

## مقایسه قدرت پیش بینی شبکه عصبی مصنوعی با رگرسیون لجستیک چندگانه در تفکیک بیماران دیابتی رتینوپاتی از غیر رتینوپاتی

اقبال زندکریمی: کارشناس ارشد آمار زیستی، دانشگاه علوم پزشکی کرمانشاه، کرمانشاه، ایران. [eghbal1363@gmail.com](mailto:eghbal1363@gmail.com)  
\* علیرضا افشاری صفوی: دانشجوی دکتری آمار زیستی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران (\*نویسنده مسئول). [ar8as12@Gmail.Com](mailto:ar8as12@Gmail.Com)

تاریخ پذیرش: ۹۳/۶/۱۲

تاریخ دریافت: ۹۲/۲/۲

### چکیده

**زمینه و هدف:** بیماری دیابت شیوع بالایی در جامعه دارد و در صورت عدم کنترل، دارای عوارض جبران ناپذیری است و باعث آسیب زدن به چشم و نابینایی می‌شود. هدف این مطالعه مقایسه کارایی و قدرت پیش بینی مدل آماری رگرسیون لجستیک چندگانه با مدل شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) در تفکیک بیماران دیابتی دارای رتینوپاتی از دیابتی بدون رتینوپاتی است.

**روش کار:** نمونه‌ها از بین ۱۶۰۰۰ پرونده بیماران دیابتی مرکز تخصصی دیابت کرمانشاه جمع‌آوری گردید. ۱۵۰ نفر مورد و ۱۵۰ نفر کنترل وارد مطالعه شدند. اطلاعات دموگرافیک، BMI، FBS، HbA1c، فشارخون، چربی خون (TC) و مدت زمان ابتلا، وضعیت سیگاری بودن و سن بیماران در دو چک لیست جداگانه از پرونده بهداشتی بیماران گردآوری شد. به منظور شناسایی ریسک فاکتورها، مدل‌های شبکه عصبی مصنوعی و رگرسیون لجستیک چندگانه بر داده‌ها برازش داده شد و از نمودار راک جهت مقایسه قدرت پیش بینی مدل‌ها استفاده شد. همچنین حساسیت و ویژگی دو مدل با هم بررسی گردیدند و با توجه به معیارهای (سطح زیر منحنی راک، حساسیت و ویژگی) مدل برتر معرفی گردید.

**یافته‌ها:** قدرت پیش بینی رگرسیون لجستیک و MLP به ترتیب برابر ۰/۷۳ و ۰/۸۳ برآورد شد. همچنین مدل MLP دارای ویژگی (۸۰٪) و حساسیت (۸۵٪) بالاتری برخوردار بود. متغیرهای FBS ( $p=0/029$ )، BMI ( $p<0/0001$ )، سن ( $p<0/0001$ ) و مدت زمان ابتلا به دیابت ( $p<0/0001$ ) در مدل رگرسیون لجستیک همچنین متغیرهای سن، FBS، مدت ابتلا به دیابت، BMI، وضعیت سیگاری بودن، TC با توجه به روش Wrapper، با قدرت پیش بینی ۸۳٪ در MLP معنی دار بودند.

**نتیجه‌گیری:** در این مطالعه مدل MLP در تفکیک بیماران دیابتی دارای رتینوپاتی از دیابتی بدون رتینوپاتی قدرت بیشتری نشان داد. بنابراین در جوامعی که گروه‌های مورد و کنترل قرابت زیادی دارند (همانند این مطالعه که هردو گروه از میان دیابتی‌ها انتخاب گردید)، کشف تفاوت آن‌ها نیازمند روش‌های نیرومندتر مانند شبکه عصبی مصنوعی است. بنابراین استفاده از این روش‌ها در مطالعات پزشکی توصیه می‌گردد.

**کلیدواژه‌ها:** رگرسیون لجستیک، شبکه عصبی مصنوعی پرسپترون چند لایه، دیابت نوع دو، رتینوپاتی، منحنی راک

### مقدمه

کاربرد زیادی در مدل‌های Biomedicine دارند، به طوری که در Pubmed ۴۵۶۴۶ مقاله از رگرسیون لجستیک و ۸۰۱۵ مورد از شبکه عصب مصنوعی (ANN) استفاده نموده‌اند (۲). با توجه به محدودیت‌ها و مزیت‌های مدل‌های کلاسیک (رگرسیون لجستیک) و مدل‌های نوین (شبکه عصبی مصنوعی) در این مطالعه به انتخاب مدل برتر جهت پیش بینی ریسک فاکتورهای بیماری رتینوپاتی دیابتی می‌پردازیم.

دیابت یک بیماری با شیوع بالا بوده، عوارض آن به طور اولیه موجب آسیب به سیستم عروقی می‌شود که این عوارض باعث افزایش مرگ و میر و ناتوانی در افراد دیابتی می‌شود (۳). طبق آخرین گزارشات WHO شیوع دیابت از

در نظر گرفتن یک توزیع پیش فرض مانند توزیع نرمال برای متغیرهای پاسخ، خطی بودن رابطه‌ی پیشنهادی، یکسان بودن واریانس خطاها از جمله محدودیت‌های مدل‌های کلاسیک هستند به علاوه هیچ یک از این روش‌ها قابلیت مدل بندی روابط پیچیده‌ی غیرخطی و اثر متقابل درجه بالا ندارند. شبکه عصب مصنوعی برای تشخیص، طبقه بندی و پیش بینی که در آنها روابط معمولاً به شکل غیرخطی هستند مورد استفاده قرار می‌گیرد (۱). همچنین مدل‌های کلاسیک (رگرسیون لجستیک) به دلیل استفاده و تحلیل آسان و همچنین ارائه ضرایبی چون نسبت بخت، برای بیان میزان تاثیر هر متغیر مستقل، در مدل

رتینوپاتی در بیماران دیابتی نوع ۲ تازه تشخیص داده شده شیوع و عوامل خطر آن توسط صفایی و همکاران انجام گرفت. این مطالعه در فاصله سال‌های ۱۳۸۰ تا ۱۳۸۳ بر روی ۷۱۰ بیمار دیابتی تازه شناخته شده نوع ۲ در مرکز تحقیقات غدد و متابولیسم اصفهان انجام گرفت که در آن ۲۸۶ مرد و ۴۲۴ زن بیمار مورد بررسی قرار گرفتند که از این تعداد ۹٪ مبتلا به رتینوپاتی بودند (۹/۸٪ مردان و ۸/۵٪ زنان). در تجزیه و تحلیل نهایی این طرح که با استفاده از رگرسیون لجستیک انجام گرفت نمایه توده بدن و فشارخون دیاستولی و آلبومین ادرار ۲۴ ساعته به عنوان عوامل خطر تعیین کننده رتینوپاتی شناخته شدند (۱۳).

