

## مقایسه‌ی مدل‌های شبکه‌ی عصبی مصنوعی با رگرسیون لجستیک و تحلیل ممیزی در پیش‌بینی سندرم متابولیک

مرتضی سدهی<sup>۱</sup>، دکتر یداله محرابی<sup>۲</sup>، دکتر انوشیروان کاظم‌نژاد<sup>۱</sup>، دکتر فرزاد حدائق<sup>۲</sup>

(۱) دانشکده‌ی پزشکی، دانشگاه تربیت مدرس، ۲) گروه اپیدمیولوژی، دانشکده‌ی بهداشت، دانشگاه علوم پزشکی شهید بهشتی، ۳) مرکز تحقیقات متابولیسم، پژوهشکده‌ی علوم غدد درون‌ریز و متابولیسم، دانشگاه علوم پزشکی و خدمات بهداشتی - درمانی شهید بهشتی، نشانی مکاتبه‌ی نویسندگی مسئول: تهران، اوین، دانشگاه علوم پزشکی شهید بهشتی، دانشکده‌ی بهداشت، گروه اپیدمیولوژی، دکتر یداله محرابی؛ e-mail: ymehrabi@gmail.com

### چکیده

**مقدمه:** شبکه‌های عصبی مصنوعی به عنوان یکی از روش‌های نوین مدل‌سازی در سال‌های اخیر مورد توجه ویژه قرار گرفته است. این مدل‌ها برای پیش‌بینی و طبقه‌بندی در مواردی که روش‌های کلاسیک آماری به خاطر محدودیت‌هایشان قابل استفاده نیستند، کاربرد دارند. هدف از این مطالعه مقایسه‌ی توانایی مدل‌های شبکه عصبی مصنوعی با رگرسیون لجستیک و تحلیل ممیزی برای پیش‌بینی سندرم متابولیک در نمونه‌ای از افراد شرکت کننده در مطالعه‌ی قند و لیپید تهران بود. **مواد و روش‌ها:** با استفاده از بانک اطلاعاتی مطالعه‌ی قند و لیپید تهران، ۳۴۷ نفر از افراد شرکت کننده در آن مطالعه که در ابتدای فاز اول مطالعه بر اساس تعریف ATP III مبتلا به سندرم متابولیک نبودند، به عنوان نمونه انتخاب شدند. اندازه‌گیری شاخص‌های تن‌سنجی، سابقه‌ی بیماری قلبی - عروقی، نمایه‌ی توده‌ی بدن، کلسترول LDL و کلسترول HDL، کلسترول تام، تری‌گلیسرید، قندخون ناشتا، قند خون دو ساعته، مصرف سیگار، فشار خون سیستولی و دیاستولی و دور کمر در ابتدای مطالعه ثبت و بروز سندرم متابولیک پس از سه سال پیگیری به عنوان متغیر پاسخ در نظر گرفته شد. مدل‌های رگرسیون لجستیک، تحلیل ممیزی و شبکه‌ی عصبی مصنوعی پس‌انتشار (۱:۸:۱۵) و (۱:۱۰:۱۵) بر داده‌ها برازش داده شد و پیش‌بینی بر اساس این مدل‌ها انجام شد. از تحلیل راک و آماره‌ی کاپا برای مقایسه‌ی قدرت پیش‌بینی مدل‌ها استفاده شد. نرم‌افزار MATLAB به این منظور مورد استفاده قرار گرفت. **یافته‌ها:** مساحت زیر منحنی راک (ROC) برای مدل‌های رگرسیون لجستیک، تحلیل ممیزی و مدل‌های شبکه‌ی عصبی مصنوعی (۱:۸:۱۵) و (۱:۱۰:۱۵) به ترتیب ۰/۷۳۹ و ۰/۷۴۸ و ۰/۸۹۰ به دست آمد. میزان حساسیت مدل‌ها به ترتیب ۰/۴۸۳، ۰/۶۷۷، ۰/۴۳۵ و ۰/۸۳۶ و ویژگی آنها به ترتیب ۰/۸۵۷، ۰/۶۶۰، ۰/۹۱۰ و ۰/۸۸۴ برآورد شد. اندازه‌ی آماره‌ی کاپا برای مدل‌ها به ترتیب ۰/۳۲۲، ۰/۳۶۳، ۰/۳۷۲ و ۰/۷۱۲ به دست آمد. **نتیجه‌گیری:** یافته‌ها نشان دادند که مدل شبکه‌ی عصبی مصنوعی پس‌انتشار (۱:۱۰:۱۵) نسبت به مدل رگرسیون لجستیک و مدل تحلیل ممیزی از دقت بیشتری برای پیش‌بینی سندرم متابولیک در افراد مورد بررسی برخوردار است.

**واژگان کلیدی:** مدل‌های شبکه‌ی عصبی مصنوعی، رگرسیون لجستیک، تحلیل ممیزی، سندرم متابولیک

دریافت مقاله: ۸۸/۳/۳۱ - دریافت اصلاحیه: ۸۸/۷/۱۸ - پذیرش مقاله: ۸۸/۸/۴

## مقدمه

می‌دهد که مدل در ارتباط با یک مشاهده‌ی جدید آموزش داده نشده پاسخ مناسبی ارائه دهد.<sup>۲</sup>

