



Semnan University



## Research Article

# Normal and Abnormal Masses Detection in Mammography Images Using Deep Convolutional Neural Network (DCNN)

Farnaz Hoseini <sup>a,\*</sup>, Hamed Sepehrzadeh <sup>a</sup>

<sup>a</sup> Department of Computer Engineering, National University of Skills (NUS), Tehran, Iran

### PAPER INFO

#### Paper history:

Received: 2023-06-29

Revised: 2024-05-13

Accepted: 2024-05-18

#### Keywords:

Separated by semicolons  
Convolutional Neural  
Network (CNN);  
Mammography images;  
Breast cancer;  
Deep learning;  
Normal and abnormal  
mass.

### ABSTRACT

One of the most important and influential ways to diagnose breast cancer, especially in the early stages of the disease, is mammography. Mammography images are usually of low quality due to the complexity of breast tissues, the similarity between cancerous masses and normal tissues, the different sizes and shapes of the masses, and X-ray radiation. Therefore, it is very difficult to detect lesions, especially in the early stages; Because some mass lesions are embedded in natural tissues and have weak margins or vague margins. The proposed method in this study is to present an architecture based on a deep convolutional neural network to detect cancerous masses in mammography images, which ultimately leads to classifying the masses into normal and abnormal classes. The training of the proposed network begins with the modification of the images in the pre-processing stage in order to perform more accurate drawings with high resolution on the images and finally to improve the accuracy and sensitivity of separating the mass from the breast tissue for correct diagnosis. Python programming language and TensorFlow library have been used in the Windows environment to implement the proposed method. To ensure the performance of the proposed method, the cross-validation method was used and the obtained results were evaluated by the criteria of precision, accuracy, and sensitivity. The results obtained with an accuracy of 97.67% indicate the improvement of the diagnosis accuracy and the cost reduction in the diagnosis process.

DOI: <https://doi.org/10.22075/jme.2024.31040.2479>

© 2024 Published by Semnan University Press.

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

\* Corresponding author.

E-mail address: [f-hoseini@tvu.ac.ir](mailto:f-hoseini@tvu.ac.ir)

### How to cite this article:

Hoseini, F., & Sepehrzadeh, H. (2024). Normal and Abnormal Masses Detection in Mammography Images Using Deep Convolutional Neural Network (DCNN). Journal of Modeling in Engineering, 22(79), 29-43. doi: 10.22075/jme.2024.31040.2479

# تشخیص توده‌های نرمال و غیر نرمال در تصاویر ماموگرافی توسط شبکه عصبی کانولوشنی عمیق (DCNN)

فرناز حسینی<sup>۱\*</sup>، حامد سپهرزاده<sup>۲</sup>

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۲/۰۴/۰۸	یکی از مهمترین و موثرترین راه‌های تشخیص سرطان سینه، بخصوص در مراحل اولیه بیماری، انجام ماموگرافی است. تصاویر ماموگرافی به علت پیچیدگی بافت‌های سینه، شباهت بین توده‌های سرطانی و بافت‌های طبیعی آن، اندازه و شکل متفاوت توده‌ها و تابش اشعه ایکس، معمولاً از کیفیت پایینی برخوردار هستند. از این رو تشخیص ضایعات به خصوص در مراحل اولیه، کار بسیار دشواری است؛ زیرا برخی از ضایعات جرم در بافت‌های طبیعی جاسازی شده و حاشیه‌های ضعیف یا حاشیه‌های مبهم دارند. روش پیشنهادی در این مطالعه ارائه‌ی یک معماری مبتنی بر شبکه عصبی کانولوشنی عمیق برای تشخیص توده‌های سرطانی در تصاویر ماموگرافی می‌باشد که در نهایت به طبقه بندی توده‌ها به کلاس‌های نرمال و غیر نرمال منجر می‌گردد. آموزش شبکه‌ی پیشنهادی با اصلاح تصاویر در مرحله پیش‌پردازش آغاز می‌شود تا ترسیم دقیق‌تر با وضوح بالاتر بر روی تصاویر انجام شود و در نهایت دقت و حساسیت جداسازی توده از بافت سینه برای تشخیص صحیح بهبود یابد. برای پیاده‌سازی روش پیشنهادی از زبان برنامه‌نویسی پایتون و کتابخانه تنسورفلو در محیط ویندوز استفاده شده است. برای اطمینان از عملکرد روش پیشنهادی روش اعتبارسنجی متقابل استفاده شده و نتایج بدست آمده توسط معیارهای دقت، صحت و حساسیت مورد ارزیابی قرار گرفته است. نتایج بدست آمده با دقت ۹۷.۶۷٪ بیانگر بهبود دقت تشخیص و همچنین کاهش هزینه در فرایند تشخیص انجام شده می‌باشد.
بازنگری مقاله: ۱۴۰۳/۰۲/۲۴	
پذیرش مقاله: ۱۴۰۳/۰۲/۲۹	
<b>واژگان کلیدی:</b> شبکه عصبی کانولوشنی، تصاویر ماموگرافی، سرطان سینه، یادگیری عمیق، توده نرمال و غیر نرمال.	
DOI: <a href="https://doi.org/10.22075/jme.2024.31040.2479">https://doi.org/10.22075/jme.2024.31040.2479</a>	
© 2024 Published by Semnan University Press. This is an open access article under the CC-BY 4.0 license. ( <a href="https://creativecommons.org/licenses/by/4.0/">https://creativecommons.org/licenses/by/4.0/</a> )	

## ۱- مقدمه

به گفته سازمان بهداشت جهانی (WHO)<sup>۲</sup>، سرطان سینه از شایعترین سرطان‌ها و همچنین عامل اصلی مرگ و میر ناشی از سرطان در میان زنان است [۱]. شناسایی به موقع و زود هنگام سرطان سینه می‌تواند کمک شایانی در جلوگیری از پیشرفت و درمان این بیماری داشته باشد. روش‌های مناسب غربالگری و تشخیص اولین نشانه‌های سرطان سینه از اهمیت خاصی برخوردار است. تکنیک‌های

تصویربرداری پزشکی از یک سو و طراحی سیستم‌های تشخیص کامپیوتری (CAD)<sup>۳</sup> از سوی دیگر توانسته‌اند سهم عمده‌ای در شناسایی و درمان به موقع این بیماری ایفا کنند. یکی از موثرترین راه‌های کاهش مرگ و میر ناشی از سرطان سینه، برنامه‌های غربالگری پستان است که از ماموگرافی‌ها به عنوان روش‌های اصلی تصویربرداری استفاده می‌کند. ماموگرافی<sup>۴</sup> یک ابزار بسیار موثر و قابل اعتماد است که توسط رادیولوژیست‌ها برای تشخیص سرطان در مراحل

\* پست الکترونیک نویسنده مسئول: f-hoseini@tvu.ac.ir

۱. گروه مهندسی کامپیوتر، دانشگاه ملی مهارت، تهران، ایران

۲ World Health Organization

۳ Computer-Aided Detection

۴ Mammography

استناد به این مقاله:

حسینی، فرناز، و سپهرزاده، حامد. (۱۴۰۳). تشخیص توده‌های نرمال و غیر نرمال در تصاویر ماموگرافی توسط شبکه عصبی کانولوشنی عمیق (DCNN). مدل سازی در مهندسی، ۲۲(۷۹)، ۲۹-۴۳. doi: 10.22075/jme.2024.31040.2479

سال‌های اخیر دقت به دست آمده نسبت به سال‌های قبل پیشرفت‌هایی داشته ولی به دست آوردن دقت تشخیص بیشتر همچنان مستلزم تلاش و کار بیشتر در این زمینه می‌باشد. در این پژوهش تلاش شده تا با ارائه روشی مناسب به رادیولوژیست‌ها و پزشکان متخصص در جداسازی و تشخیص صحیح توده‌های سرطانی بر روی تصاویر ماموگرافی کمک گردد. بر همین اساس برای افزایش دقت تشخیص از مدل‌های یادگیری عمیق استفاده شده است [۸]. یادگیری عمیق به تازگی موفقیت‌های عظیمی در مسائل چالش برانگیز مانند تشخیص شیء در تصاویر طبیعی، تشخیص گفتار خودکار و تفسیر ماشینی بدست آورده است. این موفقیت‌ها باعث افزایش علاقه به استفاده از شبکه‌های عصبی کانولوشنی عمیق (DCNN)<sup>۹</sup> در تصویربرداری پزشکی شده است. ما نیز پیش‌تر برای قطعه بندی تصاویر MR<sup>۱۰</sup> مغزی از شبکه عصبی کانولوشنی عمیق استفاده کردیم [۹] و [۱۰]. نتایج بدست آمده نشان داد که استفاده از مدل‌های عمیق در فرایند آموزش و تست تصاویر پزشکی می‌تواند به طور قابل توجهی معیارهای ارزیابی را بهبود بخشد. مدل‌های یادگیری عمیق یک کلاس از ماشین‌ها هستند که می‌توانند یک سلسله مراتب از ویژگی‌ها را با ساختن ویژگی‌های سطح بالا از ویژگی‌های سطح پایین‌تر یاد بگیرند [۱۱]. شبکه‌های عصبی کانولوشنی (CNNs)<sup>۱۱</sup> یک نوع از مدل‌های عمیق هستند که در آن فیلترهای قابل تعویض و عملیات تلفیقی محلی به طور متناوب روی تصاویر ورودی خام اعمال می‌شوند و سلسله مراتبی از ویژگی‌های به هم پیچیده را به وجود می‌آورند [۳۵]. این شبکه‌ها معمولاً از تعداد زیادی لایه‌های کانولوشنی متصل به هم، و تعدادی لایه‌ی تجمعی ساخته شده‌اند [۱۲]. یکی از خصوصیات اصلی شبکه‌های عصبی کانولوشنی توانایی آن برای گرفتن عکس العمل‌های غیرخطی بین ورودی‌ها و خروجی‌ها می‌باشد [۱۳]. هدف از این پژوهش کمک به تشخیص صحیح در طبقه‌بندی توده‌های نرمال و غیر نرمال در تصاویر ماموگرافی با استفاده از یک شبکه عصبی کانولوشنی عمیق (DCNN) و در نتیجه افزایش دقت در جداسازی توده سرطانی از بافت سینه است. نوآوری پژوهش حاضر ارائه یک معماری عمیق برای شبکه