در سال ۹۰ مطالعه‌ای تحت عنوان مقایسه شبکه عصبی و رگرسیون لجستیک در پیش بینی پاسخ های دو حالتی مطالعات پزشکی که توسط اکبر بیگلریان و همکاران انجام گرفت. در این مطالعه از داده‌های ۶۳۹ بیمار مبتلا به سرطان معده، گردآوری شده توسط مرکز تحقیقات گوارش کبد دانشگاه علوم پزشکی شهید بهشتی طی سالهای ۱۳۸۱-۱۳۸۵ استفاده شد. مرحله بیماری به عنوان متغیر وابسته در نظر گرفته شد. ارزیابی شبکه بر اساس ملاک حداقل مربعات خطای پیشبینی صورت گرفت و مقایسه پیش‌بینی‌های مدل نهایی شبکه با مدل رگرسیونی با استفاده از شاخص هماهنگی و منحنی راک صورت پذیرفت. سطح زیر منحنی مشخصه عملکرد مدل شبکه عصبی برابر ۰/۷۲۵ و مدل رگرسیون لجستیک برابر ۰/۶۹۹ بدست آمد. همچنین صحت پیشبینی کل برای مدل شبکه عصبی و رگرسیونی به ترتیب برابر ۰/۷۷۱ و ۰/۷۱ محاسبه گردید. همچنین اختلاف پیش بینی دو مدل معنی دار شد ( $p=0/002$ ). صحت پیش‌بینی شبکه در تشخیص مرحله‌ی بیماری سرطان معده بیشتر از مدل رگرسیونی لجستیک به دست آمد و لذا این مدل برای تشخیص مرحله‌ی بیماری پیشنهاد گردید (۱۴).

همچنین در سال ۱۳۹۰ در مطالعه‌ای تحت عنوان کاربرد شبکه عصبی مصنوعی جهت ارزیابی

۴٪ در سال ۱۹۹۵ به ۵/۴٪ در سال ۲۰۲۵ خواهد رسید (۴). بنابراین گرچه امروزه دیابت به عنوان مشکل کشورهای پیشرفته مطرح می‌شود اما تأثیر این بیماری در کاهش امید به زندگی در کشورهای در حال توسعه بیشتر است (۵). از طرفی شیوع رتینوپاتی دیابتی در بدو تشخیص بیماری ۱۵/۲٪ و در بیماران دیابتی با سابقه کمتر از ۱۵ سال دیابت ۷۷/۸٪ بوده است. با وجود تأثیر مدت زمان بیماری در رتینوپاتی شیوع آن در بیماران دیابتی تازه تشخیص داده شده قابل ملاحظه است و در مطالعات مختلف از ۵ تا ۳۰٪ گزارش شده است (۶-۹).

رتینوپاتی یکی از عوارض بیماری دیابت است. این بیماری رابطه قوی با مدت زمان ابتلا به بیماری رادارد (۱۰). دیابت علت اصلی نابینایی در سنین ۲۰ تا ۷۴ سالگی است، از طرف دیگر احتمال بروز نابینایی مورد تأیید در افراد مبتلا به دیابت ۲۵ برابر بیشتر از افراد غیر دیابتی است (۱۱).

سیر طبیعی رتینوپاتی دیابتی معمولاً از یک الگوی منظم و قابل پیش بینی پیروی می‌کند. در درازمدت میزان بالای قند خون موجب اختلال عروقی اندوتلیال (Endothelial) شده که منجر به تخریب سلول‌های اندوتلیال و پری سیت‌ها (pericytes) می‌شود. سپس شبکه دچار آنوریسم‌های کوچک (Microaneuysms) خونریزی داخل شبکه‌ای و ایسکمی موضعی در شبکه می‌شود که در این مرحله، رتینوپاتی به عنوان رتینوپاتی دیابتی غیر تکثیری (No proliferative Diabetic Retinopathy) دسته بندی می‌شود. ادم ماکولا (Macular Edema) منجر به کاهش بینایی در بیماران دیابتی شده و در هر مرحله‌ای از رتینوپاتی می‌تواند اتفاق بیفتد. با پیشرفت رتینوپاتی رگ‌های بیشتر آسیب می‌بینند و گاهی عروق آسیب دیده شبکه باعث افزایش نفوذپذیری عروق میشود که این مسئله منجر به تجمع مایعات و یا چربی در شبکه می‌شود که از نظر کلینیکی با افتالموسکوپ مستقیم قابل مشاهده است (۱۲).

در سال ۱۳۸۵ یک مطالعه تحت عنوان

این مطالعه بسیار شبیه به هم بوده و از بین بیماران دیابتی انتخاب شده اند) دارد. با توجه به اینکه ارائه ی مدل مناسب جهت مطالعات مشابه لازم و ضروری است بنابراین ضرورت این مطالعه در آن است که با توجه به محدودیتها و مزایای هرمدل، مدلی با بیشترین قدرت و حساسیت جهت پیش بینی را پیشنهاد نماییم همچنین می توانیم متغیرهایی معنی دار در مدل برتر (از لحاظ قدرت پیش بینی) رابه عنوان ریسک فاکتورهای ابتلا به رتینوپاتی در بیماران مبتلا به دیابت معرفی نمود.

### روش کار

مطالعه حاضر از نوع مورد-شاهدی وبه صورت تحلیلی- توصیفی انجام گرفت. جامعه مورد مطالعه را پرونده بیماران دیابتی دارای رتینوپاتی (گروه مورد) و پرونده بیماران دیابتی بدون رتینوپاتی (گروه کنترل) که مراجعه منظم به مرکز تخصصی دیابت کرمانشاه داشت تشکیل می دهد. حجم نمونه ی مورد نیاز برای این مطالعه ۱۲۰ نفر برای هر گروه تعیین شد که به منظور جلوگیری از کاهش توان مطالعه در برخورد با داده های گمشده احتمالی نمونه ی مورد نیاز برای هر گروه ۱۵۰ نفر در نظر گرفته شد. در این مطالعه با استفاده از روش نمونه گیری تصادفی ساده ۱۵۰ بیمار دیابتی نوع ۲ دارای رتینوپاتی را از میان پرونده های موجود انتخاب و ۱۵۰ بیمار دیابتی بدون رتینوپاتی به عنوان گروه شاهد از میان پرونده های افراد دیابتی بدون رتینوپاتی انتخاب شدند. ابزار جمع آوری داده ها دو چک لیست شامل اطلاعات دموگرافیک (سن و جنس)، شاخص توده بدن (BMI)، قندخون ناشتا (FBS)، HbA1c، فشارخون، چربی خون (TC) و مدت زمان ابتلا به دیابت، وضعیت سیگاری بودن بود که از روی پرونده بیماران دیابتی دارای رتینوپاتی و دیابتی فاقد رتینوپاتی تکمیل گردید. آموزش های لازم جهت تکمیل چک لیست ها به منظور جلوگیری از تورش در جمع آوری اطلاعات به افرادی که اطلاعات را جمع آوری می نمودند داده شد و جهت هاهنگی تاکید شد از

