

## تشخیص بیماری پریدنتال با استفاده از الگوریتم لونیگ - مارکواردت

دکتر فرزاد فیروزی جهانتیغ<sup>۱\*</sup> سمین اربابی<sup>۲</sup> دکتر سمیه انصاری مقدم<sup>۳</sup>

۱- استادیار گروه مهندسی صنایع، دانشگاه سیستان و بلوچستان، زاهدان

۲- دانشجوی کارشناسی ارشد مهندسی صنایع، دانشگاه سیستان و بلوچستان، زاهدان

۳- استادیار گروه پریدانتیکس و عضو مرکز تحقیقات دهان و دندان دانشکده دندانپزشکی دانشگاه علوم پزشکی سیستان و بلوچستان، زاهدان

### خلاصه:

**سابقه و هدف:** بیماری پریدنتال، یکی از شایع‌ترین بیماری‌های عفونی دهان است. تشخیص صحیح و زودهنگام آن می‌تواند موجب کاهش میزان عوارض ناخوشایند گردد. هدف از این مطالعه بررسی دقت و کارایی شبکه‌ی عصبی مصنوعی در تشخیص بیماری پریدنتال است.

**مواد و روش‌ها:** این مطالعه‌ی تشخیصی، در بازه‌ی زمانی سال‌های ۹۴ و ۹۵ از بررسی پرونده‌ی پزشکی ۲۳۰ مراجعه کننده به بخش پریدانتیکس دانشکده‌ی دندانپزشکی زاهدان انجام شد. ۵ متغیر سن، جنسیت، شاخص پلاک دندانی (PI)، عمق پروبینگ (PPD) و شاخص از دست دادن چسبندگی (CAL) در این افراد بررسی شد. در مدل شبکه‌ی عصبی مصنوعی پیش‌خور با الگوریتم پس انتشار خطا از تابع آموزشی لونیگ-مارکواردت استفاده شد. ارزش پیش‌بینی مثبت و ارزش پیش‌بینی منفی جهت ارزیابی شبکه در مرحله‌ی آزمون مورد استفاده قرار گرفت.

**یافته‌ها:** نتایج نشان داد که شبکه‌ی پس انتشار خطا با ساختار ۵-۲۰-۴-۲ و الگوریتم لونیگ-مارکواردت و استفاده از توابع انتقال یکسان در تمام لایه‌ها (تانژانت هایپربولیک سیگموئیدی) می‌تواند به عنوان تابع آموزشی کارا در تشخیص بیماری پریدنتال مورد استفاده قرار گیرد. مقادیر ارزش پیش‌بینی مثبت و منفی در مرحله‌ی آزمون به ترتیب ۹۴/۷ و ۸۰ درصد به دست آمد. خروجی نرم افزار مقادیر مناسبی را برای زمان (۴/۵۸۷۰ ثانیه) و رگرسیون در فاز آزمون، آزمایش و کل (۰/۷۴۵۴، ۰/۹۷۴۹ و ۰/۹۲۵۴) به دست آورد.

**نتیجه‌گیری:** به نظر می‌رسد استفاده از شبکه عصبی مصنوعی می‌تواند در تشخیص بیماری‌های پریدنتال در حداقل زمان کمک کننده باشد.

**کلید واژه‌ها:** بیماری پریدنتال، تشخیص، مدل شبکه‌ی عصبی

وصول مقاله: ۹۶/۵/۲۵ اصلاح نهایی: ۹۶/۷/۲۶ پذیرش مقاله: ۹۶/۸/۳۰

### مقدمه:

توجه متخصصین به استفاده از ابزارهای هوشمند و سیستم‌های پشتیبان تصمیم‌گیری در امور پزشکی جلب شده است و استفاده از انواع مختلف سیستم‌های هوشمند در پزشکی روبه افزایش است.<sup>(۳،۴)</sup> شبکه‌های عصبی مصنوعی در حل مسائل مربوط به تشخیص بالینی، آنالیز تصاویر پزشکی، پیش‌بینی بقا و در دامنه وسیعی از زمینه‌های پزشکی شامل انکولوژی، کاردیولوژی و هماتولوژی، مراقبت‌های ویژه، تشخیص از روی تصاویر پزشکی، ناباروری و جراحی و ... به کار رفته است.<sup>(۵)</sup> استفاده از این ابزارها و سیستم‌ها، می‌تواند خطاهای احتمالی ناشی از خستگی یا بی‌تجربگی متخصصین بالینی در امر


