ارائه یک سیستم هوشمند در تشخیص بیماری عروق کرنری قلب با استفاده از شبکه عصبی احتمالی*

آسیه خسروانیان[1]، سید سعید آیت[2]

مقاله پژوهشی

چکیده

مقدمه: انتخاب روش مناسب برای مدل‌سازی و تحلیل داده‌های سلامت و بهداشت، مبتنی بر نوع داده‌های موجود، بسیار مهم و در مواردی بسیار حساس است. تحقیق حاضر باهدف تعیین بسته بودن یا نبودن عروق کرنری قلب بر اساس شبکه عصبی احتمالی انجام شد.

روش بررسی: این تحقیق، از نوع کاربردی و اجرایی بود و در سال ۱۳۹۲ شمسی در بیمارستان کوثر شیراز انجام شد جامعه آماری این پژوهش افرادی بودند که در شهریورماه سال ۱۳۹۲ شمسی تحت آنژیوگرافی عروق کرنری قلب قرار گرفتند. تعداد نمونه مورد مطالعه بر اساس فرمول مربوطه و تقسیم تعداد نرون‌های لایه مخفی بر میزان خطای ۱/۰ محاسبه شد. لذا تعداد ۱۵۲ نفر از افراد فوق به‌صورت تصادفی انتخاب شدند. در پیاده‌سازی‌های انجام شده، از ۸۵ درصد داده‌ها جهت مرحله آموزش شبکه و ۱۵ درصد باقیمانده جهت مرحله آزمون شبکه استفاده شد. در این پژوهش از شبکه عصبی احتمالی(PNN: Probabilistic Neural Network)به‌منظورپیش‌بینی بیماری عروق کرنری قلب استفاده شد. شبکه عصبی پیشنهاد شده با استفاده از امکانات و توابع موجود در نرم‌افزارمتلب نسخه ۷/۱۲ پیاده‌سازی گردید و بر روی سیستم Corei ۵ با پردازنده ۲/۴ GHz و حافظه GB۴ تحت ویندوز ۷ شبیه‌سازی شد.

یافته‌ها: شاخص‌های عملکردی این سیستم، اختصاصیت (Specificity) و حساسیت (Sensitivity) بودند. عملکرد سیستم ارائه‌شده بر اساس این شاخص‌ها در مرحله آزمون شبکه به ترتیب معادل اعداد ۰/۹۴ و ۱ به دست آمد. درنهایت سیستم طراحی و پیاده‌سازی شده توانست با دقت بهتری نسبت به تحقیقات مشابه در این زمینه، افراد دارای بیماری عروق کرنری را تشخیص دهد.

نتیجه‌گیری: نتایج این تحقیق نشان داد که در جامعه آماری موردمطالعه، شبکه‌های عصبی احتمالی بهتر و قوی‌تر از سایرشبکه‌های عصبی در تشخیص بیماری عمل کرده‌اند. این روش به علت اختصاصیت و حساسیت بالا می‌تواند از عوارض و آسیب‌های احتمالی آنژیوگرافی در بیمارانی که نیاز به آن ندارند، جلوگیری نماید. همچنین می‌تواند بیمارانی را که واقعاً به این اقدامات تشخیصی نیاز دارند در سریع‌ترین زمان و بیشترین دقتمشخص نماید.

واژه‌های کلیدی: بیماری عروق کرنری؛ پیش‌بینی؛ شبکه‌های عصبی (کامپیوتر).

دریافت مقاله: ۹۲/۹/۱۹ اصلاح نهایی: ۹۳/۴/۱۰ پذیرش مقاله: ۹۳/۴/۱۴

ارجاع: خسروانیان آسیه، آیت سید سعید. **ارائه یک سیستم هوشمند در تشخیص بیماری عروق کرنری قلب با استفاده از شبکه عصبی احتمالی.** مدیریت اطلاعات سلامت ۱۳۹۴؛ ۱۲(۱): ۳-۱۳.

*- این مقاله حاصل تحقیق مستقل است که از هیچ سازمانی کمک مالی نگرفته است.

۱- کارشناسی ارشد، مهندسی کامپیوتر، گروه علمی مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه پیام نور، تهران، ایران (نویسنده مسؤول)
Email:khosravanian.a@gmail.com

۲- دانشیار، مهندسی کامپیوتر، گروه علمی مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه پیام نور، تهران، ایران

www.SID.ir

مقدمه

بیماری عروق کرنری (CAD: Coronary Artery Disease) که شایع‌ترین مشکل بیماری قلبی است، از علل اصلی مرگ در زنان و مردان آمریکایی است. با توجه به گزارش انجمن قلب آمریکا، بیش از دوازده میلیون آمریکایی از این بیماری رنج می‌برند و هرساله بیش از پانصدهزار آمریکایی از حمله قلبی ناشی از این بیماری می‌میرند (۱). راه‌های مختلفی برای تشخیص این بیماری وجود دارد از جمله تست ورزش، اکوکاردیوگرام، اسکن هسته‌ای قلب و آنژیوگرافی در این مقاله با استفاده از طبقه‌بندی کننده احتمالی به تشخیص این بیماری پرداخته‌شده است.

ازآنجاکه در تحقیقات علوم پزشکی مسأله سلامت انسان مطرح است، پیش‌بینی درست نتایج اهمیت بیشتری می‌یابد بنابراین باید از روش‌هایی استفاده شود که پیش‌بینی بر اساس آن‌ها دارای کمترین خطا و بیشترین اطمینان باشد. ازجمله روش‌هایی که توجه بسیاری از محققین را به خود معطوف داشته است شبکه‌های عصبی مصنوعی است. شناخت و طبقه‌بندی الگوها به مسأله‌ای مهم و قابل‌توجه در دنیای امروزتبدیل‌شده است و تعداد تحقیقات متنوع انجام‌شده در این زمینه درسال‌های اخیر مبین اهمیت این موضوع است.