بیماری عروق کرونری قلب 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 (۱۴-۱۲-۱) تابع انتقال سیگموئید و ۱۵۰۰ سیکل آموزشی بر اساس ۸۰ درصد داده های موجود طراحی و آموزش داده شد. این روش به علت ویژگی بالا می تواند از عوارض و آسیب های احتمالی آنژیوگرافی در بیمارانی که نیاز به آن ندارند جلوگیری نماید. از طرف دیگر می تواند به علت حساسیت بالا در بیمارانی که به طور واقعی به این اقدامات تشخیصی و درمانی نیاز دارند را جدا نماید (۱۵). در سال ۱۳۸۷ مطالعه ای تحت عنوان عوامل موثر بر رتینوپاتی دیابتی در بیماران مبتلا به دیابت نوع ۲ انجام گرفت تعداد ۸۰۰ پرونده از کلینیک فوق تخصصی دیابت بیمارستان ولی عصر بیرجند مورد بررسی قرار گرفت اطلاعاتی شامل سن، جنس، طول مدت بیماری، وجود عارضه چشمی و نوع آن، وضعیت چربی خون، قندخون ناشتا، وسطح هموگلوبین A1C مورد بررسی قرار گرفت، پس از تجزیه و تحلیل همبستگی مثبت بین رتینوپاتی ومدت زمان ابتلا به دیابت ( $p < 0.001$ )، سن ( $p < 0.002$ )، جنس مرد ( $p < 0.002$ ) و سطوح بالای قندخون ناشتا ( $p < 0.003$ ) و سطوح پایین هموگلوبین ( $p < 0.001$ ) وجود داشت ولی بین رتینوپاتی وسطح چربی خون ارتباطی وجود نداشت. بنابراین نتیجه گرفتند که مدت زمان ابتلا به دیابت، سن، جنس (مرد) و سطوح بالای قندخون ناشتا وسطوح پایین هموگلوبین موجب افزایش بروز رتینوپاتی در بیماران دیابتی نوع ۲ می شود ولی وضعیت چربی خون تاثیر معنی داری در ابتلا به رتینوپاتی ندارد (۱۶).

هدف این مطالعه این بود که دریابیم کدامیک از دو مدل رگرسیون لجستیک و شبکه عصبی مصنوعی قدرت بیشتری در پیش بینی بیماری رتینوپاتی دیابتی را با توجه به قرابت دو گروه مورد بررسی (گروه مورد وشاهد مورد بررسی در

متغیر مستقل  $X$  است اگر هر کدام از ریسک فاکتورها در مقایسه دو گروه (مورد و شاهد) معنی دار شد در رابطه بالا وارد می شود بطوریکه متغیر با یک ضریب  $\beta$  در مدل تاثیر دارد.

**شبکه عصبی مصنوعی پرسپترون چندلایه (MLP):** شبکه عصبی مصنوعی پرسپترون نوعی از شبکه عصبی برمبنای یک واحد محاسباتی به نام پرسپترون ساخته می شود. پرسپترون برداری از ورودیهای با مقادیر حقیقی را گرفته و یک ترکیب خطی از این ورودیها را محاسبه می کند. اگر حاصل از یک مقدار آستانه بیشتر بود خروجی پرسپترون برابر با ۱ و در غیر اینصورت ۰ خواهد بود.


شبکه عصب مصنوعی پرسپترون چندلایه به دلیل قابلیت های باارزش موازی و یادگیری، عمدتاً به منظور حل مسائل پیچیده مورد استفاده قرار می گیرد. فرآیند یادگیری در این شبکه ها از طریق الگوریتم های یادگیری خاصی صورت می گیرد که با تنظیم وزنها موجود در ارتباطات بین نورونها، اقدام به آموزش شبکه می کنند (۱۸). شبکه عصبی به طور معمول دارای سه لایه ورودی، میانی (مخفی) و خروجی است. که در آن هر لایه ورودی به یک یا تعداد بیشتری لایه میانی مرتبط است و لایه میانی نیز به لایه خروجی مرتبط است. هر لایه دارای وزنی است که بیانگر میزان تاثیر دو نورون بر یکدیگر است که باید برآورد شوند. برآورد وزن ها (پارامترها)، در مرحله آموزش (یادگیری) شبکه صورت می گیرد. در

پرونده ها با اطلاعات کامل استفاده گردد و از آخرین اطلاعات بیماران استفاده گردد. پس از تکمیل چک لیست ها و ورود اطلاعات در رایانه، تجزیه و تحلیل داده ها با استفاده از SPSS نسخه ۱۶ و نرم افزار MATLAB نسخه ۲۰۰۹ انجام شد. جهت استخراج مدل مناسب در شبکه عصبی مصنوعی پرسپترون چند لایه از روش wrapper استفاده گردید که در این روش با توجه به اینکه در این مطالعه هشت متغیر مورد بررسی قرار گرفتند ۲۵۶ حالت (۲<sup>۸</sup>) بررسی گردید و مدل برتر از بین ۲۵۶ حالت انتخاب و با مدل رگرسیون لجستیک از لحاظ حساسیت، ویژگی و سطح زیر منحنی راک مقایسه گردید.

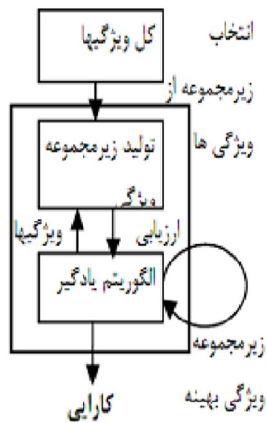
رگرسیون لجستیک یکی از ابزارهای آماری است که به منظور مدل سازی و تحلیل داده ها از آن استفاده می شود. رگرسیون لجستیک دارای شکل کلی زیر است:

$$\text{Log}\left(\frac{\pi}{1-\pi}\right) = \alpha + \sum \beta \chi \quad (17)$$

$X$  بردار متغیرهای مستقل شامل شاخص توده بدن (BMI)، قند خون ناشتا (FBS)، Hba1c، فشارخون، چربی خون (TC) و مدت زمان ابتلا، وضعیت سیگاری بودن و سن بیماران را شامل می شود است. همچنین  $\beta$  بردار ضرایب برآورد شده مدل برای متغیرهای مستقل است و  $\pi$  احتمال پیامد یا واقعه مورد نظر تحت وجود



شکل ۱- ساختار شبکه عصبی مصنوعی



شکل ۲- روش انتخاب متغیر با استفاده از روش wrapper

در این روش جهت انتخاب ویژگی از الگوریتم ورودی (induction algorithm) استفاده می‌شود. به این صورت که کلیه حالت‌هایی که متغیرها وارد مدل می‌شوند در نظر گرفته می‌شود. برای  $n$  متغیر تعداد  $2^n$  فضای بررسی داریم (۲۰).