برای پیشگویی، تحلیل و طبقه‌بندی مدل‌های آماری زیادی ارائه شده‌اند.<sup>(۱)</sup> شبکه‌ی عصبی مصنوعی (Artificial Neural Network) ANN یک روش غیرپارامتری برای طبقه‌بندی است، که در حیطه‌ی پزشکی براساس متغیرهای ورودی نسبت به طبقه‌بندی افراد به بیمار یا سالم اقدام می‌کند.<sup>(۲)</sup> تاریخچه‌ی شبکه‌ی عصبی به اواسط قرن بیستم میلادی بر می‌گردد. شبکه‌های عصبی ممکن است در ابتدا پیچیده به نظر برسد اما به راحتی می‌توانند با محیط بالینی ادغام شود.<sup>(۳)</sup> امروزه بدلیل گسترش دانش در حوزه‌ی پزشکی و پیچیدگی تصمیمات مرتبط با تشخیص و درمان،

پرپودنتیت یک بیماری التهابی شایع در انسان است<sup>(۱۱)</sup>، که علت اصلی این بیماری عفونت باکتریایی در طولانی مدت است.<sup>(۱۲)</sup> این بیماری از جمله بیماری‌های رایج دهان و دندان محسوب می‌شود.<sup>(۱۳)</sup> تحقیق بر روی پاتوبیولوژی بیماری پرپودنتال دانش ما را از این بیماری افزایش می‌دهد.<sup>(۱۴)</sup> در تحقیق حاضر با استفاده از شبکه‌ی عصبی چندلایه پیشخور و با الگوریتم آموزشی لونبرگ مارکواردت و سه فاکتور اصلی بیماری پرپودنتال یعنی عمق پروبینگ (Probing Pocket Depth)، شاخص از دست دادن چسبندگی (Clinical Attachment Loss)، شاخص پلاک دندان (Plaque Index) و سن و جنس به تشخیص بیماری پرپودنتال پرداخته شد.

#### مواد و روش‌ها:

تحقیق حاضر یک مطالعه‌ی تشخیصی است که براساس متغیر-های ورودی به پیشگویی بیماری پرپودنتال می‌پردازد. این مطالعه در بازه‌ی زمانی سال‌های ۹۴ و ۹۵ از بررسی پرونده‌ی ۲۳۰ مراجعه کننده به بخش پرپودانتیکس دانشکده‌ی دندان-پزشکی زاهدان صورت گرفت. در این مطالعه یک شبکه‌ی عصبی طراحی شد که براساس متغیرهای ورودی به تشخیص بیماری پرپودنتال پرداخته است. این مطالعه در دو مرحله، که مرحله اول (تعیین فاکتورهای بیماری و استخراج مقادیر از پرونده‌ی مراجعه‌کنندگان) و مرحله‌ی دوم (طراحی و ارزیابی سیستم) انجام گرفت. سیستم طراحی شده با استفاده از مجموعه‌ی داده‌های مربوط به پرونده‌ی مراجعه‌کنندگان ارزیابی شد. به منظور پیاده‌سازی شبکه از امکانات و توابع موجود در نرم افزار MATLAB نسخه‌ی ۲۰۱۵ بهره گرفته شد. با توجه به نظر متخصص پرپودنتیست متغیرهای ورودی شامل سن، جنس، عمق پروبینگ، شاخص از دست دادن چسبندگی و شاخص پلاک دندان در نظر گرفته شد. در این پژوهش از ساختار شبکه‌های عصبی چندلایه‌ی پیش-خور (پرسپترون چندلایه) استفاده شد. مکانیزم یادگیری شبکه-