شبکه های عصبی مصنوعی ازجمله روش های شناخت و طبقه‌بندی الگوهاهستند (۲)که به‌نوعی عملکرد مغز را شبیه‌سازی می کنند (۴، ۳). شبکه عصبی مصنوعی در حل مسائلی که دارای راه‌حل الگوریتمی نیستند یا مسائلی که راه‌حل 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 به‌خوبی عمل کرده‌اند (۵).از جمله مهم‌ترین شبکه‌های عصبی که به منظور شناخت و طبقه‌بندی الگوهای مورد استفاده قرار می‌گیرند، می‌توان به شبکه‌های خودسازمان‌ده، شبکه‌های عصبی Bayesian، شبکه‌های چندلایه پیش‌خور،شبکه‌های عصبی شعاعی محور و شبکه‌های طبقه‌بندی کننده‌های احتمالی اشاره کرد (۶).

در بعضی مطالعات نتایج حاصل از استفاده روش‌های نوین نظیر شبکه‌های عصبی بر روش‌های کلاسیک همچون رگرسیون دیده‌شده است، به‌طور مثال در مطالعه متاآنالیزی که Sargent در ۲۸ مورد انجام داده بود مشاهده نمود که در ۳۶ درصد موارد شبکه عصبی مصنوعی بهتر، در ۱۴ درصد موارد روش‌های رگرسیونی بهتر و در ۵۰ درصد موارد شبیه هم عمل کرده‌اند (۷). بررسی متاآنالیزی که Dreiseitl در جمع‌بندی۷۲ مطالعه انجام داده بود، مشاهده نمود در ۱۸ درصد موارد شبکه عصبی مصنوعی بهتر، در ۱ درصد موارد روش‌های رگرسیون لجستیک بهتر و در ۴۲ درصد موارد شبیه هم عمل کرده‌اند. درضمن ۳۹ درصد موارد مقالات آزمون‌های آماری کافی نداشتند بنابراین در نظر گرفته نشده‌اند (۸، ۹).

مطالعات نشان می‌دهدکه شبکه‌های عصبی مصنوعی به‌صورت وسیعی در تشخیص بیماری‌های به کارگرفته شده استواینسیستم ها قادرهستند که برای تشخیص سرطان، بیماری های قلبی عروقی، بیماری سل وعفونت‌های سینوسی مورد استفاده قرار گیرند.

شبکه‌های عصبی احتمالی یکی از موفق‌ترین و کاربردی‌ترین نوع از این شبکه‌ها بوده که بر اساس نظر کارشناسان ابزارهای قدرتمندی برای شناخت و طبقه‌بندی الگوها با بیشترین احتمال موفقیت‌اند (۱۰).شبکه‌های عصبی احتمالی ازمهم‌ترین روش‌های با ناظر بوده که برای اولین بار در سال۱۹۸۸ میلادی توسط Specht معرفی شدند (۱۱). این شبکه در سال‌های اخیر در مقالات بسیاری به عنوان ابزار پیش‌بینی و شناخت الگو مورد توجه قرار گرفته و نتایج مطلوبی نیز در مقایسه با سایر روش‌ها ارائه کرده است (۱۲).

شبکه‌های عصبی که به منظور شناخت و طبقه‌بندی الگوها مورد استفاده قرار می‌گیرند. به‌طورکلی الگوهای موجود در داده‌های آموزش را یاد گرفته، سپس نمونه‌های جدید را بر اساس این الگوها دسته‌بندی می‌نماید (۱۴، ۱۳).

شبکه‌های عصبی احتمالی الگوها رابر اساس تراتژی Bayesian و تخمین زننده های غیر پارامتریک توابع چگالی

Archive of SID
www.SID.ir

احتمال طبقه‌بندی می‌کنند و از جمله روش‌هایی هستندکه مبتنی بر الگوهای آماری موجود در داده عمل می‌کنند. این‌گونه از شبکه‌ها ازالگوریتم‌های یادگیری یک‌بار گذر ازداده‌ها استفاده کرده به این معنا که شبکه تنها در یک دور آموزش می‌بیند و نیاز به تکرار دورهای آموزشی نیست این یکی از بزرگ‌ترین مزیت‌های شبکه عصبی احتمالی به‌حساب می‌آید، چرا که روش‌هایی که از رویکردهای ذهنی به منظور به دست آوردن الگوهای موجود در داده‌ها استفاده می‌نمایند معمولاً مستلزم ایجاد مقدار زیادی از تغییرات کوچک در پارامترهای شبکه به منظور اصلاح تدریجی بازه خود می‌باشند و این به معنای زمان یادگیری طولانی است (۱۴).

شبکه های عصبی احتمالی یک اشکال عمده نیز دارند و آن نیاز به ذخیره‌سازی تمامی نمونه‌های آموزشی به منظور طبقه‌بندی الگوهای جدید است که این خود باعث اشغال حجم بزرگی از حافظه می‌شود. از آنجایی‌که حافظه کامپیوترها خیلی ارزان و پربازده هستند امروزه میزان ذخیره اطلاعات خیلی جای نگرانی ندارد (۱۵).