اولیه استفاده می‌شود [۲]. به طور کلی ماموگرافی یک عکس رادیوگرافی ساده از سینه و ابزاری برای کشف زودرس سرطان‌های غیرقابل لمس پستان است. تصاویر ماموگرافی معمولی، بر روی فیلم‌های ساده گرفته می‌شد، ولی اخیراً تصاویر ماموگرافی بر روی صفحه نمایش کامپیوتر، نمایش داده می‌شوند که ماموگرافی دیجیتال نام گرفته‌اند [۳]. با وجود پیشرفت در تکنیک‌های ماموگرافی، محدودیت‌هایی نیز در این روش‌ها وجود دارند. تحلیل ماموگرام به این دلیل که متأثر از شرایط محیطی، کیفیت تصویر و میزان تخصص رادیولوژیست است می‌تواند یک تلاش زمان‌بر، پرهزینه و مهمتر از همه مستعد خطا باشد و از طرفی چون علائم دیداری در مراحل اولیه سرطان سینه ظریف می‌باشند لذا عمل تشخیص را برای رادیولوژیست یا فرد متخصص مشکل می‌کند. به همین دلیل استفاده از سیستم‌های تشخیص کامپیوتری (CAD) برای پردازش تصاویر پزشکی به عنوان موثرترین و سریعترین راه برای برطرف کردن این مشکل مورد توجه قرار گرفته است [۴]. در سال‌های اخیر، سیستم تشخیص کامپیوتری (CAD) در بسیاری از سایت‌های غربالگری و بیمارستان‌ها به عنوان بخشی از کار بالینی معمول برای تشخیص سرطان سینه در سراسر جهان استفاده می‌شود. به طور کلی یک سیستم تشخیص کامپیوتری (CAD) مجموعه‌ای از ابزارهای خودکار یا نیمه خودکار را برای کمک به رادیولوژیست‌ها در تشخیص و یا طبقه‌بندی اختلالات ماموگرافی ایجاد می‌کند [۵] و تکنیک‌های آن از مراحل اصلی قطعه‌بندی<sup>۵</sup>، استخراج ویژگی<sup>۶</sup>، انتخاب ویژگی<sup>۷</sup> و طبقه‌بندی<sup>۸</sup> تشکیل شده‌اند [۶]. یک تصویر حاوی مقدار زیادی داده‌ی مفید و راهی برای انتقال اطلاعات است. در عمل، اغلب تمام قسمت‌های تصویر مهم نیستند، بلکه فقط برخی از مناطق خاص که دارای ویژگی‌های مشابه هستند، دارای اهمیت می‌باشند [۷]. در تصاویر ماموگرافی برخی از ضایعات جرم در بافت‌های طبیعی جاسازی شده و حاشیه‌های ضعیف یا حاشیه‌های نامفهوم دارند. علاوه بر این، شکل و تراکم توده‌ها در ماموگرام‌ها متفاوت است. دستیابی به دقت تشخیص بالا مستلزم تخصص است که در طول سال‌ها تجربه به عنوان یک رادیولوژیست به دست می‌آید [۳۴]. با وجود اینکه در

<sup>9</sup> Deep Convolutional Neural Networks

<sup>10</sup> Magnetic Resonance

<sup>11</sup> Convolutional Neural Networks


<sup>5</sup> Segmentation

<sup>6</sup> Feature Extraction

<sup>7</sup> Feature Selection

<sup>8</sup> Classification

تمام واحدهای متصل به آنها را شامل می‌شود. به همین ترتیب، واحدهای لایه پایین‌تر، شیب‌هایی از تمام واحدهای متصل به آنها را شامل می‌شوند. استراتژی محاسبه گرادین‌هایی که با یک شبکه کانولوشنی پیاده‌سازی شده‌اند، تا حدودی پیچیده می‌باشند. دلیل این امر این است که در یک لایه کانولوشن<sup>۱۴</sup>، تعداد اتصالات که هر واحد را ترک می‌کند به دلیل اثرات مرزی ثابت نیست [۱۵].



شکل ۱- معماری کلی یک شبکه عصبی کانولوشنی [۱۵]

شکل (۱) معماری یک شبکه عصبی کانولوشنی را نشان می‌دهد. این نوع شبکه عصبی یکی از انواع شبکه‌های یادگیری عمیق است که از شبکه عصبی پرسپترون الهام گرفته شده است. این شبکه عمیق شامل یک لایه ورودی، یک لایه خروجی و یک لایه عمیق پنهان است. ابتدا تصاویر یا داده‌های مسئله به صورت طبقه‌بندی شده وارد شبکه شده و مورد آموزش قرار می‌گیرند؛ پس از آموزش وزن‌های لایه پنهان خروجی به چند صورت می‌توانند ظاهر شود. اگر خروجی الگوریتم شامل چند المان عددی مثل عدد باینری یا شاخص باشد (مثلاً طبقه‌بندی تصاویر حیوانات) در این صورت الگوریتم ارائه شده یک الگوریتم طبقه‌بندی یا تشخیص است. بدین ترتیب که بعد از آموزش تعدادی از تصاویر نتایج به صورت وزن‌هایی به دست می‌آیند. اگر تصویر جدیدی به جز تصاویر آموزش به شبکه ارائه شود، می‌تواند نوع تصویر را تشخیص دهد؛ مثلاً تصاویر انواع تصاویر تومورهای مغزی را به صورت مجزا به شبکه داده و به سیستم آموزش دهیم که تصاویر برای انواع بیماری، آلزایمر، سارکوما یا تومور مغزی خوش‌خیم یا بدخیم می‌باشند. شبکه با وزن‌های به دست آمده می‌تواند به تشخیص نوع بیماری بپردازد. در حالی دیگر، اگر خروجی شبکه هم اندازه تصویر ورودی باشد، خروجی به صورت کانتوری از رنگ‌ها یا اعداد مشخص می‌شود. در این صورت

عصبی کانولوشنی به منظور بهبود روند آموزش و افزایش دقت تشخیص می‌باشد. اجرای روش پیشنهادی با ارائه یک مدل عمیق مبتنی بر شبکه‌های عمیق کانولوشنی انجام شده است و برای آموزش شبکه از بانک داده INbreast<sup>۱۳</sup> استفاده شده است. عملکرد مدل‌های عمیق ارائه شده توسط معیارهای دقت (Accuracy)، صحت (Precision) و حساسیت (Sensitivity) مورد ارزیابی قرار گرفته است. همچنین قابلیت اطمینان عملکرد سیستم با استفاده از اعتبارسنجی متقابل<sup>۱۳</sup> تضمین شده است. ساختار این مقاله به این شکل است که در بخش دوم معرفی مختصری از شبکه‌های عصبی کانولوشنی و لایه‌های آن انجام می‌شود. در بخش سوم مروری بر تکنیک‌ها و روش‌های مختلف در تشخیص توده‌ها در تصاویر ماموگرافی مربوط به سال‌های اخیر مورد بحث و بررسی قرار گرفته است. در بخش چهارم روش پیشنهادی با ارائه یک معماری عمیق مبتنی بر شبکه عصبی کانولوشنی مورد بحث قرار گرفته است. در بخش پنجم نتایج بدست آمده از روش پیشنهادی ارائه شده است. نتیجه‌گیری و پیشنهادات آتی نیز در بخش ششم ارائه شده است.