تشخیص و درمان بیماری‌ها را کاهش دهد. همچنین با استفاده از این سیستم‌ها، می‌توان پایگاه داده‌های پزشکی را در زمان بسیار کم‌تر و با جزییات بیشتر تحلیل نمود.<sup>(۳،۴،۵)</sup> بنابراین باید از دسته مدل‌هایی استفاده کرد که دارای اطمینان بالا باشند. در مطالعه‌ای که توسط Kositbowornchai و همکاران، با عنوان عملکرد شبکه‌ی عصبی مصنوعی به منظور تشخیص شکستگی عمودی ریشه دندان صورت گرفت، دریافتند که شبکه‌ی عصبی طراحی شده در این مطالعه دارای حساسیت بالا، دقت و صحت در تشخیص شکستگی عمودی ریشه دندان می‌باشد.<sup>(۶)</sup> مطالعه‌ی دیگری تحت عنوان شبکه‌ی عصبی پرسپترون چندلایه به منظور تشخیص پوسیدگی پروگزیمال دندان توسط Devito و همکاران انجام گرفت و با توجه به نظر متخصصان، ۳۹/۴ درصد بهبود در تشخیص دیده شد.<sup>(۷)</sup> Živko-Babić و همکاران در مطالعه خود تحت عنوان برآورد مقاومت شیمیایی سرامیک‌های دندانی با استفاده از شبکه‌ی عصبی نشان دادند که شبکه‌ی عصبی مصنوعی پتانسیل بسیار زیادی به عنوان یک روش اضافی در بررسی خواص مواد دندانی دارد.<sup>(۸)</sup> Shankarapillai و همکاران در مطالعه خود نشان دادند که شبکه‌ی عصبی آموزش دیده با استفاده از الگوریتم لونبرگ مارکواردت می‌تواند به طور کارآمد در ارزیابی خطر بیماری پرپودنتال استفاده شود.<sup>(۹)</sup> در مطالعه‌ای تحت عنوان طراحی و بکارگیری ترکیبی از الگوریتم ژنتیک و شبکه‌ی عصبی مصنوعی برای پیش بینی اندازه دندان نیش نهفته و پرمولر که توسط Moghimi و همکاران انجام گرفت، دریافتند که روش پیشنهادی یک ابزار موثر برای پیش بینی اندازه دندان نیش نهفته و پرمولر با دقت بالا نسبت به تجزیه و تحلیل رگرسیونی می‌باشد.<sup>(۱۰)</sup> براساس مطالعات انجام گرفته پیشین، می‌توان گفت قابلیت منحصر به فرد شبکه‌ی عصبی مصنوعی در ایجاد تمایز و دسته‌بندی و تشخیص بیماری‌ها، می‌تواند مطلوب و مفید واقع گردد.



شکل ۱. سلول عصبی نمونه در انسان

شبکه‌ی عصبی از جهاتی همانند یک مغز عمل می‌کند. به این معنا که از مشاهدات انتزاعی خود به قضاوت می‌پردازد. لذا شبکه‌ی عصبی مدتی را صرف آموزش کرده و سپس به صورت عملیاتی به کار گرفته می‌شود. شبکه‌ی عصبی آن‌چه را مشاهده می‌کند در قالب پارامترهای درونی خود به خاطر می‌سپارد. در واقع تکرار هر یک از مشاهدات موجب تغییر پارامترهای درونی شبکه در جهت حفظ روابط حاکم بر مشاهدات است. آن‌چه در ذهن شبکه‌ی عصبی در قالب پارامترهای شبکه نگه‌داری می‌شود، نه تک تک مشاهدات بلکه الگو و برداشت کلی از مشاهدات است، بنابراین معمولاً این استواری و ثبات را در عمل دارد که در برخورد با عموم نمونه‌های مشابه، عملکردی مناسب همراه با خطای قابل اغماض داشته باشد.<sup>(۱۶)</sup> در این گونه ساختارها هدف این است که با معرفی عملکرد یک سیستم دینامیکی، مدل را آموزش داده، چگونگی عملکرد سیستم در حافظه مدل ذخیره و از آن برای مواردی که قبلاً با آن مواجه نشده است استفاده شود. شکل (۲) شبکه‌ی عصبی مصنوعی را نشان می‌دهد که از سه لایه‌ی ورودی، خروجی و پنهان ساخته شده‌اند. بخش‌هایی در شبکه‌ی عصبی مصنوعی به نام نرون یا گره وجود دارد که کار پردازش اطلاعات را انجام می‌دهد. ارتباط بین نرون‌ها، لایه نام دارد و میزان تاثیر نرون‌ها بر یکدیگر را وزن لایه‌ها در نظر می‌گیرد و یک مقدار ثابت به عنوان بایاس به هر لایه اضافه می‌شود. یکی از کاربردهای بسیار مهم شبکه‌ی عصبی مصنوعی شبیه‌سازی فرایندهایی است که

