گزارش نشده است و میزان حساسیت و ویژگی مدل متفاوت اعلام شده است (۲۰-۱۷). هدف این مطالعه تعیین میزان دقت پیشگویی مدل شبکه های عصبی مصنوعی در طبقه بندی بیماران عروق کرونر از افراد سالم براساس 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 تست های غیر تهاجمی مانند تست ورزش و اکوکاردیوگرافی درباره وضعیت بیماری عروق کرونر پیشگویی کرد. این نتیجه از آن جهت دارای اهمیت می باشد که می تواند از عوارض و آسیب های احتمالی آنژیوگرافی و درمان های 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 صرفه جویی خواهد شد.

مواد و روش ها

تحقیق حاضر یک مطالعه تشخیصی است که بر اساس متغیرهای ورودی، به پیشگویی وضعیت تنگی عروق کرونر می پردازد. جامعه آماری بیمارانی هستند که در مرکز قلب ساری تحت آنژیوگرافی عروق کرونر قرار گرفتند. تعداد نمونه براساس فرمول مربوطه و تقسیم تعداد نرون های 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، تست های تشخیصی و نتیجه آنژیوگرافی موجود در پرونده برای آن ها تکمیل گردید.

ابتدا این داده ها را در نرم افزار Excel وارد شده سپس از نرم افزارهای مربوط به طراحی شبکه عصبی مصنوعی نظیر Pythia-Neural Network استفاده شد. نحوه استفاده از این داده ها 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.

یافته ها

فراهم کردن نمونه های 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 تری گلیسیرید 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

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.

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 (1-12-14) NN 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 معنی داری
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
تری گلیسیرید	۲۰۲/۲۱ (۱۰۴/۰۵)	۲۰۸/۶ (۱۰۷)	۱۹۹/۵ (۱۰۲)	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 معنی داری
جنس مرد (درصد)	۶۷	۱۰ (۲۲/۷)	۵۷ (۵۳/۸)	۰/۰۰۱
زن	۸۳	۳۴ (۷۷/۳)	۴۹ (۴۶/۲)	
سیگاری بودن (درصد)	۲۹	۳ (۶/۸)	۲۶ (۲۴/۵)	۰/۰۰۶
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

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

پیشگویی شبکه	نتیجه آنژیوگرافی		
	طبیعی	بیماری CAD	جمع
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		
	طبیعی	بیماری CAD	جمع
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.

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). Sagioglu و همکارانش در ترکیه نیز نشان دادند که MLP بهتر از روش‌های دیگر الگوریتم‌های آموزشی عمل می‌کند (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 مدل‌های 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 نرون‌های لایه میانی ۲۶ در نظر گرفته شده است. این تعداد زیاد نرون‌های لایه میانی ممکن است شبکه عصبی مصنوعی را با مشکلاتی نظیر افزایش زمان آموزش شبکه مواجه کند و همچنین ممکن است شبکه نظام بی‌اهمیت داده‌های 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

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 می‌باشد زیرا از عوارض و آسیب‌های احتمالی آنژیوگرافی برای بیمارانی که نیاز به آن ندارند جلوگیری می‌شود. از طرف دیگر می‌تواند بیمارانی را که به طور واقعی به این اقدامات تشخیصی و درمانی نیاز دارند در سریع‌ترین زمان و بیشترین دقت مشخص نماید. حتی در آینده می‌توان با تکیه بر تعداد داده‌های بیشتر آموزشی از مراکز فوق تخصصی قلب در سراسر کشور به صورت چند مرکزی یک شبکه عصبی مصنوعی جامع‌تری پیاده‌سازی 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 رگ‌های بسته به کار گرفت.

سپاسگزاری

از معاونت محترم پژوهشی دانشگاه علوم پزشکی مازندران و همه کسانی که در جمع‌آوری داده‌های این تحقیق کمک نموده‌اند به ویژه آقای زلیکانی تشکر می‌نمایم. این مقاله حاصل پایان نامه دانشجویی کارشناسی ارشد آمار آقای محمدی اسماعیلی می‌باشد.

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 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, Almassy 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, Babaee 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.