

# تشخیص سرطان سینه با استفاده از شبکه بهبودیافته ZFNet-ELM با الگوریتم بهینه‌سازی COA

سارا خسروی<sup>\*</sup>، استادیار

<sup>۱</sup> گروه کامپیوتر، دانشکده فنی و مهندسی، دانشگاه پیام نور، تهران، ایران، khosravi\_un@pnu.ac.ir

چکیده: امروزه بسیاری از محققان با استفاده از سیستم‌های مبتنی بر یادگیری عمیق و هوش مصنوعی، در حوزه پزشکی به تشخیص و طبقه‌بندی بسیاری از بیماری‌ها مانند تشخیص سرطان می‌پردازند. تشخیص زودهنگام و دقیق سرطان سینه براساس تصاویر ماموگرافی می‌تواند به پزشکان در درمان به موقع بیماری کمک بسزایی کند. از طرفی اکثر شبکه‌های عمیق مورد استفاده در سیستم‌های تشخیص سرطان سینه (BC)، به دلیل استفاده از لایه‌های تمام متصل (FC)، روش آموزشی زمان‌بر و حجم محاسبات بالا، برای کاربردهای بلادرنگ مناسب نیستند. لذا در این مقاله، یک روش جدید ترکیبی مبتنی بر یادگیری عمیق و هوش ازدحامی به نام EZFNet-ELM-COA جهت تشخیص بلادرنگ سرطان سینه (BC) پیشنهاد شده است. در شبکه پیشنهادی (Enhanced ZFNet)، در لایه‌های کانولوشنی شبکه ZFNet، فیلترهای سایز بزرگ با دو سری فیلتر سایز کوچک‌تر جایگزین شده‌اند و سپس خروجی‌های فیلترها با یکدیگر الحاق شده است. استفاده از این تکنیک چندمقیاسی باعث استخراج ویژگی‌های موثرتر توسط شبکه می‌گردد. همچنین جهت بالابردن سرعت آموزش و کاهش محسوس حجم محاسبات، لایه‌های تمام متصل شبکه EZFNet از پیش‌آموزش دیده توسط شبکه یادگیری افراطی (ELM) جایگزین شد. در انتها نیز قابلیت تعمیم ELM با استفاده از پروژرسانی وزن‌ها و بایاس‌های لایه و روی ELM توسط الگوریتم بهینه‌سازی کوآتی (COA) بهبود داده شده است. جهت بررسی عملکرد سیستم، از شش معیار ارزیابی، استفاده شده است، که مدل پیشنهادی ما در معیارهای: دقت، صحت، حساسیت، تشخیص‌پذیری، FI-score و MCC به ترتیب مقادیر: ۹۷/۹۷، ۹۵/۷۰، ۹۷/۱۵، ۹۸/۲۸، ۹۶/۴۲ و ۹۳/۹۸ درصدی را بدست آورده است. نتایج بدست آمده افزایش دقت، بهبود کارایی، کاهش چشمگیر زمان محاسبات و سطح عملکردی بالای سیستم پیشنهادی را نسبت به روش‌های موجود نشان می‌دهد.

واژه‌های کلیدی: یادگیری عمیق، هوش مصنوعی، تشخیص سرطان سینه، شبکه عصبی کانولوشن عمیق، الگوریتم بهینه‌سازی کوآتی (COA).

\* سارا خسروی، khosravi\_un@pnu.ac.ir

# Breast cancer diagnosis using improved ZFNet-ELM network with COA optimization algorithm

Sara Khosravi<sup>1\*</sup>, assistant professor

<sup>1</sup> Computer Department, Faculty of Technology and Engineering, Payam Noor University, Tehran, Iran, khosravi\_un@pnu.ac.ir

**Abstract:** Nowadays, many researchers use systems based on deep learning and artificial intelligence to diagnose and classify many diseases in the field of medicine, such as cancer diagnosis. Early and accurate diagnosis of breast cancer based on mammography images can greatly help doctors in timely treatment of the disease. On the other hand, most of the deep networks used in breast cancer (BC) detection systems are not suitable for real-time applications due to the use of fully connected (FC) layers, time-consuming training method and high calculation volume. Therefore, in this article, a new hybrid method based on deep learning and crowd intelligence called EZFNet-ELM-COA is proposed for real-time detection of breast cancer (BC). In the proposed network (Enhanced ZFNet), in the convolutional layers of the ZFNet network, large size filters have been replaced by two series of smaller size filters, and then the outputs of the filters have been joined together. The use of this multi-scale technique makes the network extract more effective features. Also, in order to increase the speed of training and significantly reduce the volume of calculations, fully connected layers of the pre-trained EZFNet network were replaced by Extreme learning machine (ELM). At the end, the generalization capability of ELM has been improved by updating the weights and biases of the ELM layer by the Quati Optimization Algorithm (COA). In order to check the performance of the system, six evaluation criteria have been used, and our proposed model has the following criteria: accuracy, precision, sensitivity, recognizability, F1-score and MCC values respectively: 97.97, 95.70, 97.15, 98.28, 96.42 and 93.98 percent have been obtained. The obtained results show the increase of accuracy, improvement of efficiency, significant reduction of calculation time and high performance level of the proposed system compared to the existing methods.

**Keywords:** *Deep learning, artificial intelligence, breast cancer diagnosis, deep convolutional neural network, Coati optimization algorithm (COA)*

\* Sara Khosravi, khosravi\_un@pnu.ac.ir

## ۱. مقدمه

در سال‌های اخیر، سرطان سینه<sup>۱</sup> (BC) یکی از شایع‌ترین سرطان‌ها در بین زنان بوده است که تعداد مبتلایان به آن در سراسر دنیا رو به افزایش است. به این معنی که امروزه از هر هشت زن، یک نفر در زندگی خود به سرطان سینه مبتلا می‌شود. بنابراین، تشخیص زودهنگام این بیماری در همان مراحل ابتدایی، به پزشکان کمک می‌کند که از پیشرفت این بیماری جلوگیری کرده و یک برنامه درمانی مؤثر را برای درمان آن انتخاب کنند و همچنین هزینه‌های ناشی از درمان نیز کاهش یابد [۱-۴]. از این-رو، تشخیص زود هنگام این بیماری، نیازمند یک روش تشخیصی دقیق و قابل اطمینان است.

در تشخیص سرطان سینه، تمایز بین ساختار سرطانی و شناسایی درجه بدخیمی آن امری ارزشمند است. پیش از این، روش‌های تصویربرداری مختلفی برای تشخیص سرطان سینه وجود داشت، از جمله: تصویربرداری تشدید مغناطیسی<sup>۲</sup> (MRI) [۲]، توموگرافی کامپیوتری<sup>۳</sup> (CT) [۴]، فناوری اولتراسوند<sup>۴</sup> (US) [۵] و ماموگرافی<sup>۵</sup> (X-ray) [۶]. در آزمایش غربالگری سرطان سینه با استفاده از تصویربرداری ماموگرافی، علاوه بر ثبت ویژگی‌ها و جزئیات بیشتر از بافت داخلی سینه، یک روش مقرون به صرفه نیز در تشخیص سرطان می‌باشد. با این حال، تصاویر به‌دست‌آمده از ماموگرافی اغلب شامل انواع ناهنجاری‌ها و اختلالاتی است که تشخیص دقیق و زودهنگام سرطان در مراحل اولیه را عملاً دشوار می‌کند [۷].

در حال حاضر، از روش تشخیصی هیستوپاتولوژیک<sup>۶</sup> و استفاده از تکنیک H&E<sup>۷</sup> که نوع بدخیمی سرطان را با مشاهده

میکروسکوپی بافت تعیین می‌کند، استفاده می‌شود. در این روش، آسیب‌شناسان با مشاهده ضایعات بافتی در زیر میکروسکوپ، ناحیه سرطانی و درجه بدخیمی را بر اساس ساختار بافت، هسته و سیتوپلاسم<sup>۸</sup> و الگوی رشد سلول‌ها تعیین می‌کنند [۷]. با توجه به اینکه تومورها خود بخش کوچکی از تصویر را تشکیل می‌دهند، ممکن است تشخیص سرطان سینه در مراحل پیش‌بالینی آن با آزمایش ماموگرافی دشوار باشد. وضوح تصاویر ماموگرافی دیجیتال معمولاً<sup>۹</sup> ۵۰۰۰ در ۴۰۰۰ پیکسل است. با این حال، منطقه موردنظر<sup>۹</sup> (ROI) مشکوک ممکن است وضوح ۵۰ در ۵۰ پیکسل داشته باشد. بنابراین از تصاویر ماموگرافی دیجیتال برای تشخیص سرطان سینه استفاده می‌شود. از طرفی دیگر، به منظور ارائه اطلاعات بیشتر و بهبود تشخیص بالینی، سیستم تشخیص خودکار باید علاوه بر بررسی ضایعات بافتی کشف شده، قادر به تجزیه و تحلیل کامل تصاویر ماموگرافی نیز باشد [۸]. محاسبات و تجزیه و تحلیل سیستم‌های تشخیصی به طور قابل توجهی به ROIهای تعیین شده نیز بستگی دارد. بنابراین، توصیف ROIهای برچسب‌گذاری شده<sup>۱۰</sup> اولین قدم بسیار مهم است. در صورت دسترسی به برچسب‌های ROI در پایگاه‌های اطلاعاتی ماموگرافی، می‌توان از روش RCNN استفاده کرد. با این حال، از روش‌های تشخیصی که به برچسب‌های ROI نیاز دارند، نمی‌توان برای مجموعه داده‌های بزرگ سرطان سینه استفاده کرد، زیرا جمع‌آوری آن‌ها به زمان زیادی نیاز دارد و بسیار پرهزینه است [۸].

در چندین مطالعه تحقیقاتی صورت‌گرفته از جمله [۹]، شبکه‌های عصبی بدون استفاده از هیچ شناسه‌ای در فرآیند آموزش، آموزش داده شده‌اند. از طرفی دیگر، چنین شبکه‌هایی توانستند ضایعات بافتی مهم را شناسایی کرده و پیش‌بینی‌های خود را بر اساس بخش‌های ماموگرافی مربوطه قرار دهند.