روش wrapper نیازمند حجم بالای محاسبات است. مثلاً در این مقاله برای ۸ متغیر تعداد  $2^8 = ۲۵۶$  حالت بررسی شد اما علی‌رغم این عیب، این روش در مقابل over fitting قدرتمند است (۲۱).

ابتدا به منظور دستیابی به یک دید کلی از مشاهدات از آمار توصیفی ساده و نمودارهای آماری استفاده شد. نرمال بودن متغیرهای کمی سن و چربی خون (TC) و مدت زمان ابتلا با استفاده از آزمون کولموگروف-اسمیرنوف بررسی شد. ابتدا از مدل رگرسیون لجستیک به منظور شناسایی ریسک فاکتورها و ارزیابی دقت مدل در تفکیکی بیماران دیابتی از پره دیابتی استفاده شد. در این مدل انتخاب متغیرها به روش Forward LR انجام گرفت. در ادامه از مدل تحلیل ممیزی به منظور کشف ریسک فاکتورهای مهم و ارزیابی دقت این روش استفاده شد. انتخاب متغیرها در این مدل بر اساس روش Wilks' lambda بود و در پایان مدل شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) در نرم افزار MATLAB ورژن ۲۰۰۹ برآزش داده شد و منحنی راک (ROC Curve) برای سه مدل رسم

شکل شماره ۱ نمونه ای از شبکه عصبی مصنوعی با یک لایه ورودی (سه متغیر ورودی)، دو لایه میانی (با هشت گره) و یک لایه خروجی (با سه متغیر خروجی مثلاً یک بیماری با سه حالت خفیف، متوسط و شدید) را نشان می‌دهد.

شبکه عصب مصنوعی دارای دو جنبه اصلی است (۱) معماری (۲) یادگیری معماری: شبکه عصبی مصنوعی مورد نظر ما پرسپترون چندلایه (MLP) است که در مقایسه با سایر روش‌های دیگر بهتر عمل می‌کند (۱۹). اگر  $r$  تعداد ورودی‌ها و  $s_1$  تعداد نرون‌های لایه میانی و  $s_2$  تعداد نرون‌های لایه خروجی باشد آنگاه چنین شبکه ای رابه صورت زیر نشان می‌دهند:

$$NN(r-s_1-s_2)$$

خروجی تمامی واحدهای پردازش، از هر لایه، به عنوان ورودی به تمام واحدهای پردازش لایه بعدی داده می‌شوند. واحدهای پردازش در لایه ورودی همگی خطی هستند ولی در لایه‌های مخفی خصوصاً لایه خروجی از نرون‌های غیر خطی، با تابع تانژانت هیپربولیک و یا سیگموئید و یا هر تابع غیرخطی پیوسته و مشتق پذیر دیگری می‌توان استفاده کرد (۱۵).

یادگیری در شبکه‌های عصبی به ۲ صورت زیر است:

(۱) تحت نظارت (supervised)

(۲) بدون دخالت انسان (unsupervised)

یادگیری در شبکه‌های عصبی رایج به شکل supervised است. در واقع کار شبکه های عصبی مانند یادگیری کودکان است. بانسان دادن اشیا ماهیت هر شی برای کودک مشخص می‌شود.

مدل‌های شبکه عصبی مصنوعی به مدل‌های Black box معروف‌اند و قادر به ارائه ضرایب  $\beta$  و همانند مدل‌های کلاسیک نیستند. بنابراین نمی‌دانیم میزان تاثیر هر متغیر در مدل چقدر است؟ اما تعدادی روش انتخاب ویژگی وجود دارد. یکی از این روش‌ها Wrapper است. در تصویر شماره ۲ روش کار مشخص شده است:

و سطح زیر منحنی راک آن‌ها مقایسه گردید. همچنین میزان حساسیت و ویژگی برای سه مدل محاسبه گردید.

### یافته‌ها

از نمونه‌ی بدست آمده، ۱۵۰ نفر (۵۰٪) بیماران دیابتی دارای رتینوپاتی ۱۵۰ نفر (۵۰٪) دیابتی فاقد رتینوپاتی بودند. از این تعداد ۱۸۰ نفر (۶۰٪) زن و ۱۲۰ نفر (۴۰٪) مرد در مطالعه حضور داشتند. میانگین سنی در گروه رتینوپاتی  $48/68 \pm 11/56$  و میانگین سنی در گروه بیماران دیابتی فاقد رتینوپاتی  $55/41 \pm 11/08$  سال بود. جدول ۱ درصد فراوانی هر یک از متغیرهای کیفی را برای گروه دیابتی فاقد رتینوپاتی و بیماران دیابتی دارای رتینوپاتی را نشان می‌دهد. مدل رگرسیون لجستیک برای چهار متغیر پیشگوی سن، FBS (با سه سطح)، BMI (با سه سطح) و مدت زمان ابتلا به دیابت برازش داده شد. سطح اول هر متغیر کیفی به عنوان طبقه مرجع برای تحلیل در نظر گرفته شد.

$$\text{Logit}[p (y=1)] = 1/463(\text{constant}) + 1/699 (BMI_1) + 0/131 (\text{modatebtele}) + 1/034 (FBS_1) - 0/073 (\text{Age})$$

FBS<sub>1</sub>: میزان قند خون ناشتا کمتر از ۱۰۰

BMI<sub>1</sub>: شاخص توده بدنی کمتر از ۲۵

با برازش مدل رگرسیون لجستیک بر روی مشاهدات، متغیرهای پیشگوی چهار مرحله وارد مدل شدند. آزمون هاسمر-لمشو با  $(p\text{-value}=0/046)$  در مرحله آخر صحت برازش مدل را نشان داد. همچنین آماره Nagelkerke R square = ۰/۳۶۷ نشان می‌دهد که مدل تا چه اندازه توانسته تغییرات مربوط به متغیر وابسته (دیابتی بدون رتینوپاتی - دیابتی دارای رتینوپاتی) را تبیین کند. متغیرهایی که توسط مدل رگرسیون لجستیک به عنوان ریسک فاکتور شناخته شدند شامل سن، مدت ابتلا به