های استفاده شده در این پژوهش براساس مفهوم گرادیان نزولی است. برای آموزش این نوع شبکه به طور معمول از قانون پس‌انتشار خطا استفاده می‌شود، که دارای الگوریتم‌های مختلفی بود. همچنین با توجه به ماهیت مسئله از الگوریتم لونبرگ مارکواردت استفاده شد. تعداد نرون‌های لایه‌ی ورودی همان فاکتورهای بیماری پریدونتال بودند. بنابراین تعداد نرون‌های لایه‌ی ورودی ۵ نرون در نظر گرفته شد. متغیرهای ورودی (فاکتورها) به منظور تشخیص بیماری پریدونتال برای همه‌ی ۲۳۰ مراجعه کننده مورد بررسی قرار گرفت، که در جدول (۱) قابل مشاهده است. داده‌های موجود در این مجموعه پیش‌پردازش شدند. زیرا در این مجموعه داده‌ها، مقدار بعضی از داده‌ها وارد نشده بود، به عبارتی گم شده بود، هدف این پیش‌پردازش این بود که داده‌های گمشده حذف شوند تا میزان خطا حداقل گردد، همچنین در پایان داده‌ها به روش خطی نرمال شدند به گونه‌ای که مقادیر عددی آن‌ها بین صفر و یک قرار گیرد تا قابل اعمال به شبکه‌ی عصبی مصنوعی گردد. داده‌ها بعنوان مقادیر ورودی وارد نرم افزار Matlab شدند.

جدول ۱. عوامل تشخیص بیماری پریدونتال و دامنه‌ی مقادیر آن‌ها

به عنوان پارامترهای ورودی

عوامل	دامنه‌ی مقادیر
سن	۱۸-۵۵
جنسیت	۰ و ۱
PPD	(۴-۱)
CAL	(۴-۰)
PI	٪۱۰۰-۰

### شبکه‌های عصبی مصنوعی

یکی از ابزارهای مناسب در حوزه‌ی مهندسی که می‌تواند در کشف الگوهای پیچیده و مدل‌سازی سیستم‌های غیرخطی کاربرد داشته باشد شبکه‌های عصبی مصنوعی هستند، که در سال ۱۹۴۳ توسط McClouth و Pittes با الهام از نرون‌های مغز انسان به صورت یک مدل ریاضی پیشنهاد شد<sup>(۱۵)</sup>. شکل (۱) یک سلول عصبی نمونه در انسان را نشان می‌دهد.


