



شناسایی سرطان پستان از روی تصاویر ماموگرافی با استفاده از شبکه‌های عصبی کانولوشن

الهام قوچ‌داشی : کارشناسی ارشد، گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران.
سعید مشگینی : استادیار گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران، (*نویسنده مسئول) meshgini@tabrizu.ac.ir
سمیه ماکویی : استادیار گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران.

چکیده

کلیدواژه‌ها

یادگیری عمیق،
شبکه‌های عصبی کانولوشن،
ماموگرافی،
سرطان پستان،
طبقه بندی

تاریخ دریافت: ۱۴۰۰/۱۲/۲۰

تاریخ چاپ: ۱۴۰۱/۰۳/۲۵

زمینه و هدف: سرطان سینه، شایع‌ترین سرطان در میان زنان و دومین علت مرگ‌ومیر ناشی از سرطان در زنان است. ماموگرافی یک نوع تصویربرداری ساده و ابزاری برای کشف زودهنگام سرطان‌های غیرقابل لمس پستان است؛ اما بررسی و تفسیر تعداد بسیار زیادی از تصاویر ماموگرام، کاری بسیار دشوار و زمان‌بر و احتمال وقوع خطاهای انسانی بسیار است. یکی از مهم‌ترین روش‌های یادگیری عمیق، شبکه‌های عصبی کانولوشنی هستند. در مقاله، از پایگاه داده دیجیتال برای ماموگرافی غربالگری از نسخه‌ی CBIS با هدف ارتقا اعتبارسنجی داده‌ها مورد استفاده گردید.

روش کار: در این پژوهش، در حالت دو کلاس سه نوع معماری و در حالت سه کلاس یک نوع معماری طراحی گردید. برای طراحی شبکه، لایه‌ها با توجه به شکل ۵ چپ‌چین گردید که از یک لایه ورودی به اندازه $1 \times 145 \times 159$ و یک لایه کانولوشنی دوبعدی به اندازه 8×20 و از یک لایه ادغام ماکسیمم با سایز 2×5 و از دو لایه تماماً متصل استفاده شد (از لایه ادغام ماکسیمم به این دلیل استفاده شد که از حداکثر مقدار خوشه‌های نورونی لایه پیشین استفاده می‌کند و همچنین باعث همگرایی سریع‌تر، بهبود تعمیم‌دهی و انتخاب ویژگی‌های نامتغیر شود) و مقاردهی وزن هر لایه به‌صورت تصادفی بوده است. سومین معماری شبکه طراحی شده نشان داده‌شده، به این صورت است که از یک لایه ورودی و سه لایه کانولوشنی دوبعدی و از سه لایه ادغام ماکسیمم و از دو لایه تماماً متصل استفاده شده که سایز هر لایه در جدول (۳) نشان داده شده است. لایه‌سازی برابر با یک است. زمان آموزش $37:6$ است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی $92/58\%$ و آزمایش $86/5\%$ به‌دست آمده است.

یافته‌ها: نتایج حاصل از شبیه‌سازی برای ۳۱۰ داده برای دومین نوع معماری دو کلاس زمان آموزش $6:06$ است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی $84/40\%$ و آزمایش $72/82\%$ به‌دست آمده است همچنین نتایج حاصل از شبیه‌سازی برای ۱۲۴۰ داده برای اولین نوع معماری دو کلاس زمان آموزش $44:3:54$ است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی $51/72\%$ و آزمایش $51/69\%$ به‌دست آمده است.

نتیجه‌گیری: پس از یک‌سری پیش‌پردازش‌های صورت گرفته تعداد تصاویر مورد استفاده ۳۱۰ عدد انتخاب گردید. سپس دو نوع معماری دیگر طراحی گردید که با اعمال داده‌های پردازش شده، دقت حاصل از معماری‌ها برای ۳۱۰ داده به ترتیب $42/39\%$ ، $72/82\%$ ، $79/34\%$ بدست آمد. دقت حاصل از معماری‌ها برای ۱۲۴۰ داده $51/69\%$ ، $65/45\%$ ، $72/46\%$ بدست آمد. در حالت سه کلاس از ۱۳۱۸ تصویر موجود در پایگاه‌داده استفاده شد و به‌دلیل هم اندازه نبودن تصاویر، تغییر سایز صورت‌گرفت و سپس ماسک تصاویر بر روی تصاویر منطبق گردید و به شبکه عصبی کانولوشنی طراحی شده داده‌شده داده‌ها به سه کلاس طبقه‌بندی گردید. با توجه به پیش‌پردازش و عملیاتی که انجام داده شده است، دقت شبکه افزایش یافته ($72/39\%$) و نتیجه بهبود یافته است. مزیت روش دقت داده‌های اعتبارسنجی و داده‌های آزمایش افزایش یافته است.

تعارض منافع: گزارش نشده است.

منبع حمایت‌کننده: حامی مالی ندارد.

شیوه استناد به این مقاله:

Ghochdashi E, Meshgini S, Makouei S. Breast Cancer Detection from Mammography Images Using Convolutional Neural Network. Razi J Med Sci. 2022;29(3): 240-253.

*انتشار این مقاله به‌صورت دسترسی آزاد مطابق با **CC BY-NC-SA 3.0** صورت گرفته است.

Breast Cancer Detection from Mammography Images Using Convolutional Neural Network

Elham Ghochdashi: Master Degree, Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran.

Saeed Meshgini: Assistant Professor; Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran. (*Corresponding author) meshgini@tabrizu.ac.ir

Somayeh Makouei: Assistant Professor; Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran.

Abstract

Background & Aims: Mammography is one of the reliable methods for early detection of breast cancer. However, it is difficult for the radiologist to provide an accurate and uniform assessment of the massive mammograms produced in the extensive screening. Therefore, the presence of an intelligent system that is highly accurate in detecting the location of a cancerous mass will be very necessary and necessary. In this regard, this research, by using mammography images and image processing techniques, has been tried to get an accurate diagnosis of the location of breast cancer. For this purpose, first by using some digital image enhancement techniques, an attempt is made to increase the recognition of cancerous tissues, and then by using classification techniques, the precise separation of cancerous parts from healthy parts of the breast is done. In research, various techniques have been proposed to improve the detection of tumors in mammograms and the accuracy of breast cancer classification. The basic problems in breast mammography in identifying and classifying masses and microcalcifications are caused by various factors. One of these complications is due to the awkward and illogical shape of some clusters of calcifications. The boundaries of each of the microcalcifications in the cluster cannot be well defined, and the radiologist may not be able to make an accurate diagnostic decision about the clinical nature of the microcalcifications in an area, but he can usually identify suspicious areas. In the paper, they presented a CAD system for processing mammographic images. They used the compressed breast thickness parameter for feature selection showed the importance of breast compression and changes in breast composition and then applied it to a variety of mammography image processing tasks. Considering that breast thickness is a key parameter in calculations and is not usually recorded; they showed that breast thickness can be estimated from an image and examined its sensitivity on the estimates. Then they discussed how to simulate X-rays in each examination and also simulate the appearance of anatomical structures inside the breast. In the research, tissue characteristics were used to automatically evaluate breast tissue density in digital mammograms. In this approach, the target area is limited to breast tissue only; so that artifacts, background, and head muscles are removed. Breast cancer is the most common cancer among women and the second cause of cancer-related death in women. Mammography is a simple type of imaging and a tool for early detection of non-palpable breast cancers; however, examining and interpreting a large number of mammogram images is a challenging and time-consuming task, and the possibility of human errors is high. One of the most important deep learning methods is convolutional neural networks. In the article, the digital database for screening mammography from the CBIS version was used to improve data validation.