## ۲- شبکه‌های عصبی کانولوشنی

چنانچه نویسندگان به هر دلیل نتوانند از این نمونه مقاله به عنوان شبکه‌های عصبی کانولوشنی (CNNs) نوعی شبکه عصبی هستند که نسبت به روش‌های کلاسیک عصبی مصنوعی از پیچیدگی بالاتری برخوردار می‌باشند [۱۴]. شبکه‌های عصبی کانولوشنی معمولاً از قوانین زیر برای پیاده‌سازی شبکه عصبی پیش و پس انتشار خطا استفاده می‌کنند:

$$x_j^{L+1} = \sum_i w_{j,i}^{L+1} x_i^L \quad (1)$$

$$g_i^L = \sum_j w_{j,i}^{L+1} g_j^{L+1} \quad (2)$$

در عبارات (۱) و (۲)  $x_j^L$  و  $g_i^L$  به ترتیب فعال‌ساز و گرادین واحد  $i$  در لایه  $L$  هستند.  $w_{j,i}^{L+1}$  واحد اتصال وزن  $i$  در لایه  $L$  به واحد  $j$  در لایه  $L+1$  است که می‌توان به عنوان واحدهای فعال‌سازی لایه بالاتر مشاهده کرد که فعال کردن

<sup>13</sup> 5-folds Cross-validation

<sup>14</sup> Convolutional Layer

<sup>12</sup> <https://www.kaggle.com/datasets/ramanathansp20/inbreast-dataset>

گذاری یا پدینگ پیکسل‌های اضافی خارج از تصویر است و افزونه صفر به این معنی است که ارزش هر پیکسل اضافه شده صفر است. هر بار که ما از فیلتر برای اسکن کردن تصویر استفاده می‌کنیم، اندازه تصویر کوچکتر و کوچکتر خواهد شد. ما این را نمی‌خواهیم، زیرا ما می‌خواهیم اندازه اصلی تصویر را حفظ کنیم تا ویژگی‌های سطح پایین را استخراج کنیم. بنابراین، از لایه گذاری با صفر استفاده می‌کنیم [۲۱].

لایه ادغام<sup>۲۱</sup> در معماری شبکه عصبی کانولوشنی، معمول است که به صورت دوره‌ای لایه‌های ادغام یا پولینگ را وارد کنند. به طور معمول، این لایه برای کاهش اندازه فضایی شبکه، آماده کردن بعضی از تفسیر انحراف و کاهش خطای بیش برآزش<sup>۲۲</sup> استفاده می‌شود. این عملیات همانند لایه‌های فعال‌سازی به صورت جداگانه بر روی هر عمق انجام می‌شود و انواع مختلفی دارند. Max Pooling، Sum Pooling و Avg Pooling انواع ادغام یا پواینگ‌های مورد استفاده در شبکه‌های عصبی کانولوشنی هستند. معمولاً تابع Max Pooling بیشتر مورد استفاده قرار می‌گیرد که نمونه‌ای از کاربرد آن در شکل (۲) نشان داده شده است [۲۲]. این تابع عملی غیر خطی است. هر نورون خروجی حداکثر برای یک منطقه کوچک ورودی است، که بستگی به اندازه فیلتر دارد. لایه‌های ادغام یا پدینگ می‌توانند گام بزرگتر از یک داشته باشند. این امر مهم است، زیرا قدرت محاسباتی مورد نیاز، حافظه و تعداد پارامترهایی که نیاز به یادگیری دارند را در لایه‌های متوالی کاهش می‌دهد. این کاهش فضایی همچنین اجازه می‌دهد تا واحدهای لایه‌های بعدی تحت تاثیر یک منطقه بزرگ از تصویر اصلی قرار گیرند [۲۳].



شکل ۲- مثالی از لایه Max Pooling

تابع فعال‌ساز<sup>۲۳</sup>: این توابع غیر خطی معمولاً در مدل‌های عمیق استفاده می‌شوند. اگر تابع فعال‌سازی روی سیستم

نتایج ارائه شده می‌تواند تغییر محسوس تصاویر را ثبت کند، مثلاً می‌تواند مکان تومور را در تصویر مغزی یا سرطان پستان تشخیص دهد. لایه پنهان شبکه شامل لایه‌های جزئی است که معماری سیستم را می‌سازند. از انواع معماری‌های معروف می‌توان به LeNet [۱۶]، GoogLeNet [۱۷] و AlexNet [۱۸] اشاره کرد. لایه پنهان شبکه عصبی کانولوشنی شامل آرایش خاص از لایه‌های عددی است که در زیر به چند نوع از لایه‌های کاربردی پرداخته شده است [۱۹].

لایه کانولوشن: این لایه هسته اصلی تشکیل دهنده شبکه عصبی کانولوشنی است و توده خروجی آن را می‌توان بصورت یک توده سه بعدی از نورون‌ها<sup>۱۵</sup> تفسیر کرد که نورون‌ها در سه بعد آن مرتب شده‌اند. در نتیجه خروجی این مکعب نیز یک توده سه بعدی خواهد بود. هر کدام از این نورون‌ها به یک منطقه از لایه قبلی متصل هستند، که بستگی به اندازه فیلتر لایه کانولوشنی دارد. برای مثال، اگر ما یک فیلتر با اندازه (۳،۳) داشته باشیم، نورون در موقعیت  $[z; y; x]$  به تمام نورون‌های لایه قبلی با موقعیت‌های افقی و عمودی متصل می‌شود [۲۰]. فرآپارامترها<sup>۱۶</sup> اندازه توده خروجی را کنترل می‌کنند. عمق<sup>۱۷</sup> گام<sup>۱۸</sup> و لایه‌گذاری با صفر<sup>۱۹</sup> از انواع مهم این فرآپارامترها هستند. عمق توده خروجی پارامتری است که ما می‌توانیم خود انتخاب کنیم. این پارامتر تعداد نورون‌هایی که در لایه کانولوشنی به یک ناحیه در توده ورودی متصل می‌شوند را کنترل می‌کند. گام را باید به وسیله ستون‌های عمقی که حول ابعاد مکانی (عرض و ارتفاع) تعریف کرده‌ایم، مشخص کنیم. در مورد گام، شایع‌ترین ارزش یک است. زمانی که گام برابر با یک باشد ما یک ستون عمقی جدید از نورون‌ها را به مختصات مکانی با فاصله تنها یک واحد مکانی از هم، اختصاص می‌دهیم. این امر باعث بوجود آمدن نواحی ادراکی<sup>۲۰</sup> دارای اشتراک زیاد بین ستون‌ها و همچنین توده‌های خروجی بزرگ می‌شود. برعکس اگر ما گام‌ها را بزرگتر بگیریم نواحی ادراکی اشتراک کمتری داشته و توده خروجی نیز از لحاظ ابعاد مکانی کوچکتر می‌شوند. برخی اوقات راحت‌تر است که مرز توده ورودی را با صفر بپوشانیم (zero-pad). به عبارت دیگر یعنی دور تصویر ورودی را با صفر پر کنیم. لایه

<sup>20</sup> Receptive Field

<sup>21</sup> Pooling

<sup>22</sup> Over-fitting

<sup>23</sup> Activation Function

<sup>15</sup> Neurons

<sup>16</sup> Hyper Parameter

<sup>17</sup> Depth

<sup>18</sup> Stride

<sup>19</sup> Zero-padding

پیش بینی استفاده شده و پارامترهای آن به طور تصادفی با آموزش‌های تحت نظارت راه اندازی می‌گردند. پارامترهای تمام لایه‌ها با روش پس انتشار خطا به طور دقیق تنظیم می‌گردند [۲۵].

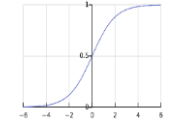
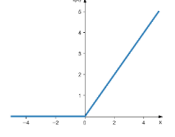
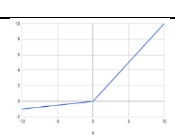
### ۳- پیشینه تحقیق

در حوزه‌ی تشخیص توده‌های سرطانی از تصاویر ماموگرافی تا به حال تحقیقات بسیاری انجام شده است. در ادامه به بررسی تحقیق‌های مشابه با محوریت موضوع مورد مطالعه به صورت کلی و موردی پرداخته شده است.