دیابت، FBS و BMI بودند (جدول ۲). متغیرهای کنترل دیابت با  $(p=0/196)$ ، فشار خون با  $(p=0/052)$  و چربی خون با  $(p=0/219)$  و وضعیت سیگاری بودن  $(p=0/158)$  در مدل معنادار نبودند. اطلاعات مربوط به برآورد پارامترهای مدل در جدول ۲ نمایش داده شده است. قدرت مدل در تفکیک بیماران دیابتی از پره دیابتی  $0/73/3$  برآورد گردید. برای تحلیل ممیزی آزمون لاندای ویلکز با  $(p < 0/0001)$  معناداری مدل را نشان داد. همچنین آماره Box's M با  $(p < 0/0001)$  همگنی واریانس‌ها را در دو گروه را تایید نمی‌کند. تحلیل طی پنج گام انجام گرفت که در انتهای گام پنجم، متغیرهای سن و قند خون ناشتا FBS، شاخص توده بدن (BMI)، فشارخون و مدت ابتلا به بیماری دیابت در مدل باقی ماندند. متغیرهای کنترل قند خون، چربی خون (TC) و وضعیت سیگاری بودن بر اساس آماره لاندای ویلکز مجوز ورود به مدل را نگرفتند. تابع ممیزی خطی فیشر برای تفکیک بیماران دیابتی از پره دیابتی بصورت زیر بدست آمد.

$$\hat{y} = -3.709 - 0.665 (\text{مدت ابتلا به دیابت}) +$$

$$0.822(BMI) - 0.35(HT) +$$

$$0.459(FBS) + 0.058(\text{سن})$$

هر مشاهده‌ی جدید را می‌توان با قرار دادن مقادیر خواسته شده در تابع فوق به یکی از گروه های دیابتی یا پره دیابتی منسوب کرد. همچنین قدرت مدل در تفکیک بیماران دیابتی دارای رتینوپاتی از بیماران دیابتی فاقد رتینوپاتی  $0/70$  برآورد گردید. نتایج مربوط به حساسیت و اختصاصیت مدل در جدول ۳ آمده است.

بر اساس اطلاعات ارائه شده در جدول ۳ مدل شبکه عصبی مصنوعی پرسپترون چندلایه دارای حساسیت (۸۵٪) بالاتری نسبت به رگرسیون لجستیک با حساسیت (۷۳/۳٪) و تحلیل ممیزی با حساسیت (۶۹/۳٪) شبکه عصبی مصنوعی از

جدول ۱- مقایسه توزیع فراوانی متغیرهای مورد بررسی در بیماران دیابتی با و بدون رتینوپاتی

متغیرها	دیابتی بدون رتینوپاتی تعداد (درصد)	دیابتی دارای رتینوپاتی تعداد (درصد)
جنس	مرد ۶۰(۴۰)	زن ۹۰(۶۰)
FBS	<۱۰۰ ۱۰۰-۱۲۵ >۱۲۵	۷(۴/۷) ۱۰(۶/۷) ۱۳۳(۸۸/۷)
HbA1C	>۶ ۴-۶ <۲۵	۱۲(۸) ۱۳۸(۹۲) ۳۲(۳۱/۳)
BMI	۲۵-۳۰ >۳۰	۶۶(۴۴) ۵۲(۳۴/۷)
سیگاری	بله خیر	۲۲(۱۴/۷) ۱۲۸(۸۵/۳)
HT	<۹۰ و <۱۲۰ <۹۰ و <۱۴۰ ≤۹۰ و ≤۱۴۰	۴۴(۲۹/۳) ۴۹(۳۲/۷) ۵۷(۳۸)

جدول ۲- متغیرهایی که حضورشان در مدل رگرسیون لجستیک معنی دار شناخته شده اند

متغیرها	ضرایب مدل	انحراف استاندارد	آماره والد	p
FBS < ۱۰۰	۱/۰۳۴	۰/۵	۴/۲۸۴	۰/۰۳۸
BMI < ۲۵	۱/۶۹۹	۰/۳۷۷	۲۰/۳۵۱	۰/۰۰۰۱
مدت زمان ابتلا به دیابت	۰/۱۳۱	۰/۰۲۵	۲۶/۸۴۲	<۰/۰۰۰۱
سن	۰/۰۷۳	۰/۰۱۳	۳۰/۱۵۶	<۰/۰۰۰۱
constant	۱/۴۶۳	۰/۶۹۶	۴/۴۱۳	۰/۰۳۶

می‌باشد. بر اساس این نمودار مدل شبکه عصبی مصنوعی پرسپترون چندلایه از قدرت بهتری در پیش بینی برخوردار می‌باشد.

### بحث و نتیجه‌گیری

به دلیل تشابه زیاد میان این گروه از بیماران دیابتی دارای رتینوپاتی با بیماران دیابتی فاقد رتینوپاتی، شناسایی این ریسک فاکتورها در جوامعی که رفتاری تقریباً مشابه دارند، نیازمند ابزار آماری دقیق و حساس می‌باشد. در این مطالعه به مقایسه‌ی کارایی و صحت تشخیصی مدل‌های پرکاربرد و معروف شبکه عصبی پرسپترون چند لایه و رگرسیون لجستیک پرداختیم.

در این مطالعه متغیرهای FBS(1) ( $p=0/038$ )، BMI (1) ( $p<0/0001$ )، سن ( $p<0/0001$ ) و مدت زمان ابتلا به بیماری دیابت ( $p<0/0001$ )

اختصاصیت بالاتری (۰/۸۰) نسبت به مدل رگرسیون لجستیک (۰/۷۳/۳) و تحلیل ممیزی (۰/۷۰) برخوردار بود.

متغیرهای سن (AGE)، قند خون ناشتا (FBS)، مدت ابتلا به دیابت، BMI، وضعیت سیگاری بودن، کلسترول (TC) با توجه به روش Wrapper، با قدرت پیش بینی ۰/۸۳ و ساختار ۱، ۱۰، ۲، ۶ در شبکه عصبی مصنوعی پرسپترون چندلایه از بین ۲۵۶ مدل معنادار بودند (جدول ۴).

شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) در کل از قدرت تشخیصی بالاتری برخوردار می‌باشد (۰/۸۳). نمودار ۱ سطح زیر منحنی راک را برای مدل رگرسیون لجستیک، تحلیل ممیزی و شبکه عصبی پرسپترون چندلایه را نشان می‌دهد. این مقادیر برای سه مدل به ترتیب برابر ۰/۸۱۲، ۰/۸۱۵ و ۰/۸۵

جدول ۳- صحت پیش بینی مدلها در تفکیک بیماران دیابتی دارای رتینوپاتی از بیماران دیابتی بدون رتینوپاتی

مدلها	مشاهده شده	پیش بینی شده			درصد
		دیابتی بدون رتینوپاتی	دیابتی بارتینوپاتی	کل	
رگرسیون لجستیک	دیابتی بدون رتینوپاتی	۱۱۰	۴۰	۱۵۰	۷۳/۳۰
	دیابتی بارتینوپاتی	۴۰	۱۱۰	۱۵۰	۷۳/۳۰
	کل	۱۵۰	۱۵۰	۳۰۰	٪۷۳/۳
MLP	دیابتی بدون رتینوپاتی	۳۴	۶	۴۰	۸۵/۰۰
	دیابتی بارتینوپاتی	۷	۲۸	۳۵	۸۰/۰۰
	کل	۴۱	۳۴	۷۵	۸۳/۰۰
تحلیل ممیزی	دیابتی بدون رتینوپاتی	۱۰۶	۴۴	۱۵۰	۷۰/۷
	دیابتی بارتینوپاتی	۴۶	۱۰۴	۱۵۰	۶۹/۳
	کل	۱۵۲	۱۴۸	۳۰۰	۷۰

جدول ۴- مقایسه قدرت پیش بینی در شبکه عصب مصنوعی پرسپترون چندلایه برای متغیرها

متغیر	بهترین مدل	قدرت پیش بینی (TCR)	ساختار شبکه	
سن	سن	۶۸	۱،۸،۴،۱	
	FBS	۶۸	۱،۴،۸،۲	
	HbA1C	۵۷/۳	۱،۱۰،۸،۲	
	BMI	۶۹/۳	۱،۲،۶،۲	
	وضعیت سیگاری بودن	۶۲/۶۷	۱،۸،۸،۱	
	HT	۵۸/۶۷	۱،۸،۲،۱	
	TC	۶۲/۶۷	۱،۶،۴،۲	
	مدت زمان ابتلا به بیماری	۷۲	۱،۴،۴،۱	
	دو متغیره	سن، FBS	۷۶	۲،۲،۸،۱
	سه متغیره	سن، FBS، Hba1c	۷۸/۶۷	۳،۶،۶،۲
چهار متغیره	سن، FBS، Hba1c، مدت زمان ابتلا	۸۰	۴،۴،۴،۱	
پنج متغیره	سن، FBS، Hba1c، مدت زمان ابتلا، HT	۸۱/۳۳	۵،۲،۸،۲	
شش متغیره	سن، FBS، Hba1c، مدت زمان ابتلا، HT، BMI	۸۳	۶،۲،۱۰،۱	
هفت متغیره	سن، FBS، Hba1c، مدت زمان ابتلا، HT، BMI، کلسترول	۸۱/۳۳	۷،۶،۲،۱	
هشت متغیره	همه متغیرها	۷۷/۳۳	۸،۶،۴،۲	


(۸۵٪) همچنین قدرت تشخیص مدل MLP در شناسایی افراد دیابتی از پره دیابتیک بیشتر از دو مدل دیگر بود (۸۳٪).  
به طور کلی شبکه‌های عصبی مصنوعی دارای مزایای زیر می‌باشند:

- ۱) اجازه وارد نمودن تعداد زیادی از متغیرها در مدل (۲۲)
  - ۲) عدم نیاز به پیش فرض‌هایی چون نرمال بودن و ... (۱۸)
  - ۳) پیدا کردن الگو علی‌رغم وجود داده‌های گمشده (۲).
- همچنین این مدل‌ها دارای محدودیت‌هایی نیز

در مدل رگرسیون لجستیک معنی دار بودند و متغیرهای BMI ( $p < 0.001$ )، سن ( $p < 0.001$ ) و مدت زمان ابتلا به بیماری دیابت ( $p < 0.001$ )، FBS ( $p < 0.001$ ) و فشارخون ( $p < 0.001$ ) در مدل تحلیل ممیزی معنی دار بودند.

همچنین متغیرهای سن (AGE)، قند خون ناشتا (FBS)، مدت ابتلا به دیابت، BMI، وضعیت سیگاری بودن، کلسترول (TC) با توجه به روش Wrapper، با قدرت پیش بینی ۸۳٪ در شبکه عصب مصنوعی پرسپترون چندلایه معنادار بودند. مدل MLP از حساسیت بیشتری برخوردار بود





Diagonal segments are produced by ties.

نمودار ۱- مقایسه سطح زیر منحنی راک در دو مدل

تک متغیرها را وارد مدل نمودیم مدت زمان ابتلا به دیابت با قدرت (۰.۷۲) و مدل (۱,۴,۴,۱)، بیشترین قدرت را داشت. در حالت یک، دو، سه، چهار تا ۸ متغیری، قدرت پیشگویی و ساختار شبکه به دست آمد که مدل با شش متغیر از همه قدرت بیشتری در پیشگویی داشت (جدول ۵).

همچنین مشکل بیش برآزشی (Over fitting) ناشی از تنظیم وزن‌ها برای در نظر گرفتن مثال‌هایی است که ممکن است با توزیع کلی داده‌ها مطابقت نداشته باشد. به عبارت دیگر اگر تعداد تکرارها برای تعیین وزن‌های مناسب زیاد باشد، باعث بیش برآوردی می‌شود و همان طور که بیان شد روش Wrapper در مقابل over fitting قدرتمند است (۲۱). اگر چه شبکه عصب مصنوعی می‌تواند داده‌ها را کمی بهتر نسبت به رگرسیون لجستیک برآزش دهد و همچنین مدل‌های قدیمی تر مانند رگرسیون لجستیک

هستند:

#### ۱) Over fitting (۲۳)

۲) ارائه ندادن ضرایبی همچون OR و  $\beta$  همانند مدل‌های رگرسیونی (۲۴).

