

# آشکارسازی توده سرطانی پستان به کمک شبکه عصبی کانولوشنی در تصاویر ام.آر.آی

امیر ارجمند<sup>۱</sup>، دانشجوی کارشناسی ارشد؛ سعید مشگینی<sup>۲</sup>، استادیار؛ رضا افروزیان<sup>۳</sup>، استادیار

۱- دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران - amir.arjmand96@ms.tabrizu.ac.ir

۲- دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران - meshgini@tabrizu.ac.ir

۳- دانشکده فنی مهندسی میانه - دانشگاه تبریز - میانه - ایران - afrouzian@tabrizu.ac.ir

**چکیده:** سرطان پستان، متداولترین نوع سرطان است که جمعیت زنان را تحت تأثیر قرار می‌دهد. تشخیص زودهنگام سرطان می‌تواند شانس درمان را افزایش دهد و همچنین مؤثرترین راه برای مبارزه با این بیماری است. ارائه روش‌های خودکار برای آشکارسازی توده سرطانی یا تومور مورد توجه پژوهشگران بوده است. در این مقاله، یک روش مبتنی بر شبکه‌های عصبی عمیق کانولوشنی به منظور آشکارسازی ناحیه‌ی توموری از تصاویر MRI معرفی شده است. روش پیشنهادی به صورت جمع‌آوری تصاویر MRI به همراه تصویر GT از ناحیه‌ی توموری آن‌ها و بسط داده‌ها به منظور آموزش و آزمون شبکه عصبی می‌باشد. نوع روش یادگیری مورد استفاده در این مقاله، روش یادگیری بانظارت می‌باشد. الگوریتم بر روی مجموعه داده‌ی RIDER breast آزمایش شده و نتایج به خوبی نشان می‌دهند که روش پیشنهادی، عملکرد بهتری از سایر روش‌های آشکارسازی تصویر مانند روش‌های مبتنی بر خوشه‌بندی دارد. از مزایای می‌توان به کیفیت بالا در آشکارسازی تومور و سرعت قابل قبول در زمان اجرا اشاره کرد.

**واژه‌های کلیدی:** آشکارسازی توده سرطانی، یادگیری عمیق، شبکه عصبی کانولوشنی، سرطان پستان.

## Breast Tumor Detection using Convolutional Neural Network in MRI Images

A. Arjmand<sup>1</sup>, MSc Student; S. Meshgini<sup>2</sup>, Assistant Professor; R. Afrouzian<sup>3</sup>, Assistant Professor

1- Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: amir.arjmand96@ms.tabrizu.ac.ir

2- Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: meshgini@tabrizu.ac.ir

3- Miyaneh Technical College, University of Tabriz, Miyaneh, Iran, Email: afrouzian@tabrizu.ac.ir

**Abstract:** Breast cancer is the most common type of cancer that affects the female population. Early detection of cancer can increase the chance of treatment and is also the most effective way to fight the disease. The development of automated methods for the detection of cancer or tumor mass has been of interest to researchers. In this paper, a method based on deep convolutional neural networks for detecting tumor area from MRI images is introduced. The proposed method is to collect MRI images along with GT images from their tumor area and expand the data to train and test the neural network. The type of learning method used in this paper is supervised learning. The algorithm is tested on the RIDER breast dataset and the results show that the proposed method performs better than other image detection methods such as clustering methods. Benefits include high quality in tumor detection and acceptable speed at runtime.

**Keywords:** Tumor detection, Deep Learning, Convolutional Neural Networks (CNN), Breast Cancer.

تاریخ ارسال مقاله: ۱۳۹۸/۰۶/۱۷

تاریخ اصلاح مقاله: ۱۳۹۸/۰۸/۰۴

تاریخ پذیرش مقاله: ۱۳۹۸/۰۹/۰۸

نام نویسنده مسئول: سعید مشگینی

نشانی نویسنده مسئول: ایران - تبریز - بلوار ۲۹ بهمن - دانشگاه تبریز - دانشکده مهندسی برق و کامپیوتر - گروه مهندسی پزشکی.

## ۱- مقدمه

سرطان سینه بیشترین نوع مرگ ناشی از سرطان در زنان و همچنین دومین نوع متداول کلی سرطان و پنجمین علت مرگ و میر در آمار کلی است. لازم به توجه است که کشورهای در حال توسعه، بالاترین نرخ موارد را دارند. تسریع در تشخیص سرطان، می‌تواند از شانس بالایی برای درمان برخوردار باشد و همچنین موثرترین راه برای مبارزه با این بیماری است [۱].

در حال حاضر، معمول‌ترین روش معاینه برای تشخیص زودرس سرطان سینه، ماموگرافی می‌باشد. ماموگرافی حالت خاصی است از روش تصویربرداری اشعه ایکس است که برای تشخیص زودرس سرطان، قبل از آشکارشدن علائم فیزیکی به کار می‌رود. یک رادیولوژیست، تصاویر سیاه و سفید ایجاد شده از سینه را بررسی می‌کند و پزشک متخصص آن‌ها را تحلیل کرده و به صورت بصری محل ضایعه را شناسایی می‌نماید [۱،۲]. علائم زودرس سرطان سینه شامل: اشکال توده بی‌قاعده، خوشه‌های میکرو انباشته‌ای، ایرادات ساختاری و عدم تقارن دوطرفه‌ای می‌باشند [۳].

توموگرافی دیجیتالی پستان<sup>۱</sup> (DBT) روشی نسبتاً جدید در تصویربرداری می‌باشد. در تصویربرداری پستان با استفاده از منبع متحرک اشعه ایکس، نمایش پستان از زوایای مختلف به دست می‌آید که منجر به دستیابی تصاویر دوبعدی با رزولوشن بالا می‌شود [۲]. اهمیت روش توموگرافی دیجیتالی پستان در این است که با ایجاد برش‌های مقطعی، تا حد زیادی مشکل هم‌پوشانی بافت‌ها را حل می‌نماید [۴]. سپس این تصاویر دوبعدی با استفاده از الگوریتم دوباره-سازی به صورت حجم سه‌بعدی ایجاد می‌گردند که پزشک را قادر می‌سازد تا ساختارهای اساسی ماموگرافی و توده‌های مبهم در تصویر دو بعدی را متصور شود [۵].

