

تخمین دوز متوسط غده‌ای در غربالگری‌های رایج ماموگرافی با شبکه عصبی

محمد نبی پور^{۱*}، محمدرضا دیوبند^۱، امین اصغرزاده^۱ و نرگس سلیمانی^۲

^۱گروه مهندسی و فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران.

^۲دانشکده پزشکی، دانشگاه علوم پزشکی گلستان، گرگان، ایران.

*تهران، دانشگاه علوم پزشکی شهید بهشتی، گروه مهندسی و فیزیک پزشکی، کدپستی: ۱۹۸۵۷۱۷۴۴۳

پست الکترونیکی: nabipour_mohammad@sbmu.ac.ir

چکیده

با توجه به کاربرد فراوان آزمون‌های رایج ماموگرافی به منظور غربالگری و تشخیص سرطان پستان، نگرانی‌هایی در مورد افزایش دوز جذبی بیمار، به علت حساس بودن بافت سینه و دوز جذبی در بافت پستان، وجود دارد. بنابراین اطلاع از میزان دوز متوسط غده‌ای قبل از پرتودهی به بیمار از طریق تخمین آن می‌تواند، کمک‌کننده باشد. بدین منظور و برای اندازه‌گیری داده‌ها از فانتومی با مشخصات مشابه محتویات بافت سینه استفاده شده و میزان کرمای هوا در سطح ورودی به پوست، ماکزیمم کیلوولتاژ، میلی‌آمپر ثانیه، ضخامت لایه نیم‌جذب و نوع فیلتر/هدف، ثبت گردید. سپس مدل شبکه عصبی پرسپترون چند لایه با الگوریتم آموزشی لونیگ-مارکواریت، با استفاده از نرم‌افزار متلب آموزش داده شده و کرمای هوای سطحی، تخمین زده شد. برای رسیدن به بهترین نتیجه، شبکه عصبی با پارامترهای متفاوت از جمله گرادیان خطا و تعداد نورون‌های لایه پنهان و روش آموزش مناسب بهینه شد. پس از اجرای برنامه برای تعداد نورون‌های متفاوت، مشخص شد که تعداد ۳۵ نورون، بهینه‌ترین مقدار می‌باشد که ضریب رگرسیون ۹۵٫۷ درصد را به دست داده و مقدار میانگین مربعات خطا برای تمام داده‌ها، ۰٫۴۳۷ میلی‌گری است که ۴٫۸ درصد دامنه تغییرات خروجی می‌باشد و مین پیش‌گویی با صحت ۹۵٫۲ درصدی در پژوهش حاضر می‌باشد. روش پیشنهادی در تحقیق حاضر با استفاده از شبکه‌های عصبی در پیش‌بینی کرمای هوا، تخمین کرمای هوای احتمالی بیمار را قبل از اینکه در معرض پرتوی ایکس قرار بگیرد، میسر می‌کند. نتایج نشان داده است که ضریب رگرسیون بدست آمده، مبین اختلاف ۴٫۳ درصدی بین کرمای اندازه‌گیری شده توسط دوزیمتر حالت جامد در میدان پرتو و مقدار پیش‌گویی شده در پژوهش حاضر می‌باشد که در مقایسه با روش شبیه‌سازی مونت‌کارلو از صحت خوبی نیز برخوردار است.

کلیدواژگان: تخمین دوز، غربالگری ماموگرافی، دوز متوسط غده‌ای، شبکه عصبی، پرسپترون چند لایه.

۱. مقدمه

پستان دومین عامل منجر به مرگ در بین انواع سرطان‌ها در بین زنان است [۱]. محققین بر این باورند که تشخیص زودهنگام سرطان پستان می‌تواند تا ۳۰ درصد مرگ ناشی از آن را کاهش

سرطان پستان یکی از شایع‌ترین سرطان‌ها در بین زنان است که هر سال جان نیم میلیون انسان را در دنیا می‌گیرد. به‌طور کلی اکثر انجمن‌های سرطان پستان نشان می‌دهند که سرطان

دهد [۲].