در [۲۶] سال ۲۰۲۳ یک چارچوب محاسباتی برای تشخیص سرطان سینه با استفاده از شبکه عصبی کانولوشنی مبتنی بر رزنت (ResNet-50) برای طبقه‌بندی تصاویر ماموگرافی پیشنهاد شد. در این پژوهش برای آموزش و طبقه‌بندی شبکه از مجموعه داده INbreast استفاده شده و تصاویر ماموگرافی مربوط به توده‌های سرطان سینه به دسته‌های نرمال و غیر نرمال طبقه‌بندی شده‌اند. به طور کلی این چارچوب از یادگیری انتقالی توسط ResNet-50 CNN از پیش آموزش دیده در ImageNet استفاده کرده است. نتایج نشان داد که چارچوب پیشنهادی به دقت طبقه‌بندی ۹۳/۰۰٪ دست یافته است. این رویکرد تشخیص زودهنگام و طبقه‌بندی سرطان سینه را تسهیل می‌کند و به طور بالقوه جان و منابع انسانی را نجات می‌دهد. در [۲۷] سال ۲۰۲۱ یک چارچوب یادگیری عمیق دوگانه (Dual CNN) برای پردازش تصاویر ماموگرافی معرفی شد. این چارچوب تقسیم‌بندی توده را محاسبه کرده و به طور همزمان نتایج تشخیص را پیش‌بینی می‌کند. به طور خاص، این روش توسط یک معماری دو مسیره<sup>۲۸</sup> ارائه شده است. یک مسیر، به نام یادگیرنده حفظ محلی (LPL<sup>۲۹</sup>)، به استخراج سلسله مراتبی و بهره برداری از ویژگی‌های ذاتی ورودی اختصاص داده شده است. در حالی که مسیر دیگر، به نام یادگیرنده گراف مشروط (CGL<sup>۳۰</sup>)، بر تولید ویژگی‌های هندسی از طریق مدل‌سازی تصویر مبتنی بر پیکسل برای پوشاندن همبستگی‌ها تمرکز دارد. با ادغام این دو یادگیرنده، هم معاشناسی سرطان و هم بازنمایی سرطان به خوبی آموخته می‌شوند و مسیرهای یادگیری مؤلفه‌ها در مقابل یکدیگر را تکمیل می‌کنند. نتایج تجربی

اعمال نشود سیگنال خروجی یک تابع خطی ساده خواهد بود. تابع خطی فقط چند جمله‌ای درجه اول است. حل یک معادله خطی آسان است، پیچیدگی آن محدود بوده و توانایی کمتری برای یادگیری عملکرد تابعی پیچیده از داده‌ها دارد. این لایه یک عنصر ساده عملی را در مدل انجام می‌دهد و اندازه لایه را بدون نیاز به هیچ پارامتر آماری حفظ می‌کند. چند نمونه از توابع فعال‌سازی پر کاربرد (Sigmoid، ReLU<sup>۲۴</sup> و Leaky ReLU) همراه با نمودار و معادله دو بعدی آنها در جدول ۱ نشان داده شده‌اند. تابع ReLU به دلیل تسهیل فرآیند آموزش بیشترین استفاده را دارد [۲۴].

جدول ۱- چند نمونه از توابع فعال‌سازی پر کاربرد

تابع	نمودار	معادله
Sigmoid		$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$
ReLU		$f(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases}$
Leaky ReLU		$f(x) = \begin{cases} 0.01x & x < 0 \\ x & x \geq 0 \end{cases}$

آموزش شبکه<sup>۲۵</sup>: شبکه عصبی کانولوشنی از الگوریتم تغذیه رو به جلو برای آموزش سیستم استفاده می‌کند. همچنین برای محاسبه خطا از روش پس انتشار خطا<sup>۲۶</sup> (BP) استفاده می‌کند که دارای مزیت‌های است که اجازه می‌دهد تا شبکه‌های عصبی به صورت مادولار<sup>۲۷</sup> ارائه و اشکال زدایی شوند. روش آموزش به این شکل است که اولین لایه را به عنوان یک کدگذار اتوماتیک با کمینه کردن تابع هدف با مجموعه‌های آموزشی به عنوان ورودی، آموزش می‌دهیم. سپس لایه دوم را نیز به صورت کدگذار اتوماتیک آموزش می‌دهیم. لایه دوم، خروجی لایه اول را به عنوان ورودی می‌گیرد. این گام برای تعداد مورد نظر لایه‌ها برآورد می‌شود. از خروجی آخرین لایه به عنوان ورودی برای لایه

<sup>28</sup> Dual-path

<sup>29</sup> Locality Preserving Learner

<sup>30</sup> Conditional Graph Learner

<sup>24</sup> Rectified Linear Unit

<sup>25</sup> Network Training

<sup>26</sup> Back Propagation

<sup>27</sup> Modular

می‌دهد که روش ارائه شده توانسته دقت  $90/50\%$  را بر روی مجموعه داده MIAS بدست آورد.

در [۳۱] سال ۲۰۱۸ از یک سیستم تشخیص کامپیوتری (CAD) مبتنی بر شبکه‌های عصبی کانولوشنی عمیق (DCNN) استفاده شده که هدف آن کمک به رادیولوژیست در طبقه‌بندی ضایعات توده‌ای ماموگرافی است. یادگیری عمیق معمولاً به مجموعه داده‌های بزرگی نیاز دارد تا شبکه‌هایی با عمق معین را از ابتدا آموزش دهد. یادگیری انتقالی روشی موثر برای مقابله با مجموعه داده‌های نسبتاً کوچک است. در این مطالعه پس از پیش پردازش و عادی سازی تمام مناطق مورد علاقه ( $ROI^2$ ) استخراج شده از ماموگرافی کامل، از تمام تصاویر مجموعه داده برای ساخت یک مجموعه بزرگ با کمک تکنیک‌های افزایش داده و ادغام تصاویر استفاده شده است. نتایج تجربی نشان می‌دهد که روش ارائه شده توانسته دقت  $96/67\%$  را بر روی مجموعه داده INbreast بدست آورد.

در [۳۲] سال ۲۰۱۸ یک رویکرد محاسباتی مبتنی بر شبکه‌های عصبی کانولوشنی عمیق (DCNN) برای طبقه‌بندی تصویر بافت‌شناسی سرطان پستان توسعه یافت. در این روش از چندین معماری شبکه عصبی عمیق و طبقه‌بندی‌کننده درختان تقویت‌شده با گرادیان استفاده شده است. نتایج تجربی نشان می‌دهد که روش ارائه شده توانسته در طبقه‌بندی خودکار تصاویر به دو کلاس نرمال و غیرنرمال برای تشخیص سرطان دقت  $93/08\%$  را بر روی مجموعه داده  $MNIST^{35}$  بدست آورد.

نتایج بدست آمده از تحقیقات انجام شده در سال‌های اخیر، نشان می‌دهد که شبکه عصبی کانولوشنی را می‌توان برای دستیابی به نتایج بسیار دقیق در ماموگرافی‌های مختلف، همراه با ظرفیت بهبود ابزارهای پزشکی با کاهش میزان خطا در غربالگری ماموگرافی آموزش داد.

#### ۴- روش پیشنهادی

در این بخش به معرفی مدل عمیق پیشنهادی مورد استفاده در این پژوهش، معادلات حاکم و روش‌های پردازش تصویر مورد استفاده برای پیش پردازش و آماده‌سازی تصاویر پرداخته شده است. دیاگرام مفهومی روش پیشنهادی ارائه شده در این پژوهش در شکل (۳) نشان داده شده است. این

نشان می‌دهد که روش ارائه شده توانسته دقت قطعه بندی  $93/69\%$  بر روی مجموعه داده INbreast بدست آورد.

در [۲۸] سال ۲۰۲۱ از ترکیب شبکه کانولوشنی گراف و شبکه عصبی کانولوشنی (Graph CN + CNN) برای تشخیص توده‌ها در تصاویر ماموگرافی استفاده شده است. در این معماری ترکیبی یک شبکه عصبی کانولوشنی استاندارد هشت لایه بکار برده شده است. در این پژوهش دو تکنیک بهبود عادی سازی دسته‌ای ( $BN^{31}$ ) و حذف تصادفی یا Dropout با هم ادغام شده‌اند و در نهایت، از ادغام تصادفی مبتنی بر رتبه ( $RSP^{32}$ ) برای جایگزینی حداکثر ادغام سنتی استفاده شده است. برای اجرای روش پیشنهادی از بانک داده  $MIAS^{33}$  استفاده شده است. نتایج تجربی نشان می‌دهد که روش ارائه شده توانسته دقت  $96/10\%$  بر روی مجموعه داده MIAS بدست آورد.

در [۲۹] سال ۲۰۲۱ از یک شبکه عصبی کانولوشنی (CNN) برای تقویت شناسایی خودکار سرطان پستان با تجزیه و تحلیل مناطق بافتی کارسینوم مجرای متخاصم در تصاویر کل اسلاید استفاده شده است. در پیاده‌سازی سیستم پیشنهادی از معماری شبکه عصبی کانولوشنی برای تشخیص خودکار توده‌های سرطانی استفاده شده است. برای ارزیابی نیز از الگوریتم‌های مختلف یادگیری ماشین ( $ML^{34}$ ) استفاده شده است. تمام معماری‌ها توسط مجموعه داده بزرگی با عنوان  $IDC^{35}$  مورد بررسی و آزمایش قرار گرفتند. آزمون‌های اعتبارسنجی برای نتایج کمی با استفاده از معیارهای عملکرد برای هر روش انجام شد. سیستم پیشنهادی توانست به میانگین دقت  $87/00\%$  بر روی این مجموعه داده دست یابد.