Methods: In this research, three types of architecture were designed in the two-class mode and one type of architecture was designed in the three-class mode. To design the network, the layers were arranged according to Figure 5, which uses an input layer of size 159 x 145 a two-dimensional convolution layer of size 20 x 8, and a maximum integration layer of size 5 x 2, and two fully connected layers. (The maximum integration layer was used because it uses the maximum amount of neuron clusters of the previous layer and also causes faster convergence,

Keywords

Deep Learning,
Convolutional Neural
Networks,
Mammography,
Breast Cancer,
Classification

Received: 11/03/2022

Published: 15/06/2022

and improves generalization and selection of invariant features). The third designed network architecture is shown in such a way that one input layer three 2D convolutional layers three maximum integration layers and two fully connected layers are used, the size of each layer is shown in Table (3). Layering is equal to one. The training time is 6:37 and the accuracy obtained for the validation data is 92.58% and the test data is 86.5%.

Results: The simulation results for 310 data for the second type of two-class architecture, the training time is 6:06, and the accuracy obtained for the validation data is 84.40% and 72.82% for the test data. Also, the simulation results for 1240 The data for the first type of two-class architecture, the training time is 3:44:54, and the accuracy obtained for the validation data is 51.72% and the test data is 51.69%.

Conclusion: After a series of pre-processing, the number of used images was selected as 310. Then two other types of architecture were designed, and by applying the processed data, the accuracy of the architectures for 310 data was 42.39%, 7and 2.82%, respectively. 79.34% was obtained. The accuracy of the architectures for 1240 data was 51.69%, 65.45%, 72.46%. In the three-class mode, 1318 images in the database were used, and due to the lack of the same size, the images were resized. Then the image mask was applied to the images and given to the designed convolutional neural network, and the data was classified into three classes. According to the pre-processing and operations that have been done, the accuracy of the network has increased (72.39%) and the result has improved. The advantage of the method is the increased accuracy of validation and test data.

Conflicts of interest: None

Funding: None

Cite this article as:

Ghochdashi E, Meshgini S, Makouei S. Breast Cancer Detection from Mammography Images Using Convolutional Neural Network. Razi J Med Sci. 2022;29(3): 240-253.

*This work is published under CC BY-NC-SA 3.0 licence.

مقدمه

سرطان سینه، پس از سرطان پوست شایع‌ترین سرطان در میان زنان است. همچنین دومین علت مرگ‌ومیر ناشی از سرطان، در زنان پس از سرطان ریه است. سرطان سینه ناشی از رشد خارج از قاعده سلول‌های غیرطبیعی در پستان است. در تمام دنیا، این بیماری شایع‌ترین سرطان در بانوان و یکی از قابل‌درمان‌ترین آن‌ها است. این سرطان هم شبیه تمام سرطان‌ها از یک سلول آغاز می‌شود. در هر دو نوع سرطان سینه تومورهای خوش‌خیم و بدخیم، رشد سریع و زیاد سلول‌ها وجود دارد. روند زیاد شدن سلول‌ها در تومورهای خوش‌خیم در مرحله مشخصی متوقف می‌شود، در تومورهای بدخیم این رشد به‌صورت غیرقابل مهار ادامه می‌یابد تا حدی که در صورت عدم درمان، تمامی قسمت‌های بدن را تحت تأثیر قرار داده و از کار می‌اندازد (۱). معمول‌ترین نشانه‌ی سرطان سینه، تشکیل توده‌های جدید و بدون درد در سینه است. سرطان پستان شایع‌ترین سرطان در بین زنان است که احتمالاً ۱/۶۷ میلیون مورد سرطان جدید در سال ۲۰۱۲ تشخیص داده شده است. ماموگرافی یک نوع تصویربرداری رادیوگرافی ساده با دز کم از پستان و ابزاری برای کشف زودهنگام سرطان‌های غیرقابل لمس پستان است (۲).

ماموگرافی یکی از روش‌های قابل اعتماد برای تشخیص زودهنگام سرطان‌های پستان است. با این حال، ارائه ارزیابی دقیق و یکنواخت برای ماموگرافی عظیم تولید شده در غربالگری گسترده برای رادیولوژیست دشوار است. بنابراین وجود یک سیستم هوشمند که دقت بالایی در تشخیص مکان توده سرطانی دارد، بسیار ضروری و لازم خواهد بود. در این راستا در این پژوهش با استفاده از تصاویر ماموگرافی و تکنیک‌های پردازش تصویر سعی بر آن شده است که تشخیص دقیقی از موقعیت قرار گیری سرطان سینه بدست آید (۳). برای این منظور ابتدا با استفاده از برخی تکنیک‌های بهبود تصاویر دیجیتال سعی در افزایش تشخیص پذیری بافت‌های سرطانی شده و سپس با استفاده از تکنیک‌های طبقه‌بندی عملیات جداسازی دقیق بخش‌های سرطانی از بخش‌های سالم سینه انجام می‌گیرد (۴). انواع تکنیک‌ها به‌منظور بهبود تشخیص تومورها در

ماموگرام‌ها و دقت دسته‌بندی سرطان سینه پیشنهاد شده‌اند. مشکلات اساسی در ماموگرافی سینه در شناسایی و طبقه‌بندی توده‌ها و میکروکلسیفیکاسیون‌ها ناشی از عوامل گوناگون می‌باشند. یکی از این پیچیدگی‌ها به‌دلیل شکل ناجور و غیرمنطقی برخی خوشه‌های کلسیفیکاسیون‌ها می‌باشد. مرزهای هر یک از میکروکلسیفیکاسیون‌های موجود در خوشه به‌خوبی قابل تعریف شدن نیست و ممکن است رادیولوژیست نتواند تصمیم تشخیصی دقیق، در مورد طبیعت بالینی میکروکلسیفیکاسیون‌های یک ناحیه بگیرد، ولی معمولاً می‌تواند نواحی مشکوک را مشخص کند (۵).