شبکه‌های عصبی مصنوعی در حل مسائل مربوط به تشخیص بالینی، آنالیز تصاویر پزشکی، پیش‌بینی بقا و در دامنه وسیعی از زمینه‌های پزشکی شامل آنکولوژی، کاردیولوژی، هماتولوژی، مراقبت‌های ویژه، تشخیص از روی تصاویر پزشکی، ناباروری، جراحی به‌کار رفته است (۲۶-۱۶).

به‌طور خاص تحقیقات وسیعی در زمینه بیماری عروق کرنری قلب با استفاده از شبکه عصبی مصنوعی انجام‌شده است که در این قسمت به چند نمونه آن اشاره می‌کنیم.

در مقاله‌ای که با عنوان کاربرد شبکه عصبی مصنوعی در تعیین پیش‌بینی کننده‌های مهم مرگ‌ومیر درون بیمارستانی پس از جراحی قلب باز و مقایسه آن با مدل رگرسیون لجستیک ارائه شد (۲۷)، از یک شبکه عصبی مصنوعی دارای ۱۸ نرون در لایه ورودی، ۴ نرون در لایه مخفی و ۲ نرون در لایه خروجی با الگوریتم پس انتشار خطا و تابع انتقال سیگموید استفاده گردید. هدف از این مطالعه مقایسه توانایی‌های دو مدل شبکه عصبی مصنوعی و رگرسیون لجستیک به منظور پیش‌بینی مخاطره مرگ درون بیمارستانی پس از عمل جراحی قلب باز بود. جامعه آماری در این مطالعه بیمارانی بودند که در بیمارستان دکتر شریعتی تهران تحت عمل جراحی قلب باز قرارگرفته بودند. برای نشان دادن دقت نتایج این مطالعه از دو شاخص حساسیت و اختصاصیت استفاده شده بود. حساسیت (Sensitivity) به معنی تعداد افراد بیمار تشخیص داده‌شده‌به‌کل بیماران است. اختصاصیت(Specificity) به معنی تعداد افراد سالم تشخیص داده‌شده توسط شبکه عصبی به‌کل افراد سالم است.

در مقاله فوق حساسیت و اختصاصیت در گروه آموزش برابر ۱۰۰ درصد و در گروه آزمایش به ترتیب ۹۹/۳۳ درصد و ۱۰۰ درصد به دست آمد؛ اما در مدل رگرسیون لجستیک ارایه‌شده حساسیت و اختصاصیت به ترتیب ۹۹ درصد و ۹۰ درصد به دست آمد که مقایسه آن با حساسیت و اختصاصیت شبکه عصبی مصنوعی نشان می‌دهد که شبکه عصبی در حل مسائل از مدل رگرسیون لجستیک تواناتر است.در مقاله‌ای دیگر به مقایسه شبکه عصبی مصنوعی با دیگر روش‌های آماری ازجمله رگرسیون لجستیک برای پیش‌بینی بیماری عروق کرنری قلب پرداختند که در این مقایسه از منحنی (ROC: Receiver Operating Characteristic) استفاده شد در منحنی ROC حساسیت در مقابل اختصاصیت رسم می‌شود که نتایج مبنی بر بیشتر بودن سطح زیر نمودار ROC در شبکه عصبی مصنوعی بر دیگر روش‌های آماری بود که نشان‌دهنده برتری شبکه عصبی مصنوعی در حل این‌گونه مسائل است (۲۳).

از شبکه عصبی مصنوعی برای تشخیص تفاوت بین بیماری قلبی و انسداد ریوی که دارای علائم مشابهی هستند در بین ۲۶۶ بیمار در یکی از بیمارستان‌های تهران استفاده شده است و شبکه‌های عصبی مصنوعی پرسپترون چند لایه (MLP: Multi Layer Perceptron) و شبکه عصبی پایه شعاعی(RBF: Radial Basis Networks) برای تشخیص به کار گرفته شدند که در شبکه (MLP) حساسیت

Archive of SID
www.SID.ir

و اختصاصیت به ترتیب ۸۳/۹ درصد و۸۶ درصد و در شبکه (RBF) حساسیت و اختصاصیت به ترتیب ۸۸/۴ درصد و ۸۱/۸ درصد حاصل‌شده است.

در مقاله حاضر،هدف تعیین بسته بودن یا نبودن عروق کرنری قلب است که برای رسیدن به این هدف از شبکه عصبی مصنوعی احتمالی جهت طبقه‌بندی افراد به دو دسته بیمار و سالم استفاده‌شده است.سیستم هوشمند ارائه شده در این مقاله ازآن‌جهت دارای اهمیت است که از عوارض و آسیب‌های احتمالی آنژیوگرافی و درمان‌های مربوط به عروق کرنری قلب برای بیمارانی که نیاز به آن ندارند جلوگیری می‌کند و نیز در هزینه آزمون تشخیصی برای این افراد صرفه‌جویی می‌شود.

روش بررسی

تحقیق حاضر یک مطالعه کاربردی اجرایی است که بر اساس متغیرهای ورودی به پیشگویی وضعیت عروق کرنری قلب پرداخته است. جامعه آماری افرادی بودند که در شهریور ماه سال ۱۳۹۲ خورشیدی در بیمارستان کوثر شیراز تحت آنژیوگرافی قرار گرفته‌اند. تعداد نمونه مورد مطالعه بر اساس فرمول مربوطه و تقسیم تعداد نرون‌های لایه مخفی بر میزان خطای ۰/۱ محاسبه شد. لذا تعداد ۱۵۲ نفر از افراد فوق به‌صورت تصادفی انتخاب شدند و پرسش‌نامه محقق ساخته حاوی اطلاعات دموگرافیک، بیماری، تست‌های تشخیصی و نتیجه آنژیوگرافی موجود در پرونده برای آن‌ها تکمیل گردید.