تفاوت در مشخصات دستگاه‌ها، برای هر مرکز و هر دستگاه، شبیه‌سازی جداگانه صورت گیرد که کار سخت و پیچیده‌ای است و با توجه به عمر بالای دستگاه‌ها در کشور ما، کارکرد دستگاه‌ها با مشخصات اسمی آن‌ها نیز متفاوت خواهد بود که در شبیه‌سازی ملحوظ نمی‌گردد [۷-۸]. در پژوهشی که محمدی و همکارانش برای آزمون‌های ماموگرافی با استفاده از دو روش اندازه‌گیری با دوزیمتر تی ال دی^۲ و شبیه‌سازی مونت کارلو انجام شد، نشان داده شد که اختلاف دوزهای جذب شده در بافت پستان برای این دو روش (اندازه‌گیری و محاسباتی) از ۷/۵ درصد تا ۱۷ درصد متغیر می‌باشد [۹].

برای حل این معضلات و رسیدن به تخمینی دقیق و کارآمد، محققین حاضر بر آن شدند تا از شبکه عصبی برای تخمین کرما استفاده کنند. مزیت روش شبکه‌های عصبی مصنوعی این است که از صحت و دقت خوبی برخوردار است زیرا توسط داده‌های دستگاه‌های مراکز متفاوت و به تعداد زیاد، آموزش را فراگرفته [۱۰] و میزان کرمای هوا را به صورت خودکار اندازه‌گیری می‌کند، به طوری که در فرآیند محاسبات مذکور به دوزیمتر و اپراتورهای آموزش دیده نیازی نیست و کاربری راحت‌تری نیز دارد. همچنین ما را از خطای محاسباتی و اختلافی که بین دوز جذبی اندازه‌گیری شده با روش دوزیمتری و محاسباتی با روش شبیه‌سازی مونت کارلو وجود دارد، مصون نگه می‌دارد [۱۱].

۲. مواد و روش‌ها

برای انجام پژوهش حاضر، تعداد ۲۲۴ نمونه خروجی از ۳۲ مرکز ماموگرافی از سراسر کشور جمع‌آوری شده است. برای اندازه‌گیری این داده‌ها از فانتومی با مشخصات مشابه محتویات بافت سینه (میزان غده/چربی ۵۰-۵۰ درصد) استفاده

برای تشخیص این بیماری یک آزمایش تشخیصی مانند تهیه یک تصویر ماموگرافی پیشنهاد می‌شود تا قبل از ظهور نشانه‌های بیماری، توده در مراحل اولیه تشخیص داده شود [۳]. با توجه به موارد زیاد استفاده از ماموگرافی به منظور غربالگری و تشخیص توده‌های پستان، نگرانی‌هایی در مورد افزایش دوز جذبی بیمار، به علت حساس بودن بافت سینه و جذب حداکثری میزان اشعه توسط پستان، وجود دارد. بنابراین اطلاع از میزان دوز متوسط غده‌ای^۱ بوسیله تخمین آن می‌تواند در شناخت میزان دوز جذبی کمک کننده باشد [۴].

چندین روش برای محاسبه دوز متوسط غده‌ای در پستان ارائه شده است که بیش‌تر این روش‌ها بر مبنای شبیه‌سازی مونت کارلو^۲ استوار می‌باشند. به این صورت که میزان کرمای ورودی به سطح پوست با استفاده از دوزیمتر اندازه‌گیری شده و سپس ضرایب فاکتور تبدیل لازم با درون‌یابی از جداول پارامترهای محاسبه شده به روش شبیه‌سازی مونت کارلو در مطالعات مختلف بدست می‌آید [۵-۶]. عیب روش مشروحه این است که برای محاسبه دوز متوسط غده‌ای، به نتیجه دوزیمتری بافت پستان نیاز است. لازم به ذکر است که براساس آمار موجود در سال ۱۳۹۶ کشور، تعداد ۷۲۲ دستگاه ماموگرافی موجود است که از این تعداد حداکثر ۱۴ مرکز مجهز به دستگاه‌های اندازه‌گیری مناسب می‌باشند. بنابراین روش‌های مبتنی بر نتایج اندازه‌گیری برای برآورد دوز، نمی‌تواند روش کارآمدی باشد.