به منظور طراحی یک شبکه‌ی عصبی مصنوعی می‌بایست داده‌ها را به دو مجموعه مختلف به نام نمونه آموزشی و نمونه آزمایشی تقسیم نمود. چرا که استفاده از داده‌های آموزشی و آزمایشی برای طراحی شبکه ضروری می‌باشد. نمونه آموزشی، مجموعه‌ای از ورودی‌ها و خروجی‌های شبکه است، که از آن برای آموزش یک کار خاص به شبکه استفاده می‌شود. پس از آموزش شبکه و توقف فرایند یادگیری، از نمونه آزمایشی برای بررسی کارایی شبکه استفاده می‌گردد. قاعده‌ی دقیقی برای تعیین تعداد داده‌های آموزش و آزمایش وجود ندارد، به عنوان مثال Zhang و همکاران از یکی از قاعده‌های ۹۰ درصد در برابر ۱۰ درصد، ۸۰ درصد در برابر ۲۰ درصد و ۷۰ درصد در برابر ۳۰ درصد را انتخاب می‌کنند. Pultan توصیه می‌کند، تعداد نمونه‌های آزمایش تقریباً باید ۱۰ برابر تعداد وزن‌های شبکه باشد.<sup>(۱۷)</sup> در این مطالعه نیز حدود ۸۰ درصد داده‌ها را به عنوان نمونه آموزشی و ۲۰ درصد داده‌ها را به عنوان نمونه آزمایشی استفاده شد. برای آموزش و تست شبکه‌های عصبی در طول فاز طراحی از داده‌های مربوط به ۱۸۴ نمونه استفاده گردید (آموزش، به منظور یادگیری شبکه‌ی عصبی) و ۴۶ نمونه‌ی باقی مانده به منظور شبیه‌سازی مدل‌های شبکه‌ی عصبی استفاده گردید (آزمایش، به منظور ارزیابی شبکه‌ی عصبی).

### ماتریس کانفیوژن

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 (TP) یا مثبت کاذب (FP یا False Positive) و منفی حقیقی (TN یا True Negative)، منفی کاذب (FN یا False Negative) می‌شود. مقادیر ارزش اخباری مثبت و منفی به صورت زیر محاسبه می‌گردد.<sup>(۱۸)</sup>


$$\text{ارزش اخباری مثبت} = \frac{TP}{TP+FP}$$

می‌تواند یک رابطه‌ی مستقل را بین ورودی و خروجی آن استنتاج نمود



شکل ۲- ساختار شبکه‌ی عصبی مصنوعی

این رابطه مستقل در شکل (۳) نمایش داده شده است. با ضرب مقادیر ورودی در وزن‌های متناظر با آن، شبکه‌ی ورودی محاسبه می‌شود و این فرایند تا تحویل مقادیر به تابع فعال-ساز  $F(x)$  تکرار خواهد شد. معمولاً از تابع فعال‌سازی تانژانت‌هایپربولیک سیگموئیدی استفاده می‌شود و ما نیز از این تابع استفاده کردیم. خروجی حاصل آمده شبکه با خروجی مطلوب مقایسه خواهد شد و خطا در هر بار حرکت از ورودی به خروجی برای هر نرون محاسبه می‌شود. خطاها در تمام لایه‌ها انتشار یافته‌اند و به این ترتیب می‌توان میزان خطا را برآورد نمود و در تکرار بعدی آن را به حداقل رساند. این روش تا زمانی که همگرایی مطلوبی حاصل آید ادامه خواهد یافت و وزن شاخه‌ها در هر بار تکرار فرایند بروزرسانی خواهد شد.<sup>(۱۵)</sup>