در [۳۰] سال ۲۰۱۹ یک شبکه عصبی کانولوشنی بهبود یافته برای طبقه‌بندی توده‌ها در سرطان پستان (CNI-CNN) ارائه شده است. روش پیشنهادی از شبکه عصبی کانولوشنی استفاده می‌کند که طبقه بندی ضایعات سرطان سینه را بهبود بخشد تا به متخصصان در تشخیص سرطان سینه کمک کند. در واقع هدف از روش ارائه شده کمک به متخصصان حوزه پزشکی برای طبقه‌بندی ضایعات سرطان پستان از طریق اجرای شبکه عصبی کانولوشنی برای طبقه‌بندی سرطان پستان بوده است. نتایج تجربی نشان

<sup>35</sup> <https://www.kaggle.com/datasets/kasikrit/idc-dataset>

<sup>36</sup> Region of Interest

<sup>37</sup> <https://www.kaggle.com/datasets/hojjatk/mnist-dataset>

<sup>31</sup> Batch Normalization


<sup>32</sup> Rank-based Stochastic Pooling

<sup>33</sup> <https://www.kaggle.com/datasets/kmader/mias-mammography>

<sup>34</sup> Machine Learning

بار با افزایش تصویر بعدی وزن‌های لایه‌های پنهان به روز می‌شوند. در این پروسه وزن‌ها به روش تغذیه رو به جلو به روز شده و به روش پس انتشار خطا در هر مرحله خطای هر مرحله محاسبه می‌گردد، آلفا ( $\alpha$ ) نرخ یادگیری و لاندا ( $\lambda$ ) نرخ منظم‌سازی یا نرخ رفع خطای بیش برآزش است که به طور همزمان با استفاده از نمونه‌گیری تصادفی متناسب می‌شوند. در الگوریتم یادگیری عمیق جهت افزایش کارایی تحلیل به وسیله سیستم‌های محاسباتی، تصاویر به صورت دسته‌ای وارد مدل می‌شوند. برای هر دسته، شبکه برای پنج دوره آموزش می‌بیند و بهترین مقادیر ( $\alpha$  و  $\lambda$ ) را با استفاده از ۱۵٪ مجموعه آموزشی به طور تصادفی به عنوان یک مجموعه اعتبارسنجی انتخاب می‌کند.

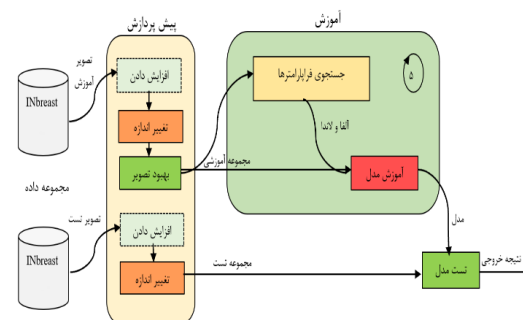
در فرآیند تست، مدل به دست آمده از فرآیند آموزش با استفاده از تصاویر جدید مجزا شده و مورد آزمایش قرار می‌گیرند. اگر مدل فقط برای تصاویر آموزش دیده درست عمل کرده و برای تصاویر تست نتایج درستی ندهد، منجر به خطای بیش برآزش می‌گردد. در مدل‌سازی مبتنی بر یادگیری عمیق، هدف اصلی رفع این خطا بوده که با اصلاح پارامترهای مدل پیشنهادی و افزایش تعداد تصاویر آموزشی باید رفع گردد.



شکل ۴- معماری شبکه عصبی کانولوشنی عمیق پیشنهادی (DCNN)

همانطور که در شکل (۴) نشان داده شده، معماری شبکه عصبی کانولوشنی عمیق پیشنهادی شامل هفت لایه کانولوشن، هشت لایه فعال‌ساز Leaky ReLU، سه لایه Max Pooling می‌باشد. همچنین در لایه کاملاً متصل<sup>۳۸</sup> نیز از دو لایه Soft-Max و فعال‌ساز استفاده شده است.

مدل بانک داده را به دو بخش آموزش و تست برای بیماران تقسیم می‌کند و یک شبکه ارتباطی را آموزش می‌دهد. مدل آموزش دیده ( $\alpha$  و  $\lambda$ ) با استفاده از ۱۵٪ داده‌های مجموعه آموزشی اعتبارسنجی می‌گردد که هر آزمایش ۵ بار تکرار شده است.



شکل ۳- دیاگرام مفهومی روش پیشنهادی

در الگوریتم‌های مبتنی بر یادگیری عمیق هر چه تعداد تصاویر آموزش دیده بیشتر و متنوع‌تر باشد الگوریتم کارایی بالاتری خواهد داشت. به همین منظور معمولاً در فرآیند یادگیری مدل‌های عمیق از تکنیک افزایش داده استفاده می‌شود. در واقع به علت کمبود تعداد تصاویر نسخه اصلی و بازتاب، هر تصویر با درجه چرخش‌های مختلف (۰، ۹۰، ۱۸۰ و ۲۷۰) را نیز وارد فرآیند آموزش می‌کنیم.

برای بهبود سرعت پردازش تصاویر در فرآیند یادگیری بهتر است در صورت امکان تصاویر هم اندازه باشند. شبکه‌های عصبی کانولوشنی دارای فضایی مؤثر و فضایی در اطراف پیکسل هستند که بر پیش‌بینی خود بر نواحی تا حدود ۱۲۸ × ۱۲۸ پیکسل تأثیر می‌گذارند. به منظور پیش پردازش در این مرحله، تصاویر با اندازه ۲ × ۲ سانتیمتر در این ناحیه تغییر اندازه داده شدند. با در نظر گرفتن این که جرم به ندرت از ۲ سانتیمتر (طول محور بلند) بزرگتر است، شبکه بخشی از ضایعه توده در طبقه مورد نظر را مشخص می‌کند.

در گام بهبود تصویر هر پیکسل با سطح میانگین تصویر فقط در ناحیه سینه و بقیه به صورت خطی برای پوشش شدت کل محدوده (۰.۲۵۵) محاسبه می‌شود تا وضوح تصویر را بهبود ببخشد. کاهش پس زمینه، توده‌های سینه را برجسته می‌کند که روشن‌تر از بافت پستان معمولی هستند. در فرآیند آموزش تصاویر تک به تک وارد مدل شده و هر

<sup>38</sup> Fully Connected Layer



تصاویر مربوط به خروجی مدل پیشنهادی پرداخته شده است.

جدول ۲- جزئیات معماری شبکه عصبی کانولوشنی عمیق

پیشنهادی (DCNN)

شماره لایه	لایه	فیلتر	گام	پد	حجم	پارامترها
۰	Input	-	-	-	۱۱۲*۱۱۲*۱	-
۱	Conv - > Leaky ReLU	۶*۶	۲	۲	۵۶*۵۶*۵۶	۲۰۷۲
۲	Conv - > Leaky ReLU	۳*۳	۱	۱	۵۶*۵۶*۵۶	۲۸۲۸۲
۳	MP	۲*۲	۲	۰	۲۸*۲۸*۵۶	-
۴	Conv - > Leaky ReLU	۳*۳	۱	۱	۲۸*۲۸*۸۴	۴۲۴۲۰
۵	Conv - > Leaky ReLU	۳*۳	۱	۱	۲۸*۲۸*۸۴	۶۳۵۸۸
۶	MP	۲*۲	۲	۰	۱۴*۱۴*۸۴	-
۷	Conv - > Leaky ReLU	۳*۳	۱	۱	۱۴*۱۴*۱۱۲	۸۴۷۸۴
۸	Conv - > Leaky ReLU	۳*۳	۱	۱	۱۴*۱۴*۱۱۲	۱۱۳۰۰۸
۹	Conv - > Leaky ReLU	۳*۳	۱	۱	۱۴*۱۴*۱۱۲	۱۱۳۰۰۸
۱۰	MP	۲*۲	۲	۰	۷*۷*۱۱۲	-
۱۱	FC -> Leaky ReLU	۷*۷	۱	۳	۷*۷*۴۴۸	۲۴۵۹۰۷۲
۱۲	FC	۱*۱	۱	۰	۷*۷*۱	۴۴۹
۱۳	Soft- Max	-	-	-	۱۱۲*۱۱۲*۱	-

\*Conv: Convolutional Layer  
\*MP: Max Pooling Layer  
\*Leaky ReLU(Rectified Linear Unit): Activation Function  
\*FC: Fully Connected Layer

#### ۵-۱- بانک داده

ماموگرافی دیجیتال تصویر را به دو منطقه جداگانه جرم سینه و بافت عمومی طبقه‌بندی می‌کند. در بسیاری از مطالعات انجام شده ناحیه سینه از طریق آستانه، از پس زمینه جدا شده، در این مطالعه به طور خاص، یک شبکه عصبی کانولوشنی عمیق را آموزش دادیم تا احتمال هر