روش دیگر، شبیه‌سازی دستگاه ماموگرافی با در اختیار داشتن جزئیات دستگاه ماموگرافی، با استفاده از کد مونت کارلو است. عیب روش مونت کارلو نیز این است که با توجه به

¹Mean Glandular Dose

²Monte-Carlo

³ThermoLuminescent Dosimeter

شده است [۱۲]. همچنین برای اندازه گیری کرمای هوای ورودی سطح پوست^۱ و لایه نیم جذب^۲، از آشکارساز حالت جامد استفاده شده است. هم زمان با ثبت و اندازه گیری میزان کرمای هوای بر روی سطح فانتوم معادل بافت سینه و لایه نیم جذب، میزان ماکزیمم کیلوولتاژ^۳، میلی آمپر ثانیه^۴ و نوع فیلتر/هدف نیز ثبت گردید که به عنوان عوامل مداخله کننده در میزان ضخامت لایه نیم جذب دستگاه محسوب می شوند. لایه نیم جذب به ولتاژ آند، فیلتر، جنس آند و سن تیوب بستگی دارد. بنابراین نوع برند و طول عمر هر دستگاه در ضخامت لایه نیم جذب دیده می شود که این پارامتر به عنوان ورودی، به شبکه اعمال شده است [۱۳]. شبکه طراحی شده در تحقیق حاضر، از ۶ ورودی شامل: برند دستگاه، میزان ماکزیمم کیلوولتاژ، میزان میلی آمپر ثانیه، نوع و جنس فیلتر/هدف، ضخامت کلی فیلتر و لایه نیم جذب تشکیل شده است که به عنوان متغیر در ورودی شبکه، کدگذاری شده اند. خروجی نیز میزان کرمای ورودی سطح پستان می باشد. داده ها پس از جمع آوری به ۳ دسته، تقسیم بندی شدند: مجموعه های آموزش، ارزیابی و تست. داده های آموزش متشکل از ۷۰ درصد کل داده و مجموعه های ارزیابی و تست هر کدام متشکل از ۱۵ درصد کل داده ها می باشند که برای جداسازی آن ها از ساده ترین روش که همان انتخاب هر مجموعه به صورت تصادفی می باشد، استفاده شده است.

شبکه های عصبی مصنوعی بر اساس محاسبات روی داده های عددی یا مثال ها، قوانین کلی را یاد می گیرند. زمانی که ضرورت استفاده از روش های پیش بینی با کمترین خطا و بیشترین قابلیت اطمینان وجود داشته باشد از شبکه عصبی مصنوعی استفاده می شود. مزیت های روش شبکه عصبی

مصنوعی نسبت به روش های آماری عبارتند از: عدم محدودیت در تعداد ورودی و خروجی، عدم حساسیت به تغییرات ناگهانی در داده، قابلیت مدل سازی رفتارهای به شدت غیر خطی، آموزش سریع و دارای فرایند جلوگیری از آموزش بیش از اندازه [۱۴-۱۵].

در محاسبه کرمای هوای ورودی سطح از معماری شبکه عصبی پرسپترون با تعداد نورون های لایه پنهان متفاوت، استفاده شد. شبکه عصبی پرسپترون چندلایه^۵ با روش یادگیری پس انتشار خطا یکی از متداول ترین شبکه های کاربردی است. در تحقیقات مختلف، اثبات شده است که شبکه پرسپترون چندلایه که از نوع یادگیری با ناظر بوده، در صورت انتخاب صحیح ساختار مناسب داخلی، قادر است هرگونه سیستم غیرخطی را مدل کرده و شبیه سازی نماید [۱۶].

برای آموزش شبکه عصبی از الگوریتم پس انتشار لونیبرگ-مارکواریت^۶، استفاده شده است. الگوریتم لونیبرگ-مارکواریت در واقع شکل تغییر یافته ای از روش نیوتن می باشد که برای کمینه کردن توابعی که به صورت مجموع مربعاتی از دیگر توابع غیرخطی هستند، طراحی شده است. معمولاً الگوریتم لونیبرگ مارکواریت در شبکه های چند لایه ای که تا چند صد عدد وزن و بایاس دارند و برای تقریب تابع مورد استفاده قرار گرفته و شاخص عملکرد، در آن ها میانگین مربعات خطا می باشد، سریع ترین روش آموزش می باشد [۱۷-۱۸].