شکل ۳- رابطه بین ورودی و خروجی

**بحث:**

هدف از این پژوهش، طراحی سیستم تشخیصی با استفاده از شبکه‌ی عصبی مصنوعی جهت تشخیص بیماری پریدنتال بود. متغیرهای سن، جنس، عمق پروبینگ، شاخص از دست دادن چسبندگی و شاخص پلاک دندان به‌عنوان متغیرهای اصلی در یادگیری شبکه‌ی عصبی انتخاب گردید. همانطور که نتایج نشان دادند، این شبکه مقادیر ارزش پیش‌بینی مثبت را ۹۴/۷ درصد به دست آورد، این بدان معنا است که شبکه قادر است ۹۴/۷ درصد از موارد ابتلا به بیماری پریدنتال را درست شناسایی کند. همچنین مقادیر ارزش پیش‌بینی منفی ۸۰ درصد به دست آمد که بیان‌کننده‌ی این موضوع است که شبکه می‌تواند ۸۰ درصد از افراد سالم را واقعاً سالم تشخیص دهد. همچنین میزان رگرسیون برای هر یک از فازهای شبکه، مقادیر مناسبی به‌دست آمد و نشان می‌دهد مدل در مدیریت خطا خوب عمل می‌کند. این مدل در ۴/۵۸۷۰ ثانیه به جواب بهینه رسید که بیان‌گر این است که مدل زود اجرا می‌شود. همچنین در تحقیقی که توسط Shahabi و همکاران در سال ۲۰۱۶ تحت عنوان استفاده از تکنیک‌های هوش مصنوعی برای شناسایی میزان شدت بیماری کبد چرب غیر الکلی توسط شاخص‌های بالینی انجام گرفت، نتایج نشان دادند که روش پیشنهادی قادر است که علاوه بر صرف هزینه کم‌تر و قابلیت دسترسی آسان‌تر در شناسایی بیماری کبد چرب غیر الکلی، نحوه تشخیص بیماری و شرایط هر سطح از بیماری را در قالب مجموعه قوانینی برای تشخیص بیماری برای پزشکان تعیین نماید.<sup>(۲۰)</sup> در مطالعه‌ای که توسط Thohamtan و همکاران به منظور کاربرد شبکه‌ی عصبی مصنوعی جهت ارزیابی بیماری عروق کرونری قلب انجام گرفت، این روش به علت ویژگی بالا می‌تواند از عوارض و آسیب‌های احتمالی آنژیوگرافی در بیمارانی که نیاز به آن ندارند، جلوگیری کند. از طرف دیگر می‌تواند به علت حساسیت بالا، بیمارانی که به طور واقعی به این اقدامات تشخیصی و درمانی نیاز دارند را تفکیک نماید<sup>(۵)</sup>

برای پیاده‌سازی الگوریتم از محیط برنامه نویسی Matlab نسخه ۲۰۱۵ استفاده شد. مدل‌سازی در شبکه‌ی عصبی مصنوعی با استفاده از مجموعه داده‌های آموزشی صورت پذیرفت. ابتدا از ۱۸۴ نمونه برای آموزش شبکه‌ی عصبی توسط الگوریتم لونیبرگ مارکواردت استفاده شد و سپس با ۴۶ نمونه‌ی باقی‌مانده برای آزمایش شبکه‌ی عصبی استفاده گردید. بهترین مدل، مدلی است که درصد پیش‌بینی صحیح بالایی داشته باشد، برای ارزیابی این شبکه ارزش پیش‌بینی (اخباری) مثبت و منفی محاسبه گردید. همچنین میزان رگرسیون نیز محاسبه گردید. از ۴۶ نمونه که در مرحله‌ی آزمون مورد استفاده قرار گرفتند، ۳۶ مورد مبتلا به بیماری پریدنتال بودند و ۱۰ نفر سالم بودند. شبکه‌ی عصبی ۳۸ مورد را مبتلا به بیماری و ۸ مورد را سالم تشخیص داده است که به این معناست که شبکه عصبی ۲ مورد بیماری پریدنتال را اشتباه تشخیص داده است. برای مجموعه داده‌های به کار رفته در این مقاله، مقادیر ارزش پیش‌بینی مثبت و منفی به ترتیب مقادیر ۹۴/۷ و ۸۰ درصد به دست آمد. خروجی نرم‌افزار میزان رگرسیون برای فاز آموزش، آزمایش و ترکیبی را به ترتیب ۰/۷۴۵۴، ۰/۹۷۴۹ و ۰/۹۲۵۴ به دست آورد، که نمایانگر عملکرد بالای شبکه در کنترل خطا است. زیرا هر چه مقدار رگرسیون به ۱ نزدیک‌تر باشد، خطای آن کم‌تر می‌باشد، مدل ساخته شده توسط شبکه‌ی عصبی مصنوعی در ۴/۵۸۷۰ ثانیه اجرا شد، که بیان‌گر سرعت عمل بالای این شبکه می‌باشد. اطلاعات این شبکه به طور برجسته در جدول (۲) نمایش داده شده است.