1 Breast Cancer

2 Magnetic Resonance Imaging

3 Computed Tomography

4 Ultrasound Technology

5 Mammography

6 Histopathological

7 Hematoxylin & Eosin

8 Cytoplasm

9 Region of Interest

10 Labeled

به تازگی، روش‌های جدید مبتنی بر یادگیری عمیق<sup>۱</sup> (DL) برای بررسی و تشخیص سرطان از تصاویر ماموگرافی معرفی شده است. در این مطالعات، ویژگی‌های موردنظر از تصاویر ورودی به صورت خودکار استخراج می‌شود. یادگیری عمیق، مستلزم آموزش داده‌های زیادی است تا بتواند به حداکثر کارایی خود دست یابد. استفاده از مجموعه داده‌های برجسب‌دار و بدون برجسب برای بهبود دقت طبقه‌بندکننده‌های<sup>۲</sup> سرطان سینه، که براساس وضعیت سرطان تصاویر هستند، امری مهم است. اکثر این سیستم‌ها به این دلیل که بیشتر استراتژی‌های یادگیری عمیق موجود بر شبکه عصبی کانولوشن<sup>۳</sup> (CNN) تکیه کرده‌اند، عملکرد طبقه‌بندی بهتری نسبت به روش‌های مرسوم دارند<sup>۴</sup> [۷]. در صورت عدم دسترسی به مجموعه داده‌های آموزشی بزرگ و جامع در روش‌های یادگیری عمیق می‌توان با استفاده از مرحله پیش‌آموزش<sup>۴</sup>، آموزش طبقه‌بند را امکان‌پذیر کرد. نمونه‌ای از پیش‌آموزش لایه‌ای برای پیش‌آموزش پارامترهای وزن یک شبکه باور عمیق<sup>۵</sup> (DBN) با سه لایه پنهان در مرجع [۱۰] استفاده شده است. براساس مطالعات انجام شده، استفاده از مرحله پیش‌آموزش هم سرعت و هم دقت شناسایی و تشخیص را بهبود می‌بخشد. همچنین پارامترهای وزن به سادگی قابل تغییر هستند تا مجموعه جدیدی از داده‌های آموزشی را بپذیرند، این کار باعث صرفه‌جویی در زمان و بهبود عملکرد مدل می‌شود [۱۱]. با این حال، طبقه‌بندی ماموگرافی و تشخیص سرطان به صورت خودکار و با روش‌های دقیق، کارآمد و به‌روز، در حال حاضر با چالش‌ها و مشکلاتی روبرو است که نیاز به تحقیقات بیشتر در این حوزه احساس می‌شود.

در این مقاله، از شبکه عصبی بهبودیافته ZFNet (EZFNet) برای استخراج خودکار ویژگی‌ها در ترکیب با ماشین یادگیری

افراطی<sup>۶</sup> (ELM) برای تشخیص و طبقه‌بندی بلادرنگ سرطان سینه از تصاویر ماموگرافی، استفاده شده است. در روش ارائه شده برای کاهش زمان محاسبات آموزش و آزمایش، در ساختار شبکه EZFNet از ELM [۱۲]، به عنوان یک روش آموزش به جای لایه تمام متصل<sup>۷</sup> (FC) استفاده شده است تا کاستی‌هایی را که قبلاً ذکر شد، برطرف سازد. بنابراین، اولین کاری که باید انجام شود آموزش شبکه EZFNet است که به عنوان یک استخراج‌کننده خودکار ویژگی عمل می‌کند [۱۳]. پس از آن، لایه‌های باقیمانده EZFNet توسط ELM جایگزین و تنظیم می‌شود. در انتها نیز قابلیت‌های تعمیم ELM با استفاده از الگوریتم بهینه‌سازی کواتی<sup>۸</sup> (COA) [۱۴] بهبود داده خواهد شد. در نهایت عملکرد شبکه عمیق پیشنهادی EZFNet-ELM-COA بر روی دو پایگاه داده تصاویر ماموگرافی و هیستوپاتولوژی مورد ارزیابی قرار می‌گیرد. مشارکت‌های اصلی مقاله به شرح زیر می‌باشد:

- تصاویر ماموگرام معمولاً دارای نویز و مصنوعات رادیولوژی هستند. بدین منظور ابتداءً فاز پیش‌پردازش، نویز، برجسب‌های رادیولوژی و بافت‌های ماهیچه‌ای حذف شده و تصاویر بهبود می‌یابند و سپس به ورودی شبکه اعمال می‌شوند.
- در ساختار شبکه EZFNet به منظور افزایش سرعت، دقت و استفاده از ویژگی‌های چندمقیاسی<sup>۹</sup>، از لایه‌های کانولوشنی با دو سری فیلتر ساینز کوچک‌تر، به جای یک سری فیلتر ساینز بزرگ استفاده شده است.
- کاهش محسوس زمان محاسبات آموزش و شناسایی، با استفاده از تکنیک ELM به جای لایه تمام متصل (FC) در ساختار معماری شبکه عصبی EZFNet.
- استفاده از ELM به علت تنظیم تصادفی وزن‌ها و بایاس‌های لایه ورودی، در کنار افزایش سرعت، باعث ایجاد عدم

<sup>6</sup> Extreme learning machine

<sup>7</sup> Fully Connected Layer

<sup>8</sup> Coati Optimization Algorithm

<sup>9</sup> Multi-Scale

<sup>1</sup> Deep Learning

<sup>2</sup> Classifiers

<sup>3</sup> Convolutional Neural Network

<sup>4</sup> Pre-training

<sup>5</sup> Deep Belief Network

قطعیت در مدل نهایی می‌شود که یک ضعف قابل توجه است. برای رفع این مشکل از الگوریتم بهینه‌سازی COA برای تنظیم وزن‌ها و بایاس‌های لایه ورودی ELM استفاده شده است.

- همان‌طور که در [۱۴] نشان داده شده است، الگوریتم بهینه‌سازی COA نسبت به سایر الگوریتم‌های فراابتکاری از سرعت همگرایی بالاتری برخوردار است که این ویژگی موجب افزایش سرعت تنظیم وزن‌ها و بایاس‌های لایه ورودی ELM می‌شود.
- در روش پیشنهادی به دلیل استفاده از شبکه ELM نیازی به آموزش مدل EZFNet نیست و از شبکه از قبل آموزش دیده استفاده شده است.

در ادامه، ساختار این مقاله به شرح زیر سازماندهی شده است: بخش دوم جدیدترین کارهای انجام شده در زمینه شناسایی BC توسط سایر محققان را مورد بحث قرار می‌دهد. در بخش سوم پایگاه داده تصاویر مورد استفاده و روش پیش پردازش بیان شده است. بخش چهارم به جزئیات مربوط به طرح پیشنهادی می‌پردازد. نتایج حاصل از شبیه‌سازی و بحث در بخش پنجم ارائه شده و در نهایت در بخش ششم نتیجه‌گیری بیان شده است.

## ۲. کارهای مرتبط

تشخیص زودهنگام سرطان یکی از روش‌های پیشگیری از تکثیر سریع سلولی تومورهای خوش‌خیم و تبدیل آن به تومور بدخیم است. همان‌طور که در مرجع [۱۵] ذکر شده است، افزایش دقت موضوع اصلی بحث در حوزه تشخیص سرطان است. به طور کلی پژوهش‌های انجام شده در زمینه BC را می‌توان به دو دسته کلی زیر تقسیم کرد.

۱- روش‌های مبتنی بر یادگیری ماشین: در بیشتر مطالعات انجام شده در زمینه BC در حدود سال ۲۰۱۲، از شبکه‌های

عصبی کلاسیک<sup>۱</sup> استفاده شده است. شبکه عصبی کلاسیک عملکرد قابل توجهی در زمینه‌های مختلف دارد، اما محدودیت‌هایی نیز دارد، مانند: بیش‌برازش راحت، آهسته بودن سرعت آموزش و تنظیم پارامترها به صورت تجربی و آزمون و خطا. همچنین به دلیل پایین بودن سرعت محاسباتی کامپیوتر و نبود داده‌های کافی برای آموزش سیستم در آن زمان، استخراج ویژگی‌های مؤثر از داده‌های خام غیرممکن بود. بنابراین، از شبکه‌های عصبی کلاسیک در زمینه BC بیشتر به عنوان طبقه‌بند استفاده می‌شد. در بُعد انتخاب ویژگی نیز، بیشتر کارهای پژوهشی از ویژگی‌های بافت<sup>۲</sup> و ویژگی‌های ریخت‌شناسی<sup>۳</sup> برای تقسیم‌بندی<sup>۴</sup> و طبقه‌بندی<sup>۵</sup> تصاویر استفاده می‌کردند [۱۶]. با این حال، سیستم‌های طراحی سنتی به کمک رایانه عموماً به ویژگی‌های ایجاد شده دستی بستگی دارند و بنابراین عملکرد کلی را تضعیف می‌کنند [۱۷]. در [۱۶]، به طور جامع روش‌های موجود مبتنی بر ML برای تشخیص سرطان سینه براساس پردازش تصویر مورد بررسی و ارزیابی قرار گرفته است.

۲- روش‌های مبتنی بر یادگیری عمیق: با ظهور روش‌های یادگیری ماشین<sup>۶</sup> (ML) و هوش مصنوعی و به دلیل موفقیت فوق‌العاده‌ای که یادگیری عمیق در زمینه‌های مختلف داشته است، بسیاری از پژوهشگران علاقه‌مند به توسعه روش‌های یادگیری عمیق خصوصاً در حوزه پزشکی و تشخیص سرطان هستند. این امر به پزشکان در تشخیص درست و زودهنگام کمک کرده و دقت غربالگری ماموگرافی و سایر انواع تصاویر پزشکی را بهبود می‌بخشد [۶]. در مقایسه با رویکردهای ML [۱۸]، روش‌های DL عملکرد مؤثرتری در حل مسائل پیچیده و زمینه‌های مختلف از جمله تجزیه و تحلیل تصویر، تشخیص

<sup>1</sup> Classical ANNs

<sup>2</sup> Texture

<sup>3</sup> Morphological

<sup>4</sup> Segmentation

<sup>5</sup> Classification

<sup>6</sup> Machine Learning

چهره، شناسایی الگو، تشخیص صدا و تقسیم‌بندی تصاویر داشته و در مقایسه با تکنیک‌های یادگیری ماشین کلاسیک، به مداخلات انسانی کمتری برای استخراج ویژگی‌های مشابه نیاز دارد [۱۹]. علاوه بر این، از این تکنیک‌ها می‌توان برای یادگیری مناسب‌ترین ویژگی‌ها و یافتن الگوها در داده‌های پردازش نشده نیز استفاده کرد [۱۸].

در میان رویکردهای مختلف DL، روش CNN محبوب‌ترین تکنیک است که در چندین مطالعه از آن برای تشخیص سرطان سینه استفاده شده است. برخی از CNN‌های مورد استفاده از روش‌های مبتنی بر یادگیری انتقال<sup>۱</sup> (TL) که شامل شبکه‌های عصبی آموزش‌دیده قبلی مانند AlexNet، ResNet و VGG است، در تشخیص سرطان سینه استفاده کرده‌اند [۱۸]. همچنین، تحقیقات انجام شده نشان می‌دهد که تکنیک DCNN می‌تواند برای شناسایی و استخراج خودکار اطلاعات از تصاویر ماموگرافی و تخمین احتمال ابتلا به سرطان استفاده شود [۲۰]. DCNN‌ها معمولاً الگوریتم‌های پردازش داده دوبعدی<sup>۲</sup> با چندین کانال هستند که در معماری آنها، پیچیدگی شبکه با جایگزینی ضرب ماتریس با کانولوشن کاهش یافته است. برخلاف فرآیندهای معمول یادگیری، که نیازمند یادگیری مجموعه‌ای از پارامترهای جدید برای هر مکان است، DCNN‌ها فقط باید یک مجموعه از پارامترها را یاد بگیرند و آن‌ها را در کل تصویر اعمال کنند. این استراتژی اغلب منجر به کاهش زمان محاسبات و افزایش عملکرد سیستم نیز می‌شود [۲۱].