در شبکه های چندلایه که برای تقریب تابع و شناسایی الگو مورد استفاده قرار می گیرند، تعداد لایه های پنهان مورد نیاز در شبکه، توسط صورت مساله تعیین نمی گردد، بنابراین هر تعداد لایه پنهان، ممکن می باشد. فرآیند استاندارد این است که

¹Entrance Surface Air Kerma

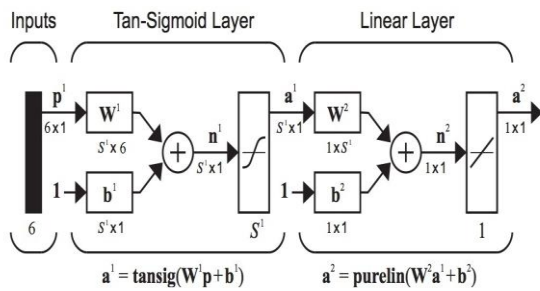
²Half-Value layer

³Kilovoltage peak

⁴milliAmperage-seconds

⁵Multi Layer Perceptron

⁶Levenberg Marquardt



شکل (۱): شبکه عصبی دولایه با ۶ ورودی و تابع فعال‌ساز تانژانت سیگموید و دارای ۱ خروجی با تابع همانی.

توابع تبدیل سیگموید به‌طور عمده در شبکه‌های چندلایه که توسط الگوریتم پسانتشار آموزش داده می‌شوند مورد استفاده قرار می‌گیرند که یکی از عوامل آن، مشتق‌پذیر بودن این توابع می‌باشد [۱۸]. از نقطه نظر بهینه‌سازی، یادگیری در شبکه عصبی مصنوعی، با حداقل‌سازی یک تابع خطا به‌عنوان شاخصی از عملکرد مدل، معادل می‌باشد. از رایج‌ترین و مهم‌ترین شاخص‌های عملکرد مدل می‌توان به شاخص میانگین مربعات خطا^۱ بین خروجی و هدف، و شاخص رگرسیون که همبستگی بین خروجی و هدف را نشان می‌دهد، اشاره کرد [۱۸]. بنابراین برای بررسی صحت شبکه عصبی و میزان دقت در تخمین کرما، علاوه بر بررسی شاخص‌های عملکرد مدل، نتایج مدل، با نتایج تحقیقات گزارش شده، مقایسه شده‌است.

۳. بحث و نتایج

پس از طراحی شبکه، آموزش و اجرای برنامه، شبکه با شرایط و پارامترهای مختلف برای رسیدن به بهترین نتیجه، آموزش داده شد. گرادیان خطا که مشتق تابع می‌باشد، زمانی که نزدیک صفر است، نشان‌دهنده این است که شیب تابع در آن نقطه صفر شده‌است، بنابراین نشان‌دهنده اکسترمم تابع بوده و یعنی در مینیمم محلی قرار داریم، بنابراین مبین همگرایی مقادیر هدف و خروجی می‌باشد و دیگر ادامه دادن برنامه مورد نیاز

آموزش با شبکه‌ای متشکل از یک لایه پنهان شروع شود. اگر عملکرد شبکه دولایه رضایت‌بخش نبود، در آن صورت می‌توان از شبکه سه لایه استفاده کرد. استفاده بیش از دو لایه پنهان در شبکه‌های عصبی مصنوعی، غیرمتداول است [۱۸]. که در پژوهش ما نیز شبکه عصبی دولایه، مورد استفاده قرار گرفت. همچنین باید تعداد نورون‌های هر لایه نیز تعیین گردد. تعداد نورون‌ها در لایه خروجی برابر با اندازه بردار داده‌های هدف می‌باشد که شبکه ما به دلیل وجود تنها یک خروجی، دارای یک نورون لایه خروجی می‌باشد. تعداد نورون‌ها در لایه‌های پنهان براساس میزان پیچیدگی مساله مورد نظر تعیین می‌شود که دارای یک میزان حداقلی و حداکثری می‌باشد. حداقل تعداد نورون‌های لایه اول در شبکه عصبی دولایه به‌صورت تجربی از رابطه ۱ بدست می‌آید که n_1 تعداد ورودی لایه اول و n_0 تعداد نورون لایه خروجی می‌باشد که به‌ترتیب ۶ و یک می‌باشند.

$$2 * (n_1 + n_0) \tag{1}$$


بنابراین حداقل تعداد نورون‌های لایه اول شبکه، ۱۴ می‌باشد. حداکثر تعداد نورون‌های لایه اول در شبکه عصبی دولایه نیز از رابطه ۲ بدست می‌آید که k تعداد نمونه‌ها می‌باشد.

$$\frac{k(n_1 + n_0) - n_0}{n_1 + n_0 - 1} \tag{2}$$

بنابراین حداکثر تعداد نورون‌های لایه اول شبکه، ۲۶۱ می‌باشد [۱۸]. همچنین برای آموزش شبکه، از تابع فعال‌سازی تانژانت سیگموید استفاده شد (شکل ۱).