با توجه به محدودیتهای ذکر شده، شبکه‌های عصبی مصنوعی که به جعبه سیاه (black box) معروف‌اند و استخراج اطلاعات از آن‌ها (همچون OR و  $\beta$ ) مشکل است، در حقیقت یک دید کلی از روابط ارائه می‌دهند. برای رفع محدودیت‌های ذکر شده برای شبکه عصبی مصنوعی، در این مطالعه از روش Wrapper (روش لحاف) (۲۳) استفاده شده و کلیه مدل‌های ممکن در MLP در نظر گرفته شد و بهترین مدل با بیشترین قدرت پیش بینی (۰.۸۳) در این مطالعه را که با حضور سن (AGE)، قند خون ناشتا (FBS)، مدت ابتلا به دیابت، BMI، وضعیت سیگاری بودن، کلسترول (TC) بدست آمد، برگزیدیم. وقتی تک

پاتی می‌باشند. همچنین حضور متغیرهای سن (AGE)، قند خون ناشتا (FBS)، مدت ابتلا به دیابت، BMI، وضعیت سیگاری بودن، کلسترول (TC) را با قدرت پیش بینی ۸۳٪ و ساختار ۶,۲,۱۰,۱ به عنوان بهترین مدل در MLP انتخاب شد. با توجه به اینکه سطح زیر منحنی راک شبکه عصبی مصنوعی پرسپترون چندلایه (۸۵٪) از مدل رگرسیون لجستیک (۸۱/۲٪) و تحلیل ممیزی (۸۱/۵٪) بیشتر است و حساسیت (۸۵٪) و ویژگی (۸۰٪) مدل MLP از مدل رگرسیون لجستیک و تحلیل ممیزی بیشتر بود. بنابر این مدل شبکه عصب مصنوعی قدرت بیشتری در تفکیک بیماران دیابتی دارای رتینوپاتی و بیماران دیابتی فاقد رتینوپاتی را دارد. بعلاوه همانند مدل‌های کلاسیک نیازمند هیچ پیش فرضی نیست. چون در جوامعی که گروه‌های مورد و کنترل قرابت زیادی دارند، کشف تفاوت‌ها نیازمند روش‌های نیرومندتری نسبت به مدل‌های کلاسیک (نظیر رگرسیون لجستیک و تحلیل ممیزی) است بنابراین استفاده از این روش‌های نوین (شبکه عصبی مصنوعی پرسپترون) در مطالعات پزشکی توصیه می‌گردد

### منابع

- Hagan MT. Neural network design, pws, USA; 1995. <http://facutly.nps.edu>
- Eftekhari B, Mohammad K, Eftekhari Ardebili H, Ghodsi M and Ketabchi E. Comparison of artificial neural network and logistic regression models for prediction of mortality in head trauma based on initial clinical data. BMC Medical Informatics and Decision Making. 2005; 5: 3 [Persian].
- Klein R, Klein BEK, Moss SE, Davis MD, Demets DL. The Wisconsin Epidemiologic Study of Diabetic Retinopathy II. Prevalence and risk of diabetic retinopathy when age at diagnosis is less than 30 years. Arch. Ophthalmol. 1984; 102: 520-26
- Porte D, Sherwin R. Ellenberg & Rifkins. Diabetes mellitus II. USA/ Appleton & large. 1997. p:931-971.566-570.
- Roglic G, Unwin N, Bennett PH, Mathers C, Tuomilehto J, Nag S, et al. The burden of mortality attributable to diabetes: realistic estimates for the

قدرت کمتری دارند، اما با توجه به این حقیقت که تفسیر متغیرها در مدل‌های لجستیک ساده تر است، بنابراین ترجیح داده می‌شود که از این مدل‌ها در کاربردهای بالینی استفاده گردد (۲۵).

در مطالعه کاظم نژاد و همکاران در سال ۲۰۰۸ که به منظور مقایسه شبکه عصبی پرسپترون و رگرسیون لجستیک در بررسی متابولیسم قند بیماران دیابتی انجام گرفت، مدل شبکه عصبی پرسپترون بر اساس سطح زیر منحنی راک از قدرت بیشتری در پیش بینی مدل برخوردار بود (۲۶).

در مطالعه ای که در سال ۲۰۱۰ توسط گارسیا و همکاران بر روی ۱۱۵ تصویر شبکیه‌ی بیماران دیابتی با هدف ارزیابی چهار مدل شبکه عصبی (MLP، SVM، RBF، و MV) و رگرسیون لجستیک در کشف خودکار ضایعه قرمز به منظور تشخیص و غربالگری رتینوپاتی انجام گرفت، مدل RBF با حساسیت ۱۰۰ درصد، اختصاصیت ۵۶ درصد و دقت ۸۳/۰۸ درصد بهترین نتایج را بدست داد (۲۷).

در مطالعه‌ی کالرا و همکاران در سال ۲۰۰۳ بر روی ۳۲۶۸ مرد به منظور کشف سرطان پروستات انجام گرفت، شبکه عصبی با سطح زیر منحنی ۰/۸۲۵ قدرت بهتری در پیش بینی نسبت به مدل‌های رگرسیون لجستیک، تابع ممیزی خطی و تابع ممیزی درجه دو نشان داد (۲۸) ( $P < 0.002$ ).

در مطالعه‌ی لی و همکاران در سال ۲۰۱۲ بر روی ۲۷۴ بیمار دیابتی نوع ۲ به منظور پیش بینی نوروپاتی پیش از موعد از مدل‌های درخت تصمیم، پرسپترون چندلایه و رگرسیون لجستیک استفاده شد. مدل شبکه عصبی از دقت تشخیصی بیشتری (۸۳٪) برخوردار بود. سطح زیر منحنی راک برای درخت تصمیم (۸۸۶۳٪) و رگرسیون لجستیک (۸۸۰۲٪) بیشتر از شبکه عصبی (۸۵۳۶٪) بود (۲۹).

در این مطالعه مدل رگرسیون لجستیک نشان داد سن، FBS (با یک سطح)، BMI (با یک سطح) و مدت زمان ابتلا به دیابت می‌توانند ریسک فاکتورهای مهمی برای ابتلا شدن به رتینو