از آنجایی که DCNN‌ها در اکثر رویکردهای یادگیری عمیق عملکرد خوبی داشته‌اند، انتظار داریم که در تشخیص BC نیز عملکرد موفقیت‌آمیزی داشته باشد. با این وجود، فرآیند آموزش در تکنیک‌های قبلی DCNN، حداقل در مراحل اولیه بسیار زمان‌بر است [۲۶]. این امر نشان می‌دهد که حتی اگر طبقه‌بندی-کننده در سناریوی داده شده به خوبی عمل کند، ممکن است چند ساعت طول بکشد تا فرآیند آموزش و آزمایش کامل شود، تا کاربر بتواند از مرحله آموزش بازخورد دریافت کند [۲۷].

اخیراً برای رفع این چالش، در [۷] و [۲۸] از تکنیک ELM برای کاهش زمان محاسبات آموزش و آزمایش در معماری شبکه استفاده شده است که نتایج بدست آمده عملکرد موفقیت‌آمیز این روش را نشان می‌دهد. در حال حاضر، با توجه به کاربردهای طبقه‌بندی و تشخیص تصویر، انواع مختلفی از ELM‌ها در

چهره، شناسایی الگو، تشخیص صدا و تقسیم‌بندی تصاویر داشته و در مقایسه با تکنیک‌های یادگیری ماشین کلاسیک، به مداخلات انسانی کمتری برای استخراج ویژگی‌های مشابه نیاز دارد [۱۹]. علاوه بر این، از این تکنیک‌ها می‌توان برای یادگیری مناسب‌ترین ویژگی‌ها و یافتن الگوها در داده‌های پردازش نشده نیز استفاده کرد [۱۸].

در میان رویکردهای مختلف DL، روش CNN محبوب‌ترین تکنیک است که در چندین مطالعه از آن برای تشخیص سرطان سینه استفاده شده است. برخی از CNN‌های مورد استفاده از روش‌های مبتنی بر یادگیری انتقال<sup>۱</sup> (TL) که شامل شبکه‌های عصبی آموزش‌دیده قبلی مانند AlexNet، ResNet و VGG است، در تشخیص سرطان سینه استفاده کرده‌اند [۱۸]. همچنین، تحقیقات انجام شده نشان می‌دهد که تکنیک DCNN می‌تواند برای شناسایی و استخراج خودکار اطلاعات از تصاویر ماموگرافی و تخمین احتمال ابتلا به سرطان استفاده شود [۲۰]. DCNN‌ها معمولاً الگوریتم‌های پردازش داده دوبعدی<sup>۲</sup> با چندین کانال هستند که در معماری آنها، پیچیدگی شبکه با جایگزینی ضرب ماتریس با کانولوشن کاهش یافته است. برخلاف فرآیندهای معمول یادگیری، که نیازمند یادگیری مجموعه‌ای از پارامترهای جدید برای هر مکان است، DCNN‌ها فقط باید یک مجموعه از پارامترها را یاد بگیرند و آن‌ها را در کل تصویر اعمال کنند. این استراتژی اغلب منجر به کاهش زمان محاسبات و افزایش عملکرد سیستم نیز می‌شود [۲۱].

دقت طبقه‌بندی<sup>۳</sup> نیز یکی از مهم‌ترین عواملی است که باید در نظر گرفته شود. محققان راه‌های مختلفی را برای طبقه‌بندی توده‌های موجود در بافت سینه در تصاویر ماموگرافی پیشنهاد کرده‌اند. در مرجع [۲۲] طبقه‌بندی ماموگرافی به تومورهای

<sup>4</sup> Support Vector Machine

<sup>5</sup> Fully Connected Layer

<sup>6</sup> Contour

<sup>1</sup> Transfer Learning

<sup>2</sup> Dimensional

<sup>3</sup> Classifier

با توجه به گستردگی پایگاه داده و در دسترس بودن برچسب<sup>۸</sup>، DDSM ابزاری مؤثر برای ایجاد و ارزیابی سیستم‌های پشتیبانی تصمیم‌گیری<sup>۹</sup> است. پایگاه داده CBIS-DDSM یک زیرمجموعه با دقت انتخاب شده از داده‌های DDSM است که توسط متخصصان ماموگرافی تهیه شده است. این مجموعه شامل ۱۰۲۳۹ تصویر کوچک شده در فرمت استاندارد DICOM است که از طریق آدرس اینترنتی<sup>۱۰</sup> ارائه شده در پاورقی در دسترس می‌باشد.

### ۲.۳. پایگاه داده IDC

این پایگاه داده شامل ۱۶۲ تصویر اسلاید کامل از نمونه‌های هیستوپاتولوژی سرطان سینه است که در وضوح ۴۰ برابر اسکن شده‌اند. از این مجموعه تصاویر تعداد ۲۷۷۵۲۴ تصویر کوچک<sup>۱۱</sup> با اندازه ۵۰×۵۰ استخراج شده است که تعداد ۱۹۸۷۳۸ تصویر مربوط به موارد طبیعی و تعداد ۷۸۷۸۶ تصویر مربوط به موارد سرطانی می‌باشد. این پایگاه داده از طریق آدرس اینترنتی<sup>۱۲</sup> ارائه شده در پاورقی در دسترس می‌باشد.

### ۳.۳. پیش پردازش

در صورت استفاده از تکنیک‌های CAD، با استفاده از پیش-پردازش ماموگرافی، امکان تشخیص ناهنجاری‌هایی که قابل مشاهده یا قابل احساس نیستند، فراهم می‌شود [۲۸]. تصاویر ماموگرام معمولاً دارای نویز و مصنوعات رادیولوژی است. در شکل (۱) انواع مختلفی از نویز که ممکن است به طور بالقوه در تصویر ماموگرافی وجود داشته باشد نشان داده شده است. بدین منظور ابتدا در فاز پیش‌پردازش، نویز، برچسب‌های رادیولوژی،

دسترس هستند. با این وجود، این نوع شبکه‌ها با مسائل مهمی مانند انتخاب نوع تابع فعال‌ساز<sup>۱</sup> و تعداد زیاد گره پنهان<sup>۲</sup> برای دسترسی به تعمیم بهبودیافته، مواجه هستند. همچنین در پردازش تصاویر با ابعاد بالا، به دلیل ماهیت تصادفی ELM چالش‌های بیشتری وجود دارد. شبکه‌های ELM یک انتخاب تصادفی هم برای بایاس‌های پنهان<sup>۳</sup> و هم برای وزن‌های ورودی<sup>۴</sup> که در تولید وزن‌های خروجی به کار می‌روند، انجام می‌دهند. با این فرآیند و جستجوی حداقل وزن‌های خروجی، میزان خطای آموزشی به حداقل می‌رسد. با توجه به انتخاب تصادفی وزن‌های ورودی و بایاس، ماتریس خروجی ELM ممکن است نتواند به طور دقیق رتبه<sup>۵</sup> کامل ستون را منعکس کند و در نتیجه راه‌حل‌های غیربهبوده توسط ماتریس‌های نامطلوب ایجاد می‌شوند [۲۸]. بنابراین، برای پیشگیری از این مشکل و بهبود شرطی‌سازی و افزایش قابلیت‌های تعمیم ELM و همچنین تضمین نتایج بهینه، در [۷] و [۲۸] از الگوریتم‌های بهینه‌سازی هوشمند استفاده شده است.

### ۳. پایگاه داده و پیش پردازش

در این مقاله، از پایگاه داده دیجیتال غربالگری ماموگرافی با زیرمجموعه تصاویر سینه انتخاب شده<sup>۶</sup> (CBIS-DDSM) [۲۹] و همچنین پایگاه داده هیستوپاتولوژی مجرای تهاجمی سرطان (IDC) [۳۰] استفاده شده است.

### ۱.۳. پایگاه داده CBIS-DDSM

پایگاه داده DDSM اصلی شامل ۲۶۲۰ مطالعه موردی از مجموعه تصاویر ماموگرافی دیجیتالی است که شامل موارد طبیعی، خوش‌خیم و بدخیم و اطلاعات مربوط به آسیب‌شناسی می‌باشد.

<sup>8</sup> Ground Truth

<sup>9</sup> Decision Support Systems

<sup>10</sup> <https://wiki.cancerimagingarchive.net/display/Public/CBIS-DDSM>

<sup>11</sup> Patch

<sup>12</sup> <https://www.kaggle.com/datasets/paultimothymooney/breast-histopathology-images>

<sup>1</sup> Activation Function

<sup>2</sup> Hidden Node

<sup>3</sup> Hidden Biases

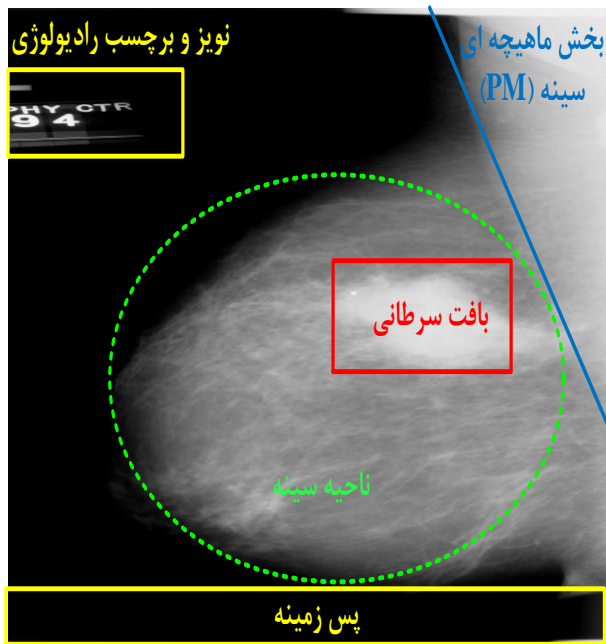
<sup>4</sup> Input Weights

<sup>5</sup> Rank

<sup>6</sup> Curated Breast Imaging Subset-Digital Database Screening Mammography

<sup>7</sup> Invasive Ductal Carcinoma

بهبود کیفیت تصاویر. شکل (۳) مراحل مختلف پیش-پردازش را نشان می‌دهد.