¹Mean Squared Error

مشاهده است با افزایش تعداد نورون‌ها، میزان میانگین مربعات خطا، افزایش می‌یابد. بنابراین شبکه عصبی بالاتر از ۶۰ نورون در لایه پنهان، بهینه نیست.




شکل (۳): میانگین مربعات خطا نسبت به تعداد نورون‌های لایه پنهان

برای دستیابی به بهینه‌ترین تعداد نورون، مقادیر میانگین شاخص‌های ارزیابی شبکه نسبت به تعداد نورون لایه پنهان در جدول ۱ ارائه شده است. همان‌طور که مشاهده می‌شود، در شبکه با ۳۵ نورون موجود در لایه پنهان، شبکه دارای بالاترین رگرسیون بین خروجی و هدف با مقدار ۹۴٫۹ درصد می‌باشد. همچنین میانگین مربعات خطای داده‌های تست و آموزش به ترتیب ۰٫۹۱۲ میلی‌گری و ۰٫۲۰۱ میلی‌گری بدست آمد که ۹٫۱۵ درصد دامنه تغییرات و ۲٫۱۴ درصد برای خروجی بدست آمد. بنابراین تعداد ۳۵ نورون، بهترین تعداد برای آموزش شبکه می‌باشد. حال بار دیگر شبکه با ۳۵ نورون لایه پنهان، آموزش داده شد که نتایج آن در شکل‌های ۴ و ۵ ارائه شده است. همان‌طور که مشاهده می‌شود مقدار میانگین مربعات خطا برای تمام داده‌ها مقدار ۰٫۴۳۷ میلی‌گری بدست آمد که ۴٫۸ درصد دامنه تغییرات خروجی می‌باشد و میزان رگرسیون بین خروجی و هدف مقدار ۹۵٫۷ درصد می‌باشد. میانگین و

نیست. بر همین اساس گرادینان خطا صفر در نظر گرفته شد [۱۹-۲۰].

در آموزش شبکه عصبی در هر تکرار، با شبکه جدیدی روبرو هستیم. به همین منظور و برای افزایش اعتمادپذیری عملکرد شبکه، برای یک تعداد نورون معین، ۵ بار شبکه را آموزش داده و میانگین مقادیر شاخص ارزیابی آن، ملاک عمل قرار داده شد [۲۱]. همان‌طور که گفته شد، تعداد نورون‌ها در لایه‌های پنهان توسط میزان پیچیدگی مساله مورد نظر تعیین می‌شوند که برای مساله حاضر، این مقدار بین ۱۴ و ۲۶۱ بدست آمد. با اجرای برنامه برای همه این تعداد نورون‌ها، مشخص شد که در مقادیر بالای ۶۰ نورون به علت پیچیده شدن حل مساله و محاسبات، رگرسیون به کمتر از ۸۵ درصد رسید (شکل ۲).



شکل (۲): رگرسیون خروجی و هدف نسبت به تعداد نورون‌های لایه پنهان.

همچنین مقدار جذر میانگین مربعات خطا برای داده‌های تست، در مقادیر بالای ۶۰ نورون به بالای ۱٫۷۳ میلی‌گری رسید که حدود ۱۹٫۰۵ درصد دامنه تغییرات خروجی می‌باشد. تغییرات میانگین مربعات خطا نسبت به تعداد نورون‌ها در شکل ۳ ارائه شده است. همان‌طور که از شکل قابل



۰,۸۹۱	۰,۹۲۵	۰,۸۰۳	۶۰	۰,۹۲۵	۱,۵۷۸	۰,۴۹۷	۳۶	جدول (۱): میانگین شاخص های ارزیابی شبکه نسبت به تعداد نورون های لایه پنهان.
				۰,۸۹۷	۵,۲۳۹	۰,۲۹۰	۳۷	

انحراف معیار میانگین مربعات خطا در نمودار هیستوگرام به ترتیب ۰,۰۳ و ۰,۶۶ می باشد. همچنین مقدار میانگین مربعات خطا برای داده های تست مقدار ۰,۵۰۳ میلی گری است که ۵,۱ درصد دامنه تغییرات خروجی می باشد و میزان رگرسیون بین خروجی و هدف مقدار ۹۵ درصد بدست آمد. همچنین میانگین و انحراف معیار میانگین مربعات خطا در نمودار هیستوگرام داده های تست به ترتیب ۰,۱۹ و ۰,۶۹ می باشد. بنابراین با استفاده از شبکه عصبی آموزش دیده می توان کرمای ورودی سطح پوست را با صحت خوبی (۹۵,۷ درصد) تخمین زد.