سندرم متابولیک به مجموعه‌ای از اختلال‌های متابولیک گفته می‌شود که وقوع همزمان آنها در هر شخص بیشتر از خطر وقوع احتمالی هر یک به تنهایی است. مطالعه‌ها نشان داده‌اند که مرگ و میر ناشی از بیماری‌های قلبی - عروقی به طور مشخصی در مبتلایان به سندرم متابولیک بیشتر است. این سندرم به علت ارتباط با دیابت و بیماری‌های قلبی - عروقی و نیز به خاطر شیوع بالا در بین جمعیت‌ها، توجه بسیاری از محققان را به خود جلب نموده است. سازمان جهانی بهداشت (WHO)<sup>ii</sup> پژوهشگران بین‌المللی دیابت (IDF)<sup>iii</sup> و پانل درمانی بزرگسالان (ATPIII)<sup>iv</sup> معیارهایی را برای سندرم متابولیک ارائه کرده‌اند.<sup>۴</sup> در تعریف ATP III از شاخص‌های دور کمر، فشارخون، تری‌گلیسرید، کلسترول تام، کلسترول HDL و قند خون ناشتا استفاده شده است. سندرم متابولیک بر اساس چاقی، افزایش فشار خون، افزایش سطح تری‌گلیسرید، پایین بودن کلسترول HDL و افزایش قند خون ناشتا تشخیص داده می‌شود. در تعریف ATP III وجود سه معیار از پنج معیار فوق الزامی است.<sup>۴</sup> این سندرم، ۲۳٪ جهان غرب را مبتلا کرده است.<sup>۵</sup> در آمریکا، شیوع خام و تطبیق داده شده بر اساس سن به ترتیب ۲۱/۸٪ و ۲۳/۷٪ گزارش شده است.<sup>۵</sup> در بزرگسالان کره‌ی جنوبی، شیوع تطبیق داده شده بر اساس سن در مردان ۱۴/۲٪ و در زنان ۱۷/۷٪ گزارش شده است.<sup>۵</sup> در ایران، در مطالعه‌ی عزیزی و همکاران شیوع سندرم متابولیک در جمعیت مورد بررسی ۳۰/۱٪ و شیوع استاندارد شده بر اساس سن ۲۳/۷٪ گزارش شده است.<sup>۶</sup> فخرزاده و همکاران در مطالعه خود شیوع سندرم متابولیک در جمعیت مورد بررسی ۲۹/۹٪ و شیوع تطبیق داده شده با سن را ۲۷/۵٪ گزارش کرده‌اند.<sup>۵</sup> حدائق و همکاران در مطالعه‌ی خود با استفاده از مدل رگرسیون لجستیک به بررسی عوامل مختلف مرتبط با سندرم متابولیک در بزرگسالان با وزن طبیعی پرداختند.<sup>۲</sup> صدر بافقی و همکاران در مطالعه‌ی خود ضمن بررسی شیوع سندرم متابولیک به بررسی عوامل مؤثر بر آن نیز پرداختند. در آن مطالعه، شیوع سندرم متابولیک در جمعیت مورد بررسی ۳۲/۱٪ گزارش شد.<sup>۷</sup> دانش‌پور و همکاران نیز در مطالعه،

شناسایی الگو و طبقه‌بندی، یکی از مهم‌ترین کاربردهای روش‌های آماری در علوم مختلف است. یکی از اهداف عمده‌ی مدل‌سازی و طبقه‌بندی در آمار، پیش‌بینی بر اساس واقعیت‌ها و متغیرهای موجود و اطلاعات در دسترس از یک موضوع خاص است. این وظیفه در آمار به طور عمده بر دوش روش‌هایی مانند رگرسیون، تحلیل ممیزی، سری‌های زمانی، رده‌بندی، رگرسیون درختی و روش‌های دیگر آماری است.<sup>۱</sup>

روش‌های کلاسیک آماری برای مدل‌بندی روابط بین متغیرها دارای تعدادی پیش‌فرض و محدودیت است. در نظر گرفتن یک توزیع پیش‌فرض مانند توزیع نرمال برای متغیرهای پاسخ، خطی بودن رابطه‌ی پیشنهادی، یکسان بودن واریانس خطاها و غیره از جمله محدودیت‌های روش‌های کلاسیک هستند که هنگام استفاده‌ی عملی از این روش‌ها، اگر داده‌های واقعی، شرایط مفروض مدل را نداشته باشند استفاده از این روش‌ها امکان‌پذیر نبوده یا با خطای قابل توجه همراه است. به علاوه، هیچ‌یک از این روش‌ها قابلیت مدل‌بندی روابط پیچیده‌ی غیر خطی و اثر متقابل درجه‌ی بالا را ندارند. حساس بودن بیشتر این مدل‌ها به مشاهده‌های گم شده و داده‌های پرت از دیگر محدودیت‌های این روش‌ها به شمار می‌آید.<sup>۱</sup>

بنابراین، نیاز به روش‌هایی که با محدودیت‌های کمتری در این زمینه مواجه باشند، احساس می‌شود. در این بین، مدل‌های شبکه‌ی عصبی مصنوعی<sup>i</sup> می‌توانند یکی از مناسب‌ترین روش‌ها باشند. شبکه‌ی عصبی هیچ فرض اولیه‌ای بر توزیع داده‌ها تحمیل نمی‌کند، ضمن این که هیچ محدودیتی نیز برای شکل تابعی رابطه‌ی بین متغیرهای مستقل و وابسته اعمال نمی‌کند بلکه شبکه‌ی عصبی - خود - این رابطه‌ی تابعی را کشف می‌کند، که لزوماً این رابطه، یک رابطه‌ی خطی نیست. از دیگر مزایای شبکه‌ی عصبی مصنوعی این است که در آن اطلاعات به صورت ضمنی پردازش می‌شوند. بر این اساس، چنانچه بخشی از سلول‌های شبکه‌ی حذف شوند یا عملکرد غلط داشته باشند باز هم احتمال رسیدن به پاسخ صحیح وجود دارد، ضمن این که تعمیم‌پذیری شبکه‌ی عصبی این امکان را

ii- World Health Organization

iii - International Diabetes Federation

iv - Adult Treatment Panel

i-Artificial Neural Network

واریانس مساوی از قاعده‌ی TPM برای رده‌بندی استفاده می‌شود.<sup>۹</sup>

**شبکه‌ی عصبی مصنوعی:** شبکه‌های عصبی مصنوعی برای تشخیص، طبقه‌بندی و پیش‌بینی که در آنها روابط معمولاً به شکل غیرخطی هستند، مورد استفاده قرار می‌گیرند. مبحث شبکه‌ی عصبی مصنوعی مربوط به شبیه‌سازی قوه‌ی یادگیری در انسان و پیاده‌سازی آن به صورت الگوریتم‌های کامپیوتری است. شبکه‌های عصبی یکی از پویاترین حوزه‌های پژوهش در دوران معاصر می‌باشد که افراد متعددی از رشته‌های گوناگون علمی را به خود جلب کرده است. فلسفه‌ی اصلی محاسبه‌های شبکه‌های عصبی مصنوعی، مدل‌سازی عمده‌ی ویژگی‌های مغز و نحوه عملکرد آن در جهت ساخت مدل‌هایی است که بتواند ویژگی‌های مفید مغز را حتی الامکان از خود بروز دهد.<sup>۱۰</sup>