در ارائه معماری شبکه عصبی کانولوشنی عمیق پیشنهادی پیشنهادی ابتدا از یک معماری ساده برای داشتن عملکرد مینا برای شبکه‌های عصبی کانولوشنی استفاده شد و تأثیر استفاده از تابع زیان وزن‌دار و افزایش تصویر ورودی مورد آزمایش قرار گرفت. در این مدل ابتدا تصویر ورودی پستان با اندازه  $۵۲ \times ۵۲$  وارد مدل می‌شود. تصویر ورودی در لایه اول همگشت با فیلتر  $۵ \times ۵$  ترکیب شده و تصویری به اندازه  $۵ \times ۵$  با حرکت بر روی المان‌ها با گام ۲ بوده که باعث کاهش اندازه ماتریس به نصف می‌شود. همچنین برای جبران پوشش فیلتر بر کناره‌ها از دو لایه صفر استفاده شده است که تمام تصویر در پوشش فیلتر قرار گیرد. تعداد فیلترهای استفاده شده در لایه پنهان ابتدا ۳۲ لایه بود که نتیجه‌ی استفاده از آن، تشکیل لایه اول ماتریس سه بعدی به اندازه  $۲۶ \times ۲۶ \times ۳۲$  می‌باشد. در انتهای لایه اول پنهان از تابع فعال‌ساز واحد خطی ReLU استفاده شد که مقادیر منفی ماتریس را به صفر تبدیل کند؛ زیرا اندازه نهایی ماتریس پس از اعمال تابع فعال‌ساز تغییر نخواهد کرد. در ادامه لایه‌های بعدی نیز به ترتیب اطلاعات را از لایه قبلی گرفته و در مجموع یک سیستم غیر خطی با وزن‌های کانولوشنی را تشکیل دادند. خروجی نهایی این مدل اول یک ماتریس به اندازه ماتریس ورودی بود که به صورت نقشه حرارتی یا کانتور ظاهر می‌گردد. برای اینکه شکل نهایی به صورت نقشه حرارتی ظاهر شود باید از لایه‌ای مبتنی بر تابع Soft-max نیز در مدل استفاده گردد. برای بررسی اینکه آیا نتایج منفی معماری انتخاب شده ضعیف هستند یا نه، معماری شبکه عصبی کانولوشنی عمیق‌تر و تعداد پارامترها کاهش یافت. برای بهبود عملکرد مدل ارائه شده و افزایش دقت خروجی در لایه کاملاً متصل از این مدل نیز دو لایه Soft-max و فعال‌ساز استفاده شده است. خروجی نهایی مدل وزن‌های نهایی را تبدیل کرده و طبقه‌بندی می‌کند. وزن‌هایی که اولویت بالایی داشته باشند قرمز رنگ و وزن‌های کم اهمیت با رنگ آبی مشخص شده‌اند. جدول ۲ جزئیات معماری شبکه عصبی کانولوشنی عمیق پیشنهادی را نمایش می‌دهد. این جدول اندازه فیلتر، گام، حجم و تعداد پارامترهای یادگیری در هر لایه از معماری را نشان می‌دهد.

#### ۵- نتایج تجربی

در این بخش به بیان نتایج بدست آمده از روش پیشنهادی، معرفی بانک داده، محیط شبیه‌سازی و نمایش نمودارها و

### ۵-۲- محیط شبیه‌سازی

روش پیشنهادی با استفاده از زبان برنامه‌نویسی پایتون<sup>۴۰</sup> و کتابخانه تنسورفلو<sup>۴۱</sup> در محیط ویندوز<sup>۴۲</sup> و توسط یک رایانه استاندارد (پردازنده Intel(R) Core(TM) i۵۵۰۰-۷ U ۲.۴۰GHz CPU با رم ۸ گیگابایت پیاده‌سازی شد.


### ۵-۳- اعتبارسنجی متقاطع ۵-folds

برای اعتبارسنجی مدل پیشنهادی از روش 5-folds Cross-validation (اعتبارسنجی متقابل با ۵ دسته) استفاده شده است. در هر دسته ۲۰ نمونه تصویر قرار گرفته است که مربوط به توده‌های نرمال و غیر نرمال هستند. نحوه توزیع توده‌های نرمال و غیر نرمال در جدول ۳ نمایش داده شده است با جداسازی پیکسل‌هایی با مقادیر صفر به عنوان پس زمینه، هر پیکسل غیر صفر آستانه جرم پستان و هر پیکسل باقیمانده به بافت طبیعی پستان طبقه‌بندی می‌شود. در ادامه تصاویر بانک داده سرطان سینه به طور جداگانه وارد مدل پیشنهادی می‌شوند. جستجوی فراپارامتر برای تنظیم نرخ یادگیری و پارامتر تنظیم کننده هر شبکه نیز انجام شده و پارامترهای دیگر به صورت دستی تنظیم می‌شوند. در جدول ۴ نمونه‌هایی از خروجی توسط روش پیشنهادی و نتایج وجود توده‌ها نمایش داده شده است. این جدول حاوی اطلاعات مربوط به تصویر ماموگرام، توده جدا شده، نتایج احتمالی وجود توده توسط مدل پیشنهادی و نوع توده (نرمال و غیرنرمال) می‌باشد.

جدول ۳- تعداد توده‌های نرمال و غیرنرمال در هر دسته

پوشه تست fold	نرمال Normal	غیرنرمال Abnormal	کل
دسته ۱ (fold 1)	۱۰	۱۰	۲۰
دسته ۲ (fold 2)	۱۵	۵	۲۰
دسته ۳ (fold 3)	۱۲	۸	۲۰
دسته ۴ (fold 4)	۷	۱۳	۲۰
دسته ۵ (fold 5)	۳	۱۷	۲۰

پیکسل متعلق به یک جرم را تخمین زده و این پیش بینی‌ها را ارزیابی کنیم. اجرای مدل پیشنهادی بر روی بانک داده INbreast انجام شده است. تصاویر این مجموعه در یک مرکز پستان واقع در بیمارستان دانشگاهی در پورتو<sup>۳۹</sup> با مجوز رسمی کمیته ملی حفاظت از داده‌ها و کمیته اخلاق بیمارستانی پرتغال جمع آوری شده است [۳۳]. نسخه اولیه این مجموعه داده شامل ۱۱۵ مورد بیمار به همراه ۴۱۰ ماموگرافی بود که اندازه تصویرها  $3328 \times 4084$  پیکسل هستند. در این پژوهش از داده‌های مربوط به تصاویر سرطان نرمال و غیرنرمال استفاده شده و سایر اطلاعات از جمله داده‌های بیمار (سن و چگالی پستان) و سایر ویژگی‌های تصویر (شدت، بافت، شکل و توصیف مکانی) نادیده گرفته شده است. مجموعه داده مورد استفاده در این مطالعه شامل ۳۳۶ تصویر ماموگرافی است که ۶۷ مورد آن نرمال و ۲۶۹ مورد آن غیرنرمال می‌باشند. از ۶۷ تصویر نرمال ۴۰ تصویر برای فرآیند آموزش و ۲۷ تصویر برای فرآیند تست مدل پیشنهادی استفاده شده است. از ۲۶۹ تصویر غیرنرمال ۱۶۲ تصویر برای فرآیند آموزش و ۱۰۷ تصویر برای فرآیند تست مدل پیشنهادی استفاده شده است. نمونه‌ای از تصویر مورد استفاده از این مجموعه داده طی مراحل پیش پردازش در شکل (۵) نشان داده شده است. در این تصویر توده خوش خیم یا بدخیم به رنگ سفید، ناحیه سینه به صورت سطح خاکستری و پس زمینه به رنگ سیاه در نظر گرفته شده است. برای هر قطعه، به طور تصادفی ۸۰٪ تصاویر را به مجموعه آموزشی و ۲۰٪ به مجموعه تست که ۱۵٪ از مجموعه آموزشی به طور تصادفی برای اعتبارسنجی مدل در هر دوره اختصاص داده می‌شود.



شکل ۵- نمونه‌ای از تصویر مورد استفاده از بانک داده INbreast طی مراحل پیش پردازش

<sup>41</sup> TensorFlow

<sup>42</sup> Windows

<sup>39</sup> Centro Hospitalar de S. João [CHSJ], Breast Centre, Porto

<sup>40</sup> Python

کیفیت، انتخاب ویژگی و در نهایت آموزش و تست به کمک شبکه عصبی کانولوشنی انجام شده است. درصدی از تصاویر موجود در بانک داده INbreast به صورت تصادفی جهت آموزش و بخشی برای آزمایش کنار گذاشته می‌شوند که در فرایند آموزش اولیه دخالتی ندارند. این انتخاب تصادفی و تکرارهای فرآیند آموزش گاهی منجر به درصد بسیار پایینی از نتایج اشتباه نیز می‌گردند. نتایجی همچون تشخیص ناحیه سینه به جای بخش خاکستری به عنوان پس زمینه و سایر عوامل مشابه. این امر بیشتر به دلیل حساسیت بیش از حد شبکه به استخراج ویژگی‌های موثر در بهبود کیفیت تصویر است. این مورد را نیز با افزایش تعداد تکرارها می‌توان بهینه‌تر کرد. با افزایش تکرارها در فرآیند آموزش بالطبع هزینه‌ی محاسباتی نیز بالاتر می‌رود اما بهینگی محلی و قحطی‌زدگی اتفاق نمی‌افتد.