برای پیاده‌سازی این شبکه از نرم‌افزار متلب نسخه ۷/۱۲/۰ استفاده شده است و از ۸۵ درصد داده‌ها جهت مرحله آموزش شبکه و ۱۵ درصد باقیمانده برای مرحله آزمون شبکه استفاده گردید.

از ۱۳ متغیر بالینی به‌عنوان ورودی شبکه استفاده شده که برای این منظور از ماتریسی دارای ۱۳ سطر (متغیرهای بالینی) و ۱۲۹ ستون برای مرحله آموزش و ماتریس دیگری با ۲ سطر (وضعیت نرمال=۰ و بیمار=۱) و ۱۲۹ ستون به‌عنوان ماتریس هدف در مرحله آموزش استفاده‌شده است.

برای مقایسه اولیه بین دوگروهی که نتیجه آنژیوگرافی آن‌ها نرمال گزارش‌شده بود و گروهی که حداقل یکی از رگ‌هایآن‌ها بالای ۵۰ درصد بسته بود از آزمون‌هایtو chi-square استفاده شد.

متغیرهای ورودی بر اساس جدول ۱ نرمال شده است و سپس به‌عنوان ورودی به شبکه عصبی احتمالی اعمال گردیده است. در این شبکه بردارهای ورودی بر اساس جدول ۱ نرمال شده‌اند که نحوه نرمال کردن این داده‌ها و قرار گرفتن آن‌ها در دو کلاس متفاوت موجب افزایش دقت این شبکه نسبت به دیگر شبکه‌هاپیاده‌سازی شده در این موضوع شده است و کاهش زمان یادگیری در مرحله آموزش شبکه عصبی را به دنبال داشت. هر بردار هدف دارای دو عنصر است که یکی یک و دیگری صفر است. زمانی که بردار ورودی به شبکه اعمال می‌شود فاصله آن از کلیه بردارهای آموزشی تعیین می‌گردد و مشخص می‌شود که ورودی به کدام‌یک از این بردارهای آموزشی نزدیک‌تر است. حاصل کار به صورت عنصر به عنصر در بایاس ضرب شده و به تابع انتقال radbas اعمال‌شده است این تابع فاصله بین بردار ورودی ضرب شده در بایاس و بردار وزن را به دست می‌آورد در نتیجه این تابع به ازای بردار ورودی نزدیک به بردار آموزشی مقدار ۱ را تولید می‌کند. وزن‌های لایه دوم این شبکه برابر ماتریس هدف قرار داده شده که هر بردار از این ماتریس تنها دارای یک مقدار ۱ متناظر با کلاس مربوط به آن است و بقیه مقادیر صفر هستند بنابراین شبکه بردارهای ورودی را به یکی از دو کلاس موجود که دارای حداکثر احتمال است طبقه‌بندی می‌کند.

لازم به ذکر است که می‌توان بردار ورودی را به صورت مستقیم و بدون نیاز به نرمال شدن به شبکه اعمال کرد و با استفاده از توابع موجود ماتریس را به ماتریس خلوت متشکل از صفر و یک تبدیل کردکه البته پیامد آن این است که شبکه هم در مرحله آموزش و هم مرحله آزمون دارای خطا بوده است.

Archive of SID
www.SID.ir

جدول ۱: متغیرها و مقادیر نرمال شده جهت ورودی شبکه عصبی

متغیرها	توضیحات
جنس	زن=۱مرد=۰
مصرف سیگار	دارد=۱ندارد=۰
فشارخون بالا	دارد=۱ندارد=۰
دیابت	دارد=۱ندارد=۰
سابقه خانوادگی بیماری قلبی	دارد=۱ ندارد=۰
سابقه سکته قلبی	دارد=۱ندارد=۰
نتیجه تست ورزش	نرمال=۰غیر نرمال=۱
نتیجه اکو	نرمال=۰غیر نرمال=۱
سن	سال/۱۰۰
کراتینین	عدد/۱۰
کلسترول	عدد/۱۰۰۰
تری گلیسیرید	عدد/۱۰۰۰
کسر تخلیه	عدد/۱۰۰

یافته‌ها

در ابتدا بر اساس مطالعات قبلی و نظر کارشناسی متخصصین قلب و عروق متغیرهای مورد استفاده تعیین گردید و سپس نمونه ۱۵۲تایی از این متغیرها از بیمارستان کوثر شیراز جمع‌آوری گردید. برای ایجاد یک دید کلی متغیرها به دو دسته کمی و کیفی تقسیم شدند. جدول ۲ شامل میانگین و انحراف معیار متغیرهای کمی مانند سن، کراتنین و کسر تخلیه است که مقادیر این متغیرها در دو گروه افراد سالم و بیمار تفاوت معنی‌داری داشته است و مقادیر متغیرهای کلسترول و تری گلیسیرید در دو گروه اختلاف نداشته‌اند. علت اختلاف نداشتن کلسترول در دو گروه به خاطر عدم وجود (HDL:High Density Lipoprotein) و (LDL: Low Density Lipoprotein) است.

اطلاعات مربوط به متغیرهای کیفی نشان می‌دهد که به‌جز سیگار و سابقه بیماری بقیه متغیرها مانند جنس، فشارخون بالا، دیابت، سابقه سکته قلبی، نتیجه تست ورزش و نتیجه اکوکاردیوگرافی با نتیجه آنژیوگرافی ارتباط معنی‌داری 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 بود و ۴۱ نفر تنگی سه رگ بود).