مغز به عنوان یک سیستم پردازش موازی، از حدود ۱۰<sup>۱۱</sup> نورون به هم مرتبط با ۱۰<sup>۱۶</sup> ارتباط نورونی تشکیل شده است.<sup>۵</sup> نورون‌ها از سه قسمت اصلی بدنه‌ی سلولی،<sup>۱۱</sup> دندریت<sup>۱۲</sup> و آکسون<sup>۱۳</sup> تشکیل می‌شوند. دو قسمت اخیر عناصر ارتباطی نورون هستند. دندریت‌ها سیگنال‌های الکتریکی را به هسته‌ی سلول منتقل می‌کنند. بدنه‌ی سلول، انرژی لازم را برای فعالیت سلول فراهم نموده، بر سیگنال‌های دریافتی یکسری اعمال انجام می‌دهد. آکسون بر خلاف دندریت، از سطحی هموارتر و تعداد شاخه‌های کمتری برخوردار است. آکسون طول بیشتری دارد و سیگنال الکتروشیمیایی دریافتی از هسته‌ی سلول را به نورون دیگر منتقل می‌کند.

مشابه با یک نورون منفرد، یک شبکه‌ی عصبی نیز دارای ورودی‌هایی است که سیگنال‌های ورودی شبکه از اندام‌های حساس و یا دیگر شبکه‌ها هستند و مانند نورون منفرد، شبکه‌ی عصبی خروجی‌هایی را تولید می‌کند که به سایر شبکه‌ها یا اعضا منتقل می‌شوند اما خروجی شبکه متفاوت از خروجی یک نورون تنها است زیرا لزوماً شامل یک تک مقدار نمی‌باشد بلکه می‌تواند شامل تعداد زیادی از مقادیر خروجی باشد. مانند نورون منفرد، شبکه‌ی خروجی‌هایش را به عنوان تابعی از ورودی‌هایش محاسبه می‌کند، اما به دلیل این که قدرت ارتباط بین نورون‌ها در شبکه قابل تغییر است، رابطه

خود عوامل مرتبط با سندرم متابولیک را با استفاده از تحلیل عاملی بررسی کردند.<sup>۸</sup> با توجه به مرگ و میر ناشی از این بیماری‌ها و بار عظیم اقتصادی ناشی از آنها ارزیابی مدل‌هایی که با دقت بتواند ابتلا به سندرم متابولیک را در افراد پیش‌بینی نماید از اهمیت ویژه‌ای برخوردار است.<sup>۲</sup>

هدف از این مطالعه پیش‌بینی ابتلا به سندرم متابولیک با استفاده از مدل شبکه‌ی عصبی مصنوعی و مقایسه‌ی دقت پیش‌بینی این مدل با روش‌های مرسوم آماری مانند رگرسیون لجستیک و تحلیل ممیزی بود. لازم به ذکر است که در این مطالعه هدف اصلی تنها مقایسه‌ی قدرت پیش‌بینی مدل‌های مختلف مورد بحث بود و از مباحث پیچیده درباره‌ی اصول کار و طراحی شبکه‌های عصبی مصنوعی صرف‌نظر شده است.

**رگرسیون لجستیک:** یکی از ابزارهای آماری است که به منظور مدل‌سازی و تحلیل داده‌ها از آن استفاده می‌شود. رگرسیون لجستیک دارای شکل کلی زیر است:

$$\log \left( \frac{\pi}{1-\pi} \right) = \alpha + \sum_{i=1}^k \beta_i \cdot x_i$$

در این مدل،  $\pi$  احتمال تعلق فرد به سطح اول متغیر وابسته است،  $x_i$  متغیر مستقل  $i$  ام و  $\beta_i$  ضریب برآورد شده مدل برای متغیر مستقل  $i$  ام است. از مزایای استفاده از مدل رگرسیون لجستیک علاوه بر مدل‌سازی مشاهده‌ها، امکان پیش‌بینی احتمال تعلق هر فرد به هر یک از سطوح متغیر وابسته و همچنین امکان محاسبه‌ی مستقیم نسبت شانس<sup>۱</sup> با استفاده از ضرایب مدل است.<sup>۹</sup>

**تحلیل ممیزی:** تحلیل ممیزی تکنیک چند متغیره است که با جدا کردن مجموعه‌های متمایز مشاهده‌ها و با تخصیص مشاهده‌های جدید به دسته‌های از پیش تعریف شده سر و کار دارند. مسأله‌ی آماری در مورد به وجود آوردن یک قانون (تابع تشخیص) بر مبنای اندازه‌های حاصل از افراد می‌باشد. با استفاده از این قانون می‌توان افراد جدید را که معلوم نیست از کدام جمعیت هستند، به یکی از جمعیت‌ها منتسب کرد. از معروف‌ترین توابع مورد استفاده در تحلیل ممیزی می‌توان به تابع ممیز فیشتر اشاره کرد. در روش دیگر، قاعده‌ی رده‌بندی با به حداقل رساندن تابع متوسط هزینه (ECM) به دست می‌آید. برای جامعه‌های نرمال با

ii- Soma


iii- Dendrite

iv- Axon

i Odds Ratio (OR)

تابع محرک<sup>۱</sup> می‌تواند خطی یا غیر خطی باشد. یک تابع محرک بر اساس نیاز خاص حل مسأله انتخاب می‌شود. در عمل، تعداد محدودی از توابع محرک مورد استفاده قرار می‌گیرند که از بین آنها می‌توان به تابع آستانه‌ای دو مقداره‌ی متقارن، تابع آستانه‌ای دو مقداره، تابع همانی، تابع خطی مثبت، تابع سیگموئیدی و تابع تانژانت هایپربولیک اشاره کرد.<sup>۱۱</sup>

**مدل ساده تک ورودی:** مدل ریاضی این شبکه را می‌توان به صورت  $a = f(WP + b)$  نشان داد. اسکالره‌ای  $a$  و  $P$  به ترتیب خروجی و ورودی هستند.