#### ۴-۵- معیارهای ارزیابی

در این مطالعه از معیارهای دقت (Accuracy)، صحت (Precision) و حساسیت (Sensitivity) برای ارزیابی عملکرد سیستم استفاده شده است. معیار دقت عبارت است از تعداد نمونه‌هایی که به درستی طبقه‌بندی شده‌اند، نسبت به کل نمونه‌ها. معیار صحت معیاری است که به ما می‌گوید الگوریتم چند درصد «بله»‌هایش درست بوده است. در واقع تمرکز اصلی این معیار، بر روی درستی تشخیص‌های «بله» توسط الگوریتم است. تمرکز اصلی معیار حساسیت بر خلاف معیار صحت بر روی داده‌هایی است که واقعاً «بلی» بوده‌اند. در تمام معیارهای ارزیابی فوق چنانچه نمونه مثبت باشد و به عنوان مثبت نیز طبقه‌بندی شده باشد، مثبت حقیقی به حساب خواهد آمد؛ و چنانچه این نمونه به صورت منفی طبقه‌بندی شود، منفی کاذب است. در صورتیکه نمونه منفی بوده و به عنوان منفی طبقه‌بندی شده باشد، منفی حقیقی به حساب می‌آید و چنانچه این نمونه به صورت مثبت طبقه‌بندی شود، مثبت کاذب خواهد بود.  $^{43}TP$  (مثبت حقیقی) نشان دهنده تعداد پیش‌بینی‌های صحیح مربوط به همان کلاس،  $^{44}TN$  (منفی حقیقی) نشان دهنده تعداد درست پیش‌بینی شده به غیر از کلاس فعلی،  $^{45}FP$  (مثبت کاذب) نشان دهنده تعداد پیش‌بینی نادرست مربوط به کلاس‌های دیگر و  $^{46}FN$  (منفی کاذب) نشان دهنده

جدول ۴- نمونه‌هایی از نتایج تصویری بدست آمده توسط مدل عمیق پیشنهادی (DCNN)

نوع توده	نتایج احتمالی وجود توده توسط مدل عمیق پیشنهادی (DCNN)	توده جدا شده	تصویر ماموگرام
نرمال			
غیر نرمال			
غیر نرمال			
نرمال			
غیر نرمال			
نرمال			

برای پیشبرد اهداف اصلی تحقیق ابتدا پیش‌پردازش، بهبود

<sup>46</sup> False Negative

<sup>43</sup> True Positive

<sup>44</sup> True Negative

<sup>45</sup> False Positive

جدول ۶- مقایسه دقت مدل عمیق پیشنهادی با سایر کارهای انجام شده در سال‌های اخیر

شماره مرجع	سال چاپ مقاله	بانک داده	روش کار	دقت (%) Accuracy
[۲۶]	۲۰۲۳	INbreast	ResNet 50	۹۳.۰۰
[۲۷]	۲۰۲۱	INbreast	Dual CNN	۹۳.۶۹
[۲۸]	۲۰۲۱	MIAS	Graph CN + CNN	۹۶.۱۰
[۲۹]	۲۰۲۱	IDC	CNN	۸۷.۰۰
[۳۰]	۲۰۱۹	MIAS	CNNI-BCC	۹۰.۵۰
[۳۱]	۲۰۱۹	INbreast	DCNN	۹۶.۶۷
[۳۲]	۲۰۱۸	MNIST	DCNN	۹۳.۰۸
[#]	۲۰۲۳	INbreast	DCNN	۹۷.۶۷

### ۶- نتیجه‌گیری و پیشنهادات آتی

طبق تحقیقات انجام شده سرطان سینه شایع‌ترین سرطان در میان زنان می‌باشد؛ میزان ابتلا به سرطان سینه در جهان در حال افزایش است به همین دلیل تشخیص به موقع و سریع این بیماری شانس فرد را در بهبودی کامل و تسریع روند درمان افزایش می‌دهد. ماموگرافی یکی از مؤثرترین و مهمترین روش‌های تصویربرداری برای تشخیص سرطان سینه است. خواندن ماموگرام توسط رادیولوژیست‌ها دشوار است و بستگی به کیفیت تصویر، تخصص و تجربه رادیولوژیست دارد. از این رو استفاده از سیستم‌های تشخیص کامپیوتری (CAD) به عنوان نظر دوم اهمیت می‌یابد. هدف این پژوهش، افزایش دقت و بهبود تشخیص توده‌های نرمال و غیر نرمال در تصاویر ماموگرافی با استفاده از یک شبکه‌های عصبی کانولوشنی عمیق با هفت لایه کانولوشن و کمک به تشخیص رادیولوژیست‌ها و پزشکان در جداسازی و تشخیص توده‌های سرطانی بافت سینه در تصاویر ماموگرافی بود. اجرا و ارزیابی روش پیشنهادی در پژوهش حاضر بر روی بانک داده INbreast انجام شد. پیش پردازش‌های لازم همچون افزایش داده، تغییر اندازه و بهبود تصویر به منظور آماده سازی داده‌ها قبل از ورود به مرحله یادگیری انجام شد، سپس آموزش شبکه انجام شد. با توجه به نتایج بدست آمده از ارزیابی مدل عمیق پیشنهادی،

تعداد پیش‌بینی نادرست مربوط به همان کلاس می‌باشد. برای ارزیابی فاکتورهای مورد بررسی توسط مدل‌های پیشنهادی، متغیرهای وابسته برای معیار دقت توسط عبارت (۳)، صحت توسط عبارت (۴) و حساسیت توسط عبارت (۵) تعریف و محاسبه می‌شوند. جدول ۵ نتایج بدست آمده توسط معیارهای ارزیابی را برای مدل عمیق پیشنهادی نشان می‌دهد.

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (۳)$$

$$Precision = \frac{TP}{TP + FP} \quad (۴)$$

$$sensitivity = \frac{TP}{TP + FN} \quad (۵)$$

جدول ۵- مقادیر معیارهای دقت، صحت و حساسیت برای مدل

عمیق پیشنهادی (DCNN)

پوشه تست fold	دقت (%) Accuracy	صحت (%) Precision	حساسیت (%) Sensitivity
دسته ۱ (fold 1)	۹۶.۱۷	۹۳.۱۱	۹۶.۱۱
دسته ۲ (fold 2)	۹۶.۱۷	۷۸.۱۳	۸۷.۲۵
دسته ۳ (fold 3)	۹۷.۲۳	۸۹.۰۰	۹۵.۰۰
دسته ۴ (fold 4)	۹۹.۴۰	۹۰.۰۴	۹۷.۴۰
دسته ۵ (fold 5)	۹۹.۴۰	۹۰.۰۰	۹۹.۰۰
میانگین	۹۷.۶۷%	۸۸.۰۵%	۹۳.۷۸%

پژوهش حاضر به منظور کمک به تشخیص رادیولوژیست‌ها در طبقه‌بندی توده‌های سرطانی بافت سینه از طریق بهبود طبقه‌بندی توده‌های سرطانی در تصاویر ماموگرافی با استفاده از شبکه‌های عصبی کانولوشنی عمیق انجام گرفت. اولین یافته‌ای که از این پژوهش بدست آمد این بود که با عمیق کردن شبکه عصبی کانولوشنی و کنترل بیش برآزش می‌توان به دقت بالاتری رسید. نتایج بدست آمده در جدول ۴ نشان می‌دهد که مدل عمیق پیشنهادی دارای کارایی بالایی می‌باشد. جدول ۶ مقایسه‌ای از عملکرد مدل عمیق پیشنهادی را در مقایسه با سایر کارهای مورد مطالعه در بخش ۲ مربوط به این حوزه در سال‌های اخیر نمایش می‌دهد.

کانولوشنی عمیق پیشنهادی می‌توان از الگوریتم‌های یادگیر برای تشخیص سرطان در سیستم‌های مبتنی بر ابر با رویکرد کاهش زمان پاسخ استفاده کرد، از الگوریتم‌های بهینه‌سازی تصادفی مانند الگوریتم ژنتیک و بهینه‌سازی ازدحام ذرات برای آموزش و بهینه‌سازی زیر پارامترهای شبکه استفاده کرد، استخراج بهترین و مؤثرترین ویژگی‌ها برای تشخیص سرطان را با استفاده از بهینه‌سازی فرا ابتکاری و ترکیب آن با شبکه عصبی عمیق انجام داد و همچنین از روش‌های خوشه‌بندی برای استخراج ویژگی‌های وزن‌دار استفاده کرد تا درجه اهمیت هر ویژگی مشخص گردد.