با توجه به این‌که تصاویر ماموگرافی به صورت روزانه در مراکز پزشکی و بیمارستان‌ها ثبت می‌شوند؛ مشکل رایج در این کار، بررسی تمام تصاویر است که باعث خستگی رادیولوژیست‌ها و خطای زیاد می‌شود [۶]. دقت تشخیص نیز به صورت قابل توجه به کیفیت تصویر و تخصص رادیولوژیست بستگی دارد. بنابراین مهم است که با شناسایی دقیق، دقت و ارزش تصاویر ماموگرافی افزایش یابد. سیستم شناسایی به کمک کامپیوتر<sup>۲</sup> (CAD) یک مشاهده بصری دومی را برای کمک به ارزیابی پزشکان برای تفسیر و شناسایی بیماری‌ها ارائه می‌دهد [۷]. کاربرد سیستم شناسایی به کمک کامپیوتر، به صورت برجسته-گذاری یا تمایز بین ضایعات بدخیم و خوش‌خیم است. توده یکی از نشانه‌های مهم وجود بدخیمی می‌باشد که به صورت شکل دایره‌ای متراکم در قسمت‌های میانی به وجود می‌آید [۲،۸].

میزان تأثیر سیستم شناسایی به کمک کامپیوتر بستگی به روش‌های کاربردی برای دسته‌بندی و استخراج ویژگی‌ها دارد. از زمانی که یک الگوی یادگیری ماشین به نام یادگیری عمیق پدید آمد، در استخراج ویژگی‌ها نقش اساسی دارد. یادگیری عمیق اطلاعات معنایی زیادی را ارائه می‌دهد که دستیابی به ساختارهای تصویر را امکان‌پذیر می‌سازد [۹].

در نتیجه این تلاش‌ها، ساختارهای یادگیری عمیق مانند یادگیری شبکه‌های عصبی کانولوشنی (CNN) موفقیت‌آمیز بوده‌اند. شبکه‌های عصبی کانولوشنی در زمینه شناسایی اشیاء بصری و کاربردهای دسته‌بندی تصاویر مورد استفاده قرار می‌گیرند. در رشته تصویر برداری پزشکی، پیشرفت‌های زیادی با معرفی سیستم‌های جدید پدید آمده است [۶].

شبکه‌های عصبی کانولوشن برای استخراج تمامی ویژگی‌های نهان تصاویر کاربرد دارد. همچنین هزینه‌های محاسباتی را کم کرده و قابلیت آموزش ساده‌تری دارد. CNN به طور موفقیت‌آمیز در حل مشکلات تشخیصی به کار گرفته شده است. از آنجایی که مشخصه‌های توده با ویژگی‌هایی همچون شکل و نوع بافت رابطه دارد، CNN ساختاری مناسب را برای تشخیص توده ارائه می‌دهد [۸].

با توجه به توضیحات ارائه شده، در این مقاله یک روش مبتنی بر CNN برای آشکارسازی ناحیه‌ی توموری معرفی می‌شود. ادامه‌ی مقاله به شرح زیر تنظیم شده است:

در بخش ۲ مروری بر مقالات مرتبط با موضوع تحقیق ارائه می‌شود. در بخش ۳، لایه‌های مختلف شبکه عصبی کانولوشن معرفی می‌شود. در بخش ۴ روش پیشنهادی بصورت کامل مورد بررسی قرار می‌گیرد و در بخش ۵ نتایج حاصل از ارزیابی روش پیشنهادی بر روی مجموعه داده‌ی RIDER بررسی می‌گردد. در نهایت، بخش ۶ به نتیجه‌گیری و بحث در مورد کارهای آینده می‌پردازد.

## ۲- مروری بر کارهای پیشین

در [۱] روشی برای شناسایی توده در تصاویر ماموگرافی با بافت سینه متراکم با استفاده از روش‌های پردازش تصویر و شبکه‌های عصبی کانولوشنی بیان شده است. داده‌های DDSM<sup>۳</sup> برای شناسایی ناحیه مشکوک (ناحیه نامتقارن) به کار گرفته شده‌اند، با این حال نیاز به روشی است که خطای مثبت را کاهش داده و بهره‌وری را بالا ببرد. شبکه عصبی کانولوشن برای دسته‌بندی تراکم بافت سینه و همچنین برای تشخیص نهایی توده به کار گرفته شده است. در دسته‌بندی توده، استفاده از CNN بسیار موثر است. حتی در موارد با ساختار ساده، امکان دستیابی به ۹۷٪ توده‌ها وجود دارد. قابل توجه است که تعداد محدودی از منابع دسته‌بندی، تراکم را بر تشخیص توده ارجحیت داده اند. تشخیص ناحیه توده و غیر توده‌ای بر اساس تراکم در مقایسه با

<sup>۱</sup> Digital Breast Tomography  
<sup>۲</sup> Computer Aided Diagnosis

<sup>۳</sup> Digital Database for Screening Mammography

تشخیص لبه رسیده است. البته مقدار حساسیت بسته به نرخ مثبت کاذب تغییر کرده و هر مرحله‌ای از یک نرخ متفاوت استفاده کرده است.

در [۱۳] ناحیه پستان با استفاده از چرخش گرادیان برداری تعدیل یافته<sup>۶</sup> مشخص می‌گردد. تحلیل رگرسیون برای حذف عضلات ماهیچه‌ای از ناحیه پستان به‌کار گرفته شده است. با بهره‌گیری آشکارساز لایه فوقانی و تحلیل بافت ناحیه اولیه توده تخمین زده شده و با پیاده‌سازی الگوریتم دسته‌بندی ناحیه توده با دقت بالا به‌دست آمده است.

در [۱۴] الگوریتم فازی برش توده کلاسیک به توده‌های قطعه-بندی شده در ماموگرام‌ها اعمال شده و تمرکز بر روی نواحی توده می‌باشد. با بهره‌گیری از توزیع گاما تصاویر بدون نویز و با لبه مشخص به-دست آمده که نتایج خوبی در کیفیت قطعه‌بندی نشان می‌دهد.

در [۱۵] جهت رسیدن به قطعه‌بندی مناسب، یک نوع قطعه‌بندی مبتنی بر متغییر تصادفی مورد استفاده قرار می‌گیرد. و به ۴ دسته‌ی: خوش‌خیم، خوش‌خیم احتمالی-بدخیم ممکن، بدخیم احتمالی-خوش‌خیم ممکن و بدخیم دسته‌بندی می‌شوند. بیش از ۱۳۰۰ تصویر مورد بررسی قرار گرفته و براساس مقایسه‌ی نتایج داده‌ها و نظر رادیولوژیست‌ها، تکنیک‌های مبتنی بر نقاط بنیادی عملکرد خوبی برای دسته‌بندی توده‌ها نشان داده است.

در [۱۶] روش خودکار جدیدی برای دسته‌بندی و کلاس‌بندی ماموگرافی ارائه می‌دهد. ابتدا استخراج ناحیه مورد نظر انجام گرفته و سپس ناحیه توده‌دار دسته‌بندی شده و ویژگی‌ها همانند ورودی به چنین روش کلاس‌بندی وارد می‌شوند. کانتورهای فعال برای قطعه-بندی توده‌ها استفاده شده و با استفاده از اندازه‌گیری اشتراک بین تصاویر قطعه‌بندی شده و Ground Truth به دقت ۸۶/۸۵٪ رسیده‌اند.