جدول ۲: شاخص‌های 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 معنی‌داری
سن	(۱۰/۵۲۲)۵۶/۹۶	(۱۰/۳)۵۱/۷۹	(۱۰/۳)۵۹/۴۱	۰/۱۶
کراتینین	(۰/۲۴)۱/۱۶۴	(۰/۱۹)۱/۴۲	(۰/۲۵)۱/۲۲	۰/۱۶
کلسترول	(۴۸/۶۷)۱۶۹/۱۱	(۳۳/۲)۱۵۰/۱۲	(۵۳/۸)۱۷۸/۴۱	۰/۶۴۴
تری گلیسیرید	(۱۰۴/۵)۱۳۷	(۱۰۷)۹۷/۳۶	(۱۰۲)۱۵۵/۴۲	۰/۶۲۸

Archive of SID
www.SID.ir

ادامه جدول ۲: شاخص‌های آمار توصیفی مربوط به متغیرهای کمی و کیفی برای سه حالت کل افراد،افراد طبیعی و بیمار

کسر تخلیه	(۹/۹۸)۴۹/۱۶	(۷/۹)۵۴/۲۸	(۹/۵)۴۶/۶۶	۰/۱
	فراوانی کل N=۱۵۲	فراوانی (درصد) نرمال N=۴۹	فراوانی (درصد) بیماری CAD N=۱۰۳	
جنس				
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	(۳۲/۶۵) ۱۶	(۴۷/۵۷)۴۹	
دیابت	۵۱	(۱۸/۳۶) ۹	(۴۰/۷۷) ۴۲	
سابقه خانوادگی بیماری قلبی	۳۴	(۲۶/۵۳)۱۳	(۲۰/۳۸) ۲۱	
سابقه سکته قلبی	۱۹	(۰)۰	(۱۸/۴۴) ۱۹	
نتیجه تست ورزش غیرنرمال	۱۰۹	(۴۲/۸۵) ۲۱	(۸۵/۴۳)۸۸	
نتیجه اکوغیرنرمال	۱۰۶	(۳۶/۷۳) ۱۸	(۸۵/۴۳)۸۸	

n = ۱۷۵. **Significant at p < ۰/۰۱

مرحله آموزش شبکه عصبی

در این مرحله از ۸۵ درصد داده‌ها (۱۲۹ نمونه) جهت آموزش شبکه عصبی مصنوعی استفاده شده است. برای پیاده‌سازی شبکه عصبی احتمالی در نرم‌افزار متلب از یک ماتریس ورودی شامل ۱۳ سطر (متغیرهای جدول ۱) و ۱۲۹ ستون و ماتریس دیگری با ۲ سطر (وضعیت فرد نرمال=۰ و فرد دچار بیماری CAD=1) و ۱۲۹ ستون به‌عنوان ماتریس هدف استفاده شد. داده‌های ورودی به شبکه بر اساس جدول ۱ نرمال شده‌اند و سپس به شبکه عصبی احتمالی وارد شده‌اند. به دلیل استفاده از شبکه‌های عصبی احتمالی، تنها از یک دور برای آموزش شبکه استفاده شد که همان‌طور که پیش‌تر اشاره شد، این از مزایای مهم شبکه‌های عصبی احتمالی نسبت به دیگر شبکه‌هاست.

شکل ۱ ساختار شبکه عصبی احتمالی پیاده‌سازی شده در نرم‌افزارمتلب را نشان می‌دهد.

مرحله آزمون شبکه عصبی

در این مرحله ۱۵ درصد داده‌ها (۲۳ نمونه) که در مرحله آموزش استفاده نشده بودند، به صورت بردار به شبکه عصبی احتمالی پیاده‌سازی شده در نرم‌افزار اعمال گردید. جدول ۳ خروجی شبکه در مقابل خروجی واقعی را در مرحله آزمون شبکه نشان می‌دهد.

همان‌طور که در جدول نشان داده شده است از ۲۳ نمونه که در مرحله آزمون مورد استفاده قرار گرفت ۱۷ نفر دارای نتیجه آنژیوگرافی نرمال و ۶ نفر دچار بیماری بودند، اما شبکه عصبی مصنوعی ۱۶ نفر را نرمال و ۷ نفر را بیمار تشخیص داده است که به این معناست که شبکه یک نفر سالم را به اشتباه بیمار تشخیص داده است.

به طور کلی برای بررسی میزان موفقیت و کارایی سیستم‌های دسته‌بندی و تشخیص بیماری‌ها، از ماتریس کانفیوژن استفاده می‌شود. تحلیل‌های ماتریس کانفیوژن در دسته‌بندی و تشخیص بیماران منجر به ۴ حالت مثبت حقیقی (True Positive یا TP)، منفی حقیقی (True Negative یا TN)، مثبت کاذب (False Positive یا FP) و منفی کاذب (False Negative یا FN) می‌شود. از نتایج ماتریس کانفیوژن دو شاخص حساسیت و اختصاصیت به دست می‌آید که برای تحلیل عملکرد سیستم‌های طبقه‌بندی استفاده می‌شود.

$$\text{حساسیت} = \frac{TP}{TP+FN} \quad (۱) \qquad \text{اختصاصیت} = \frac{TN}{FP+TN}$$

Archive of SID
www.SID.ir

برای مجموعه داده‌های به کاررفته در این مقاله حساسیت و اختصاصیت به ترتیب اعداد ۱ و ۰/۹۴به‌دست‌آمده است.

عناصر قطری در این ماتریس نشان‌دهنده تعداد مواردی هستند که به درستی طبقه‌بندی شده‌اند. عناصر غیر قطری نیز عناصری هستند که به‌درستی طبقه‌بندی نشده‌اند.