شکل (۱): بخش‌های مختلف تصویر ماموگرافی

#### ۴. طرح پیشنهادی

ما در این مقاله روشی جدید با دقت بالا جهت شناسایی بلادرنگ سرطان سینه، با استفاده از ترکیب روش‌های یادگیری عمیق و هوش ازدحامی پیشنهاد کردیم. روش ارائه شده شامل استفاده از شبکه عمیق اصلاح شده ZFNet است که برای جلوگیری از استخراج ویژگی‌های ناکارآمد و زمان زیاد آموزش و تست، در ساختار شبکه ZFNet به جای لایه تمام متصل، از ELM به عنوان طبقه‌بند و یک روش آموزش، استفاده شده است. در ادامه به منظور برطرف کردن عدم قطعیت و افزایش دقت، از الگوریتم بهینه‌سازی COA برای تنظیم وزن‌ها و بایاس‌های لایه ورودی ELM استفاده شده است.

#### ۱.۴. شبکه ZFNet

در سال ۲۰۱۳ محققان با بهینه‌سازی پارامترهای شبکه عصبی AlexNet، تکنیکی را برای تجسم ویژگی‌های استخراج شده در هر لایه CNN ایجاد کردند. این تغییرات، ویژگی‌های متنوع و

خطوط افقی و عمودی، رگ‌های خونی و بافت‌های ماهیچه‌ای حذف شده و سپس تصویر ماموگرام بهبود می‌یابد. مراحل پیش‌پردازش در ادامه توضیح داده شده است. در روش پیشنهادی، طی سه مرحله کلیدی که در شکل (۲) نشان داده شده است، هرگونه نویز ناخواسته و غیرضروری از تصاویر ماموگرافی حذف، کیفیت تصاویر افزایش یافته و تصاویر برای آموزش شبکه عمیق آماده می‌شود. این سه مرحله شامل:

۱- حذف خطوط سیاه-سفید افقی و عمودی: با استفاده از روش تشخیص خطوط هاف<sup>۱</sup> [۳۱] خطوط افقی و عمودی سیاه رنگ و یا سفید رنگ در صورت وجود شناسایی و سپس حذف می‌شوند.

۲- حذف مصنوعات و نویزهای پس‌زمینه: در ابتدا تصویر را با آستانه<sup>۲</sup> مشخص باینری می‌کنیم. مقدار آستانه به روش آزمون و خطا برابر مقدار 0.02 تعیین شد. سپس کانتورهای<sup>۳</sup> تصویر باینری را مشخص کرده و ماسک بزرگترین کانتور را به عنوان بافت سینه در نظر می‌گیریم. با این کار پس‌زمینه و برجسب‌های رادیولوژی حذف می‌شوند.

۳- حذف بخش ماهیچه‌ای سینه<sup>۴</sup> (PMR): در این مرحله با استفاده از تکنیک نقشه توپوگرافی و سیلوئت تغییر شکل<sup>۵</sup> بافت ماهیچه‌ای سینه را حذف می‌کنیم. این تکنیک به صورت کامل در مرجع [۳۲] توضیح داده شده است.

۴- بهبود کیفیت تصاویر: برای این منظور سه روش بهبود کیفیت تصاویر را اعمال کردیم تا نتایج آنها را با یکدیگر مقایسه کنیم: اعمال فیلتر CLAHE، استفاده از الگوریتم Primal-Dual [۳۳] و اعمال روش تصحیح گاماً جهت

<sup>1</sup> Hough Line Detection

<sup>2</sup> Threshold

<sup>3</sup> Contours

<sup>4</sup> Pectoral Muscle Removal


<sup>5</sup> Topographic Map And Shape-Shifting Silhouette

<sup>6</sup> Gamma Correction




تمایزتری با معماری جدید ZFNet ایجاد کرد که باعث بهبود  
دقت و عملکرد در شبکه‌های CNN شد [۳۴].

پذیرفته شده در مجله محاسبات نرم



شکل (۲): مراحل اصلی در فرآیند پیش پردازش



شکل (۳): نتایج روش پیش پردازش پیشنهاد

در واقع ZFNet یک پیشرفت نسبت به AlexNet بود که نشان داد هر لایه AlexNet چگونه عمل می‌کند و چه پارامترهایی را می‌توان برای دستیابی به دقت بیشتر تنظیم کرد. به منظور بهبود، در شبکه ZFNet تنها از فیلتر  $7 \times 7$  در لایه اول و  $3 \times 3$  در لایه‌های آخر استفاده شده است. اندازه گام نیز از ۴ به ۲ تغییر یافته است. همچنین AlexNet از نرمال‌سازی پاسخ محلی استفاده می‌کند، در حالی که در ZFNet از نرمال‌سازی کنتراست محلی استفاده شده است [۳۴]. بنابراین در این مقاله از کلیات معماری شبکه ZFNet آموزش دیده شده، به همراه برخی اطلاعات مورد نیاز برای استخراج ویژگی‌های تصویربرداری از تصاویر ماموگرافی سینه استفاده می‌کنیم [۳۴].

#### ۲.۴. شبکه EZFNet

همان‌طور که در مقاله [۲۵] نشان داده شده است؛ چنانچه در معماری شبکه عمیق از لایه‌های کانولوشنی با مقیاس‌های بزرگ (۵، ۷، ۹، ۱۱ و...) استفاده شود، میدان دریافتی لایه افزایش یافته و علاوه بر افزایش بار محاسباتی، باعث می‌شود که مدل، برخی از اطلاعات مکانی و جزئیات دقیق را از دست بدهد و برای کاربردهایی نظیر تشخیص سرطان سینه که نیاز به تمام جزئیات تصویر است، مناسب نباشد. این مقاله برتری استفاده از دو فیلتر کوچک به جای یک فیلتر بزرگ را نشان داده است. همچنین در مقاله [۳۵] نیز ثابت شده است، چنانچه در معماری شبکه عمیق از لایه‌های کانولوشنی با مقیاس‌های مختلف استفاده شود و اطلاعات لایه‌های کانولوشنی مختلف به جای ضرب<sup>۱</sup> در یکدیگر با هم الحاق<sup>۲</sup> شوند، ویژگی‌های تصاویر ورودی شبکه به نحو مناسب‌تری استخراج می‌شوند. همچنین این ویژگی‌ها به علت استفاده از فیلترهای دارای سایزهای مختلف، دارای خاصیت چندمقیاسی<sup>۳</sup> هستند که در نتیجه باعث بهبود دقت نهایی شبکه می‌شود.

بنابراین ما در معماری مدل شبکه پیشنهادی از این رویکردها استفاده کرده و شبکه ZFNet را مطابق زیر اصلاح کردیم:

- لایه کانولوشنی با اندازه فیلتر  $7 \times 7$  با دو لایه کانولوشنی با اندازه فیلتر  $5 \times 5$  و  $3 \times 3$  که خروجی‌های آنها با یکدیگر الحاق شده‌اند جایگزین گردید.
- لایه کانولوشنی با اندازه فیلتر  $5 \times 5$  با دو لایه کانولوشنی با اندازه فیلتر  $3 \times 3$  و  $1 \times 1$  که خروجی‌های آنها با یکدیگر الحاق شده‌اند جایگزین گردید.
- لایه‌های کانولوشنی با اندازه فیلتر  $3 \times 3$  با دو لایه کانولوشنی با اندازه فیلتر  $3 \times 3$  و  $1 \times 1$  که خروجی‌های آنها با یکدیگر الحاق شده‌اند جایگزین گردید.

معماری شبکه اصلاح شده پیشنهادی در شکل (۴) نشان داده شده است. در روش پیشنهادی به دلیل استفاده از ELM، از شبکه کانولوشنی از قبل آموزش دیده استفاده می‌کنیم. اما بدلیل جایگزین کردن فیلترهای شبکه ZFNet امکان فرایند transfer learning در شبکه EZFNet وجود ندارد و باید شبکه یکبار با تعداد تکرار کم (۱۰ تکرار) آموزش ببیند تا وزن‌ها و بایاس‌های شبکه در محدوده مناسب قرار بگیرند و سپس از این شبکه پیش آموزش دیده شده در روش پیشنهادی استفاده گردد.