$$a = f(WP + b)$$

شکل ۱- مدل ریاضی نورون

تأثیر  $P$  بر  $a$  به وسیله‌ی مقدار وزن  $w$  تعیین می‌شود.  $b$  را بایاس می‌گویند و خاصیت آن این است که ورودی نورون همواره برابر یک است. در مقایسه‌ی این نورون تک ورودی با یک نورون بیولوژیک،  $w$  معادل شدت سیناپس، مجموعه‌ی جمع‌کننده و تابع محرک معادل هسته و بدنه‌ی سلول و  $a$  معادل سیگنال گذرنده از آکسون است. نکته‌ی قابل توجه اهمیت و تأثیر جمله‌ی بایاس است. این جمله را می‌توان مانند دیگر وزن‌ها در نظر گرفت، با این تصور که میزان تأثیر ورودی ثابت  $۱$  را بر نورون منعکس می‌کند. باید توجه داشت که متغیرهای  $w$  و  $b$  قابل تنظیم هستند و تابع محرک  $f$  نیز توسط طراح شبکه عصبی انتخاب می‌شود. بر اساس انتخاب  $f$  و نوع الگوریتم یادگیری، متغیرهای  $w$  و  $b$  تنظیم می‌شوند. یادگیری به این معنی است که  $w$  و  $b$  طوری تغییر می‌کنند که رابطه‌ی ورودی و خروجی نورون با هدف خاصی مطابقت نماید.<sup>۱۱</sup>

**مدل چند ورودی:** به طور عمومی یک شبکه بیش از یک ورودی دارد. در این حالت، شکل ماتریسی ساختار شبکه به صورت زیر است:

$$n = WP + b = \sum_{i=1}^R P_i W_{1i} + b$$

$$W = [W_{11}, \dots, W_{1R}], \quad P = [P_1, \dots, P_R]$$

بین خروجی‌های شبکه می‌تواند بنا به تجربه با ورودی‌های آن تغییر کند. این فرایند را در اصطلاح، یادگیری شبکه‌ی عصبی مصنوعی می‌نامند.<sup>۱۱</sup>

مسأله‌ی مدل‌سازی مغز از روی مدل‌سازی تک نورون عصبی شروع شد و مدل نورون وارن - کلوش و والتر پیترز (۱۹۴۳) اولین تلاش برای این کار بود.<sup>۱۱</sup> در این مدل هر اتصال دارای وزنی است که سیناپس نامیده می‌شود و به وسیله‌ی  $W_{ij}$  نشان داده شده و به عنوان میزانی از قدرت اتصال از واحد  $j$  ام به واحد  $i$  ام در نظر گرفته شده است. ورودی هر واحد، مجموع وزن خروجی دیگر متصل به آن است. بنابراین، ورودی واحد  $i$  ام عبارت است از:

$$Net\_input_i = \sum_j w_{ij} \times output_j + w_i$$

که در آن  $W_i$  مقدار آستانه‌ی واحد  $i$  ام است.

سپس، تابع محرک بر این مجموع عمل می‌کند که مقدار این تابع، مقدار محرک آن واحد نامیده می‌شود. در یک شبکه عصبی، نورون‌ها در لایه‌های مختلف طبقه‌بندی می‌شوند. لایه‌ی ورودی مشتمل بر نورون‌هایی است که ورودی را از محیط خارج دریافت می‌کنند. لایه‌ی خروجی نیز مشتمل بر نورون‌هایی است که خروجی سیستم را به محیط خارجی یا کاربر یا طراح سیستم ارائه می‌دهد. علاوه بر لایه‌های ورودی و خروجی، ممکن است یک یا چند لایه‌ی نهانی نیز بین این دو لایه در نظر گرفته شود که تعداد این لایه‌ها به ساختار شبکه، ساختار داده‌ها و شیوه‌ی طراحی شبکه بستگی دارد. هنگامی که لایه‌ی ورودی، داده را دریافت می‌کند، نورون‌های آن لایه، خروجی را تولید می‌کند که همین خروجی، به عنوان ورودی لایه‌ی بعدی در نظر گرفته می‌شود. این مراحل به همین ترتیب ادامه پیدا می‌کند تا این که شرط معین و مورد نظر برای پایان فرایند یادگیری برقرار گردد. سپس، لایه‌ی خروجی نتیجه‌ی شبکه را ارائه می‌دهد و فرایند به اتمام می‌رسد. تعیین تعداد نورون‌های لایه‌های نهانی شبکه برای طراحی شبکه الزامی است و تعداد آن بستگی به میزان بهینه‌سازی شبکه دارد. در واقع، آنقدر نورون به لایه‌ی نهانی افزوده می‌شود تا کارایی شبکه بهینه شود. البته باید در نظر داشت که افزایش بی‌رویه‌ی تعداد نورون‌های لایه‌ی نهانی ممکن است باعث بیش‌برازش مدل شبکه شود. به عبارت دیگر، این امکان به وجود می‌آید که شبکه حتی خطاهای مستتر در داده‌ها را نیز فرا گیرد.<sup>۱۱</sup>

است (یادگیری با ناظر). اعتبار شبکه‌های عصبی مصنوعی با استفاده از داده‌های آزمون و روش‌های اعتبار مقطعی<sup>vii</sup> مورد بررسی قرار می‌گیرد.<sup>۱۲</sup>

در این مطالعه از مدل‌های شبکه‌ی عصبی مصنوعی برای پیش‌بینی سندرم متابولیک استفاده و سپس یافته‌ها حاصل با دو روش آماری مرسوم یعنی تحلیل ممیزی و رگرسیون لجستیک مقایسه شدند.