19. Imran K, Mevlut T, Turhan K. Comparing performances of logistic regression, classification and regression tree, and neural network for predicting coronary artery disease. *Expert systems with applications*, 2008; 34(1): 366-74.
20. Kohavi R, John G H. Wrappers for feature subset selection. *Artificial Intelligence*, 1997; 51: 273-324.
21. Isabelle Guyton. An introduction to variable and feature selection. *Journal of Machine Learning Research*, 2003; 3: 1157-82.
22. Bishop C. *Neural networks for pattern recognition*. 1<sup>st</sup> Ed, Oxford University Press, USA, 1996. <http://www.amazon.com>
23. Haykin S. *Neural networks: A comprehensive foundation*. 2<sup>nd</sup> Ed, Upper Saddle River, NJ, USA, 1998. <http://dl.acm.org>
24. Harrell FE JR, Lee KL, Mark DB. Multivariable prognostic models: issues in developing models, evaluating assumptions and adequacy, and measuring and reducing errors. *Stat Med*, 1996; 15: 361-387.
25. Luis Mariano Esteban Escaño, Gerardo Sanz Saiz Francisco, Javier López Lorente, Ángel Borque Fernando, and José María Vergara Ugarriza. Logistic Regression versus Neural Networks for Medical Data. *Monografías del Seminario Matemático García de Galdeano*, 1996; 33: 245-252.
26. Kazemnejad A, Batvandi Z, Faradmali J. Comparison of artificial neural network and binary logistic regression for determination of impaired glucose tolerance/diabetes. *EMHJ*, 2010; 16(6): 615-620 [Persian].
27. Garcia M, Lopez MI, Alvarez D, Hornero R. Assessment of four neural networks based classifiers to automatically detect red lesions in retinal images. *Medical Engineering and Physics*, 2010; 32: 1085-93.
28. Kalra P, Togami J, Bansal G, Partin AW, Brawer MK, Babaian RJ, et al. A Neuro-computational Model for Prostate Carcinoma Detection 2003; 98: 1849-54.
29. Chang-ping LI, Xin-yue ZHI, Jun MA, Zhuang CUI, Zi-long ZHU, Cui ZHANG, et al. Performance comparison between Logistic regression, decision trees, and multilayer Perceptron in predicting peripheral neuropathy in type 2 diabetes mellitus, *Chinese Medical Journal* 2012;125(5):851-857.
- year 2000. *Diabetes Care* 2005; 28(9): 2130-50
6. Owens DR, Volund A, Jones D, Shanon AG, Jones IR, Birtwell AJ, et al. Retinopathy in newly presenting noninsulin dependent (type 2) diabetic patients. *Diabetes res* 1988;9:59-65.
7. Lein R, Barret-Connor EI, Blunt BA, Wingard D. Visual impairment and retinopathy in people with normal glucose tolerance, impaired glucose tolerance, and newly diagnosed NIDDM. *diabetes care* 1991;14:914-918.
8. West KM, Erdreich J, Stober JA. A detailed study of risk factors for retinopathy and nephropathy in diabetes. *Diabetes*. 1980;29:501-508.
9. Ciulla TA, Amador AG, Zinman B. Diabetic retinopathy and diabetic macular edema. Pathophysiology, screening and novel therapies. *Diabetes care*. 2003;26:2653-2664.
10. Klein R, Kleib BE, Moss SE, Davis MD, Demets DL. The wisconsin in epidemiologic study of diabetic retinopathy .prevalence and risk of diabetic retinopathy when age at diagnosis is 30 or more years. *Arch Ophthalmol*. 1984;102:527-532.
11. Davidsom MB. *Diabetes mellitus diagnosis and treatment*. Philadelphia, W.B. Saunders Company. 4th ed. 1998; 267-311.
12. Garg S, Davis RM. Diabetic Retinopathy Screening Update. *Clin Diabetes* 2009; 27(4):140-5.
13. Safaei H, Amini M, Behrooz G, Timuri A. *Iranian Journal of Diabetes and Lipid Disorders*. 2006 5 (3), 235-243 [Persian].
14. Biglarian A, Bakhshi E, Rahgozar M, Karimloo M. Comparison of Artificial Neural Network and Logistic Regression in Predicting of Binary Response for Medical Data: the stage of disease in Gastric Cancer. *Journal of North Khorasan University of Medical Sciences*, 2011;3:120-5 [Persian].
15. Esmaeili MH, Mohammadpour RA, Qaymyan A, Esmaeili J. Assessment of coronary heart disease using artificial neural network. 1<sup>st</sup> Congress Application of Information Technology in health, Mazandaran University of Medical Sciences, 2011: 50-56 [Persian].
16. Davari MH, Kalbasi S, Yaghoobi GH, Sharifzade GH, Khodashenas M. Factors of diabetic retinopathy in patients with type 2 diabetes. *Bina Journal of Ophthalmology*. 2007;1(14) [Persian].
17. Danesh Pour MS, Mehrabi Y, Hedayati M, Azizi F. Multivariable survey of factors correlated with metabolic syndrome using factor analysis. *Iranian Journal of Endocrinology and Metabolism*, 2006; 30: 139-146 [Persian].
18. Rahati S, Tahami E. The Comparison of artificial neural network Elman Recurrent and artificial neural networks three layer Perceptron to predict fluctuations blood sugar levels in patients with type 1 diabetes. 12<sup>th</sup> International Conference of Computer Society of Iran, Shahid Beheshti University, 2007: 2034-38 [Persian].

## Comparison of artificial neural network predictive power with multiple logistic regressions to determine patients with and without diabetic retinopathy

Eghbal Zandkarimi, Msc of Biostatistics, Kermanshah University of Medical Sciences, Kermanshah, Iran. Eghbal1363@gmail.com

\*Alireza Afshari Safavi, PhD student Biostatistics, Isfahan University of Medical Sciences, Isfahan, Iran (\*Corresponding author). ar8as12@Gmail.Com

### Abstract

**Background:** Diabetes mellitus is a high prevalent disease among the population, and if not controlled, it causes complications and irreparable damage to the eye and cause blindness. This study goal is to investigate the predictive power of multiple logistic regression model and the Artificial Neural Network Multi-layer Perceptron (MLP) in determining patients with and without diabetic retinopathy.

**Methods:** Of 16,000 diabetic cases from Kermanshah diabetic center a sample including 150 cases and 150 controls were enrolled. Demographic data, BMI, FBS, HbA<sub>1c</sub>, blood pressure, cholesterol (TC) and duration of disease, smoking status, and age of patient, and health records were collected into two separate checklists. For identifying risk factors, and artificial neural network models multiple logistic regression was fitted to the data and the Rock charts was used to compare the predictive power of the models. Also sensitivity and specificity were analyzed together with the standards of both models (ROC curve, sensitivity and specificity) and superior model was introduced.

**Results:** The predictive power of logistic regression and MLP were 73.0 and 83.0, respectively. The MLP model features (80%) and sensitivity (85%) were higher. Variables of FBS ( $p=0.029$ ), BMI ( $p<0.0001$ ), age ( $p<0.0001$ ) duration of diabetes ( $p<0.0001$ ) in the logistic regression model, the variables of age, FBS, duration of diabetes, BMI, smoking status, TC according to the Wrapper, the predictive power of 83% in MLP were significant.

**Conclusion:** In this study, the MLP model showed more power to identify diabetic retinopathy patients from those without retinopathy. Thus, in communities that case and control groups have high affinity (like this study), discovering the difference needs a more powerful method such as artificial neural network MLP. This method is recommended for medical research.

**Keywords:** Logistic regression, Artificial neural network multilayer perceptron, Type II diabetes, Retinopathy, ROC curve