#### ۳.۴. ماشین یادگیری بی‌نهایت (ELM)

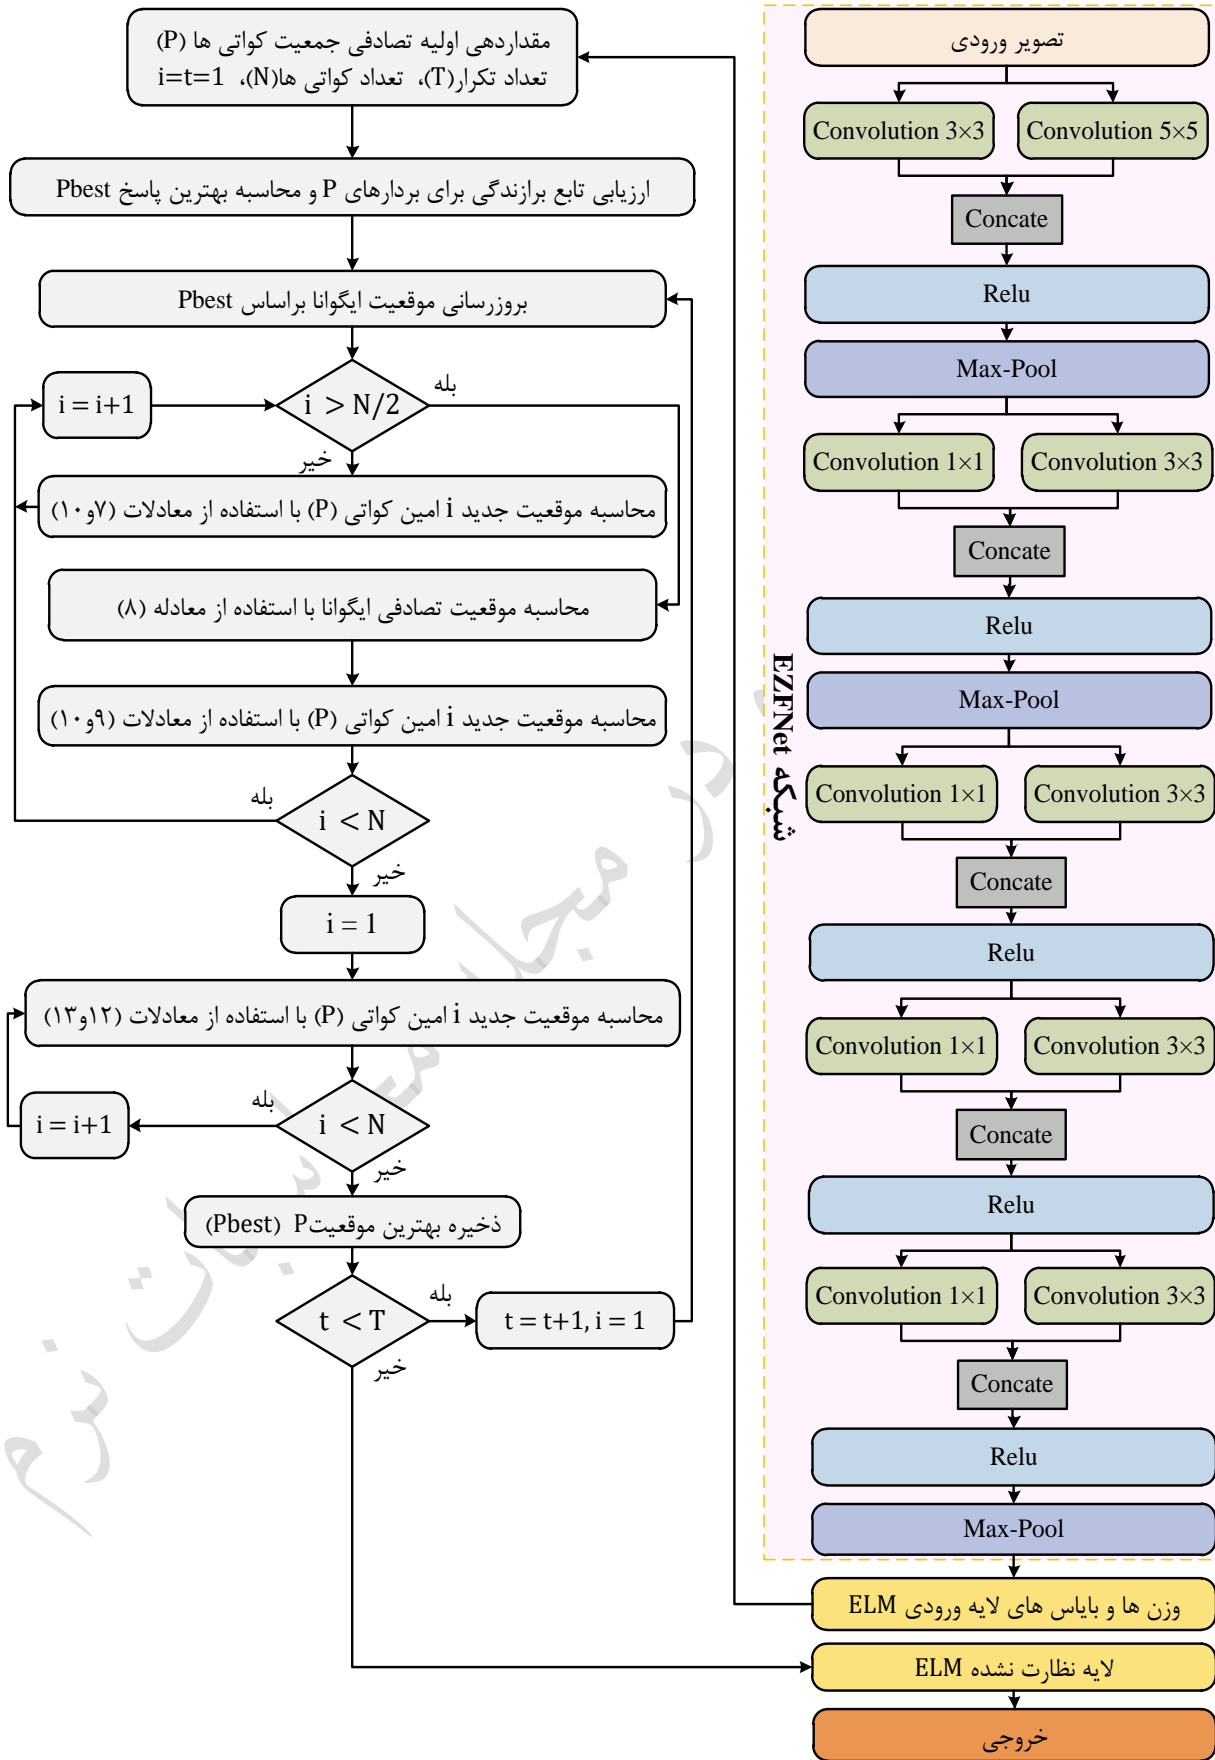
در اغلب کاربردهای یادگیری ماشین از شبکه‌های عصبی با یک لایه مخفی<sup>۴</sup> مانند ELM به طور گسترده استفاده می‌شود. در این شبکه‌ها، ابتدا وزن‌ها و بایاس‌های لایه ورودی به صورت تصادفی ایجاد شده و سپس، وزن‌ها و بایاس‌های لایه خروجی براساس مقادیر لایه ورودی، محاسبه می‌شوند. در شبکه‌های عصبی با ساختار ساده، عملکرد شبکه ضعیف‌تر و سرعت یادگیری نیز پایین است [۳۶].

<sup>1</sup> Multiple

<sup>2</sup> Concat

<sup>3</sup> Multi scale

<sup>4</sup> Hidden Layer



شکل (۴): بلوک دیاگرام EZFNNet-COA-ELM

شده است. از مزایای الگوریتم COA می‌توان به عدم وجود پارامتر کنترلی، همگرایی سریع و عملکرد مؤثر و قدرتمند این الگوریتم در مدیریت انواع مسائل بهینه‌سازی پیچیده با ابعاد بالا در دنیای واقعی اشاره کرد [۱۴]. معادلات (۷) تا (۱۰) شبیه‌سازی این الگوریتم را به صورت ریاضی نشان می‌دهند.

$$X_i^{P1}: x_{i,j}^{P1} = x_{i,j} + r.(Iguana_j - I.x_{i,j}), \quad (7)$$

for  $i = 1, 2, \dots, \lfloor \frac{N}{2} \rfloor$  and  $j = 1, 2, \dots, m$ .

$$Iguana^G: Iguana_j^G = lb_j + r.(ub_j - lb_j), \quad (8)$$

$j = 1, 2, \dots, m$ .

$$X_i^{P1}: x_{i,j}^{P1} = \begin{cases} x_{i,j} + r.(Iguana_j^G - I.x_{i,j}), & F_{Iguana^G} < F_i, \\ x_{i,j} + r.(x_{i,j} - Iguana_j^G), & else, \end{cases} \quad (9)$$

for  $i = \lfloor \frac{N}{2} \rfloor + 1, \lfloor \frac{N}{2} \rfloor + 2, \dots, N$  and  $j = 1, 2, \dots, m$ .

$$X_i = \begin{cases} X_i^{P1}, & F_i^{P1} < F_i, \\ X_i, & else. \end{cases} \quad (10)$$

for  $i = 1, 2, \dots, N$ .

که در آن،  $X_i^{P1}$  موقعیت جدید  $i$  امین کواتی در فضای جستجو است،  $x_{i,j}^{P1}$  بعد  $j$  امین آن،  $F_i^{P1}$  مقدار تابع هدف<sup>۴</sup> آن،  $r$  مقداری تصادفی بین  $[0,1]$ ،  $Iguana$  نشان‌دهنده موقعیت ایگوانا (موقعیت بهترین عضو) در فضای جستجو،  $Iguana_j$  بعد  $j$  امین آن،  $I$  عدد صحیح تصادفی با مقدار 1 یا 2 است. همچنین،  $Iguana^G$  موقعیت تصادفی ایگوانا روی زمین،  $Iguana_j^G$  بعد  $j$  امین آن و  $F_{Iguana^G}$  مقدار تابع هدف آن می‌باشد. علامت  $[.]$  نیز نماد تابع جزء صحیح است [۱۴]. فرآیند به‌روزرسانی موقعیت کواتی‌ها در فضای جستجو به صورت ریاضی توسط رابطه‌های (۱۱) تا (۱۳) مدل‌سازی شده است.

$$lb_j^{local} = \frac{lb_j}{t}, ub_j^{local} = \frac{ub_j}{t} \quad t = 1, 2, \dots, T \quad (11)$$

$$X_i^{P2}: x_{i,j}^{P2} = x_{i,j} + (1 - 2r). (lb_j^{local} + r.(ub_j^{local} - lb_j^{local})), \quad (12)$$

for  $i = 1, 2, \dots, N$ ,  $j = 1, 2, \dots, m$ .

$$X_i = \begin{cases} X_i^{P2}, & F_i^{P2} < F_i, \\ X_i, & else. \end{cases} \quad (13)$$

اگر مقدار نورون‌ها در لایه ورودی با  $n$  و تعداد نورون‌های لایه پنهان و لایه خروجی به ترتیب با  $L$  و  $m$  نشان داده شوند، تابع فعال‌ساز<sup>۱</sup> توسط معادله (۱) بدست می‌آید:

$$Z_j = \sum_{i=1}^L Q_i f(w_i \cdot b_i \cdot x_i) \quad (1)$$

که در آن،  $w_i$  وزن اتصال ورودی،  $b_i$  بایاس  $i$  امین نورون پنهان،  $x_i$  وزن اتصال خروجی و  $Z_j$  خروجی نهایی ELM است. معادله (۲) شکل ماتریسی معادله (۱) را نشان می‌دهد.

$$Z^T = HQ \quad (2)$$

که در آن، ماتریس  $Z^T$  ترانزپوز ماتریس  $Z$  است و  $H$  و  $Q$  به صورت معادلات (۳) و (۴) توصیف می‌شوند:

$$H = \begin{bmatrix} f(w_1 \cdot b_1 \cdot x_1) & \dots & f(w_L \cdot b_L \cdot x_1) \\ \vdots & \ddots & \vdots \\ f(w_1 \cdot b_1 \cdot x_\gamma) & \dots & f(w_L \cdot b_L \cdot x_\gamma) \end{bmatrix}_{\gamma \times L} \quad (3)$$

$$Q = [Q_1, Q_2, \dots, Q_L]^T \quad (4)$$

هدف اصلی از آموزش ELM کاهش مقدار خطاهایی است که در طول آموزش ایجاد می‌شود. در ELM کلاسیک، بایاس‌ها و وزن‌های ورودی به‌طور تصادفی انتخاب می‌شوند و تابع فعال‌ساز باید قادر به تفکیک بی‌نهایت باشد. در این روش، ELM برای تولید وزن خروجی ( $Q$ ) با بهینه‌کردن مقدار تابع حداقل مربعات در معادله (۵) آموزش داده شده و نتیجه با استفاده از معادله (۶) بدست می‌آید.

$$\min_Q \|HQ - Z^T\| \quad (5)$$

$$\hat{Q} = H^+ Z^T \quad (6)$$

که در آن،  $H^+$  ماتریس معکوس مور-پنروز<sup>۳</sup> تعمیم‌یافته ماتریس  $H$  است [۳۶].