## مواد و روش‌ها

داده‌های مورد استفاده در این پژوهش از مطالعه‌ی قند و لیپید تهران به دست آمد. مطالعه‌ی قند و لیپید، یک مطالعه‌ی آینده‌نگر بود که در جمعیت نماینده‌ای از ساکنان منطقه ۱۳ تهران، با هدف تخمین میزان شیوع اختلال‌های متابولیک و شناسایی عوامل خطر ساز بیماری‌های قلبی - عروقی انجام شد. در آن مطالعه، ۱۵۰۰۵ نفر از جامعه‌ی شهری تهران به صورت تصادفی انتخاب شدند که از بین آن‌ها ۱۰۳۶۸ فرد بالای ۲۰ سال، در سال ۱۳۷۹ در فاز اول مطالعه مورد بررسی قرار گرفتند. افراد شرکت‌کننده در پژوهش حاضر، شامل ۳۴۷ نفر بودند که در ارتباط با ابتلا به سندرم متابولیک بررسی شدند. این افراد در فاز اول مطالعه (۱۳۸۱ - ۱۳۷۹) به سندرم متابولیک مبتلا نبوده و پس از حدود سه سال پیگیری در فاز دوم مطالعه مجدداً بررسی شدند که ۱۲۲ نفر از آن‌ها براساس معیار ATP III به سندرم متابولیک مبتلا شدند. متغیرهای مورد بررسی در این مطالعه عبارت بودند از سن، جنس، وضعیت تأهل، سابقه بیماری‌های قلبی - عروقی، نمایه‌ی توده‌ی بدن (BMI)، LDL، HDL، کلسترول تام، تری‌گلیسرید، قندخون ناشتا، قند خون دو ساعته، مصرف سیگار (هرگز، گاهی، همیشه)، فشارخون سیستولی، فشارخون دیاستولی و دور کمر که اندازه‌گیری همه‌ی آن‌ها در فاز ۱ مطالعه‌ی قند و لیپید تهران انجام شده بود.

با توجه به این که هدف اصلی ما در این پژوهش مقایسه‌ی دقت مدل‌های مختلف برای پیش‌بینی سندرم متابولیک بود، بایست با استفاده از معیارهای آماری مناسب مقایسه‌ای بین مدل‌های مختلف انجام می‌شد تا در صورت لزوم بتوان یکی از آنها را به عنوان مدل بهینه انتخاب نمود و مورد استفاده قرار داد. با توجه به دو سطحی بودن متغیر

تعداد عناصر بُردار ورودی با توجه به مسأله مورد بررسی تعیین می‌شود.

**یادگیری:** فرایند یادگیری در واقع مشخص کردن ارتباط بین ورودی و خروجی در طول زمان با تکرار فرایند است. می‌دانیم که تجربه‌ها در طول زمان حاصل می‌شوند و به عبارت دیگر، هیچکس آینده‌ی خود را تجربه نکرده است. میزان یادگیری ما به درجه‌ی کامل بودن اطلاعات قبلی بستگی دارد.<sup>۱۲</sup> در حالت کلی سه نوع یادگیری در شبکه‌ی عصبی مصنوعی وجود دارد:

روش اول، یادگیری با ناظر<sup>i</sup> است. در این روش فرض بر این است که در هر مرحله از تکرار الگوریتم، جواب مطلوب سامانه‌ی یادگیرنده از قبل آماده است، به عبارت دیگر، الگوریتم یادگیری به جواب واقعی و مطلوب دسترسی دارد که می‌توان خروجی شبکه را با آن مقایسه نمود. روش دوم، یادگیری بدون ناظر<sup>ii</sup> یا خودسازمانده است که در آن به جواب مطلوب و مقدار واقعی پاسخ برای بهبود رفتار سامانه یادگیرنده دسترسی نداریم و خود شبکه باید در بین ورودی‌ها، این کار را انجام دهد. یک اشکال یادگیری با ناظر این است که شبکه‌ی عصبی ممکن است بدون معلم نتواند مواضع جدیدی را که توسط مجموعه‌ی داده‌های جدید تجربی پوشانده نشده است، یاد بگیرد. روش سوم، یادگیری تشدید<sup>iii</sup> یا تقویتی است که این محدودیت را برطرف می‌کند.

یکی از معماری‌های شبکه‌های عصبی مصنوعی که به طور گسترده‌ای به کار می‌رود و در راستای یادگیری با ناظر قرار دارد، پرسپترون چند لایه (MLP)<sup>iv</sup> است که از آن به عنوان تقریب‌زن کلی<sup>v</sup> یاد می‌شود.<sup>۱۰</sup> در پرسپترون یادگیری توسط کمینه کردن میانگین مربع‌های خروجی و با به کارگیری الگوریتم یادگیری پس انتشار (BP)<sup>vi</sup> خطا یا قاعده‌ی دلتای تعمیم یافته حاصل می‌شود.<sup>۱۲</sup>

برای آموزش شبکه که تقریباً شبیه برآورد ضرایب در رگرسیون است، تعدادی از نمونه‌ها به تصادف انتخاب شده به درون شبکه فرستاده می‌شوند. در داده‌های آموزشی وضعیت واقعی طبقه‌ای که نمونه به آن تعلق دارد، مشخص

- i. Supervised Learning
- ii- Unsupervised Learning
- iii- Reinforcement Learning
- iv. Multi Layer Perceptron (MLP)
- v. Universal Approximator
- vi. Back Propagation

vii- Cross Validation

مساحت زیر آن که عددی بین ۰ و ۱ است و به عنوان ملاکی برای سنجش توانایی پیش‌بینی مدل‌ها مورد استفاده قرار می‌گیرد. هر چه این عدد به ۱ نزدیک‌تر باشد، نشانه‌ی توانا تر بودن مدل برای پیش‌بینی است.<sup>۱۳</sup>

پاسخ، یک ملاک مناسب برای سنجش کیفیت مدل‌های برازش شده و تعیین توان پیش‌بینی صحیح آنها استفاده از سطح زیر منحنی مشخصه‌ی عملکرد (ROC) است. این منحنی عبارت است از حساسیت برحسب یک منهای ویژگی و

جدول ۱- مقایسه‌ی مقادیر میانگین متغیرهای کمی پایه در مبتلایان و غیر مبتلایان به سندرم متابولیک