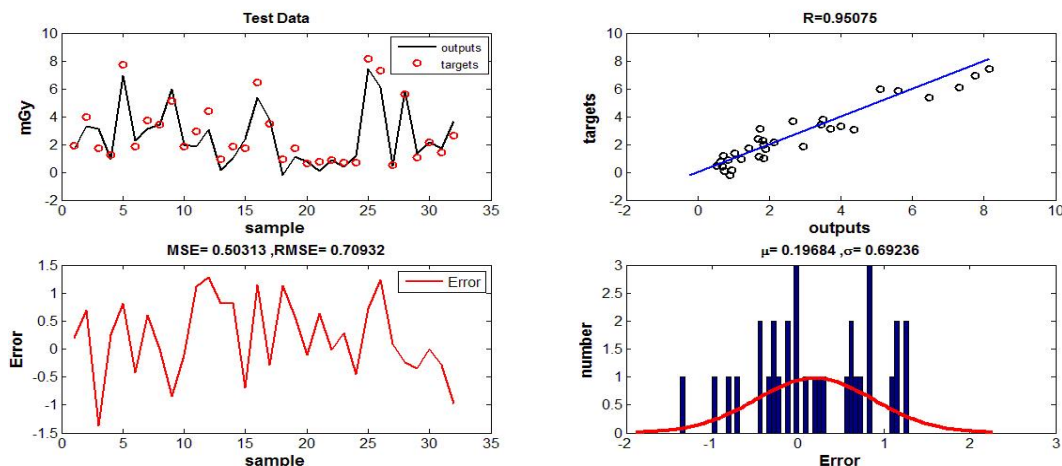
۴. نتیجه گیری

در این مقاله، مدل شبکه های عصبی پرسپترون چندلایه با الگوریتم آموزش لونبرگ مارکوارت برای پیش بینی کرمای هوا براساس پارامترهای قابل اندازه گیری، آموزش دیده است. با توجه به شکل های ۴ و ۵ می توان دریافت که ضریب رگرسیون بین خروجی و هدف در پژوهش صورت گرفته ۹۵,۷ درصد می باشد که نشانگر اختلافی ۴,۳ درصدی بین کرمای اندازه گیری شده توسط دوزیتر حالت جامد و شبیه سازی