#### ۴.۴. الگوریتم بهینه‌سازی COA

الگوریتم بهینه‌سازی کواتی در واقع یک الگوریتم فراابتکاری مبتنی بر جمعیت است که برای حل مسائل بهینه‌سازی پیاده‌سازی

<sup>1</sup> Activation Function

<sup>2</sup> Transpose

<sup>3</sup> Moore-Penrose

<sup>4</sup> Objective Function

|     |   |
|-----|---|
| ۱.  | ورود و تنظیم پارامترهای مسئله بهینه سازی  |
| ۲.  | تنظیم تعداد تکرار (T) و تعداد کوتاهی ها (N)   |
| ۳.  | مقداردهی اولیه موقعیت‌های همه کوتاهی‌ها و ارزیابی تابع برازندگی برای این جمعیت اولیه. |
| ۴.  | <b>شروع حلقه: برای <math>T=1</math>: انجام بده:</b>                                   |
| ۵.  | موقعیت ایگوانا را بر اساس مکان بهترین عضو جمعیت به روز کنید                           |
| ۶.  | # فاز ۱: استراتژی شکار و حمله به ایگوانا (فاز اکتشاف)                                 |
| ۷.  | <b>شروع حلقه: برای <math>i=1</math> تا <math>[N/2]</math>: انجام بده:</b>             |
| ۸.  | محاسبه موقعیت جدید $i$ امین کوتاهی با استفاده از معادله (۷)                           |
| ۹.  | بروزرسانی موقعیت جدید $i$ امین کوتاهی با استفاده از معادله (۱۰)                       |
| ۱۰. | <b>پایان حلقه</b>   |
| ۱۱. | <b>شروع حلقه: برای <math>i=1</math> تا <math>N</math>: انجام بده:</b>                 |
| ۱۲. | محاسبه موقعیت تصادفی ایگوانا با استفاده از معادله (۸)                                 |
| ۱۳. | محاسبه موقعیت جدید $i$ امین کوتاهی با استفاده از معادله (۹)                           |
| ۱۴. | بروزرسانی موقعیت جدید $i$ امین کوتاهی با استفاده از معادله (۱۰)                       |
| ۱۵. | <b>پایان حلقه</b>   |
| ۱۶. | # فاز ۲: فرآیند فرار از دست شکارچیان (فاز بهره برداری)                                |
| ۱۷. | محاسبه مرزهای محلی متغیرها با استفاده از معادله (۱۱)                                  |
| ۱۸. | <b>شروع حلقه: برای <math>i=1</math> تا <math>N</math>: انجام بده:</b>                 |
| ۱۹. | محاسبه موقعیت جدید $i$ امین کوتاهی با استفاده از معادله (۱۲)                          |
| ۲۰. | بروزرسانی موقعیت جدید $i$ امین کوتاهی با استفاده از معادله (۱۳)                       |
| ۲۱. | <b>پایان حلقه</b>   |
| ۲۲. | ذخیره موقعیت و برازندگی بهترین پاسخی که تاکنون پیدا شده است                           |
| ۲۳. | <b>پایان حلقه</b>   |
| ۲۴. | استفاده از بهترین راه حل به دست آمده توسط COA برای مسئله بهینه سازی                   |

که در آن،  $X_i^{P2}$  موقعیت جدید محاسبه شده برای  $i$  امین کوتاهی بر اساس مرحله دوم COA،  $X_{i,j}^{P2}$  بعد از  $j$  امین آن، مقدار تابع هدف آن،  $r$  مقداری تصادفی بین  $[0,1]$ ،  $t$  شمارنده تکرار و  $lb_j^{local}$  و  $ub_j^{local}$  به ترتیب کران پایین<sup>۱</sup> محلی و کران بالای<sup>۲</sup> محلی متغیر تصمیم<sup>۳</sup>  $z$  ام هستند. همچنین  $lb_j$  و  $ub_j$  نیز به ترتیب کران پایین و کران بالای  $z$  امین متغیر تصمیم می‌باشند. در الگوریتم ۱، شبه‌کد COA توضیح داده شده است [۱۴].

#### ۵.۴. ELM بهبود یافته با الگوریتم COA

استفاده از ELM به جای آخرین لایه متصل در ساختار شبکه، باعث کاهش زمان پردازش می‌شود. در هنگام استفاده از ELM به دلیل وجود سطحی از عدم قطعیت در مدل نهایی، بایاس‌ها و وزن‌های لایه ورودی به‌طور تصادفی تنظیم می‌شوند که این یک اشکال اساسی است. برای رفع این مشکل، در مرحله بعد از الگوریتم COA به عنوان یک تثبیت‌کننده سیستم، جهت افزایش انعطاف‌پذیری شبکه و همچنین حفظ پردازش بلادرنگ استفاده می‌کنیم. این روش با تنظیم وزن‌ها و بایاس‌های لایه ورودی، از واگرایی شبکه جلوگیری کرده و سعی در نزدیک کردن خروجی شبکه به ورودی آن دارد.

<sup>1</sup> Lower Bound

<sup>2</sup> Upper Bound

<sup>3</sup> Decision Variable

ارزیابی شامل: دقت<sup>۴</sup>، صحت<sup>۵</sup>، تشخیص‌پذیری<sup>۶</sup>، حساسیت<sup>۷</sup>، معیار MCC و F1-score مطابق با معادلات (۱۶) تا (۲۱) استفاده کردیم [۷].

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (۱۶)$$

$$Precision = \frac{TP}{TP + FP} \quad (۱۷)$$

$$Specificity = \frac{TN}{FP + TN} \quad (۱۸)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (۱۹)$$

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(FP + TP) \times (FP + TN) \times (FN + TP) \times (FN + TN)}} \quad (۲۰)$$

$$F1 - Score = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \quad (۲۱)$$

که در آن، TP، FN، TN و FP به ترتیب مخفف مثبت صحیح<sup>۸</sup>، مثبت کاذب<sup>۹</sup>، منفی صحیح<sup>۱۰</sup> و منفی کاذب<sup>۱۱</sup> هستند. همچنین TP و TN دو معیار مثبت هستند که به ترتیب تعداد موارد مثبت و منفی واقعی را نشان می‌دهند (تعداد نمونه‌هایی که سیستم آنها را درست تشخیص داده است). FN و FP نیز معیارهای منفی هستند که به ترتیب موارد مثبت و منفی کاذب را نشان می‌دهند (تعداد نمونه‌هایی که سیستم آنها را اشتباه تشخیص داده است) [۳].

## ۲.۵. تنظیم پارامترها

به منظور ارزیابی عملکرد الگوریتم بهینه‌سازی COA بر روی روش پیشنهادی، معیارهای ارزیابی بر روی چهار الگوریتم جدید شامل: الگوریتم بهینه‌سازی شامپانزه<sup>۱۲</sup> (ChOA) [۳۷]،

$$P = [W_{11}, W_{12}, \dots, W_{nT}, b_1, b_2, \dots, b_T] \quad (۱۴)$$

که در آن،  $W_{ij}$  وزن بین گره ورودی  $i$  امین ELM و ورودی  $i$  از آخرین لایه ادغام ZFNet و  $b_j$  نشان‌دهنده بایاس‌های نورون  $j$  ام است. این بردار در ابتدای الگوریتم مقداردهی اولیه می‌شود و سپس با هدف کمینه شدن خطای طبقه‌بندی به عنوان تابع برازندگی، با استفاده از الگوریتم تکاملی بروز می‌شود.

الگوریتم COA نیز مانند تمامی الگوریتم‌های فراابتکاری، برای ارزیابی عملکرد عوامل جستجوی خود به یک تابع تحت عنوان تابع تناسب<sup>۲</sup> یا تابع هدف نیاز دارد. ما در اینجا به منظور افزایش دقت طبقه‌بندی، میانگین مربعات خطا<sup>۳</sup> (MSE) را به عنوان تابع تناسب در نظر می‌گیریم که به صورت زیر تعریف می‌شود:

$$Cost Function = MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2 \quad (۱۵)$$

که در آن،  $y$  و  $\hat{y}$  به ترتیب خروجی‌های واقعی و تخمینی شبکه و همچنین  $n$  تعداد کل نمونه‌های مورد استفاده برای آموزش را نشان می‌دهند. شکل (۴) بلوک دیاگرام EZFNet-ELM-COA را نشان می‌دهد.

## ۵. نتایج و بحث

سیستم شناسایی پیشنهادی با استفاده از زبان‌های برنامه‌نویسی Python 3.6.8 تحت پلتفرم Google Colab، مجهز به واحد پردازش گرافیکی NVIDIA Tesla T4 16 GB، پردازش مرکزی Intel Xeon (R) 2.20 GHz و ظرفیت حافظه 13 GB RAM تحت سیستم عامل Ubuntu 18.04 پیاده‌سازی شده است.

### ۱.۵. معیارهای ارزیابی

به منظور انجام تحلیل و بررسی عملکرد پروتکل پیشنهادی و مطالعه تطبیقی آن با سایر پروتکل‌های دیگر، از شش معیار

<sup>4</sup> Accuracy

<sup>5</sup> Precision

<sup>6</sup> Specificity

<sup>7</sup> Sensitivity

<sup>8</sup> True Positive

<sup>9</sup> False Positive

<sup>10</sup> True Negative

<sup>11</sup> False Negative

<sup>12</sup> Chimp Optimization Algorithm

<sup>1</sup> Pooling Layer

<sup>2</sup> Fitness

<sup>3</sup> Mean Square Error

است و نتایج عملکرد این دو روش در جدول (۴) مقایسه شده است. با توجه به نتایج، استفاده از دو فیلتر کوچکتر با مقیاس-های مختلف و الحاق خروجی‌های آنها با یکدیگر در شبکه EZFNet، باعث بهبود عملکرد شبکه و افزایش دقت تشخیص نسبت به شبکه ZFNet مرسوم شده است.

جدول (۱): پارامترهای اولیه تکنیک‌های مختلف

| الگوریتم | جمعیت | تکرار | سایر پارامترها   |
|----------|-------|-------|--|
| ChOA     | 30    | 250   | $f, m, c, a, d$ :<br>dynamic parameters  |
| WSO      | 30    | 250   | فاقد پارامتر کنترلی  |
| AVOA     | 30    | 250   | $p_1 = 0.6, p_2 = 0.4,$<br>$p_3 = 0.6, \alpha = 0.8, \beta =$<br>$0.2, \gamma = 2.5$ |
| AHA      | 30    | 250   | فاقد پارامتر کنترلی  |
| COA      | 30    | 250   | فاقد پارامتر کنترلی  |

جدول (۲): پارامترهای آموزش شبکه EZFNet-ELM

| پارامتر                 | مقدار |
|-------------------------|-------|
| تعداد تکرار             | 10    |
| mini-batch size         | 128   |
| نرخ یادگیری             | 1e-4  |
| فاکتور کاهش نرخ یادگیری | 0.2   |
| تعداد گره‌های پنهان ELM | 500   |

#### ۴.۵. ارزیابی نتایج الگوریتم‌های بهینه‌سازی مختلف

نتایج عملکرد الگوریتم‌های بهینه‌سازی WSO، ChOA، COA، AVOA و AHA، بر روی شبکه EZFNet-ELM در تشخیص تصاویر سرطان سینه، در جدول (۵) مقایسه شده است. با توجه به نتایج بدست آمده می‌توان مشاهده کرده که الگوریتم بهینه‌سازی COA نسبت به سایر الگوریتم‌های بهینه‌سازی توانایی بیشتری در تنظیم وزن‌ها و بایاس‌های شبکه ELM از خود نشان داده است و نتایج بهتری بدست آورده است.