شناسایی سرطان پستان از روی تصاویر ماموگرافی یک مسئله پیچیده و چالش‌برانگیز در حوزه پزشکی و علوم کامپیوتری است. ماموگرافی یکی از ابزارهای اصلی برای تشخیص زودهنگام سرطان پستان است که در آن تصاویری با استفاده از اشعه ایکس از بافت پستان گرفته می‌شود. این تصاویر می‌توانند نشانه‌های اولیه‌ای از سرطان مانند توده‌ها یا ناهنجاری‌های بافتی را نشان دهند. اما تفسیر این تصاویر نیازمند دقت بالایی است و اغلب به تخصص پزشکان رادیولوژیست وابسته است (۶). یکی از مشکلات اساسی در این حوزه، نرخ بالای خطای انسانی در تشخیص است که می‌تواند منجر به نتایج نادرست، مانند تشخیص نادرست یا عدم تشخیص سرطان شود. علاوه بر این، ویژگی‌های بصری تومورها در مراحل اولیه می‌توانند بسیار ظریف و سخت‌فهم باشند، که این موضوع فرآیند تشخیص را پیچیده‌تر می‌کند. بنابراین، نیاز به توسعه روش‌ها و ابزارهایی که بتوانند به‌صورت خودکار و با دقت بالا این تصاویر را تحلیل کرده و سرطان پستان را شناسایی کنند، احساس می‌شود (۷). در این راستا، الگوریتم‌های یادگیری ماشین و هوش مصنوعی به عنوان راهکارهای امیدوارکننده‌ای مطرح شده‌اند. این الگوریتم‌ها می‌توانند با تجزیه و تحلیل حجم زیادی از داده‌های تصویری و استخراج ویژگی‌های پیچیده از آن‌ها، به شناسایی الگوهای مرتبط با سرطان کمک کنند (۸). هدف اصلی این پژوهش‌ها، کاهش نرخ خطا و افزایش دقت در تشخیص سرطان پستان از طریق به‌کارگیری تکنیک‌های پیشرفته پردازش تصویر و یادگیری عمیق است (۹). در نهایت، چنین روش‌هایی می‌توانند به


پزشکان کمک کنند تا با اطمینان بیشتری تشخیص دهند و درمان‌های به موقع‌تری را ارائه دهند (۱۰).
 شناسایی سرطان پستان از روی تصاویر ماموگرافی با استفاده از شبکه‌های عصبی کانولوشن یکی از کاربردهای پیشرفته هوش مصنوعی در حوزه پزشکی است (۱۱). شبکه‌های عصبی کانولوشن یا CNNها، نوعی از شبکه‌های عصبی هستند که به طور خاص برای پردازش داده‌های تصویری طراحی شده‌اند و می‌توانند ویژگی‌های پیچیده و چندلایه‌ای را از تصاویر استخراج کنند (۱۲). استفاده از CNNها برای شناسایی سرطان پستان به این صورت است که این شبکه‌ها ابتدا بر روی مجموعه‌ای از تصاویر ماموگرافی که به صورت دقیق برچسب‌گذاری شده‌اند، آموزش داده می‌شوند (۱۳). این تصاویر شامل نمونه‌های سالم و نمونه‌های دارای تومورهای سرطانی هستند. شبکه با پردازش این تصاویر و یادگیری الگوهای مختلفی که نشان‌دهنده وجود یا عدم وجود سرطان هستند، به تدریج توانایی شناسایی ویژگی‌های کلیدی مرتبط با سرطان را به دست می‌آورد (۱۰). در فرآیند شناسایی، یک تصویر ماموگرافی جدید به شبکه داده می‌شود. شبکه با استفاده از فیلتراسیون و لایه‌های مختلف خود، این تصویر را تحلیل کرده و ویژگی‌های مهمی مانند لبه‌ها، ناحیه‌های مشکوک، و تراکم‌های غیرعادی را استخراج می‌کند (۱۴). سپس این ویژگی‌ها به لایه‌های عمیق‌تر منتقل می‌شوند که وظیفه‌ی تشخیص نهایی را بر عهده دارند. در نهایت، شبکه تصمیم می‌گیرد که آیا تصویر مورد نظر دارای علائم سرطان است یا خیر (۱۵). یکی از مزایای اصلی استفاده از CNNها، توانایی آن‌ها در یادگیری ویژگی‌ها به صورت خودکار و بدون نیاز به مداخله انسانی است. این امر به کاهش خطای تشخیص کمک می‌کند و دقت فرآیند شناسایی را بهبود می‌بخشد (۱۶). همچنین، CNNها می‌توانند تغییرات جزئی و نامحسوس در تصاویر را که ممکن است توسط چشم انسان نادیده گرفته شود، تشخیص دهند. به همین دلیل، این روش به عنوان یکی از ابزارهای مؤثر در تشخیص زودهنگام سرطان پستان شناخته می‌شود و می‌تواند نقشی حیاتی در بهبود نتایج درمانی ایفا کند (۱۷).

با توجه به شیوع بیماری سرطان پستان و اهمیت تشخیص این بیماری، در این مطالعه به شناسایی سرطان پستان از روی تصاویر ماموگرافی با استفاده از شبکه‌های عصبی کانولوشن پرداخته می‌شود و از نتایج این مطالعه نه تنها به بهبود فرآیند تشخیص و افزایش دقت آن کمک می‌شود، بلکه تأثیرات مثبت قابل توجهی بر سیستم‌های بهداشتی و درمانی در سطح جهانی خواهد داشت.

روش کار

شبکه‌های عصبی کانولوشنی: یکی از مهم‌ترین روش‌های یادگیری عمیق، شبکه‌های عصبی کانولوشنی هستند که در آنها چندین لایه با روشی قدرتمند آموزش می‌بینند این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی کامپیوتر است. شبکه‌های عصبی کانولوشنی به‌منظور کمینه کردن پیش‌پردازش‌ها از گونه‌ای از پرسپترون‌های چندلایه استفاده می‌کنند. به‌جای شبکه عصبی کانولوشنی گاهی از این شبکه‌ها با نام شبکه‌های عصبی پیچشی، شبکه عصبی تغییرناپذیر با انتقال یا تغییرناپذیر با فضا هم یاد می‌شود. به‌طور کلی یک شبکه عصبی کانولوشنی از سه لایه اصلی تشکیل شده است که عبارتند از: لایه کانولوشن، لایه pooling، لایه تماماً متصل و لایه‌های مختلف وظایف مختلفی را انجام می‌دهند. در هر شبکه عصبی کانولوشن دو مرحله برای آموزش وجود دارد، مرحله پیش‌رو و مرحله پس‌انتشار. در مرحله پیش‌رو ورودی از درون لایه‌ی مخفی به سمت لایه‌ی خروجی می‌رود و اطلاعات تنها به سمت جلو حرکت می‌کنند. لایه‌ی ورودی، مقدار ورودی را به لایه‌ی مخفی ارسال کرده و سپس خروجی تولید می‌شود و در مرحله پس‌انتشار زمانی که یک شبکه‌ی عصبی را تعریف می‌شود، در مرحله اول تصویر ورودی به شبکه تغذیه می‌شود و این عمل چیزی جز ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و نهایتاً اعمال عملیات کانولوشن در هر لایه نیست؛ مقدار وزن و bias را به صورت شانسی بین گره‌ها پخش می‌شوند. هنگامی که خروجی به‌دست می‌آید، به کمک آن، مقدار

یاد می‌گیرد.
۳. باعث تغییرناپذیری و ثبات نسبت به تغییر مکان شیء می‌شود.