تعداد نورون	MSE آموزش	MSE تست	رگرسیون	تعداد نورون	MSE آموزش	MSE تست	رگرسیون
۱۴	۰,۳۶۵	۱,۶۵۸	۰,۹۱۸	۳۸	۰,۳۹۰	۴,۳۰۵	۰,۸۹۰
۱۵	۰,۲۰۲	۱,۰۸۲	۰,۹۴۷	۳۹	۰,۶۵۳	۲,۲۴۶	۰,۸۹۴
۱۶	۰,۸۸۸	۱,۴۰۷	۰,۸۸۱	۴۰	۰,۲۱۳	۵,۷۴۸	۰,۸۹۸
۱۷	۰,۴۱۷	۲,۲۹۰	۰,۹۲۶	۴۱	۰,۴۸۱	۳,۸۲۹	۰,۹۰۲
۱۸	۰,۹۷۵	۲,۳۵۴	۰,۸۷۵	۴۲	۰,۶۰۱	۲,۳۸۴	۰,۹۰۵
۱۹	۱,۱۴۷	۱,۲۰۱	۰,۸۷۸	۴۳	۰,۳۶۷	۶,۱۴۳	۰,۸۶۳
۲۰	۰,۴۱۳	۱,۳۸۷	۰,۹۲۵	۴۴	۰,۴۸۷	۱,۸۶۸	۰,۹۱۴
۲۱	۰,۳۳۹	۱,۸۲۲	۰,۹۳۳	۴۵	۰,۹۳۴	۱,۲۸۴	۰,۸۶۶
۲۲	۰,۸۴۵	۱,۸۰۶	۰,۹۰۷	۴۶	۱,۰۰۳	۳,۴۱۱	۰,۸۴۸
۲۳	۰,۸۴۸	۱,۵۰۳	۰,۸۸۲	۴۷	۰,۱۵۵	۵,۴۸۲	۰,۸۷۹
۲۴	۰,۷۲۲	۱,۰۰۹	۰,۹۲۰	۴۸	۰,۲۵۰	۲,۱۸۶	۰,۹۳۵
۲۵	۱,۷۲۴	۲,۲۸۲	۰,۷۹۹	۴۹	۲,۵۹۰	۴,۱۸۳	۰,۷۸۹
۲۶	۰,۷۹۷	۱,۳۶۸	۰,۹۱۰	۵۰	۰,۵۶۵	۱,۴۶۹	۰,۹۰۵
۲۷	۰,۶۵۲	۱,۴۱۳	۰,۹۱۶	۵۱	۰,۳۸۰	۳,۶۴۹	۰,۹۰۱
۲۸	۰,۳۹۴	۲,۶۹۷	۰,۹۲۰	۵۲	۰,۲۰۳	۱,۷۷۰	۰,۸۹۵
۲۹	۰,۸۲۰	۱,۵۸۳	۰,۸۲۴	۵۳	۰,۵۴۷	۱,۸۲۵	۰,۸۹۶
۳۰	۲,۲۷۰	۳,۵۴۰	۰,۸۱۶	۵۴	۰,۱۸۶	۴,۰۲۵	۰,۸۸۷
۳۱	۰,۱۴۹	۲,۹۱۹	۰,۹۳۷	۵۵	۰,۲۱۲	۱,۲۲۹	۰,۹۴۶
۳۲	۰,۳۶۳	۳,۱۸۱	۰,۹۰۸	۵۶	۰,۴۵۸	۵,۵۱۹	۰,۸۷۶
۳۳	۰,۳۰۴	۲,۴۳۸	۰,۹۰۴	۵۷	۰,۶۲۷	۲,۵۲۵	۰,۹۰۸
۳۴	۰,۴۱۹	۱,۹۴۷	۰,۹۳۳	۵۸	۰,۲۴۲	۱,۴۷۹	۰,۹۲۰
۳۵	۰,۲۰۱	۰,۹۱۲	۰,۹۴۹	۵۹	۰,۹۶۶	۴,۱۱۰	۰,۸۶۳



شکل (۴): بالا چپ: مقایسه خروجی و هدف برای همه داده ها- بالا راست: مقایسه رگرسیون خروجی و هدف برای همه داده ها- پایین چپ: خطا برای همه داده ها- پایین راست: نمودار هیستوگرام خطا برای همه داده ها.




شکل (۵): بالا چپ: مقایسه خروجی و هدف برای داده‌های تست - بالاراست: مقایسه رگرسیون خروجی و هدف برای داده‌های تست - پایین چپ: خطا برای داده‌های تست - نمودار هیستوگرام خطا برای داده‌های تست.

با روش شبیه‌سازی مونت کارلو صورت گرفته است که دارای اختلافی ۷,۵ تا ۱۷ درصدی بین مقادیر اندازه‌گیری شده با دوزیمتر، و شبیه‌سازی شده با روش مونت کارلو بودند. اگر چه در اصل این رویکرد، روش استاندارد برای تعیین کرمای هوا در ماموگرافی رایج نیست، اما روش فعلی استفاده از شبکه‌های عصبی در پیش‌بینی کرمای هوا، تخمین کرمای هوای احتمالی بیمار را قبل از اینکه در معرض اشعه ایکس قرار بگیرد، میسر می‌کند. این رویکرد می‌تواند گامی بزرگ در توسعه چنین سیستم‌های شبکه عصبی باشد زیرا می‌تواند با داده‌های بیشتری برای رسیدن به نتایج حتی بهتر، آموزش داده‌شود.

انجام شده در پژوهش حاضر می‌باشد. همچنین میانگین مربعات خطا بین مقادیر اندازه‌گیری شده و شبیه‌سازی ۰,۴۳۷ میلی‌گری است که ۴,۸ درصد دامنه تغییرات کرمای هوای اندازه‌گیری شده می‌باشد. تست بر روی داده‌هایی که جمع‌آوری شده بود نتایج بسیار مثبتی به‌بار آورد. در همه موارد، عامل هم‌بستگی رگرسیون بیش از ۹۴ درصد بود. (شکل ۶)

در مورد این نوع رویکرد در پیش‌بینی کرمای هوا، متون اندکی وجود دارد. در حالی که در این راستا پژوهش‌های زیادی



شکل (۶): مقایسه بین تخمین شبکه عصبی (مشکی) با داده‌های جمع‌آوری شده (آبی) و همچنین میزان خطا (قرمز).