میانگین دقت ۹۷.۶۷٪ تشخیص صحیح برای شبکه عصبی کانولوشنی عمیق پیشنهادی، نشان از عملکرد مناسب روش پیشنهادی نسبت به سایر کارهای انجام شده در سال‌های اخیر دارد. به عنوان کارهای تحقیقاتی آینده که می‌تواند در جهت توسعه و بهبود روش‌های تشخیص در این تحقیق انجام شود، می‌توان از تکنولوژی GPU و پردازش موازی برای افزایش سرعت پردازش‌ها استفاده کرد. همچنین می‌توان اعمال پارامترهای سودمند دیگر و ایجاد تغییرات و بکارگیری معیارهای متفاوت در لایه‌های شبکه عصبی کانولوشنی را به منظور افزایش دقت مدل پیشنهادی امتحان کرد. همچنین برای افزایش دقت شبکه عصبی

## مراجع

- [1] E.I. Obeagu, and G.U. Obeagu. "Breastfeeding's protective role in alleviating breast cancer burden: A comprehensive review." *Annals of Medicine and Surgery* 86, no. 5 (2024): 2805-2811.
- [2] A. Dibden, J. Offman, S.W. Duffy, and R. Gabe. "Worldwide review and meta-analysis of cohort studies measuring the effect of mammography screening programmes on incidence-based breast cancer mortality." *Cancers* 12, no. 4 (2020): 976.
- [3] K.P. Traves, and S.E. Cokenakes. "Breast cancer treatment." *American Family Physician* 104, no. 2 (2021): 171-178.
- [4] I. Sechopoulos, J. Teuwen, and R. Mann. "Artificial intelligence for breast cancer detection in mammography and digital breast tomosynthesis: State of the art." In *Seminars in Cancer Biology*, vol. 72, pp. 214-225. Academic Press, 2021.
- [5] Z. Jafari, and E. Karami. "Breast cancer detection in mammography images: A CNN-based approach with feature selection." *Information* 14, no. 7 (2023): 410.
- [6] G.O. Kuttan, and M.S. Elayidom. "Review on Computer Aided Breast Cancer Detection and Diagnosis using Machine Learning Methods on Mammogram Image." *Current Medical Imaging* 19, no. 12 (2023): 1361-1371.
- [7] J.G. Melekoodappattu, A.S. Dhas, B.K. Kandathil, and K.S. Adarsh. "Breast cancer detection in mammogram: Combining modified CNN and texture feature based approach." *Journal of Ambient Intelligence and Humanized Computing* 14, no. 9 (2023): 11397-11406.
- [8] V. Narayan, M. Faiz, P.K. Mall, and S. Srivastava. "A Comprehensive Review of Various Approach for Medical Image Segmentation and Disease Prediction." *Wireless Personal Communications* 132, no. 3 (2023): 1819-1848.
- [9] F. Hoseini, A. Shahbahrani, and P. Bayat. "An efficient implementation of deep convolutional neural networks for MRI segmentation." *Journal of Digital Imaging* 31, no. 5 (2018): 738-747.
- [10] F. Hoseini, A. Shahbahrani, and P. Bayat. "AdaptAhead optimization algorithm for learning deep CNN applied to MRI segmentation." *Journal of Digital Imaging* 32 (2019): 105-115.
- [11] A. Kebaili, J. Lapuyade-Lahorgue, and S. Ruan. "Deep learning approaches for data augmentation in medical imaging: a review." *Journal of Imaging* 9, no. 4 (2023): 81.
- [12] A. Raza, N. Ullah, J. Ali Khan, M. Assam, A. Guzzo, and H. Aljuaid. "DeepBreastCancerNet: A novel deep learning model for breast cancer detection using ultrasound images." *Applied Sciences* 13, no. 4 (2023): 2082.
- [13] G.W. Lindsay. "Convolutional neural networks as a model of the visual system: Past, present, and future." *Journal of Cognitive Neuroscience* 33, no. 10 (2021): 2017-2031.

- [14] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou. "A survey of convolutional neural networks: analysis, applications, and prospects." *IEEE Transactions on Neural Networks and Learning Systems* 33, no. 12 (2021): 6999-7019.
- [15] D.X. Zhou. "Universality of deep convolutional neural networks." *Applied and Computational Harmonic Analysis* 48, no. 2 (2020): 787-794.
- [16] A. Bouti, M.A. Mahraz, J. Riffi, and H. Tairi. "A robust system for road sign detection and classification using LeNet architecture based on convolutional neural network." *Soft Computing* 24, no. 9 (2020): 6721-6733.
- [17] Y. Lee, and S. Nam. "Performance comparisons of AlexNet and GoogLeNet in cell growth inhibition IC50 prediction." *International Journal of Molecular Sciences* 22, no. 14 (2021): 7721.
- [18] S.A. Hassan, M.S. Sayed, M.I. Abdalla, and M.A. Rashwan. "Breast cancer masses classification using deep convolutional neural networks and transfer learning." *Multimedia Tools and Applications* 79, no. 41 (2020): 30735-30768.
- [19] V.H. Josephine, A.P. Nirmala, and V.L. Alluri. "Impact of hidden dense layers in convolutional neural network to enhance performance of classification model." In *IOP Conference Series: Materials Science and Engineering*, vol. 1131, no. 1, p. 012007. IOP Publishing, 2021.
- [20] A. Dhillon, and G.K. Verma. "Convolutional neural network: a review of models, methodologies and applications to object detection." *Progress in Artificial Intelligence* 9, no. 2 (2020): 85-112.
- [21] A. Jha, J.C. Peterson, and T.L. Griffiths. "Extracting low-dimensional psychological representations from convolutional neural networks." *Cognitive Science* 47, no. 1 (2023): e13226.
- [22] A. Zafar, M. Aamir, N.M. Nawi, A. Arshad, S. Riaz, A. Alruban, A.K. Dutta, and S. Almotairi. "A comparison of pooling methods for convolutional neural networks." *Applied Sciences* 12, no. 17 (2022): 8643.
- [23] C. Ozdemir, Y. Dogan, and Y. Kaya. "A new local pooling approach for convolutional neural network: local binary pattern." *Multimedia Tools and Applications* 83, no. 12 (2024): 34137-34151.
- [24] Kılıçarslan, Serhat, Kemal Adem, and Mete Çelik. "An overview of the activation functions used in deep learning algorithms." *Journal of New Results in Science* 10, no. 3 (2021): 75-88.
- [25] M. Turkoglu, D. Hanbay, and A. Sengur. "Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests." *Journal of Ambient Intelligence and Humanized Computing* 13, no. 7 (2022): 3335-3345.
- [26] H. Rahman, T.F.N. Bukht, R. Ahmad, A. Almadhor, and A.R. Javed. "Efficient breast cancer diagnosis from complex mammographic images using deep convolutional neural network." *Computational Intelligence and Neuroscience* 2023 (2023).
- [27] H. Li, D. Chen, W.H. Nailon, M.E. Davies, and D.I. Laurenson. "Dual convolutional neural networks for breast mass segmentation and diagnosis in mammography." *IEEE Transactions on Medical Imaging* 41, no. 1 (2021): 3-13.
- [28] Y.D. Zhang, S.C. Satapathy, D.S. Guttery, J.M. Górriz, and S.H. Wang. "Improved breast cancer classification through combining graph convolutional network and convolutional neural network." *Information Processing & Management* 58, no. 2 (2021): 102439.
- [29] S.A. Alanazi, M.M. Kamruzzaman, M.N.I. Sarker, M. Alruwaili, Y. Alhwaiti, N. Alshammari, and M.H. Siddiqi. "Boosting breast cancer detection using convolutional neural network." *Journal of Healthcare Engineering* 2021 (2021).
- [30] F.F. Ting, Y.J. Tan, and K.S. Sim. "Convolutional neural network improvement for breast cancer classification." *Expert Systems with Applications* 120 (2019): 103-115.
- [31] H. Chougrad, H. Zouaki, and O. Alheyane. "Deep convolutional neural networks for breast cancer screening." *Computer Methods and Programs in Biomedicine* 157 (2018): 19-30.
- [32] A. Rakhlin, A. Shvets, V. Iglovikov, and A.A. Kalinin. "Deep convolutional neural networks for breast cancer histology image analysis." In *Image Analysis and Recognition: 15th International Conference, ICIAR 2018, Póvoa de Varzim, Portugal, June 27–29, 2018, Proceedings* 15, pp. 737-744. Springer International Publishing, 2018.

- [33] I.C. Moreira, I. Amaral, I. Domingues, A. Cardoso, M.J. Cardoso, and J.S. Cardoso. "Inbreast: toward a full-field digital mammographic database." *Academic Radiology* 19, no. 2 (2012): 236-248.
- [34] S. Asadzadeh, and B. Ravaei. "diagnosis of breast cancer at the molecular-cellular level with an artificial intelligence approach." *Journal of Modeling in Engineering* 21, no. 72 (2023): 19-30. (in Persian)
- [35] A. Rashno, S. Fadaei, and A. Hamidi. "Automatic Speaker Recognition based on Gabor Features and Convolutional Neural Networks." *Journal of Modeling in Engineering* 21, no. 72 (2023): 49-67. (in Persian)