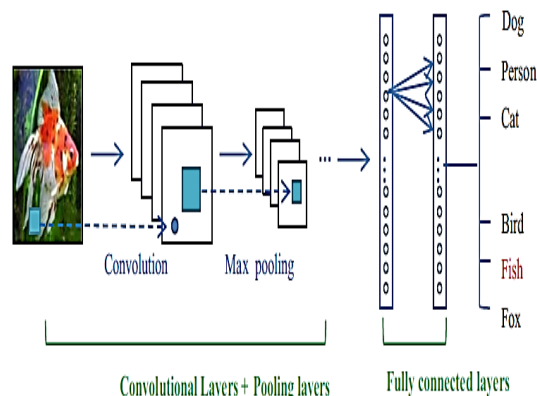


شکل ۲- عملیات لایه کانولوشن (۱۷).

شبکه‌های عصبی کانولوشنی، وزن‌ها را در لایه‌های کانولوشنی به اشتراک می‌گذارند که باعث می‌شود که حداقل حافظه به کار گرفته شود و بیش‌ترین کارایی صورت گیرد. یک فیلتر در شبکه‌های کانولوشن مانند یک وزن ماتریسی عمل می‌کند که آن را در تصویر ورودی ضرب می‌کنیم تا یک خروجی حساب‌شده به دست آوریم.

لایه نرمالیزه‌کننده (Normalization): از نظر مفهومی، می‌توان به نرمال‌سازی بسته‌ها به عنوان سدی نگاه کرد که در بخش‌های مختلفی از یک رود قرار گرفته‌است. این کار باعث می‌شود اطمینان حاصل شود که لایه‌ی بعدی همان گونه‌ای داده‌ها را دریافت می‌کند که انتظار می‌رود. نرمال‌سازی سری مقدار واحد پنهان را کاهش می‌دهد. برای توضیح بیشتر، اگر یک شبکه عمیق بر روی تشخیص گربه داشته باشیم. داده‌های خود را تنها بر روی تصاویر گربه سیاه آموزش می‌دهیم. بنابراین اگر ما حاضر سعی کنیم این شبکه را به داده‌های مربوط به تصاویر دیگر اعمال کنیم، واضح است نتیجه خوبی نخواهد داد. مجموعه آموزشی و مجموعه پیش‌بینی هر دو عکس گربه هستند اما کمی متفاوت هستند. به عبارت دیگر، اگر یک الگوریتم برخی از X را به نگاشت Y فرا گرفت، و اگر توزیع X تغییر کند، آنگاه ممکن است نیاز باشد که الگوریتم یادگیری را با تلاش برای تراز کردن توزیع X با توزیع Y باز آموزش کنیم.

خطای شبکه محاسبه شده؛ سپس این مقدار را به همراه نمودار تابع هزینه به شبکه برگردانده می‌شود تا وزن‌های شبکه بروزرسانی شوند. این وزن‌ها به گونه‌ای بروزرسانی می‌شوند که خطاها کاهش پیدا کنند. به این عمل، پس انتشار می‌گویند.



شکل ۱- یک طرح کلی از معماری یک شبکه عصبی کانولوشن (۱۷).

شبکه عصبی، یک ورودی دریافت می‌کند (در قالب بردار) و سپس آن را از تعدادی لایه مخفی عبور می‌دهد و نهایتاً یک خروجی که نتیجه پردازش لایه‌های مخفی است در لایه‌ی خروجی شبکه (لایه تماماً متصل) ظاهر می‌کند. لایه ورودی شامل مقادیر پیکسل‌های خام تصویر ورودی هستند. لایه کانولوشن، این لایه خروجی نورون‌هایی که به نواحی محلی در ورودی متصل هستند را محاسبه می‌کند. این لایه، عمل کانولوشن یا ضرب نقطه‌ای را بین وزن‌های هر نورون و ناحیه‌ای که آن‌ها به آن متصل هستند؛ انجام می‌دهد. در حالت کلی، یک شبکه عصبی کانولوشن یک شبکه عصبی سلسله مراتبی است که لایه‌های کانولوشنی آن به صورت یک در میان با لایه‌های pooling بوده و بعد از آنها تعدادی لایه تماماً متصل وجود دارد. در این لایه‌ها شبکه CNN از کرنل‌های مختلف برای کانوال کردن تصویر ورودی و همین‌طور feature map میانی استفاده می‌کند و این گونه feature map مختلفی ایجاد می‌کند. انجام عملیات کانولوشن سه فایده دارد:

۱. مکانیزم اشتراک وزن در هر feature map باعث کاهش شدید تعداد پارامترها می‌شود.
۲. اتصال محلی، ارتباط بین پیکسل‌های همسایه را

مقایسه‌ای بین دو عملیات max pooling و average pooling صورت گرفته‌است که نشان می‌دهد max pooling می‌تولند باعث همگرایی سریع‌تر، بهبود تعمیم‌دهی و انتخاب ویژگی‌های نامتغیر شود. طی سال‌های اخیر پیاده‌سازی‌های مختلفی از CNN بر روی GPU انجام شده‌است که اکثراً از عملیات max pooling استفاده می‌کنند.


لایه تماماً متصل: بعد از آخرین لایه pooling، لایه‌های تماماً متصل وجود دارند. تقریباً ۹۰ درصد پارامترهای یک شبکه را شامل می‌شوند و لایه تماماً متصل به ما اجازه می‌دهد تا نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارائه کنیم. مشکل بزرگ این نوع لایه‌ها این است که دارای تعداد زیادی پارامترند که نتیجه این امر هزینه پردازشی بسیار بالایی است که در زمان آموزش بایستی صرف شود؛ بنابراین یک روش که معمولاً به کار برده می‌شود و نتایج رضایت بخشی نیز دارد این است که یا کلاً این لایه‌ها حذف شوند و یا تعداد اتصالات در این لایه‌ها توسط روش‌هایی کاهش یابد (۱۷).

دیتاست ماموگرافی: امروزه میلیون‌ها ماموگرام، سالانه با هدف بهبود نتایج درمان و هم‌چنین زمان بقا برای بیماران مبتلا به سرطان پستان از طریق تشخیص زودرس انجام می‌شود. در این مقاله، از پایگاه داده DDSM-CBIS که زیر مجموعه‌ای از پایگاه داده DDSM تصویربرداری پستان است استفاده گردید؛ یکی از مزیت‌های این پایگاه داده این است که استاندارد شده‌ی پایگاه داده دیجیتال DDSM برای غربال‌گری ماموگرافی است. این مجموعه که توسط یک ماموگراف آموزش دیده، آموزش داده شده‌است. شامل ۱۳۱۸ ماموگرام از ۶۹۱ بیمار است. برای هر بیمار ۳ عدد عکس در پایگاه داده با فرمت dcm موجود می‌باشد که یکی از این تصاویر، تصویر حاصل از ماموگرافی است و تصویر دیگر نواحی دارای توده جداسازی را نشان می‌دهد و تصویر سوم نمونه‌ای از بافت توده استخراج شده است. ماموگرام‌ها به‌طور کلی دارای دونا می‌باشند که یکی از آن‌ها Medio - lateral oblique view است که به‌صورت زاویه‌دار گرفته می‌شود و