**جدول ۲- نتایج به دست آمده‌ی فاز آموزش و آزمایش برای الگوریتم لونیبرگ- مارکواردت**

نتایج به دست آمده برای الگوریتم لونیبرگ مارکواردت	
زمان سپری شده (ثانیه)	۴/۵۸۷۰
رگرسیون فاز آموزش	۰/۷۴۵۴
رگرسیون فازآزمایش	۰/۹۷۴۹
رگرسیون ترکیبی	۰/۹۲۵۴

**تقدیر و تشکر:**

نویسندگان مراتب تقدیر و تشکر خود را از دانشگاه سیستان و بلوچستان و بخش پرپودانتیکس دانشکده‌ی دندان پزشکی زاهدان به عمل می‌آورند.

**References:**

1. Dunne RA. A statistical approach to neural networks for pattern recognition. John Wiley & Sons Press; New Jersey. 1993.
2. Livingstone DJ. Artificial Neural Networks: Methods and Applications: Methods in Molecular Biology. Humana Press; 2008.
3. Milovic B, Milovic M. Prediction and decision making in health care using data mining. Arabian J Bus Mange Rev (Kuwait Chapter). 2012. 1; 1(12):126-127
4. Sheikhpour R, Sarram MA. Diagnosis of Diabetes Using an Intelligent Approach Based on Bi-Level Dimensionality Reduction and Classification Algorithms. Iran J Diabetes Obes 2014 Jun 1;6(2):74-84.
5. Thohamtan RA, Esmaeili MH, Ghaemian A, Esmaeili J. Application of Artificial Neural Network for Assessing Coronary Artery Disease. J Maz Univ Med Sci (JMUMS) 2012; 22(86).
6. Kositbowornchai S, Plermkamom S, Tangkosol T. Performance of an artificial neural network for vertical root fracture detection: an ex vivo study. Dental traumatology 2013; 29(2):151-5.
7. Devito KL, de Souza Barbosa F, Felipe Filho WN. An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology 2008; 106(6):879-84.
8. Živko-Babić J, Lisjak D, Čurković L, Jakovac M. Estimation of chemical resistance of dental ceramics by neural network. Dental materials 2008; 24(1):18-27.
9. Shankarapillai R, Mathur LK, Nair MA, George R. Periodontitis risk assessment using two artificial neural network algorithms—a comparative study Int J Dent Clin 2012; 4(1).
10. Moghimi S, Talebi M, Parisay I. Design and implementation of a hybrid genetic algorithm and artificial neural network system for predicting the sizes of unerupted canines and premolars. Eur J Orthod 2012; 34(4):480-6.
11. Moghaddam SA, Abbasi S, Moghaddam ES, Moghaddam AA. Triglyceride and Cholesterol Levels in Patients with Chronic Periodontitis. J Health Scope 2015; 4(2).

در مطالعه‌ای تحت عنوان مقایسه دقت پیش بینی شبکه‌های عصبی مصنوعی و رگرسیون لجستیک دو متغیره در تشخیص همزمان بیماری فشارخون و دیابت، توسط Adavi و همکاران انجام گرفت به این نتیجه دست یافتند که به کارگیری شبکه‌ی عصبی مصنوعی نسبت به مدل رگرسیون خطی دو متغیره برای تشخیص همزمان بیماری دیابت و فشار خون دقت بالاتری دارد.<sup>(۲۱)</sup>

Sheikhpour و همکاران در مطالعه‌ای تحت عنوان تشخیص سرطان پستان با استفاده از کاهش دو مرحله‌ای ویژگی‌های استخراج شده اسپیراسیون سوزنی و الگوریتم‌های داده‌کاوی، دریافتند که با استفاده از این روش‌ها می‌توان سیستم‌های نوینی برای کمک به پزشکان طراحی نمود که موجب تسهیل در فرایند های تشخیصی و درمانی می‌شود.<sup>(۲۲)</sup>

Jafarnejad و همکاران به این نتیجه دست یافتند که مدل شبکه‌ی عصبی مصنوعی با توجه به معیار سنجش دقت مدل‌ها (میانگین مربعات خطا)، اثر بخشی و کارایی بیشتری را در مقابل با روش Arima در پیش‌بینی تقاضای دستگاه سی تی اسکن از خود نشان داده است.<sup>(۲۳)</sup>