مقدار P	غیر مبتلا به سندرم متابولیک	مبتلا به سندرم متابولیک	
۰/۰۲۹	۴۶/۱ ± ۱۳/۲۱	۴۹/۳ ± ۱۲/۸۸	سن (سال)
۰/۰۰۱	۲۵/۹ ± ۴/۰۲	۲۷/۸ ± ۴/۱۱	نمایه‌ی توده‌ی بدن (کیلوگرم بر متر مربع)
۰/۰۸۷	۲۰۵/۸ ± ۳۹/۳۳	۲۱۳/۵ ± ۴۰/۸۸	کلسترول تام (میلی‌گرم بر دسی‌لیتر)
۰/۰۹۷	۱۳۳/۷ ± ۳۴/۲۵	۱۴۰/۲ ± ۳۵/۵۶	کلسترول LDL (میلی‌گرم بر دسی‌لیتر)
۰/۹۸	۱۳۰/۸ ± ۳۳/۰۲	۱۳۰/۷ ± ۳۰/۹۶	قند خون دو ساعته (میلی‌گرم بر دسی‌لیتر)
۰/۰۰۹	۱۱۶/۱ ± ۱۷/۲۶	۱۲۱/۳ ± ۱۸/۱۷	فشارخون سیستولی (میلی‌متر جیوه)
۰/۰۳۸	۷۵/۳ ± ۹/۸۴	۷۷/۷ ± ۹/۹۰	فشارخون دیاستولی (میلی‌متر جیوه)
۰/۰۰۱	۸۶/۰ ± ۹/۶۴	۹۰/۶ ± ۱۰/۱۰	دور کمر (سانتی‌متر)
۰/۰۱	۹۰/۷ ± ۹/۵۶	۹۳/۴ ± ۹/۶۶	قند خون ناشتا (میلی‌گرم بر دسی‌لیتر)
۰/۰۰۱	۱۲۹/۷ ± ۵۵/۴۴	۱۵۵/۴ ± ۷۷/۸	تری‌گلیسرید (میلی‌گرم بر دسی‌لیتر)
۰/۰۰۲	۴۶/۱ ± ۲۰/۸۹	۴۲/۲ ± ۱۱/۹۸	کلسترول HDL (میلی‌گرم بر دسی‌لیتر)

جدول ۲- مقایسه‌ی شیوع متغیرهای کیفی در مبتلایان و غیر مبتلایان به سندرم متابولیک

مقدار P	غیر مبتلا به سندرم متابولیک	مبتلا به سندرم متابولیک	
۰/۹۷۲	٪ ۴۴/۹	٪ ۴۵/۱	جنس (مرد)
۰/۳۴۱	٪ ۹۶/۴	٪ ۹۱/۸	وضعیت تأهل (متأهل)
۰/۷۳۷	٪ ۴/۹	٪ ۴/۱	سابقه‌ی بیماری قلبی - عروقی (دارد)
۰/۳۹۵	٪ ۱۸/۲	٪ ۲۲/۱	مصرف سیگار (سیگاری)

شبکه‌ی پرسپترون دو لایه (۱ : ۱۰ : ۱۵) با متغیرهای مشابه برازش داده شد.

برای برازش مدل رگرسیون لجستیک و تحلیل ممیزی از نرم‌افزار SPSS نسخه‌ی ۱۶ و برای برازش مدل شبکه‌ی عصبی مصنوعی از نرم‌افزار MATLAB نسخه‌ی ۲۰۰۸ استفاده شد. برای مقایسه‌ی دقت پیش‌بینی مدل‌های ارائه شده از سطح زیرمنحنی راک، آماره‌ی کاپا و مقادیر حساسیت و ویژگی استفاده شد.

ابتدا از نیمی از داده‌ها (۱۷۳ نفر) برای برازش مدل‌ها و آموزش شبکه‌ی عصبی مصنوعی و سپس از نیم دیگر (۱۷۴ نفر) برای بررسی دقت پیش‌بینی استفاده شد. برای برازش مدل رگرسیون لجستیک، روش حذف پسرو<sup>i</sup> و برای تحلیل ممیزی روش لاندای ویلک<sup>ii</sup> به‌کار رفت. برای طراحی مدل شبکه‌ی عصبی مصنوعی، ابتدا یک شبکه‌ی پرسپترون دو لایه (۱ : ۸ : ۱۵) با الگوریتم پس‌انتشار خطا و نرخ یادگیری ۰/۱، تابع انتقال تانژانت هایپربولیک و حداکثر خطای ۰/۰۰۱ به وجود آمد و در مرحله‌ی بعد با اضافه کردن دو نورون به لایه‌ی میانی، یک

i. Backward

ii-Wilk 's Lambda

## یافته‌ها

درستی پیش‌بینی کرده‌اند. رگرسیون لجستیک و مدل شبکه (۱۵:۸:۱) دارای حساسیت پایین ولی ویژگی به نسبت بالایی هستند. مدل شبکه‌ی عصبی (۱۵:۱۰:۱) دارای بالاترین نسبت درست‌نمایی مثبت و پایین‌ترین نسبت درست‌نمایی منفی می‌باشد (جدول ۴).

جداول ۱ و ۲ اطلاعات توصیفی مربوط به متغیرهای مورد بررسی را ارائه می‌دهند. براساس اطلاعات ارائه شده در جدول ۳، مدل رگرسیون لجستیک وضعیت ۷۲/۴٪، مدل تحلیل ممیزی وضعیت ۶۶/۷٪، مدل شبکه‌ی عصبی (۱۵:۸:۱) وضعیت ۷۳/۶٪ و در نهایت، مدل شبکه‌ی عصبی (۱۵:۱۰:۱) وضعیت ۸۷/۴٪ افراد سالم یا مبتلا به سندرم متابولیک را به

جدول ۳- طبقه‌بندی افراد مورد بررسی بر اساس پیش‌بینی مدل‌های رگرسیون لجستیک، تحلیل ممیزی و مدل‌های شبکه‌ی عصبی مصنوعی

وضعیت واقعی		پیش‌بینی مدل
سندرم متابولیک	سالم	
رگرسیون لجستیک		
۳۲ (۱۸/۴)	۹۶ (۵۵/۲)*	سالم
۳۰ (۱۷/۲)	۱۶ (۹/۲)	مبتلا به سندرم متابولیک
تحلیل ممیزی		
۲۰ (۱۱/۵)	۷۴ (۴۲/۵)	سالم
۴۲ (۲۴/۲)	۳۸ (۲۱/۸)	مبتلا به سندرم متابولیک
شبکه‌ی عصبی (۱۵ : ۸ : ۱)		
۳۵ (۲۰/۱)	۱۰۲ (۵۸/۶)	سالم
۲۷ (۱۵/۵)	۱۰ (۵/۷)	مبتلا به سندرم متابولیک
شبکه‌ی عصبی (۱۵ : ۱۰ : ۱)		
۱۰ (۵/۷)	۱۰۰ (۵۷/۵)	سالم
۵۲ (۲۹/۹)	۱۲ (۶/۹)	مبتلا به سندرم متابولیک

\* اعداد داخل پرانتز، درصد نسبت به کل را نشان می‌دهند.