لایه ReLU گاهی اوقات با قصد اجرای طرح‌های معماری مشاهده شده‌است که در مغز بیولوژیکی استفاده می‌شود برای مثال بر روی تک تک نورون‌ها یک تابع فعال‌سازی اعمال می‌کند. در تابع زیر، اگر مقدار بزرگتر از صفر باشد، خروجی است، و اگر مقدار کوچکتر یا مساوی صفر باشد، خروجی صفر است.

$$f(x) = \max(0, x) \quad (۱)$$

لایه تجمعی (Pooling): در این لایه عملیات down sampling در امتداد ابعاد مکانی (عرض و ارتفاع) صورت می‌گیرد و این لایه حساسیت شبکه را به چرخش و اندازه از بین می‌برد. یک لایه pooling معمولاً بعد از یک لایه کانولوشنی قرار می‌گیرد و از آن برای کاهش اندازه feature map ها و پارامترهای شبکه می‌توان استفاده کرد و جلوگیری از overfitting انجام می‌شود. همانند لایه‌های کانولوشنی، لایه‌های pooling به‌خاطر در نظر گرفتن پیکسل‌های همسایه در محاسبات خود، نسبت به تغییر مکان بی‌تغیر هستند. پیاده‌سازی لایه pooling با استفاده از تابع max pooling و average pooling صورت می‌گیرد. در شکل زیر نمونه‌ای از فرآیند max pooling را مشاهده می‌کنید که با استفاده از فیلتر max pooling با اندازه ۲ در ۲ و گام ۲، یک feature map با اندازه ۸ در ۸، یک خروجی با اندازه ۴ در ۴ را ایجاد می‌کند. عملیات max pooling به‌معنای حداکثر تجمع هستش یعنی از حداکثر مقدار خوشه‌های نرونی لایه پیشین استفاده شده‌است و عملیات average pooling به‌معنای این است که از مقدار میانگین خوشه‌های نرونی در لایه پیشین استفاده شده است.



شکل ۳- عملیات max pooling (۱۷).

مهم‌ترین پیش‌پردازش انجام‌شده در شبکه‌های عصبی به حساب می‌آید؛ داده‌افزایی است که صورت گرفته‌شده است. دو بار تصویر flip گردید، یک‌بار به راست سپس به پایین و بار دیگر تصویر به اندازه ۴۵ درجه چرخانیده شد که تعداد تصاویر ۳ برابر شد. در نتیجه، بعد از داده‌افزایی ۱۲۴۰ تصویر ماموگرام بدست آمد. در حالت سه کلاسه با توجه به این‌که تصاویر دارای ابعاد متفاوتی هستند از نسبت ابعاد یکنواخت (تغییر سایز) به‌عنوان پیش‌پردازش استفاده گردید و سایز تصاویر به 125×100 تغییر داده شد.

انطباق ماسک بر روی تصویر و تشخیص منطقه

ROI: با توجه به پایگاه داده، که تصاویر و ماسک آن‌ها موجود می‌باشند و با انطباق ماسک بر روی تصویر، یک منطقه به اندازه 159×145 به‌عنوان منطقه مورد نظر (ROI) انتخاب گردید.

طراحی معماری شبکه‌های عصبی کانولوشنی


Zero padding: تکنیکی است که یک مرز از پیکسل‌ها را با مقدار صفر در اطراف لبه‌های تصاویر ورودی اضافه می‌کند و امکان می‌دهد، اندازه اصلی ورودی حفظ گردد. این چیزی است که براساس یک لایه پیشین کانولوشنی مشخص گردیده و در طراحی معماری‌ها از این تکنیک استفاده گردید.

روش پیشنهادی تحقیق:

در این پژوهش، در حالت دو کلاسه سه نوع معماری و در حالت سه کلاسه یک نوع معماری طراحی گردید.

اولین معماری: در ابتدا برای طراحی شبکه، لایه‌ها با توجه به شکل ۵ چینش گردید که از یک لایه ورودی به اندازه $159 \times 145 \times 1$ و یک لایه کانولوشنی دوبعدی به اندازه 8×20 و از یک لایه ادغام ماکسیمم با سایز 2×5 و از دو لایه تماماً متصل استفاده شد (از لایه ادغام ماکسیمم به این دلیل استفاده شد که از حداکثر مقدار خوشه‌های نورونی لایه پیشین استفاده می‌کند و هم‌چنین باعث همگرایی سریع‌تر، بهبود تعمیم‌دهی و انتخاب ویژگی‌های نامتغیر شود.) و مقداردهی وزن هر لایه به‌صورت تصادفی بوده است. لایه‌سازی برابر با یک است. زمان آموزش $4:34$ است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی و آزمایش ۵۰٪ به‌دست‌آمده است.


عضلات ریه باید از بالا تا $1/4$ فوقانی خارجی پستان و زیر بغل تا زیر نوک پستان یا حتی پائین‌تر قابل رویت است و نمای دیگر، **CC (Cranio - Caudal view)** است که از بالا تصویربرداری می‌شود. در حالت دو کلاسه این پایگاه‌داده به‌علت این‌که سایز تصاویر ماموگرام از نمای MLO با ماسک آن یکی نیست از تصاویر با نمای CC استفاده گردید. تعداد تصاویر مورد استفاده ۳۱۰ است که ۵۰٪ آن شامل بافت سالم که شامل ۱۵۵ تصویر و ۵۰٪ آن دارای توده که شامل ۱۵۵ تصویر است. در حالت سه کلاسه از ۱۳۱۸ داده موجود که شامل تصاویر با نمای MLO و CC است؛ استفاده گردید.



شکل ۴- نمونه‌ای از تصاویر ماموگرام و ماسک آن‌ها: (الف) ماسک تصویر (ب) تصویر ماموگرام

پیش‌پردازش: در این پژوهش، قبل از ورود به مرحله طبقه‌بندی نیاز هست یک‌سری پیش‌پردازش‌هایی صورت‌گیرد. برای بررسی حالت دو کلاسه اولین قدم حذف داده‌های پرت است. دومین پیش‌پردازش انجام شده نسبت یکنواخت ابعاد بود، در ابتدا ابعاد تصاویر و ماسک آن‌ها به‌دست آورده شد؛ سپس به‌دلیل هماهنگ نبودن تصاویر از دید MLO با ماسک آن‌ها از تصاویر و ماسک دید CC برای پیاده‌سازی این تحقیق استفاده گردید. سومین پیش‌پردازش انجام شده، کاهش ابعاد است که چون پایگاه‌داده دارای تصاویر تک‌کناله خاکستری است یک‌بار هم بررسی گردید که تصاویری در کانال‌های RGB نباشند. پیش‌پردازش بعدی که

۲۳/۸۳ به‌دست آمده است. در شکل ۶ دومین معماری طراحی‌شده، نمایش داده شده است.