Andaieshgar و همکاران دریافتند که شبکه‌ی عصبی مصنوعی، دقت پیش بینی و غربالگری بهتری نسبت به روش‌های ممیزی لجستیک و ممیزی درجه دو در تشخیص و پیش‌بینی بیماری انفارکتوس میوکارد داشته است.<sup>(۲۴)</sup> بسیاری از مطالعات گذشته صحت عملکرد شبکه‌ی عصبی مصنوعی را به عنوان یک ابزار مهم برای تشخیص بیماری‌ها نشان داده است، اما مطالعه‌ای در حوزه‌ی بیماری‌های دهان و دندان در ایران یافت نشد که لزوم انجام این مطالعه را تاکید می‌کند.

**نتیجه‌گیری:**

به نظر می‌رسد استفاده از شبکه عصبی مصنوعی می‌تواند در تشخیص بیماری‌های پرپودنتال در حداقل زمان کمک کننده باشد.

12. Ainamo J, Ainamo A. Risk assessment of recurrence of disease during supportive periodontal care. *J Clin Periodontol* 1996; 23(3):232-9.
13. Ketabi M, Farkhani N, Amini S. Comparing the implant stability and radiographic crestal bone loss between HA/coated and RBM short Dentis implants in posterior maxilla. *Res Dent Sci* 2014; 11(2): 54-9.
14. Page RC, Krall EA, Martin J, MANCL L, Garcia RI. Validity and accuracy of a risk calculator in predicting periodontal disease. *J Am Dent Assoc* 2002; 133(5):569-76.
15. Meyer-Bäse A, Jancke K, Wismüller A, Foo S, Martinetz T. Medical image compression using topology-preserving neural networks. *Engineering Applications of Artificial Intelligence* 2005; 18(4):383-92.
16. Darbellay GA, Slama M. Forecasting the short-term demand for electricity: Do neural networks stand a better chance? *International Journal of Forecasting* 2000; 16(1):71-83.
17. Zhang, G., Hu, M.Y., Neural network forecasting of the British pound/US dollar exchange rate, *Omega*, 26(4). 495-506, 1998.
18. Khosravanian A, Ayat S. Implementing a Decision Support System Based on Probabilistic Neural Network for Diagnosing Breast Cancer Type. Zhang G, Patuwo BE, Hu MY. Forecasting with artificial neural networks: The state of the art. *Int J Forecast* 1998; 14(1):35-62.
19. Baratloo A, Safdari S. Evidence Based Medicine; Positive and Negative Likelihood Ratios of Diagnostic Tests. *Tibb-I urzhans-i Iran*. 2015 ; 2(4): 185-6.
20. Shahabi M, Hassanpour H. Using the Artificial Intelligence Techniques for Diagnosing of intensity of Non-Alcoholic Fatty Liver Disease by Clinical Parameters. *Journal of Knowledge & Health* 2016 ;11(3):Page-69.
21. Adavi M, Salehi M, Roudbari M, Asgari F, Rafei A. The comparison of the predictive precision of artificial neural networks and bivariate logistic regression in diagnosis of patients with hypertension. *Razi J Med Sci* 2014;21(123):54-61.
22. Sheikhpour R, Agha Sarram M, Zare Mirakabad MR, Sheikhpour R. Breast Cancer Detection Using Two-Step Reduction of Features Extracted From Fine Needle Aspirate and Data Mining Algorithms. *Iran J Breast Dis* 2015;7(4):43-51.
23. Jafarnejad A, Soleymani, M. Demand Forecasting Medical Equipment Based On Artificial Neural Networks and Arima Methods. *J Eco Res Policies* 2011; 19(57): 171-198.
24. Andaieshgar, B., Sedehi, M., Kheiri, S., Farahani, N.M., Comparison Of Classical Discriminant Methods With Artificial Neural Network Using Different Algorithm To The Diagnosis Of Myocardial Infarction 2015; 11(2): 349-359.