نتایج پیاده‌سازی با استفاده از جعبه ابزار شبکه عصبی موجود در نرم‌افزار در شکل ۲ نشان داده شده است و عکس‌العمل شبکه عصبی احتمالی پیاده‌سازی شده با استفاده از ماتریس کانفیوژن تحلیل‌شده است. شکل ۲ ماتریس پراکندگی و خطاهای مختلف در مورد شبکه پیاده‌سازی شده را نشان می‌دهد.

داده‌های نشان داده‌شده در این ماتریس ۸۵ درصد جهت آموزش (Training)که شامل ۱۲۹ نفر و ۵ درصد برای ارزیابی (validation)که ۸ نفر را شامل می‌شود و ۱۰ درصد جهت مرحله آزمون (Testing) که شامل ۱۵ نفر است سپس ماتریس کلی برای ۱۵۲ نفر نشان داده‌شده است.

اطلاعاتی که از ماتریس کانفیوژن برای تحلیل عکس‌العمل شبکه به دست می‌آید به شرح زیر است:

مشاهده می‌شود در مرحله آموزش میزان خطا۵/۴ درصد، در مرحله ارزیابی میزان خطا صفر، در مرحله آزمون میزان خطا ۲۰ درصد و نهایتاً برای ۱۵۲ نمونه میزان خطا ۶/۶ درصد است.

منحنیROC رسم شده برای این پیاده‌سازی، میزان حساسیت در مقابل اختصاصیت در هر یک از مراحل را نشان می‌دهد (شکل۳).

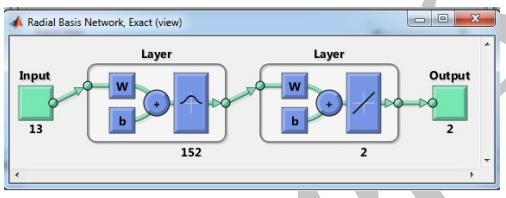

شکل ۱: ساختار شبکه عصبی احتمالی پیاده‌سازی شده در نرم‌افزار متلب

جدول ۳: پیش‌بینی وضعیت عروق کرنری در مرحله آزمون شبکه عصبی احتمالی

	نتیجه آنژیوگرافی	پیش‌بینی شبکه عصبی احتمالی *PNN*
نرمال	۱۷	۱۶
بیماری عروق کرنری *CAD*	۶	۷
جمع	۲۳	۲۳

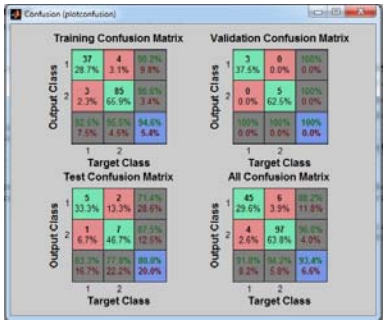

شکل ۲: ماتریس کانفیوژن مربوط به ۱۵۲ نمونه

Archive of SID
www.SID.ir

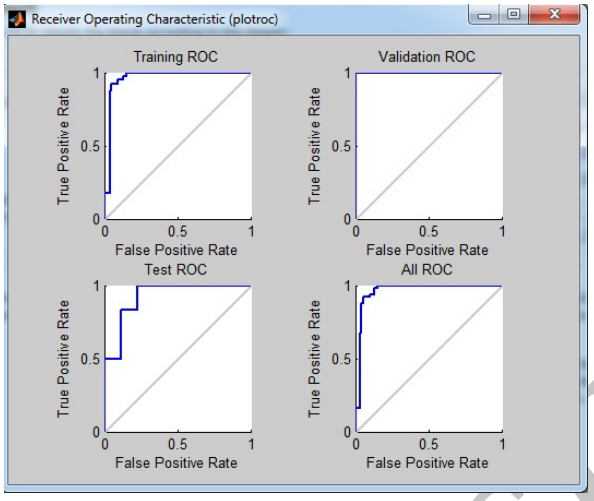

شکل ۳: منحنی ROC برای ۱۵۲ نمونه با استفاده از شبکه عصبی احتمالی

بحث

مجهز شدن علم پزشکی به ابزارهای هوشمند در تشخیص و درمان بیماری‌ها می‌تواند موجب کاهش اشتباهات پزشکان و خسارات مالی و جانی به بیماران شود. همان‌طور که در این مقاله نشان داده شد شبکه‌های عصبی مصنوعی علاوه بر دامنه کاربرد وسیعی که دارند نسبت به روش‌های آماری ابزار مناسب‌تری برای پیش‌بینی می‌باشند.

در این مطالعه وجود یا عدم وجود بیماری عروق کرنری قلب با استفاده از شبکه عصبی احتمالی بررسی شد. در ابتدا، کل نمونه که ۱۵۲ نفر بودند به دو دسته نمونه یادگیری و نمونه آزمون تقسیم شد و از دسته اول جهت مرحله آموزش شبکه عصبی و دسته دوم جهت مرحله آزمون شبکه عصبی استفاده شد. خروجی شبکه عصبی در مرحله آزمون با اطلاعات واقعی مقایسه شد و نشان داده شد که شبکه طراحی شده یک نفر سالم را به اشتباه بیمار تشخیص داده است. برای بررسی موفقیت و کارایی سیستم از ماتریس کانفیوژن استفاده شد و درصد خطا در هر یک از مراحل آموزش، ارزیابی و آزمون به دست آمد. بررسی درصد خطاها نشان می‌دهد که شبکه عصبی طراحی‌شده در مرحله آموزش و ارزیابی بهتر عمل کرده است و نهایتاً برای کل نمونه به خطای ۶/۶ درصد رسیده است.