۵. مراجع

- [1] The National Cancer Institutes (NCI) (2018). <https://www.cancer.gov/> (accessed August 21, 2018).
- [2] L. Tabár, B. Vitak, TH-H. Chen, AM-F. Yen, A. Cohen, T. Tot, et al. Swedish Two-County Trial: Impact of Mammographic Screening on Breast Cancer Mortality during 3 Decades. *Radiology*. 260 (2011) 658–663.
- [3] New Zealand National Screening Unit Website (2018). <https://www.health.govt.nz/nz-health-statistics> (accessed August 21, 2018).
- [4] DR. Dance, CL. Skinner, GA. Carlsson. Breast dosimetry. *Appl Radiat Isot*. 50 (1999) 185–203.
- [5] DR. Dance. Monte Carlo calculation of conversion factors for the estimation of mean glandular breast dose. *Phys Med Biol*. 35 (1990) 1211–1219.
- [6] WT. Sobol, X. Wu. Parametrization of mammography normalized average glandular dose tables. *Med Phys*. 24 (1997) 547–554.
- [7] K. Nigaprake, P. Puwanich, N. Phaisangitisakul, W. Youngdee. Monte Carlo simulation of average glandular dose and an investigation of influencing factors. *J Radiat Res*. 51 (2010) 441–448.
- [8] KO. Ko, SH. Park, JK. Lee. Assessment of patient dose in mammography using Monte Carlo simulation. *Nucl Sci Technol*. 41 (2004) 214–218.
- [9] A. Mohammadi, R. Faghihi, S. Mehdizadeh, K. Hadad. Total absorbed dose of critical organs in mammography, assessment and comparison of ... *Biomed Tech*. 50 (2005) 393–394.
- [10] D. Čeke, S. Kunosic, M. Kopic, L. Lincender. Using Neural Network Algorithms in Prediction of Mean Glandular Dose Based on the Measurable Parameters in Mammography. *Acta Inform Medica*. 17 (2009) 194–197.
- [11] P. Mohammadyari, R. Faghihi, MA. Mosleh-Shirazi, M. Lotfi, MR. Hematiyan, C. Koontz, et al. Calculation of dose distribution in compressible breast tissues using finite element modeling, Monte Carlo simulation and thermoluminescence dosimeters. *Phys Med Biol*. 60 (2015) 9185–9202.
- [12] R. Highnam. Patient-Specific Radiation Dose Estimation in Breast Cancer Screening Keeping Patients Safe and Informed (2018). <https://www.volparasolutions.com/assets/Uploads/VolparaDose-White-Paper.pdf> (accessed August 21, 2018).
- [13] E. Ariga, S. Ito, S. Deji, T. Saze T. Determination of half value layers of X-ray equipment using computed radiography imaging plates. *Phys Medica*. 28 (2012) 71–75.
- [14] SS. Haykin. *Neural networks: a comprehensive foundation*. Prentice Hall. (1998).
- [15] A. Asgharzadeh, MR. Deevband, M. Ashtiyani. Neutron spectrum unfolding using radial basis function neural networks. *Appl Radiat Isot*. 129 (2017) 35–41.
- [16] JA. Anderson. *An introduction to neural networks*. MIT Press. (1995).
- [17] MT. Hagan, MB. Menhaj. Training feedforward networks with the Marquardt algorithm. *IEEE Trans Neural Networks*. 5 (1994) 989–993.
- [18] MT. Hagan, HB. Demuth, MH. Beale, O. De Jesús. *Neural network design*. (2014).
- [19] MS. Iyer, RR. Rhinehart. A method to determine the required number of neural-network training repetitions. *IEEE Trans Neural Networks*. 10 (1999) 427–432.
- [20] K. Fukumizu, S. Amari. Local minima and plateaus in multilayer neural networks. *Ninth Int Conf Artif Neural Networks 1999 ICANN 99 Conf Publ No*. 470. 2 (1999) 597–602.
- [21] L. Hamm, BW. Brorsen, MT. Hagan. Comparison of Stochastic Global Optimization Methods to Estimate Neural Network Weights. *Neural Process Lett*. 26 (2007) 145–158.