در [۱۷] تشخیص توده‌های ماموگرافی با استفاده از الگوریتم تقسیم‌بندی مبتنی بر گرادیان و طبقه‌بندی عصبی مطرح شده است. ۲۲۶ توده (۱۰۹ بدخیم و ۱۱۷ خوش‌خیم) مورد تحلیل قرار گرفته است. ۱۶ ویژگی براساس شکل، اندازه و شدت توده‌های جدا شده، توسط یک شبکه عصبی پروپترون چندلایه‌ای<sup>۷</sup> آموزش داده شده است. سیستم CAD پیشنهادی در این مطالعه با استفاده از مشخصه‌گیرنده عامل<sup>۸</sup> (ROC) در تشخیص توده‌های بدخیم از خوش‌خیم مورد ارزیابی قرار گرفته است.

## ۲- شبکه عصبی کانولوشنی

شبکه عصبی کانولوشن (CNN)، یکی از مدل‌های معروف یادگیری عمیق است که بیشتر برای بازشناسی الگو در تصویر مورد استفاده قرار

کارهای مشابه، نتایج چشمگیری دارد. استفاده از شبکه‌های عصبی کانولوشن در استخراج ویژگی‌ها گام اساسی است.

در [۲] برای حل مشکل<sup>۴</sup> DCNN یک روش یادگیری انتقالی<sup>۵</sup> تعریف شده است و نشان داده می‌شود که امکان تشخیص توده در تصاویر ماموگرافی با استفاده از روش یادگیری انتقالی میسر می‌باشد. یک ساختار DCNN شامل هشت لایه وزنی که شامل ۵ لایه کانولوشنی و ۳ لایه تمام متصل است. ابتدا آموزش با استفاده از ۱،۲ میلیون تصویر نرمال برای کلاس‌بندی ۱۰۰۰ کلاس‌ه است. سپس با تغییر آخرین لایه پیوسته کامل، ۱۶۵۶ ناحیه برای کلاس‌بندی دو کلاس (نرمال- توده) انجام شده است. تست تشخیص بر روی ۱۹۸ تصویر ماموگرافی شامل ۹۹ تصویر نرمال و ۹۹ تصویر توده‌دار می‌باشد. نتایج آزمایشات حساسیت ۸۹،۹٪ و خطای مثبت ۱۹،۲٪ را نشان می‌دهد. نتایج نشان می‌دهد که DCNN همراه با روش یادگیری انتقالی، توانایی اجرای تشخیص توده بوسیله کامپیوتر را دارد. بر اساس معلومات محققین، اولین کاربرد در استفاده از روش جدید در سیستم CAD می‌باشد.

در [۳] چارچوب کلی بر اساس تصاویر برش‌های دوبعدی در نظر گرفته شده است. با تحلیل سطح به سطح برش‌های دوبعدی از تصاویر توموگرافی دیجیتال، الگو را توسط شبکه‌های عصبی کانولوشن به طور خودکار فرا می‌گیرد. سپس یادگیری برش‌های چندگانه اعمال شده و تصاویر بر اساس ویژگی‌های استخراج شده دسته‌بندی می‌شوند. با به-کارگیری CAD و گسترش آن، ۵۰۴۰ برش دوبعدی تصاویر از ۸۷ مجموعه مورد ارزیابی قرار می‌گیرد. نتایج تجربی نشان می‌دهد که روش پیشنهادی دقت بالاتری را نسبت به روش‌های دیگر، مانند روش بولتزمن ارائه می‌دهد.

در [۱۰]، مرحله‌ی قطعه‌بندی براساس لبه‌های استخراج شده مرز تومور انجام شده است. ولی به دلیل بعضی لبه‌های آسیب دیده و نامعین، شناسایی دشوار می‌باشد. قطعه‌بندی براساس ناحیه، دقت طبقه‌بندی را افزایش داده و این بدین دلیل است که ناحیه‌ی تومور معمولاً درخشان‌تر از بافت‌های اطراف تومور بوده و چگالی تقریباً یکنواختی دارند.

در [۱۱] قطعه‌بندی تومور با تکنیک‌های قطعه‌بندی ناحیه‌ای بر روی تومور انجام شده است. از الگوریتم یکنواخت جهت قطعه‌بندی خودکار مناطق کاندید تومور استفاده شده است و روی هم رفته به نرخ بازیابی ۹۰٪ برای توده‌های تومور رسیده است. اما معیار استفاده شده برای تحلیل تنها بر مبنای موقعیت تومور بوده و بر مبنای کیفیت قطعه-بندی نمی‌باشد.

در [۱۲] از تکنیک آستانه‌گذاری تطبیقی با حساسیت ۱۰۰٪ استفاده شده و با اعمال به ۱۸۸ تصویر به متوسط ۱/۸۷ اشتباه در

<sup>۶</sup> Modified Gradient Vector Flow  
<sup>۷</sup> Multi-Layered Perceptron Neural Network  
<sup>۸</sup> Receiver-Operating Characteristic (ROC)

<sup>۴</sup> Deep CNN  
<sup>۵</sup> Transfer Learning

**۳-۴- لایه  $\text{ReLU}^{12}$** 

لایه  $\text{ReLU}$  یک واحد خطی یکسوسوده را بر روی ویژگی‌ها اعمال می‌کند. این لایه دو وظیفه‌ی اصلی دارد. اول اینکه بخش منفی مقادیر به دست آمده را صفر می‌کند و دوم اینکه شبکه را پیچیده‌تر و غیرخطی‌تر می‌کند. با این هدف که الگوهای پیچیده‌تر نیز تشخیص داده شوند. لایه  $\text{ReLU}$  تنها یک تابع انتقالی است که مقدار ورودی  $u$  را به  $\max\{0, u\}$  تبدیل می‌کند.

**۳-۵- لایه حذف تصادفی<sup>۱۳</sup>**

این لایه با هدف جلوگیری از بیش برآزش استفاده می‌شود. معمولاً با افزایش پیچیدگی شبکه، احتمال وقوع بیش برآزش نیز افزایش می‌یابد. از این رو لایه حذف تصادفی می‌تواند مقداری از این پیچیدگی را در روند آموزش کاهش دهد. این لایه در روند یادگیری هر بار به صورت تصادفی درصدی از نرون‌های شبکه عصبی یا پارامترهای موجود را نادیده می‌گیرد. نرون‌هایی که در هر دور نادیده گرفته می‌شوند در آن دور آموزش نمی‌بینند و مقادیر تنظیمی آنها به روز نمی‌شود. در مطالعات دیده شده که این لایه تا حدودی می‌تواند بر دقت عملکرد شبکه عصبی و سرعت آن اثرگذار باشد.