برای بررسی دو شاخص اصلی این پیاده‌سازی (حساسیت و اختصاصیت) از نمودار ROC استفاده شد و نتایج نشان داد که پیاده‌سازی انجام‌شده نسبت به موارد مشابه به دقت مناسب‌تری در پیش‌بینی رسیده است.

شبکه عصبی احتمالی که در این مقاله استفاده شد می‌تواند بیمارانی را که نیاز به آنژیوگرافی و درمان‌های مربوط به عروق کرنری قلب ندارند را با دقت مناسبی پیش‌بینی کند. این نتیجه به‌دست‌آمده نیز همسو با دیگر تحقیقات انجام‌گرفته در جهان است (۲۲).

در پژوهش آقای Mobley و همکارانش (۲۴) مقاله‌ای با عنوان پیش‌بینی تنگی عروق کرنری به وسیله شبکه‌های عصبی مصنوعی منتشر شد که بیشترین تطبیق را با موضوع تحقیق حاضر داشت. داده‌های این تحقیق که از آنژیوگرافی از بیماران ثبت‌شده، شامل ۱۴ متغیر ورودی (سن، جنس، نژاد، سیگار کشیدن، فشارخون، دیابت، شاخص توده بدنی) و برخی عوامل خطر دیگر بود و متغیر خروجی تنگ بودن یا نبودن عروق کرنری(CAS: Coronary Artery Stenosis) بوده است. نتایج این تحقیق که از شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) استفاده کرده بود در بهترین حالت حساسیت را برابر ۱ و اختصاصیت را برابر ۰/۴۷ارزیابی کرده بود. همچنین تحقیق انجام‌شده در ایران (۲۸) با عنوان

Archive of SID
www.SID.ir

کاربرد شبکه عصبی مصنوعی جهت ارزیابی بیماری عروق کرنری قلب که از شبکه عصبی مصنوعی(MLP) با الگوریتم پس انتشار با ساختار NN(14,12,1) استفاده کرده بود پس از ۱۵۰۰ دور آموزشی حساسیت و اختصاصیت را به ترتیب ۰/۹۶و ۱ گزارش کرده بود.

علت انتخاب شبکه عصبی برای پیش‌بینی در این پژوهش مزایایی است که نسبت به روش‌های کلاسیک آماری دارد که در زیر به بعضی موارد آن اشاره‌شده است:

روش‌های کلاسیک آماری برای پیش‌بینی به‌شدت به وجود خطا وابسته هستند و از درک و یافتن روابط ریاضی میان داده‌ها عاجز هستند (۱۳). این در حالی است که اساس کار شبکه عصبی مصنوعی بر پایه یافتن روابط ریاضی میان داده‌ها است و بررسی روابط میان متغیرها تحت تأثیر خطا قرار نمی‌گیرد. علاوه بر این در روش‌های کلاسیک آماری تنها امکان بررسی رابطه میان یک یا دو متغیر مستقل و وابسته وجود دارد درحالی‌که در شبکه عصبی مصنوعی تعداد زیادی از متغیرهای مستقل و وابسته مورد مطالعه قرار گرفته و رابطه میان آن‌ها بررسی می‌شود (۱۳).

نتیجه‌گیری

پیاده‌سازی‌های این مقاله در استفاده از شبکه عصبی احتمالی نشان داد که این شبکه می‌تواند طی یک دور ایجاد گردد که زمان خیلی کمی نسبت به ۱۵۰۰ دور آموزشی در مورد مشابه منبع نیاز دارد. در واقع شبکه پیاده‌سازی شده در این مقاله به خاطر سرعت زیاد و تعمیم‌پذیری خوب آن نسبت به شبکه‌های عصبی پس انتشار برتر است. آموزش مورد نیاز برای این شبکه متفاوت و خیلی سریع‌تر از الگوریتم آموزش مورد نیاز برای شبکه عصبی مصنوعی با الگوریتم پس انتشار است. در این شبکه فرایند آموزش شامل یک مرحله است و هیچ‌گونه تکراری برای تعدیل وزن‌ها نیاز نیست که این برخلاف روش پس انتشار است که نیاز به تکرارهای زیادی برای تعدیل وزن‌ها دارد. نتایج نشان می‌دهد که شبکه به گونه‌ای مدیریت شده است که می‌تواند عکس‌العمل مناسبی به داده‌های غیر از داده‌های آموزشی نشان دهد، به عبارت دیگر شبکه دارای عمومیت مناسبی است.

در این تحقیق، پارامترهای حساسیت و اختصاصیت به کمک این شبکه به ترتیب معادل عدد ۱ و ۰/۹۴بوده است و این امر نشان می‌دهد که شبکه با دقت مناسبی طبقه‌بندی را انجام داده است. از دلایل بالا بودن حساسیت و اختصاصیت در مقاله حاضر می‌توان به نرمال کردن بردار ورودی و انتخاب مناسب شبکه عصبی برای این منظور اشاره کرد. این نتیجه بسیار حائز اهمیت است زیرا از عوارض و آسیب‌های احتمالی آنژیوگرافی برای بیمارانی که نیاز به آن ندارند جلوگیری می‌شود. همچنین می‌تواند بیمارانی را که واقعاً به این اقدامات تشخیصی نیاز دارند در سریع‌ترین زمان و بیشترین دقت مشخص نماید.