شکل ۶- دومین معماری شبکه‌های عصبی کانولوشن در حالت دو کلاسه

جدول ۲- تعداد و نوع لایه‌ها در دومین معماری طراحی‌شده نوع لایه


نوع لایه	تعداد نورون‌ها
Input layer	۱۴۹*۱۴۵*۱
Convolution layer	۲۰*۸
Pooling	۵*۵
Convolution layer	۱۶*۳۲
Pooling	۲*۲
Fully Connected	۲

سومین معماری: سومین معماری شبکه طراحی شده در شکل ۷ نشان داده‌شده، به این صورت است که از یک لایه ورودی و سه لایه کانولوشنی دوبعدی و از سه لایه ادغام ماکسیمم و از دو لایه تماماً متصل استفاده شده که سایز هر لایه در جدول (۳) نشان داده شده است. لایه‌سازی برابر با یک است. زمان آموزش ۶:۳۷ است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی ۹۲/۵۸٪ و آزمایش ۸۶/۵٪ به‌دست آمده است.



شکل ۷- سومین معماری شبکه‌های عصبی کانولوشن در حالت دو کلاسه

فایده یادگیری عمیق در قیاس با یادگیری کم‌عمق در این است که می‌توان معماری‌های عمیق را در جهت یادگیری اطلاعات انتزاعی‌تر، ایجاد کرد اما تعداد بسیار زیاد پارامترهای معرفی شده، ممکن است سبب مشکل overfitting شود. اخیراً روش‌های regularization زیادی در مقابله با overfitting ارائه شده که شامل استفاده از لایه ادغام تصادفی، استفاده از Dropout و DropConnect، داده افزایشی و افزایش عمق شبکه می‌باشد.



شکل ۵- اولین معماری شبکه‌های عصبی کانولوشن در حالت دو کلاسه

جدول ۱- تعداد و نوع لایه‌ها در اولین معماری طراحی‌شده

نوع لایه	تعداد نورون‌ها
Input layer	۱۴۹*۱۴۵*۱
Convolution layer	۲۰*۸
Pooling	۵*۵
Fully Connected	۲

دومین معماری: بعد از انجام عملیات ذکرشده برای بهبود نتیجه‌گیری، دومین معماری طراحی شد که از یک لایه ورودی و دو لایه کانولوشنی دوبعدی و دو لایه ادغام ماکسیمم و دو لایه تماماً متصل استفاده شد. در شبکه‌های عصبی کانولوشنی وزن‌ها را در لایه‌های پیچشی به اشتراک می‌گذارند که باعث می‌شود حداقل حافظه و بیشترین کارایی بدست آید؛ در این مرحله، مقداردهی وزن‌های شبکه به‌صورت تصادفی نخواهد بود؛ بلکه شبکه بعد از اولین آموزش وقتی که می‌خواهد دومین بار آموزش ببیند وزن‌های هر لایه را معنی‌دار می‌کند که به اصطلاح Finetune گفته می‌شود. لایه‌سازی برابر با یک است. زمان آموزش ۷:۴۵ است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی و آزمایش

جدول ۳- تعداد و نوع لایه‌ها در سومین معماری طراحی شده

نوع لایه	تعداد نورون‌ها
Input layer	۱۴۵*۱۴۹
Convolution layer	۸*۲۰
Pooling	۵*۵
Convolution layer	۱۶*۲۰
Pooling	۲*۲
Convolution layer	۳۲*۱۶
Pooling	۲*۲
Fully Connected	۲

در این پژوهش ابتدا بر روی تصاویر ماموگرافی عملیات پیش پردازش شامل: حذف داده‌های پرت، بررسی نسبت یکنواخت ابعاد، کاهش بعد، افزایش داده انجام گردید. سپس مناطق ROI بر روی تصاویر ماموگرافی بدست آورده شد. نوآوری این تحقیق نسبت به تحقیقات مشابه این است که از معماری‌های آماده استفاده نشده است و معماری‌ها توسط محقق طراحی شده است. سپس طراحی سه نوع شبکه عصبی کانولوشنی انجام گردید و طبقه بندی سرطان خوش خیم و بد خیم انجام گردید. برای طبقه بندی داده‌ها به سه کلاس پس از عملیات پیش پردازش (نسبت ابعاد یکنواخت (تغییر سایز))، انطباق ماسک بر روی تصاویر ماموگرام انجام گرفت. سپس طراحی شبکه عصبی کانولوشنی انجام پذیرفت. در نهایت داده‌ها به سه حالت سرطان خوش خیم بدون بازگشت، سرطان خوش خیم و سرطان بدخیم طبقه بندی گردیدند.



شکل ۹- بلوک دیاگرام روش پیشنهادی مربوط به طبقه بندی سه کلاس

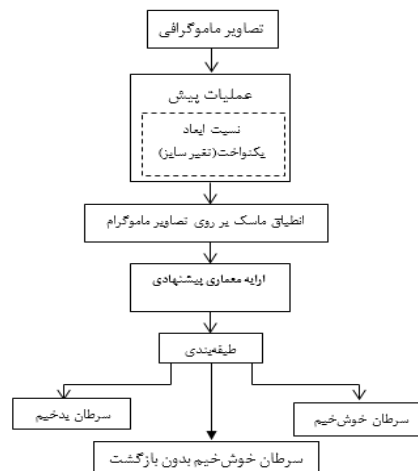
یافته‌ها

نتایج حاصل از شبیه‌سازی دو کلاس برای ۳۱۰

تصویر: با توجه به شبیه‌سازی‌هایی که از روش پیشنهادی به دست آمده است، ۷۰٪ درصد از داده‌ها به‌عنوان داده‌های آموزش و ۳۰٪ درصد از داده‌ها نتایج حاصل از شبیه‌سازی برای ۳۱۰ داده برای اولین نوع معماری دو کلاس در شکل (۱۱) نتایج حاصل از شبیه‌سازی دومین نوع معماری دو کلاس در شکل (۱۲) و نتایج حاصل از شبیه‌سازی سومین نوع معماری دو کلاس در شکل (۱۳) نشان داده شده است. به‌عنوان داده‌های آزمایش به شبکه اعمال گردید و نتایج در بخش‌های بعدی بیان شده‌است. نتایج حاصل از شبیه‌سازی برای ۳۱۰ داده برای دومین نوع معماری دو کلاس زمان آموزش "۰۶:۰۶" است و دقت به دست آمده برای داده‌های اعتبارسنجی ۸۴/۴۰٪ و آزمایش ۷۲/۸۲٪ به دست آمده است و در شکل (۱۲) دقت و داده‌هایی که آموزش داده نشده، نمایش داده شده است.

نتایج حاصل از حلت دو کلاس برای ۱۲۴۰

تصویر: نتایج حاصل از شبیه‌سازی برای ۱۲۴۰ داده



شکل ۸- بلوک دیاگرام روش پیشنهادی مربوط به طبقه بندی دو کلاس

نمونه از تصاویر موجود در پوشه‌های پایگاه‌داده را آورده منطقه تشخیص‌داده‌شده و تشخیص این‌که فرد سرطانی است یا سالم؛ توسط سیستم و نوع کلاس آن مشخص شده است که کلاس ۱ مربوط به سرطانی و کلاس ۲ مربوط به سالم می‌باشد. در شکل (۱۰) از سمت راست اولین تصویر مربوط به ماسک دومین تصویر مربوط به بافت و سومین تصویر مربوط به ماموگرام است. تصویر سمت چپ هم نتیجه حاصل از تشخیص سیستم به‌عنوان منطقه مشکوک است.