**۳-۶- لایه ترانهادهی کانولوشن<sup>۱۴</sup>**

لایه ترانهادهی کانولوشن لایه‌ای است که وظیفه‌ی نمونه‌افزایی<sup>۱۵</sup> و ایجاد تصویر خروجی را به عهده دارد. از آنجایی که هدف شبکه عصبی مورد استفاده در این تحقیق بخش‌بندی تصویر است، لایه‌ی خروجی باید با لایه‌ی ورودی هم ابعاد باشد. از این رو پس از ایجاد بردار ویژگی نهایی به کمک لایه‌های قبلی، باید لایه‌ای باشد که برعکس عملیات قبلی را انجام دهد. البته این عملیات برعکس، صرفاً از نظر ابعاد اتفاق می‌افتد نه از نظر مقادیر. یعنی قرار نیست مقادیر اولیه‌ی تصویر مجدداً به دست آید، صرفاً ابعاد مهم است. چرا که تصویر خروجی قرار نیست همانند تصویر ورودی شود. بلکه باید تنها مشخص‌کننده ناحیه‌ی تومور در تصویر ورودی باشد.

**۳-۷- لایه بیشینه هموار**

معمولاً به تعداد کلاس‌های موجود، برای شبکه عصبی خروجی در نظر گرفته می‌شود. این خروجی‌ها هر کدام از یک تابع بیشینه هموار<sup>۱۶</sup> عبور داده می‌شوند و احتمال وقوع هر کلاس محاسبه می‌شود. در نهایت هر کلاسی که بیشترین احتمال را داشته باشد به عنوان کلاس نهایی تعیین می‌شود. تابع بیشینه هموار به صورت زیر تعریف می‌شود:

می‌گیرد. این شبکه متشکل از لایه‌های مختلفی است که در این بخش به معرفی آنها پرداخته می‌شود.

**۳-۱- لایه ورودی**

در این لایه صرفاً ورودی شبکه دریافت می‌شود. از آنجایی که ورودی شبکه در روش پیشنهادی تصاویر MRI است، لذا ورودی از نوع دو بعدی است و باید ابعاد تصاویر ورودی تعریف شود. لازم به ذکر است که ابعاد ورودی شبکه باید ثابت باشد. از این رو تصاویر ورودی در هر بعدی که باشند، باید ابتدا هم اندازه‌ی ورودی شبکه شوند و سپس به شبکه به عنوان ورودی داده شوند.

**۳-۲- لایه کانولوشن دوبعدی**

مهم‌ترین لایه‌ها در شبکه‌های عصبی کانولوشنی، لایه‌های کانولوشن هستند. معمولاً چندبار از این لایه‌ها استفاده می‌شود. این لایه متشکل از فیلترهایی است که بر روی تصویر ورودی اعمال شده و نمایش دیگری از تصویر را مهیا می‌سازند. به ازای هر فیلتر یک نمایش متفاوت از تصویر به دست می‌آید که می‌تواند منجر به کشف یک الگو در تصویر یا استخراج لبه‌های تصویر شود. تنظیم مقادیر این فیلترها به عهده‌ی الگوریتم بهینه‌سازی و داده‌های آموزش است. در واقع هر لایه کانولوشنی مانند یک فیلتربانک عمل می‌کند و ویژگی‌های متفاوتی از تصویر ورودی استخراج می‌کند. کار اصلی شناسایی الگو توسط همین لایه انجام می‌شود و هرچه این لایه‌ها افزایش یابند الگوهای پیچیده‌تری استخراج می‌شود.

**۳-۳- لایه حداکثر تجمع<sup>۹</sup>**

هدف این لایه کاهش ابعاد فضای ویژگی است. در واقع این لایه بلافاصله بعد از لایه کانولوشن یک عملی نمونه‌گامی<sup>۱۰</sup> بر روی نتایج کانولوشن ایجاد می‌کند. با این کار تعداد ویژگی‌ها کاهش می‌یابد و مقیاس دیگری از تصویر ورودی به دست می‌آید. در واقع با تکرار چندلایه کانولوشن و حداکثر تجمع به صورت متوالی از پهنای ورودی کاسته شده و به درازای آن افزوده می‌شود. تا جایی که در نهایت یک بردار ویژگی یک بعدی برای تصویر به دست آید. البته لزومی ندارد حتماً شبکه را تا رسیدن به بردار یک بعدی ادامه دهیم، اما در نهایت هر آنچه در لایه‌ی آخر باقی می‌ماند به عنوان یک بردار ویژگی یک بعدی در نظر گرفته می‌شود. گاهی این مرحله را نیز یک لایه مجزا با نام صاف کردن<sup>۱۱</sup> می‌شناسند که کار آن تنها تغییر ابعاد مقادیر به یک بردار یک بعدی است.

<sup>۱۲</sup> Rectified Linear Unit<sup>۱۳</sup> Dropout<sup>۱۴</sup> Transposed Convolution<sup>۱۵</sup> Upsampling<sup>۱۶</sup> Softmax<sup>۹</sup> Max-pooling<sup>۱۰</sup> Downsampling<sup>۱۱</sup> Flattening

$$Softmax(Z) = \frac{e^z}{\sum e^z} \quad (1)$$

$$Z = f(x_i; W)$$

تابع به ازای مقادیر ورودی کلاس‌ها با خروجی بین ۰ و ۱

نظر صحت کل و کیفیت ناحیه‌ی توموری آشکارسازی شده ارزیابی می‌شوند.

#### ۴-۱- بسط داده‌های آموزش

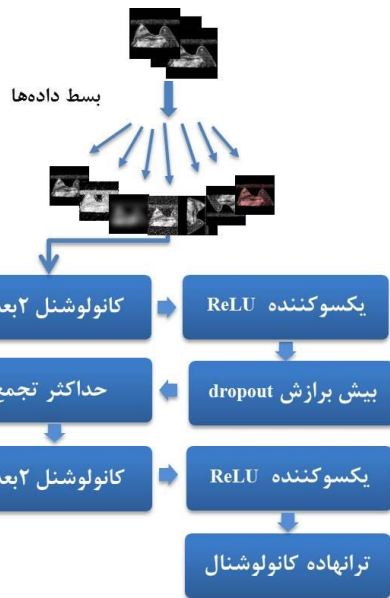
یکی از مشکلاتی که شبکه‌های عصبی مصنوعی و دیگر الگوریتم‌های یادگیری ماشین با آن همواره مواجه هستند، مسأله‌ی بیش برآزش است. زمانی که اختلاف دقت بین داده‌های آموزش و داده‌های تست زیاد شود، اصطلاحاً می‌گویند بیش برآزش رخ داده است. علت بروز این مشکل این است که شبکه عصبی خود را برای تفکیک داده‌های آموزش تا حد زیادی تنظیم می‌کند. اما اگر داده‌های تست با داده‌های آموزش تفاوت بیشتری داشته باشند، شبکه قادر نخواهد بود که با دقت بالا خروجی را تأمین کند. به بیان دیگر شبکه عصبی از جامعیت برخوردار نخواهد بود. مشکل بیش برآزش اغلب به سبب کمبود داده‌های آموزش یا زیاد بودن پارامترهای شبکه رخ می‌دهد.