جدول ۴- حساسیت، ویژگی، آماره‌ی کاپا و سطح زیر منحنی راک (ROC) برای مدل‌های مختلف

مدل	حساسیت	ویژگی	LR+*	LR-†	آماره کاپا	سطح زیر منحنی راک
رگرسیون لجستیک	۰/۴۸۳	۰/۸۵۷	۳/۳۸	۰/۶۰	۰/۳۲۲	۰/۷۴۹
تحلیل ممیزی	۰/۶۷۷	۰/۶۶	۱/۹۹	۰/۴۹	۰/۳۶۳	۰/۷۳۹
شبکه‌ی عصبی (۱۵ : ۸ : ۱)	۰/۴۳۵	۰/۹۱	۴/۸۳	۰/۶۲	۰/۳۷۲	۰/۷۴۸
شبکه‌ی عصبی (۱۵ : ۱۰ : ۱)	۰/۸۳۶	۰/۸۸۴	۷/۲۱	۰/۱۹	۰/۷۱۲	۰/۸۹۰

\*نسبت درست‌نمایی مثبت (Positive Likelihood Ratio)، †نسبت درست‌نمایی منفی (Negative Likelihood Ratio)


افراد مبتلا توسط مدل شبکه‌ی عصبی به طور قابل ملاحظه‌ای افزایش یافت. این به آن معنا است که تغییر تعداد گره‌های لایه‌ی میانی می‌تواند تأثیر زیادی بر یافته‌های حاصل از مدل‌ها داشته باشد. بنابراین، در هنگام طراحی مدل شبکه‌ی عصبی مصنوعی باید در انتخاب تعداد گره‌های لایه‌ی میانی دقت لازم را به عمل آورد. از طرفی با بررسی ویژگی، در می‌یابیم که قدرت تشخیص صحیح افراد غیر بیمار توسط مدل شبکه‌ی عصبی (۱ : ۸ : ۱۵)، بالاتر از قدرت مدل شبکه‌ی عصبی (۱ : ۱۰ : ۱۵) است که مانند رگرسیون لجستیک عمل می‌کند.

بر اساس آماره‌ی کاپا، مدل شبکه‌ی عصبی (۱ : ۱۰ : ۱۵) با اختلاف زیادی بهترین عملکرد را بین مدل‌های ارائه شده دارد. مقایسه‌ی دو مدل شبکه‌ی مصنوعی ارائه شده نشان می‌دهد که تغییر کردن تعداد نورون‌های لایه‌های میانی تا چه اندازه می‌تواند در عملکرد مدل تأثیر داشته باشد. ضمن این که شبکه‌های عصبی مصنوعی مفروضات و محدودیت‌های معمول در روش‌های کلاسیک را نیز ندارند که این مسأله خود مزیت بسیار بزرگی به حساب می‌آید. با اضافه کردن تعداد سلول‌های لایه‌ی میانی در شبکه‌ی عصبی مصنوعی می‌توان دقت پیش‌بینی را بالا برد، اما در اینجا خطری که مدل شبکه را تهدید می‌کند بیش برآزش<sup>۱</sup> است که برای تعمیم پذیری شبکه مشکل ایجاد می‌کند.

مطالعه‌هایی که تا به حال در ارتباط با مدل‌سازی آماری درباره‌ی سندرم متابولیک انجام شده است،<sup>۳۸</sup> به طور عمده با هدف بررسی عوامل مؤثر بر سندرم متابولیک انجام شده‌اند، اما در مطالعه‌ی حاضر، هدف، مقایسه‌ی صحت و دقت پیش‌بینی مدل‌های موجود آماری و مقایسه‌ی آن با صحت و دقت مدل پیشنهادی شبکه‌ی عصبی بود که تا پیش از این مطالعه بررسی نشده بود.

تاکنون استنباط‌هایی برای شبکه‌های عصبی مانند آنچه که در علم آمار برای مدل‌سازی و ارزیابی آنها وجود دارد، ارائه نشده‌است و مدل‌سازی بیشتر بر اساس الگوریتم آموزشی مورد نظر انجام می‌شود. بنابراین، تا حدودی تابع سلیقه و انتخاب‌های اولیه‌ی پژوهشگر است. در این زمینه برخی سؤال‌ها نیز در ارتباط با چگونگی طراحی معماری مناسب و توپولوژی بهینه برای شبکه‌ی عصبی، تشخیص تعداد لایه‌های پنهان و تعداد سلول‌های موجود در هر لایه

منحنی راک برای مدل‌های مورد بررسی در نمودار ۱ نشان داده شده است. بر اساس این نمودار، سطح زیر منحنی ROC برای مدل‌های رگرسیون لجستیک، تحلیل ممیزی، شبکه‌ی عصبی مصنوعی (۱ : ۱۰ : ۱۵) و بالآخره شبکه‌ی عصبی مصنوعی (۱ : ۱۰ : ۱۵) به ترتیب ۰/۷۴۹، ۰/۷۳۹، ۰/۷۴۸ و ۰/۸۹۰ به دست آمد.