ارزیابی عملکرد روش پیشنهادشده: با توجه به شبیه‌سازی‌هایی که از روش پیشنهادی به‌دست آمده برای ارزیابی عملکرد روش پیشنهادشده لازم است تا آن را با سایر روش‌ها مقایسه کرد. در ادامه روشی که ارایه شد با روش‌هایی که در این زمینه پژوهش انجام داده اند مقایسه و ارزیابی می‌شود. ارزیابی توسط دو روش کلی مقایسه توسط انسان و به‌طریق محاسباتی انجام می‌شود این معیارها به دو صورت کیفی و کمی هستند. در ارزیابی کیفی که یک ارزیابی ذهنی است مقایسه تغییرات بین ماسک و تصویر حاصل از شبیه‌سازی براساس سیستم بینایی انسان است و مقایسه تصویر از نظر ظاهری است. در روش ارزیابی کمی مقایسه تصاویر به‌صورت محاسباتی است و از معیارهای از پیش تعریف‌شده استفاده می‌شود. نتایج به‌دست آمده براساس معیارهای مورد بررسی قرار می‌گیرد. این نتایج باید مورد قبول باشند که در نتیجه آن روش پیشنهادی موثر بوده و مورد تایید می‌باشد. در این قسمت نتایج روش پیشنهادی با روش‌های مشابه مقایسه شد. در شکل (۱۸) دقت به‌دست آمده در مقاله رفرنس نشان داده‌شده‌است. در شکل (۱۹) تعداد داده‌های آموزش‌دیده‌نشده در مقاله رفرنس نشان داده‌شده‌است.

بحث

در این پژوهش یک‌بار تصاویر به دو کلاس سرطان خوش‌خیم و بدخیم و یک‌بار به سه کلاس سرطان خوش‌خیم بدون بازگشت سرطان خوش‌خیم سرطان بدخیم طبقه‌بندی گردید.

برای اولین نوع معماری دو کلاس در شکل (۱۴) نتایج حاصل از شبیه‌سازی دومین نوع معماری دو کلاس در شکل (۱۵) و نتایج حاصل از شبیه‌سازی سومین نوع معماری دو کلاس در شکل (۱۶) نشان داده شده است. نتایج حاصل از شبیه‌سازی برای ۱۲۴۰ داده برای اولین نوع معماری دو کلاس زمان آموزش "۵۴:۳:۴۴" است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی ۵۱/۷۲٪ و آزمایش ۵۱/۶۹٪ به‌دست آمده است و در شکل (۱۴) دقت و داده‌هایی که آموزش داده‌نشده، نمایش داده شده است. نتایج حاصل از شبیه‌سازی برای ۱۲۴۰ داده برای سومین نوع معماری دو کلاس زمان آموزش "۴:۴۸:۴۳" است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی ۸۶/۴۳٪ و آزمایش ۷۲/۴۶٪ به‌دست آمده است و در شکل (۱۶) دقت و داده‌هایی که آموزش داده‌نشده، نمایش داده شده است.

نتایج حاصل از حالت سه کلاس برای ۱۳۱۸

تصویر: نتایج حاصل از شبیه‌سازی برای ۱۳۱۸ داده برای حالت سه کلاس زمان آموزش ۳:۵۰ است و دقت به‌دست‌آمده برای داده‌های اعتبارسنجی ۹۸/۶۶٪ و آزمایش ۷۲/۳۹ درصد به‌دست آمده است و در شکل (۱۷) دقت و داده‌هایی که آموزش داده‌نشده، نمایش داده شده است.

معیارهای کمی حاصل از حالت دو کلاس:

معیارهای کمی که نوعی از معیارهای ارزیابی هستند و نتایج حاصل از معیارهای کمی در حالت دو کلاس در جدول (۴) بیان شده است. با توجه به جدول (۴) مشاهده می‌کنیم که با افزایش تعداد داده‌ها و طراحی معماری‌های شبکه با لایه‌های بیش‌تر تعداد مثبت درست و منفی درست افزایش یافته است. با توجه به جدول (۵) مشاهده می‌کنیم که با افزایش تعداد داده‌ها و افزایش عمق شبکه حساسیت و دقت تشخیص افزایش یافته‌است.

نتایج حاصل از معیار کیفی: ارزیابی کیفی که یک


ارزیابی ذهنی است و مقایسه تصویر از نظر ظاهری (یا توسط کد متلب) است. اگر پزشک متخصص بخواهد نواحی و سالم یا سرطانی‌بودن را می‌تواند از روش ارایه‌شده در این قسمت استفاده کند. در این بخش چند

جدول ۴- معیارهای کمی حاصل از حالت دو کلاسه


معیارهای کمی	معیارهای کمی			نوع معماری
	مفنی کاذب FN	مفنی درست TN	مثبت کاذب FP	
اولین نوع معماری برای ۳۱۰ داده	۸	۳۸	۴۵	TP مثبت درست
دومین نوع معماری برای ۳۱۰ داده	۱۱	۳۵	۱۴	
سومین نوع معماری برای ۳۱۰ داده	۱۱	۳۵	۸	
اولین نوع معماری برای ۱۲۴۰ داده	۱۸۶	۰	۰	
دومین نوع معماری برای ۱۲۴۰ داده	۱۲۶	۶۰	۷	
سومین نوع معماری برای ۱۲۴۰ داده	۵۱	۱۳۵	۵۵	

جدول ۵- شاخص‌های ارزیابی حاصل از حالت دو کلاسه


نوع معماری	شاخص ارزیابی			
	حساسیت	شفافیت	صحت	دقت
اولین نوع معماری ۳۱۰ داده	۱۱/۱۱	۴۵/۷۸	۲۱/۷۴	۴۲/۳۹
دومین نوع معماری ۳۱۰ داده	۷۴/۴۲	۷۱/۴۲	۶۹/۵۶	۷۲/۸۲
سومین نوع معماری ۳۱۰ داده	۷۷/۵۶	۸۱/۴۰	۸۲/۶۱	۷۹/۳۴
اولین نوع معماری ۱۲۴۰ داده	۵۱/۶۹	NaN	۱۰۰	۵۱/۶۹
دومین نوع معماری ۱۲۴۰ داده	۶۰/۳۸	۸۹/۵۵	۹۶/۴۹	۶۵/۴۵
سومین نوع معماری ۱۲۴۰ داده	۷۳/۸۴	۷۱/۰۵	۷۲/۳۶	۷۲/۴۶




شکل ۱۱- نتایج حاصل اولین نوع معماری برای ۳۱۰ داده




شکل ۱۳- نتایج حاصل سومین نوع معماری برای ۳۱۰ داده




شکل ۱۰- (الف) از سمت راست، اولین تصویر مربوط به ماسک؛ دومین تصویر مربوط به بافت و سومین تصویر مربوط به ماموگرام (ب) نتیجه حاصل از تشخیص سیستم به‌عنوان منطقه مشکوک