#### ۳-۸- لایه‌ی طبقه‌بندی پیکسل

این لایه همان لایه‌ی خروجی است که وظیفه‌ی آن محاسبه‌ی خطای شبکه در طبقه‌بندی پیکسل‌ها و پس‌انتشار خطای شبکه به لایه‌های قبلی است. درواقع الگوریتم بهینه‌سازی در این لایه قرار دارد. تفاوت این لایه با لایه‌های طبقه‌بندی معمولی در ابعاد آن است. صرفاً این لایه، خروجی را هم‌ابعاد با لایه‌ی ورودی در نظر می‌گیرد و همانند دیگر لایه‌های طبقه‌بندی وظیفه‌ی پس‌انتشار خطا را دارد.


#### ۴- روش پیشنهادی

هدف روش پیشنهادی ایجاد مدلی است که بتواند تصویر MRI پستان را دریافت کرده و در صورت وجود، ناحیه‌ی تومور را از دیگر قسمت‌های تصویر جدا کند. درواقع این سیستم مانند یک رادیولوژیست متخصص باید بتواند ناحیه توموری را شناسایی و با دقت بالا آشکارسازی کند. از آنجایی که روش پیشنهادی مبتنی بر شبکه عصبی مصنوعی است، نیازمند داده‌های آموزش کافی است. پس مرحله‌ی اول یافتن داده‌های مناسب است. داده‌ها باید به گونه‌ای باشد که به ازای هر تصویر MRI یک تصویر خروجی  $GT^{17}$  موجود باشد. تصویر GT باید به همان ابعاد تصویر MRI باشد و تنها شامل ناحیه‌ی توموری باشد. شکل ۱ یک مثال از ورودی و خروجی به خوبی نشان می‌دهد.



شکل ۲. بلوک دیاگرام روش پیشنهادی

به عبارت دیگر هرگاه تعداد پارامترها به نسبت تعداد داده‌های آموزش زیاد باشد، شبکه به احتمال زیاد دچار بیش برآزش خواهد شد. اما اگر پیچیدگی شبکه کاهش یابد و تعداد پارامترهای تنظیمی شبکه نیز کاهش یابد، ممکن است شبکه نتواند الگوها را به درستی از هم تفکیک کند و این بار به دلیل دیگری دقت کاهش می‌یابد. پس بهترین



شکل ۱. نمونه‌ای از تصویر MRI (ورودی) و ناحیه‌ی توموری جداشده (خروجی)

باید به اندازه‌ی کافی از این ورودی‌ها و خروجی‌ها موجود باشد تا شبکه بتواند به خوبی یاد بگیرد که ناحیه‌ی توموری را از دیگر نواحی مانند پس زمینه و بافت پستان تفکیک کند.

در این تحقیق ۸۰٪ تصاویر به عنوان داده‌های آموزش و ۲۰٪ دیگر به عنوان داده‌های تست یا آزمون در نظر گرفته شده‌اند. پس از آموزش دادن شبکه، ۲۰٪ از تصاویر که به عنوان آزمون در نظر گرفته شده‌اند به عنوان ورودی به شبکه داده می‌شود و خروجی شبکه با خروجی‌های واقعی که توسط رادیولوژیست ارائه شده، مقایسه می‌شود. خروجی‌ها از

<sup>17</sup> Ground Truth (GT)

پیکسل ندارند، اما با اعمال متعادل‌ساز هیستوگرام برخی از پیکسل‌ها بسیار تیره و بسیار روشن می‌شوند و این کار باعث افزایش تضاد و کانتراست در تصویر خواهد شد. همانند نویز و فیلتر میانه این الگوریتم نیز بر روی تصاویر اعمال شده و تصاویر جدیدی علاوه بر تصاویر قبلی ایجاد می‌شود.

با تکنیک فوق توانسته‌ایم ۳۳ تصویر موجود در مجموعه داده‌ی RIDER را به ۵۲۸ تصویر برسانیم به طوری که این تعداد داده برای آموزش شبکه عصبی عمیق کافی باشد.

#### ۲-۴- معماری شبکه پیشنهادی

در این بخش معماری پیشنهادی به کمک این لایه‌ها ارائه می‌شود. همانطور که دیده می‌شود، لایه‌ی اول یک لایه‌ی ورودی است که یک تصویر با ابعاد  $72 \times 72$  پیکسل دریافت می‌کند. لایه‌ی دوم یک لایه‌ی کانولوشنال دوبعدی است که دارای ۶۴ فیلتر  $3 \times 3$  است. همچنین یک حاشیه با اندازه‌ی ۱ پیکسل برای فیلترها در نظر گرفته شده است.

لایه‌ی سوم یک لایه‌ی یکسوکننده‌ی ReLU است. در لایه‌ی چهارم یک dropout با نرخ ۰.۵ در نظر گرفته شده است تا از بیش‌برازش جلوگیری شود.

لایه‌ی پنجم یک لایه‌ی حداکثر جمع است که با گام ۲، ابعاد تصاویر به دست آمده از لایه‌های قبلی را نصف می‌کند. لایه‌ی ششم مجدداً یک لایه‌ی کانولوشنال است که حاوی ۶۴ فیلتر  $3 \times 3$  بوده و یک پیکسل حاشیه در نظر گرفته است. سپس در لایه‌ی هفتم مجدداً از ReLU استفاده شده است.

در لایه‌ی هشتم عملیات عکس کانولوشن یا ترانهاده‌ی کانولوشن اجرا می‌شود که حاوی ۶۴ فیلتر  $4 \times 4$  با گام ۲ و برش ۱ پیکسلی در حاشیه است.

از آنجایی که تنها قرار است ۲ کلاس داشته باشیم (پیکسل‌های سفید یا توموری و پیکسل‌های سیاه یا غیرتوموری)، یک لایه‌ی کانولوشن دیگر با دو فیلتر  $1 \times 1$  در نظر گرفته می‌شود. علت استفاده از این لایه این است که هم عمق بیشتری به شبکه داده شود و هم خروجی رو محدود به کلاس‌های موجود کند. در لایه‌ی دهم یک تابع بیشینه هموار احتمال وقوع هر کلاس را برای تک تک پیکسل‌ها محاسبه می‌کند. لایه‌ی آخر نیز عملیات بهینه‌سازی را به کمک گرادینان نزولی<sup>۲۰</sup> و فیدبک خطا<sup>۲۱</sup> انجام می‌دهد.