بهینه‌ساز کوسه سفید<sup>۱</sup> (WSO) [۳۸]، الگوریتم بهینه‌سازی کرکس‌های آفریقایی<sup>۲</sup> (AVOA) [۳۹] و الگوریتم مرغ مگس‌خوار مصنوعی<sup>۳</sup> (AHA) [۴۰] نیز بررسی می‌شود. پارامترها و مقادیر اولیه مورد استفاده در روش پیشنهادی و سایر الگوریتم‌های بهینه‌سازی مورد مقایسه در جدول (۱) و پارامترهای مربوط به آموزش شبکه EZFNet-ELM نیز در جدول (۲) آورده شده است.

#### ۳.۵. بررسی انواع فیلترهای بهبود کیفیت تصاویر در مرحله پیش‌پردازش

در این بخش نتایج اعمال فیلترهای مختلف بهبود کیفیت تصاویر شامل: فیلترهای تصحیح گاما، Primal-Dual و CLAHE در مرحله پیش‌پردازش، بر روی پایگاه داده تصاویر ماموگرافی CBIS-DDSM بررسی شده است. قابل ذکر است که تصاویر هیستوپاتولوژی پایگاه داده IDC نیازی به مرحله پیش‌پردازش ندارند و در نتایج این بخش آورده نشده‌اند. با توجه به جدول (۳)، استفاده از فیلترها به طور کلی باعث بهبود کیفیت تصاویر و در نتیجه افزایش دقت تشخیص صحیح شده است. همچنین در بین این فیلترها، فیلتر CLAHE نتایج بهتری را در تمام معیارهای ارزیابی بدست آورده است. بنابراین ما در آخرین مرحله پیش‌پردازش از فیلتر CLAHE به عنوان بهبود دهنده کیفیت تصاویر استفاده می‌کنیم و نتایج ارزیابی بخش‌های بعدی بر مبنای این فیلتر گزارش شده است.

#### ۳.۵. مقایسه شبکه ZFNet با شبکه EZFNet پیشنهادی

فرآیند تشخیص سرطان سینه با استفاده از دو شبکه ZFNet-ELM-COA و EZFNet-ELM-COA پیشنهادی شبیه‌سازی شده

<sup>1</sup> White Shark Optimizer

<sup>2</sup> African Vultures Optimization Algorithm

<sup>3</sup> Artificial Hummingbird Algorithm



توجه به نتایج به دست آمده، مشخص است که مدل پیشنهادی ما نسبت به مدل [۲۸] در معیار Accuracy افزایش ۱/۶۵ درصدی، Precision کاهش ۰/۴۱ درصدی، Sensitivity افزایش ۰/۱۲ درصدی، Specificity افزایش ۲/۶۸ درصدی، F1-score کاهش ۰/۰۷ درصدی و MCC افزایش ۳/۸۴ درصدی را بدست آورده است. همچنین نسبت به مدل [۷] در معیارهای Accuracy افزایش ۱/۰۸ درصدی، Precision کاهش ۱/۰۳ درصدی، Sensitivity افزایش ۰/۲۸ درصدی، Specificity افزایش ۳/۳۰ درصدی، F1-score افزایش ۰/۴۳ درصدی و MCC افزایش ۳/۴۷ درصدی را بدست آورده است و بهترین عملکرد را در پایگاه داده CBIS-DDSM از نظر اکثر معیارهای ارزیابی دارد.

در مدل [۲۸] و [۷] نتایج مقایسه زمانی بیان نشده است، با توجه به این که مدل [۲۸] از شبکه AlexNet در ترکیب با ELM و مدل [۷] از شبکه ZFNet در ترکیب با ELM استفاده می کند و الگوریتم بهینه سازی هر دو مدل ChOA می باشد، طبق جدول (۶) روش پیشنهادی ما از نظر سرعت آموزش و تست نیز نسبت به دو روش دیگر بهترین عملکرد را دارد.

#### ۸,۵. محدودیت های سیستم

با وجود برتری های مدل پیشنهادی و قابلیت استفاده در سایر کاربردهای یادگیری ماشین، این سیستم در موارد زیر ممکن است عملکرد کمتری داشته باشد:

- در صورتی که تعداد کلاس های خروجی خیلی زیاد باشد ممکن است ELM نتواند به خوبی کلاس ها را از یکدیگر تفکیک کند
- در مواردی که تعداد نرون های شبکه ELM خیلی زیاد باشد ممکن است الگوریتم COA نتواند به خوبی همگرا شود و یا برای همگرایی به زمان زیادی نیاز داشته باشد که در این موارد باید الگوریتم COA بر روی GPU اجرا شود که در سرعت اجرای آن زیاد شود.

یک معیار مقایسه مهم در الگوریتم های مبتنی بر جمعیت، سرعت همگرایی الگوریتم است که بررسی آن در سیستم های بلادرنگ بسیار ضروری است. با مقایسه مدل پیشنهادی EZFNet-ELM- COA با چهار الگوریتم دیگر در شکل (۵) می توان نتیجه گرفت که الگوریتم COA نسبت به سایر الگوریتم های بهینه سازی دیگر، از سرعت همگرایی بالاتر و مقدار بهینه عمومی مطلوب تری برخوردار است و می تواند به طور قابل توجهی موفق تر از سایر الگوریتم های بهینه سازی در بروزرسانی وزن ها و بایاس های شبکه عمل کند. شکل (۶) چند نمونه از تصاویر خروجی شبکه پیشنهادی به همراه برچسب آنها را در دو پایگاه داده CBIS-DDSM و IDC نشان می دهد.

#### ۶,۵. مقایسه زمانی روش های مختلف تشخیص سرطان سینه بلادرنگ

جدول (۶) نتایج مقایسه زمانی روش های مختلف تشخیص بلادرنگ سرطان سینه را براساس معیار ارزیابی دقت نشان می دهد. از مقایسه الگوریتم های آموزشی SGD و Adam می توان نتیجه گرفت که الگوریتم Adam دقت و سرعت بهتری در آموزش شبکه دارد، لذا برای مقایسه زمانی روش های مختلف از این الگوریتم استفاده شده است. استفاده از لایه ELM به جای لایه FC و تنظیم وزن های و بایاس های لایه ELM با استفاده از الگوریتم COA در پایگاه داده CBIS-DDSM، باعث افزایش دقت و کاهش قابل توجه سرعت آموزش و تست شبکه شده است. در پایگاه داده IDC این روش تاثیری در افزایش دقت نداشته اما باعث کاهش قابل توجه سرعت آموزش و تست شبکه شده است.

#### ۷,۵. مقایسه نتایج روش های مختلف تشخیص سرطان سینه بلادرنگ

جدول (۷) مقایسه نتایج روش های مختلف تشخیص بلادرنگ سرطان سینه را براساس شش معیار ارزیابی نشان می دهد. با

جدول (۳): نتایج اعمال فیلترهای مختلف بهبود کیفیت تصاویر بر روی پایگاه داده CBIS-DDSM در روش EZFNet-ELM-COA


| معیار           | فیلتر      |                  |             |              |
|-----------------|------------|------------------|-------------|--------------|
|                 | بدون فیلتر | Gamma Correction | Primal-Dual | CLAHE        |
| Accuracy (%)    | 93.68      | 95.48            | 95.48       | <b>97.97</b> |
| Precision (%)   | 87.75      | 93.82            | 94.01       | <b>95.70</b> |
| Sensitivity (%) | 90.02      | 90.33            | 90.62       | <b>97.15</b> |
| Specificity (%) | 95.10      | 97.58            | 97.55       | <b>98.28</b> |
| F1 score (%)    | 88.87      | 92.04            | 92.29       | <b>96.42</b> |
| MCC (%)         | 81.49      | 85.57            | 85.71       | <b>93.98</b> |

جدول (۴): نتایج دو شبکه ZFNet-ELM-COA و EZFNet-ELM-COA پیشنهادی در فرآیند تشخیص سرطان سینه

| پایگاه داده CBIS-DDSM |               |                |
|-----------------------|---------------|----------------|
| معیار                 | ZFNet-ELM-COA | EZFNet-ELM-COA |
| Accuracy (%)          | 95.28         | <b>97.97</b>   |
| Precision (%)         | 87.42         | <b>95.70</b>   |
| Sensitivity (%)       | 96.62         | <b>97.15</b>   |
| Specificity (%)       | 94.77         | <b>98.28</b>   |
| F1 score (%)          | 91.79         | <b>96.42</b>   |
| MCC (%)               | 87.69         | <b>93.98</b>   |
| پایگاه داده IDC       |               |                |
| Accuracy (%)          | 95.44         | <b>97.82</b>   |
| Precision (%)         | 87.58         | <b>94.97</b>   |
| Sensitivity (%)       | 97.06         | <b>97.43</b>   |
| Specificity (%)       | 94.84         | <b>97.98</b>   |
| F1 score (%)          | 92.08         | <b>96.18</b>   |
| MCC (%)               | 88.24         | <b>93.76</b>   |


جدول (۵): نتایج عملکرد شبکه EZFNet-ELM با الگوریتم‌های بهینه‌سازی مختلف بر روی دو پایگاه داده تصاویر سرطان سینه

| پایگاه داده CBIS-DDSM |       |       |              |              |              |
|-----------------------|-------|-------|--------------|--------------|--------------|
| معیار                 | AVOA  | WSO   | AHA          | ChOA         | COA          |
| Accuracy (%)          | 96.92 | 96.68 | 96.92        | 97.07        | <b>97.97</b> |
| Precision (%)         | 92.04 | 91.20 | 92.13        | 92.37        | <b>95.70</b> |
| Sensitivity (%)       | 97.41 | 97.43 | 97.26        | <b>97.54</b> | 97.15        |
| Specificity (%)       | 96.73 | 96.39 | 96.79        | 96.89        | <b>98.28</b> |
| F1 score (%)          | 94.65 | 94.21 | 94.62        | 94.88        | <b>96.42</b> |
| MCC (%)               | 91.70 | 91.14 | 91.62        | 92.07        | <b>93.98</b> |
| پایگاه داده IDC       |       |       |              |              |              |
| Accuracy (%)          | 96.65 | 96.72 | 96.84        | 97.23        | <b>97.82</b> |
| Precision (%)         | 91.62 | 91.39 | 91.59        | 92.93        | <b>94.97</b> |
| Sensitivity (%)       | 96.90 | 97.31 | <b>97.55</b> | 97.47        | 97.43        |
| Specificity (%)       | 96.56 | 96.49 | 96.57        | 97.14        | <b>97.98</b> |
| F1 score (%)          | 94.19 | 94.26 | 94.48        | 95.15        | <b>96.18</b> |
| MCC (%)               | 90.88 | 91.17 | 91.55        | 92.40        | <b>93.76</b> |