نمودار ۱- منحنی راک (ROC) برای مقایسه‌ی قدرت پیش‌بینی مدل‌ها

## بحث

با توجه به اهمیت سندرم متابولیک به عنوان یک عامل خطرناک مهم برای بیماری‌های قلبی - عروقی و دیابت دسترسی به مدل‌هایی که با دقت بالا بتواند این بیماری را در افراد پیش‌بینی نماید مورد توجه است. در این مطالعه چهار مدل مختلف برای پیش‌بینی سندرم متابولیک در افراد استفاده و یافته‌های حاصل مقایسه شدند. با توجه به نتایج ارائه شده، مدل شبکه عصبی مصنوعی (۱ : ۱۰ : ۱۵) دارای بیشترین حساسیت و در مقابل مدل شبکه‌ی عصبی (۱ : ۸ : ۱۵) دارای کمترین حساسیت بود. به عبارت دیگر، با افزایش تعداد گره‌های لایه‌ی میانی شبکه، قدرت تشخیص صحیح



سپاسگزاری: از پژوهشکده‌ی علوم غدد درون‌ریز و متابولیسم دانشگاه علوم پزشکی شهید بهشتی که داده‌های این مطالعه را در اختیار پژوهشگران قرار دادند، سپاسگزاری می‌نمایم. همچنین، از همکاری صمیمانه‌ی آقای اکبر بیگلریان دانشجوی دکتری آمار زیستی دانشگاه تربیت مدرس و سرکار خانم مریم صفرخانی کارشناس ارشد واحد آمار پژوهشکده‌ی علوم غدد درون‌ریز و متابولیسم کمال تشکر و قدردانی را به عمل می‌آوریم.

ذهن پژوهشگران را به خود مشغول داشته که علاقمندان می‌توانند در این عرصه به منابع موجود مراجعه نمایند.<sup>۱۴</sup> در برخی مطالعه‌هایی که از روش‌های رگرسیون لجستیک و تحلیل ممیزی برای پیش‌بینی استفاده کرده‌اند، مدل رگرسیون لجستیک یافته‌های دقیق‌تری نسبت به تحلیل ممیزی ارائه داده‌است<sup>۱۳</sup> اما در مطالعه‌ی حاضر این موضوع تأیید نشد. اگرچه برای بررسی دقیق‌تر موضوع مطالعه‌های جامع‌تر به‌ویژه با استفاده از شبیه‌سازی پیشنهاد می‌شود.

## References

- Hagan MT, Neural network design , PWS , USA; 1995.
- Anderson A, An introduction to neural network, Cambridge , MA: MIT press; 1995.
- Hadaegh F, Zabetian A, Harati H, Azizi F. Metabolic syndrome in normal-weight Iranian adults, Ann Saudi Med 2007; 27: 18-24.
- Hadaegh F, Ghasemi A, Padyab M. Assessment of different definitions of metabolic syndrome in incidence of diabetes in Iranian urban: Tehran Lipid and Glucose Study. Journal of Iranian Diabetes and Lipid 2008; 3: 343-353. [Farsi]
- Fakhrzadeh H, Ebrahimipour P, Nouri M. Survey of prevalence of metabolic syndrome and its risk factors in an urban population. Journal of Iranian Diabetes and Lipid 2005; 3: 278-288. [Farsi]
- Azizi F, Salehi P, Etemadi A, Zahedi-Asl S. Prevalence of metabolic syndrome in an urban population: Tehran Lipid and Glucose Study. Diabetes Res Clin Pract 2003 Jul;61: 29-37.
- Sadr-Bafghi S. M, Salari M, Rafiei M, Nemayande S. M. Survey of prevalence of metabolic syndrome and its factors in an urban population. Journal of Medicine Dep, Tehran University Medical Journal 2007; 64: 90-6. [Farsi]
- Danesh-Pour M. S, 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. [Farsi]
- Jobson D.J, Applied multivariate data analysis, Springer, USA, 1992.
- Menhaj M.B, Basics of neural network, Prof Hesabi Ins. , Tehran, 2005.
- Hagan M.T, Neural networks design, PSW, USA, 1996.
- Dayhoff JE, Neural network architectures, VNR, USA, 1990.
- Sadat Hashemi S. M. , Ghorbani R. , Kavei B. Analyzing receiver operating characteristic curves to compare medical diagnostic tests. Koomesh, Journal of Semnan University of Medical Sciences, 2003; 2: 145-149. [Farsi]
- Tu JV. Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. J Clin Epidemiol 1996; 49: 1225-31.

## Original Article

# Comparison of Artificial Neural Network, Logistic Regression and Discriminant Analysis Methods in Prediction of Metabolic Syndrome

Sedehi M<sup>1</sup>, Mehrabi Y<sup>2</sup>, Kazemnejad A<sup>1</sup>, Hadaegh F<sup>3</sup>

<sup>1</sup>Faculty of Medicine, Tarbiat Modares University, <sup>2</sup>Department of Epidemiology, School of Public Health, and <sup>3</sup>Prevention of Metabolic Disorders Research Center, Research Institute for Endocrine Sciences, Shahid Beheshti University of Medical Sciences, Tehran, Iran

e-mail: ymehrabi@gmail.com

Received: 16/07/2009 Accepted: 26/10/2009

### Abstract

**Introduction:** Artificial neural networks as a modern modeling method have received considerable attention in recent years. The models are used in prediction and classification in situations where classic statistical models have restricted application when some, or all of their assumptions are met. This study is aimed to compare the ability of neural network models to discriminant analysis and logistic regression models in predicting the metabolic syndrome. **Materials & Methods:** A total of 347 participants from the cohort of the Tehran Lipid and Glucose Study (TLGS) were studied. The subjects were free of metabolic syndrome at baseling according to the ATPIII criteria. Demographic characteristics, history of coronary artery disease, body mass index, waist, LDL, HDL, total cholesterol, triglycerides, fasting and 2 hours blood sugar, smoking, systolic and diastolic blood pressure were measured at baseline. Incidence of metabolic syndrome after about 3 years of follow up was considered a dependent variable. Logistic regression, discriminant analysis and neural network models were fitted to the data. The ability of the models in predicting metabolic syndrome was compared using ROC analysis and the Kappa statistic, for which, MATLAB software was used. **Results:** The areas under receiver operating characteristic (ROC) curve for logistic regression, discriminant analysis and artificial neural network models (15: 8: 1) and (15: 10: 10) were estimated as 0. 749, 0. 739, 0. 748 and 0. 890 respectively. Sensitivity of models were calculated as 0. 483, 0. 677, 0. 453 and 0. 863 and their specificity as 0. 857, 0. 660, 0. 910 and 0. 844 respectively. The Kappa statistics for these models were 0. 322, 0. 363, 0. 372 and 0. 712 respectively. **Conclusion:** Results of this study indicate that artificial neural network models perform better than classic statistical models in predicting the metabolic syndrome.

**Keywords:** Artificial Neural Network, Logistic Regression, Discriminant Analysis, Metabolic syndrome