References

1. American Heart Association. [On Line]. Available from:URL:http://www.heart.org/HEARTORG.
2. Zhang G, Patuwo B. Forecasting with Artificial Neural Networks: The State of the Art. International Journal of Forecasting 2004; 56 (1): 35–62.
3. Dunne RA, Wiley J, Inc S. A Statistical Approach to Neural Networks for Pattern Recognition. New Jersey: John Wiley &Sons Inc; 2007.
4. Livingstone DJ, Totowa NJ. Artificial Neural Networks Methods and Application. 1th Ed. Totowa, NJ: Hummana Press; 2008.
5. Zini G, d'Onofrio G. Neural network in hematopoietic malignancies. Clin Chim Acta 2003;333(2):195-201.
6. Sun G, Dong X, Xu G. Tumor Tissue Identification Based on Gene Expression Data using DWT Feature Extraction and PNN Classifier. Neurocomputing 2006; 69(4-6): 387–402.
7. Sargent DJ. Comparison of artificial neural networks with other statistical approaches: results from medical data sets. Cancer 2001; 91(8suppl): 1636-42.
8. Dreiseitl S, Ohno-Machado L. Logistic regression and artificial neural network classification models: a methodology review. J Biomed Inform 2002; 35(5-6): 352-9.

Archive of SID
www.SID.ir

9.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): 487-95.
10. Wasserman P. Advanced Methods in Neural Computing. New York: Van Nostrand Reinhold; 1993.
11. Specht D. Probabilistic Neural Networks for Classification, Mapping, or Associative Memory. IEEE International Conference on Neural Networks 1988; 1: 525–32.
12. Kalatzis I, Liappas I. Design and Implementation of a Multi-PNN Structure for Discriminating One-Month Abstinent Heroin Addicts From Healthy Controls Using the P600 Component of ERP Signals. Pattern Recognition Letters 2005; 26: 1691–700.
13. SamadiS, Nazifi M, Abbaspour S. Estimating the Duration of Treatment and Hospitalization CostsUsing Neural Network Approach. Health Information Management 2012; 8(7):948-57. [In Persian]
14. Ghavam-Zadeh M. Forecasting in contracts organized markets. [Thesis]. Tehran: Iran, Tehran University; 1998.[In Persian]
15. Cho G, Kim T, Seo Y, Chan M. Integrated machining error compensation method using OMM data and modified PNN algorithm. International Journal of Machine Tools & Manufacture 2006; 46(12-13): 1417-27.
16.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.
17.Menhaj MB. Computational intelligence, fundamentals of neural network. 2nd Ed. Tehran :Amir Kabir University Press; 2008. [In Persian]
18. 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.
19. 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.
20. Itchhaporia D, Snow PB, Almassy RJ, Oetgen WJ. Artificial neural networks: Current status in cardiovascular medicine. J Am Coll Cardiol 1996; 28(2): 515-21.
21. 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; 160-4.
22. 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.
23. Ohno-Machado L, Musen MA. Sequential versus standard neural networks for pattern recognition: An example using the domain of coronary heart disease. Comput Biol Med 1997; 27(4): 267-81.
24. 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.
25. 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): 643-51.
26. Harrison RF, Kennedy RL. Artificial Neural Network Models for Prediction of Acute Coronary Syndromes Using Clinical Data From the Time of Presentation. Ann Emerg Med 2005; 46(5): 431-9.
27. 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): 319-31.
28. Mohammadpour R, Esmaeili M, Ghaemia A, Esmaeili J. Application of Artificial Neural Network for Assessing Coronary Artery Disease. J Mazandaran Univ Med Sci 2012; 21 (86):9-7. [In Persian]

Archive of SID

www.SID.ir

Presenting an Intelligent System for Diagnosis of Coronary Heart Disease By Using Probabilistic Neural Network*

Asieh Khosravanian[1], Sayed Saeed Ayat[2]

Original Article

Abstract

Introduction: Selecting an appropriate method for modeling and analyzing health data based on available data is very crucial. This study was conducted according to Probabilistic Neural Network (PNN) to detect if the coronary artery is closed or not.

Methods: This study was diagnostic and it was implemented on patients of Kowsar Hospital in Shiraz, Iran who were exposed to Coronary artery angiography in September 2013. The number of population was calculated based on related formulation and the division of neurons in hidden layer by error rate of 0.1. Therefore, 152 patients were randomly selected for this research. In these implementations, 85% of data was used for training phase of network and 15% for the test phase. In this study, Probabilistic Neural Network (PNN) was used for prediction of coronary artery disease. The proposed neural network was implemented through facilities and functions of MATLAB software (7.12.0version) and simulated by a system of core i5, 2.4 GHz processor and 4GB memory and windows7 as operating system.

Results: Performance indicators of this system were sensitivity and specificity. The presented system performance on the basis of these indicators was achieved1 and 0.94, respectively. Ultimately, the designed and implemented system could confirm its superiority for diagnosis of patients of coronary artery according to similar studies.

Conclusion: The results of this research indicated that in the studied population, probabilistic neural networks could achieve more accurate diagnosis for coronary heart disease comparing other studied neural networks. Due to high specificity and sensitivity of the system, it can prevent the possible side effects and injuries of angiography for the patients who don't need it. And also, it can distinguish the patients who really need diagnostic actions in the least time and the most accuracy.

Keywords: Coronary Artery Disease; Forecasting; Neural Networks (Computer).

Received: 30 Nov, 2013 Accepted: 30 Jun, 2014

Citation: 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):13.

Archive

*- This article is resulted of an independent research.

1- MSc student, Computer Engineering, Department of Computer Engineering and Information Technology, Payame Noor University, Tehran, Iran (Corresponding Author) Email: khosravanian.a@gmail.com

2- Associate Professor, Computer Engineering Department of Computer Engineering and Information Technology, Payame Noor University, Tehran, Iran

www.SID.ir