#### ۳-۴- نحوه ارزیابی

به ازای هر تصویر ورودی، یک تصویر خروجی تولید می‌شود که باید ناحیه‌ی توموری را از دیگر نواحی تفکیک کرده باشد. همچنین

راه افزایش داده‌های آموزش است. البته روش‌های دیگری مانند حذف تصادفی یا اضافه کردن تنظیم کننده L2<sup>۱۸</sup> نیز به کاهش اثر بیش‌برازش کمک می‌کند که از آنها نیز در این تحقیق استفاده شده است. اما معمولاً بیشترین تأثیر را افزایش داده‌ی آموزش می‌گذارد.

بدیهی است که همواره دسترسی به داده‌های آموزش وجود ندارد و گاهی نمی‌توان داده‌ی بیشتری فراهم کرد. اما در مسائل پردازش سیگنال و به ویژه پردازش تصویر، راه حلی تحت عنوان بسط داده<sup>۱۹</sup> وجود دارد. در این تکنیک با اضافه کردن جزئیاتی به تصاویر، یا تغییر جزئی تصاویر، از هر تصویر چندین تصویر دیگر ساخته می‌شود. این کار را می‌توان با اعمال انواع فیلترها بر روی تصویر، اضافه کردن نویز به تصاویر، چرخاندن تصاویر، تغییر ابعاد تصاویر یا اشیای موجود در تصویر ... انجام داد.

در این تحقیق برای بسط داده از نویز گاوسی، چرخش تصویر، افزایش کانتراست تصویر با متعادل‌سازی هیستوگرام، فیلتر میانه و حالت‌های ترکیبی (مانند نویز و چرخش به طور همزمان) استفاده شده است. به طوری که در مجموع تعداد داده‌های آموزش ۱۶ برابر شده است. جزئیات هر کدام از تغییرات به صورت زیر است.

**چرخش:** هر تصویر موجود در مجموعه داده‌ی آموزش سه بار (۹۰ درجه، ۱۸۰ درجه و ۲۷۰ درجه) چرخانده شده است. همچنین پس از اضافه نمودن نویز، اعمال فیلتر میانه و افزایش کانتراست، این چرخش‌ها مجدداً انجام شده است. لازم به ذکر است که در چرخش‌ها هم تصویر ورودی (MRI) چرخش داده می‌شود و هم تصویر خروجی (GT). اما زمانی که نویز یا فیلتر به تنهایی اعمال می‌شود، خروجی هیچ تغییری نمی‌کند.

**نویز گاوسی:** به هر تصویر ورودی MRI یک نویز گاوسی با میانگین صفر و واریانس ۰.۱ اضافه شده است و به عنوان داده‌های جدید در نظر گرفته می‌شود. باید توجه داشت که خروجی داده‌های نویزی همان خروجی‌های تصاویر اولیه‌ی بدون نویز است.

**فیلتر میانه:** فیلتر میانه اغلب برای حذف نویز از تصاویر استفاده می‌شود و مقداری لبه‌های تصویر را نرم می‌کند. روند اجرای این فیلتر بدین شکل است که مقدار هر پیکسل با مقدار میانگین پیکسل‌های همسایه‌اش جایگزین می‌شود. همانند نویز گاوسی، این فیلتر نیز بر روی تک تک تصاویر موجود اعمال شده و تصاویر جدیدی به دست آمده است.


**متعادل‌ساز هیستوگرام:** این الگوریتم به منظور افزایش کانتراست تصویر به کار برده می‌شود. این الگوریتم، شدت روشنایی پیکسل‌های موجود در تصویر را به گونه‌ای تغییر می‌دهد که حتی-الامکان از تمام شدت نورها، به تعداد مساوی پیکسل وجود داشته باشد. اغلب تصاویر کم کانتراست، در نقاط بسیار تیره یا بسیار روشن

<sup>۲۰</sup> Gradient Descent  
<sup>۲۱</sup> Feedback Error

<sup>۱۸</sup> L2-Regularization  
<sup>۱۹</sup> Data Augmentation

- معماری شبکه عصبی مورد استفاده شامل ۱۱ لایه است که سه لایه از آن کانولوشنی و یک لایه از آن ترانهادهی کانولوشن است.
- برای بهینه‌سازی وزن‌های شبکه عصبی از الگوریتم پیش‌فرض موجود در کتابخانه یعنی الگوریتم گرادیان نزولی استفاده شده است.
- نرخ یادگیری اولیه برای گرادیان نزولی برابر با ۰.۰۱ در نظر گرفته شده است.
- هر ۵۰ دور یک بار نرخ یادگیری تقسیم بر ۱۰ می‌شود تا به مرور زمان کوچکتر شود.
- یادگیری به صورت دسته‌ای<sup>۲۲</sup> انجام می‌شود. یعنی به جای اینکه تمام داده‌های آموزش به یکباره به شبکه داده شود، به صورت بسته‌ای و به نوبت به شبکه عصبی داده می‌شود.
- سایز هر دسته در هر دور ۱۶ ورودی است.
- تعداد دوره‌های<sup>۲۳</sup> یادگیری برابر با ۱۵۰ در نظر گرفته شده است. هر اپاک برابر با یک بار تنظیم وزن‌های شبکه به کمک تمام داده‌های آموزش است.
- نرخ حذف تصادفی برابر با ۰.۵ است. یعنی در هر دور از یادگیری نیمی از نورون‌های شبکه در نظر گرفته نمی‌شود.

شکل ۳ نتایج آشکارسازی را برای تمام چهار تصویر موجود در مجموعه داده‌ی RIDER را به صورت کیفی نمایش می‌دهد. در جدول ۱ نیز نتایج عددی به دست آمده بر حسب صحت و Q را برای ۳۳ تصویر مجموعه داده‌ی RIDER نشان داده شده است.



شکل ۳. چهار نمونه خروجی CNN پیشنهادی

Mini-batch<sup>۲۲</sup>  
Epoch<sup>۲۳</sup>

یک تصویر اعتبارسنجی (GT) نیز موجود است که خروجی شبکه با آن تصویر مقایسه می‌شود. اولین معیار برای ارزیابی نتایج T معیار صحت کل است که به طور کلی نشان می‌دهد شبکه چقدر توانسته تصویر خروجی را همانند رادیولوژیست تولید کند:

$$Accuracy = \frac{N_{++} + N_{+-}}{N} \quad (2)$$

که  $N_{++}$  تعداد پیکسل‌های توموری است که به درستی تشخیص داده شده است (یعنی هم در خروجی شبکه عصبی و هم در تصویر GT این پیکسل‌ها توموری هستند).  $N_{+-}$  تعداد پیکسل‌های غیر توموری است که به درستی تشخیص داده شده‌اند و  $N$  تعداد کل پیکسل‌های تصویر ورودی است.