شکل ۱۲- نتایج حاصل دومین نوع معماری برای ۳۱۰ داده




شکل ۱۵- نتایج حاصل دومین نوع معماری برای ۱۲۴۰ داده




شکل ۱۴- نتایج حاصل اولین نوع معماری برای ۱۲۴۰ داده



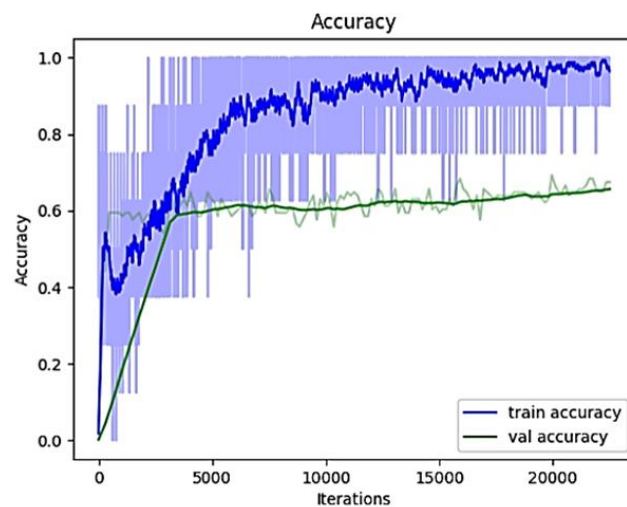
شکل ۱۷- نتایج حاصل از حالت سه کلاسه برای ۱۳۱۸ داده



شکل ۱۶- نتایج حاصل سومین نوع معماری برای ۱۲۴۰ داده



شکل ۱۹- تعداد داده‌های آموزش دیده‌نشده در مقاله رفرنس



شکل ۱۸- دقت مقاله رفرنس

ایجادشده، استفاده گردید. سپس دو نوع معماری دیگر طراحی گردید که با اعمال عملیات ذکر شده و داده‌های پردازش شده به شبکه، دقت حاصل از معماری‌ها برای ۳۱۰ داده به ترتیب برابر است با ۴۲/۳۹، ۷۲/۸۲، ۷۹/۳۴ درصد. دقت حاصل از معماری‌ها برای ۱۲۴۰

بخش اصلی این تحقیق در حالت دو کلاسه این است که سه نوع معماری طراحی گردید که بعد از تست اولین معماری طراحی شده و به دست آمدن دقت شبکه، متوجه شدیم که شبکه دچار بیش‌برازش شده است. از داده‌افزایی و افزایش عمق شبکه برای رفع بیش‌برازش

early detection to new therapies. *Radiologia*. 2017;59(5):368-379. English, Spanish.

8. Kolak A, Kamińska M, Sygit K, Budny A, Surdyka D, et al. Primary and secondary prevention of breast cancer. *Ann Agric Environ Med*. 2017;24(4):549-553.

9. Zhang YN, Xia KR, Li CY, Wei BL, Zhang B. Review of Breast Cancer Pathological Image Processing. *Biomed Res Int*. 2021;2021:1994764.

10. Winters S, Martin C, Murphy D, Shokar NK. Breast Cancer Epidemiology, Prevention, and Screening. *Prog Mol Biol Transl Sci*. 2017;151:1-32.

11. Medford AJ, Gillani RN, Park BH. Detection of Cancer DNA in Early Stage and Metastatic Breast Cancer Patients. *Methods Mol Biol*. 2018;1768:209-227.

12. Desreux JAC. Breast cancer screening in young women. *Eur J Obstet Gynecol Reprod Biol*. 2018;230:208-211.

13. Desai P, Aggarwal A. Breast Cancer in Women Over 65 years- a Review of Screening and Treatment Options. *Clin Geriatr Med*. 2021;37(4):611-623.

14. Sarıgül M, Ozyildirim BM, Avci M. Differential convolutional neural network. *Neural Netw*. 2019;116:279-287.

15. Zhang L, Wu D. A Single Target Grasp Detection Network Based on Convolutional Neural Network. *Comput Intell Neurosci*. 2021;2021:5512728.

16. Suman G, Panda A, Korfiatis P, Goenka AH. Convolutional neural network for the detection of pancreatic cancer on CT scans. *Lancet Digit Health*. 2020;2(9):e453.

17. Hochuli J, Helbling A, Skaist T, Ragoza M, Koes DR. Visualizing convolutional neural network protein-ligand scoring. *J Mol Graph Model*. 2018;84:96-108.

داده برابر است ۵۱/۶۹، ۶۵/۴۵، ۷۲/۴۶ درصد. درحالت سه کلاسه از ۱۳۱۸ تصویر موجود در پایگاه داده استفاده گردید و به دلیل هم اندازه نبودن تصاویر به عنوان پیش پردازش نسبت ابعاد یکنواخت (تغیر سایز) صورت گرفته است و سپس ماسک تصاویر را بر روی تصاویر منطبق گردید و به شبکه عصبی کانولوشنی طراحی شده داده شده است و داده‌ها به سه کلاس طبقه بندی گردید که عبارت است از کلاس سرطان خوش خیم و سرطان بدخیم و تومور خوش خیم بدون بازگشت است. دقت به دست آمده برابر است با. با توجه به پیش پردازش و عملیاتی که انجام داده شد، دقت شبکه افزایش یافته و نتیجه بهبود یافته است. یکی از مزیت‌های این تحقیق این است که از معماری‌های آماده استفاده نشده است و معماری توسط محقق طراحی شده است. نتایج کلی نشان داد دقت داده‌های اعتبارسنجی و داده‌های آزمایش افزایش یافته و در مقاله رفرنس از تعداد ۲۰۰۰۰ تکرار به دقت ۶۶/۲ دست یافته ولی در این تحقیق برای طبقه بندی دو کلاسه ۱۰۰ تکرار و برای طبقه بندی سه کلاسه با ۱۰۰۰۰ تکرار به دقت ۷۲/۳۹ رسیده شده است.

References

1. Cai T, Zhao Z. Convolutional neural network-based surgical instrument detection. *Technol Health Care*. 2020;28(S1):81-88.

2. Wang SH, Zhu Z, Zhang YD. PSCNN: PatchShuffle Convolutional Neural Network for COVID-19 Explainable Diagnosis. *Front Public Health*. 2021;9:768278.

3. Bereta M. Kohonen Network-Based Adaptation of Non Sequential Data for Use in Convolutional Neural Networks. *Sensors (Basel)*. 2021;21(21):7221.

4. Budny A, Starosławska E, Budny B, Wójcik R, Hys M, Kozłowski P, et al. Epidemiologia oraz diagnostyka raka piersi [Epidemiology and diagnosis of breast cancer]. *Pol Merkur Lekarski*. 2019;46(275):195-204. Polish.

5. Peairs KS, Choi Y, Stewart RW, Sateia HF. Screening for breast cancer. *Semin Oncol*. 2017;44(1):60-72.

6. Chantsalnyam T, Lim DY, Tayara H, Chong KT. ncRDeep: Non-coding RNA classification with convolutional neural network. *Comput Biol Chem*. 2020;88:107364.

7. Merino Bonilla JA, Torres Tabanera M, Ros Mendoza LH. Breast cancer in the 21st century: from