اما از آنجایی که تعداد پیکسل‌های غیر توموری بسیار بیشتر از پیکسل‌های توموری است، معیار صحت کل T دید درستی از نتایج به ما نمی‌دهد. از این رو از معیار Q استفاده می‌کنیم که به صورت زیر محاسبه می‌شود:

$$Q = \frac{|S \cap G|}{|G|} \times \frac{|S \cap G|}{|S|} \quad (3)$$

که S ناحیه‌ی توموری جداسازی شده توسط روش پیشنهادی و G ناحیه‌ی توموری واقعی است که توسط رادیولوژیست جداسازی شده است. در واقع مقدار Q تمرکز بیشتری بر روی ناحیه‌ی توموری دارد و دید بهتری از جداسازی تومور به ما می‌دهد.

مقدار اتلاف شبکه عصبی نیز از رابطه‌ی زیر محاسبه می‌شود:

$$Loss = \frac{1}{N} (1 - \frac{\sum intersection}{\sum union}) \quad (4)$$


که N تعداد کل نمونه‌های آموزشی است. مقادیر intersection عبارت از پیکسل‌های مشترک و توموری بین خروجی مطلوب و خروجی به دست آمده از شبکه عصبی است. مقادیر union هم عبارت از تمام پیکسل‌های توموری خروجی مطلوب و خروجی شبکه است.

## ۵- نتایج


به منظور آزمایش روش پیشنهادی از مجموعه داده‌ی RIDER Breast MRI استفاده شده است. این مجموعه داده از آرشیو تصاویر بیوپزشکی ملی (NBIA<sup>۱</sup>) قابل دریافت است [۱۸]. این مجموعه داده شامل تصاویر MRI از پنج بیمار است و برای هر بیمار تصاویر متعددی وجود دارد. ابعاد تمام تصاویر موجود ۲۸۸×۲۸۸ پیکسل است و تصاویر خاکستری می‌باشند. در مجموع، دیتاست RIDER تنها شامل ۳۳ مورد است که رادیولوژیست تصویر خروجی از تومور آنها را فراهم کرده است. همانطور که گفته شد، این تعداد به ۵۲۸ نمونه بسط داده شده است.

به منظور پیاده‌سازی روش پیشنهادی از نرم افزار MATLAB نسخه‌ی 2018b استفاده شده است. تمامی اجراها نیز بر روی یک سیستم با پردازنده Intel core i7 و بر روی سیستم عامل Window10 انجام شده است. دیگر تنظیمات به شرح زیر است:

روش پیشنهادی برخلاف روش‌های مبتنی بر خوشه‌بندی نیازمند یک مرحله‌ی آموزش است. از این رو لازم است داده‌هایی موجود باشد که از قبل آشکارسازی تومور بر روی آنها انجام شده باشد و مدل بتواند نحوه‌ی آشکارسازی تومور را از آن داده‌ها یاد بگیرد. از این رو روش پیشنهادی از نوع یادگیری بانظارت است. در حالی که روش‌های خوشه‌بندی روش‌های بدون نظارت بوده و نیازی به تأمین خروجی مطلوب ندارند.



شکل ۵. روند کاهش خطای CNN در طول یادگیری



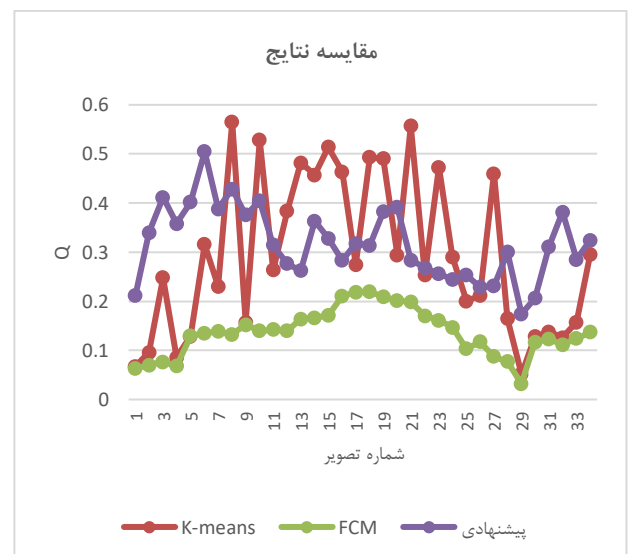
شکل ۶. روند افزایش دقت شبکه عصبی در طول یادگیری

روش پیشنهادی با طی کردن مرحله‌ی آموزش می‌تواند الگوی تومور را یاد بگیرد و در تصاویر جدید همان الگوها را بازشناسی کند. اما روش‌های بدون نظارت تنها بر اساس شدت روشنایی یا اطلاعات رنگی، تومور را آشکارسازی می‌کنند و این باعث می‌شود که بسیاری از قسمت‌های بافت سینه که شدت روشنایی‌شان نزدیک به شدت روشنایی ناحیه‌ی توموری است، به عنوان تومور تشخیص داده شوند؛ که در نهایت دقت آشکارسازی تومور را کاهش می‌دهند.

شکل ۳ نتایج به دست آمده از روش پیشنهادی را بر حسب Q با دو روش مرسوم آشکارسازی مبتنی بر خوشه‌بندی، یعنی روش نزدیکترین همسایگی<sup>۲۴</sup> و روش سی-میانگین فازی<sup>۲۵</sup> (FCM) مقایسه کرده است. در این مقایسه هر ۳۳ تصویر موجود در مجموعه داده استفاده شده است.

جدول ۱. نتایج عددی ۳۳ تصویر مجموعه داده‌ی RIDER

۳۳ تصویر	صحت (%)	Q	نوع تصویر
میانگین کل	۹۷,۲۱	۰,۳۲۴۳	آموزش و تست
Std	۰,۰۰۴۸	۰,۰۷۴۷	آموزش و تست



شکل ۴. نمودار مقایسه نتایج

همانطور که دیده می‌شود، در برخی از تصاویر مقدار Q برای روش k-means بزرگتر شده است، اما به طور کل روش پیشنهادی میانگین بالاتری داشته و همچنین پراکندگی نتایج آن کمتر است. شکل‌های زیر روند آموزش یعنی کاهش خطای شبکه عصبی و افزایش دقت را برای CNN پیشنهادی نمایش می‌دهد. همانطور که دیده می‌شود در همان چند دور اول، دقت به بالای ۹۵٪ رسیده، اما خطای شبکه در تشخیص ناحیه توموری تقریباً بعد از ۱۰۰ دور حداقل شده است.

## ۶- نتیجه‌گیری و بحث

تاکنون روش‌های مختلفی به منظور آشکارسازی تومور در تصاویر MRI معرفی شده است. از جمله این روش‌ها می‌توان به الگوریتم‌های خوشه‌بندی اشاره کرد. روش پیشنهادی تفاوت‌های عمده‌ای با این روش‌ها دارد که در ادامه این تفاوت‌ها بیان می‌شود:

<sup>۲۴</sup> Nearest Neighbors

<sup>۲۵</sup> Fuzzy C-Means



- [8] Y. Zhong, A. Ma, Y.S. Ong, Z. Zhu, L. Zhang, "Computational intelligence in optical remote sensing image processing." *Applied Soft COMPUTING* (2017).
- [9] S. H. Lewis and A. Dong, "Detection of breast tumor candidates using marker-controlled watershed segmentation and morphological analysis," in *Image analysis and interpretation (SSIAI)*, 2012 IEEE southwest symposium on, 2012, pp. 1-4.
- [10] M. M. Eltoukhy and I. Faye, "An adaptive threshold method for mass detection in mammographic images," in *IEEE international conference on signal and image processing applications (ICSIPA)*, 2013, 2013, pp. 374-378.
- [11] B. W. Hong and B. S. Sohn, "Segmentation of regions of interest in mammograms in a topographic approach," *IEEE Transactions on Information Technology in Biomedicine*, vol. 14, pp. 129-139, 2010.
- [12] F. R. Cordeiro, W. P. Santos, and A. G. Silva-Filho, "Segmentation of Mammography by Applying GrowCut for Mass Detection," *women*, vol. 1, p. 3, 2013.
- [13] S.W. Zheng, J. Liu, and C.C. Liu, "A random-walk based breast tumors segmentation algorithm for mammograms," *International Journal on Computer, Consumer and Control (IJ3C)*, vol. 2, pp. 66-74, 2013
- [14] P. Rahmati, A. Adler, and G. Hamarneh, "Mammography segmentation with maximum likelihood active contours," *Medical image analysis*, vol. 16, pp. 1167-1186, 2012.
- [15] N. Al-Najdawi, M. Biltawi, and S. Tedmori, "Mammogram image visual enhancement mass segmentation and classification," *Applied Soft Computing*, vol. 35, pp. 175-185, 2015.
- [16] M. Dong, X. Lu, Y. Ma, Y. Guo, Y. Ma, and K. Wang, "An efficient approach for automated mass segmentation and classification in mammograms," *Journal of digital imaging*, vol. 28, pp. 613-625, 2015.
- [17] P. Delogu, M.E. Fantacci, P. Kasae, A. Retico, "Characterization of mammographic masses using a gradient-based segmentation algorithm and a neural classifier" *Computers in and Biology Medicine* (37) (2007): 1479-1491.
- [18] <https://dcm.bmia.nl/ncia/login.jsf>

روش پیشنهادی وابسته به داده است و باید داده‌های آموزشی از قبل برای آنها در نظر گرفته شود. اما روش‌های بدون نظارت نیازی به داده قبلی ندارند و می‌توانند آشکارسازی را با دسته‌بندی پیکسل‌های تصویر ورودی انجام دهند. در صورتی که داده‌ی آموزش به اندازه‌ی کافی در دسترس نباشد، مطابق روش پیشنهادی می‌توان از بسط داده‌ها استفاده نمود.

از آنجایی که روش‌های بدون نظارت مرحله‌ی آموزش ندارند، در مجموع زمان کمتری برای اجرا نیاز دارند. اما در عمل، وقتی که شبکه عصبی CNN آموزش ببیند با سرعت بالایی آشکارسازی را برای تصاویر جدید انجام می‌دهد. از این رو از نظر سرعت در مرحله‌ی استفاده و عملی، روش پیشنهادی ضعیفی نسبت به سایر روش‌ها ندارد.

نتایج به خوبی نشان دادند که روش پیشنهادی از قابلیت اعتماد بالاتری برخوردار است. در حالی که روش‌های دیگر، نتایج پراکنده‌ای ایجاد می‌کنند. به طوری که برای برخی تصاویر دقت بالا و برای برخی تصاویر دقت بسیار کمی در آشکارسازی تومور از خود نشان می‌دهند. اما روش پیشنهادی تقریباً برای همه نوع تصویری متعادل رفتار می‌کند. همچنین در مجموع روش پیشنهادی مقدار میانگین Q بالاتری از روش‌های دیگر از خود نشان داده است. به طور کل می‌توان مزایای روش پیشنهادی را کیفیت بالا در آشکارسازی تومور و سرعت قابل قبول در زمان اجرا دانست و عیب اصلی آن وابستگی به داده‌های آموزش است.

## مراجع

- [1] M. Yousefi, A. Krzyzak, C.Y. Suen, "Mass detection in digital breast tomosynthesis data using convolutional neural networks and multiple instance learning", *Computers in biology and medicine*, (2018).
- [2] S. Suzuki, X. Zhang, N. Homma, K. Ichiji, N. Sugita, Y. Kawasumi, T. Ishibashi, M. Yoshizawa, "Mass detection using deep convolutional neural network for mammographic computer-aided diagnosis", in: *55th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*, 2016, pp. 1382-1386.
- [3] S.V. Fotin, Y. Yin, H. Haldankar, J.W. Hoffmeister, S. Periaswamy, "Detection of soft tissue densities from digital breast tomosynthesis": *comparison of conventional and deep learning approaches*, *Proceedings of the SPIE* 9785, Med. Imaging (2016), 97850X.
- [4] D.H. Kim, S. Kim, Y.M. Ro, "Latent feature representation with 3-D multi-view deep convolutional neural network for bilateral analysis in digital breast tomosynthesis", in: *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP*, 2016, pp. 927-931.
- [5] Z.Jiao, X.Gao, Y.Wang, J.Li, "A Deep feature based framework for breast masses classification", *Neurocomputing* 197 (2016) 221-231.
- [6] H. Chougrada, H. Zouakia, O. Alheyane, "Deep convolutional neural networks for breast cancer screening". *Comput. Methods Programs Biomed.* 157, 19-30 (2018)
- [7] W.B Sampaio, E.M Diniz, A.C Silva, A.C Paiva and M Gattass, "Detection of Masses in Mammogram Images using cnn", *Geostatistic Functions and svm, Computers in Biology and Medicine*, vol. 41(8), pp. 653-664, (2011).