شکل (۵): منحنی های همگرایی الگوریتم های بهینه سازی مختلف در بروزرسانی وزن های شبکه EZFNet-ELM


Pred: Non-Cancerous, True: Non-Cancerous




Pred: Non-Cancerous, True: Non-Cancerous




Pred: Cancerous, True: Cancerous




Pred: Non-Cancerous, True: Non-Cancerous



Pred: Non-Cancerous, True: Non-Cancerous



Pred: Cancerous, True: Cancerous



شکل (۶): خروجی شبکه و برجسب تصاویر سرطان سینه در دو پایگاه داده DDSM-CBIS و IDC

جدول (۶): مقایسه زمانی روش‌های مختلف تشخیص بلادرنگ سرطان سینه

| پایگاه داده CBIS-DDSM     |                 |                         |                                      |              |
|---------------------------|-----------------|-------------------------|--------------------------------------|--------------|
| شبکه                      | الگوریتم آموزشی | زمان آموزش شبکه (دقیقه) | متوسط زمان تست هر نمونه (میلی ثانیه) | دقت          |
| AlexNet-FC                | SGD             | 533                     | 19                                   | 90.95        |
| ZFNet-FC                  | SGD             | 492                     | 13                                   | 93.00        |
| EZFNet-FC                 | SGD             | 446                     | 11                                   | 95.22        |
| AlexNet-FC                | Adam            | 372                     | 19                                   | 93.09        |
| ZFNet-FC                  | Adam            | 345                     | 13                                   | 95.36        |
| EZFNet-FC                 | Adam            | 312                     | 11                                   | 97.91        |
| EZFNet-ELM-RANDOM         | Adam            | 0.3                     | 2.1                                  | 90.72        |
| EZFNet-ELM-AVOA           | Adam            | 5.5                     | 2.1                                  | 96.92        |
| EZFNet-ELM-WSO            | Adam            | 6.1                     | 2.1                                  | 96.68        |
| EZFNet-ELM-AHA            | Adam            | 5                       | 2.1                                  | 96.92        |
| EZFNet-ELM-ChOA           | Adam            | 7.3                     | 2.1                                  | 97.07        |
| EZFNet-ELM-COA (Proposed) | Adam            | 4.2                     | 2.1                                  | <b>97.97</b> |
| پایگاه داده IDC           |                 |                         |                                      |              |
| شبکه                      | الگوریتم آموزشی | زمان آموزش شبکه (دقیقه) | متوسط زمان تست هر نمونه (میلی ثانیه) | دقت          |
| AlexNet-FC                | SGD             | 788                     | 30                                   | 90.21        |
| ZFNet-FC                  | SGD             | 661                     | 23                                   | 94.84        |
| EZFNet-FC                 | SGD             | 665                     | 19                                   | 94.88        |
| AlexNet-FC                | Adam            | 596                     | 30                                   | 92.11        |
| ZFNet-FC                  | Adam            | 515                     | 23                                   | 95.03        |
| EZFNet-FC                 | Adam            | 498                     | 19                                   | <b>97.82</b> |
| EZFNet-ELM-RANDOM         | Adam            | 0.4                     | 4.6                                  | 91.62        |
| EZFNet-ELM-AVOA           | Adam            | 5.6                     | 4.6                                  | 96.65        |
| EZFNet-ELM-WSO            | Adam            | 7                       | 4.6                                  | 96.72        |
| EZFNet-ELM-AHA            | Adam            | 5                       | 4.6                                  | 96.84        |
| EZFNet-ELM-ChOA           | Adam            | 7.4                     | 4.6                                  | 97.23        |
| EZFNet-ELM-COA (Proposed) | Adam            | 5.1                     | 4.6                                  | <b>97.82</b> |

جدول (۷): مقایسه نتایج روش‌های مختلف تشخیص بلادرنگ سرطان سینه با روش پیشنهادی در پایگاه داده CBIS-DDSM

| معیار           | AlexNet-BN-ELM-CHOA-NEMS[28] | ZFNet-SWChOA-ELM[7] | Proposed     |
|-----------------|------------------------------|---------------------|--------------|
| Accuracy (%)    | 96.32                        | 96.89               | <b>97.97</b> |
| Precision (%)   | 96.11                        | <b>96.73</b>        | 95.70        |
| Sensitivity (%) | 97.03                        | 96.87               | <b>97.15</b> |
| Specificity (%) | 95.60                        | 94.98               | <b>98.28</b> |
| F1 score (%)    | <b>96.49</b>                 | 95.99               | 96.42        |
| MCC (%)         | 90.14                        | 90.51               | <b>93.98</b> |

## ۶. نتایج و بحث

نتایج شبیه‌سازی بر روی دو پایگاه داده تصاویر ماموگرافی و هیستوپاتولوژی نشان می‌دهد که مدل پیشنهادی EZFNet-ELM-COA توانست بهترین عملکرد را از نظر معیارهای ارزیابی: Accuracy, Sensitivity, Specificity و MCC نسبت به سایر روش‌ها بدست آورد. از آنجایی که روش پیشنهادی ساختار شبکه‌ای ساده، سرعت آموزش و آزمایش بالا و کارایی عملیاتی قابل قبولی دارد؛ در تشخیص‌های بلادرنج نیز عملکرد به موقع و مؤثری خواهد داشت. در مطالعات آتی می‌توان از مدل‌های ترکیبی عصبی به همراه نسخه‌های بهبودیافته COA یا سایر الگوریتم‌های بهینه‌سازی جدیدتر، برای حل مسئله تشخیص سرطان استفاده کرد. همچنین می‌توان روش پیشنهادی را بر روی دیگر انواع تصاویر پزشکی و سایر حوزه‌های تحقیقاتی نیز اعمال کرد.

اخیراً مسئله تشخیص برخی از سرطان‌هایی که با عکس‌برداری صورت می‌گیرد، به علت پیشرفت تکنولوژی به یکی از محبوبترین و پرکاربردترین شاخه‌های تحقیقاتی تبدیل شده است و محققان همواره به دنبال ابداع تکنیک‌های جدیدتر هستند. در این مقاله، برای تشخیص سرطان سینه و همچنین چالش‌های مطرح شده در این زمینه، یک تکنیک جدید با استفاده از شبکه عصبی ZFNet اصلاح شده به نام EZFNet-COA-ELM طراحی و پیاده‌سازی گردید. در مدل پیشنهادی به منظور افزایش سرعت و همچنین استخراج ویژگی‌های موثرتر چندمقیاسی در شبکه EZFNet، در لایه‌های کانولوشنی، از دو سری فیلتر سایز کوچک‌تر، به جای یک سری فیلتر سایز بزرگ استفاده شده است.

## مراجع

- همچنین برای کاهش زمان محاسبات در ساختار شبکه EZFNet از ELM، به عنوان یک روش آموزش به جای لایه FC استفاده شده است تا سیستم پیشنهادی مناسب کاربردهای بلادرنج شود. استفاده از ELM به علت تنظیم تصادفی وزن‌ها و بایاس‌های لایه ورودی، در کنار افزایش سرعت، باعث ایجاد عدم قطعیت در مدل نهایی می‌شود که یک ضعف قابل توجه است و ما در مدل پیشنهادی برای رفع این مشکل از الگوریتم بهینه‌سازی COA که از سرعت همگرایی بالایی برخوردار است، برای تنظیم وزن‌ها و بایاس‌های لایه ورودی ELM استفاده کردیم.
- از طرفی تصاویر ماموگرافی دارای کیفیت پایینی بوده و معمولاً دارای نویز، برچسب‌های رادیولوژی و بافت‌های ماهیچه‌ای زیادی هستند که در روش پیشنهادی، ابتدا در فاز پیش‌پردازش این موارد حذف شد و با استفاده از فیلتر CLAHE کیفیت و تشخیص‌پذیری تصاویر دیجیتال به میزان قابل توجهی افزایش یافت و سپس به ورودی شبکه اعمال گردید.
- [1] تیموری یانسی رمضان، میرزا رضایی میترا، صادقی مهدی، نچاری اعرابی بابک، پیش‌بینی زمان بقا عاری از بیماری تهاجمی در بیماران مبتلا به سرطان پستان با به‌کارگیری روش‌های یادگیری ماشین نیمه نظارتی مبتنی بر گراف، محاسبات نرم، دوره ۱۰، صفحات ۶۹-۴۸، شهریور ۱۴۰۰
  - [2] افتخاریان محسن، نوده‌ی علی، عنایتی فر رسول، بهبود کاهش نویز، تقطیع و طبقه‌بندی توده‌های سرطان توسط فیلتر تطبیقی معکوس کوانتومی، عنكبوت اجتماعی و ELM بهبود یافته، محاسبات نرم، دوره ۱۰، صفحات ۸۹-۷۰، شهریور ۱۴۰۰
  - [3] ارشقی علی، عشوریان محسن و قابل‌لیلا، استفاده از الگوریتم بهینه‌سازی لاشخور برای آستانه‌گیری چندسطحی تصاویر سی‌تی‌اسکن مغز، محاسبات نرم، دوره ۱۰، صفحات ۱۰۹-۹۸، اسفند ۱۴۰۰
  - [4] A. Khamparia et al., "Diagnosis of breast cancer based on modern mammography using hybrid transfer learning," *Multidimensional Systems and Signal Processing*, vol. 32, no. 2, pp. 747-765, 2021/04/01 2021, doi: 10.1007/s11045-020-007567.
  - [5] E. Kozegar, M. Soryani, H. Behnam, M. Salamati,

- arXiv:2006.01767, 2020.
- [18] V. Nemade, S. Pathak, and A. K. Dubey, "A systematic literature review of breast cancer diagnosis using machine intelligence techniques," *Archives of Computational Methods in Engineering*, vol. 29, no. 6, pp. 4401-4430, 2022.
  - [19] L. Alzubaidi et al., "Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions," *Journal of big Data*, vol. 8, pp. 1-74, 2021.
  - [20] P. Oza, P. Sharma, S. Patel, and P. Kumar, "Deep convolutional neural networks for computer-aided breast cancer diagnostic: a survey," *Neural Computing and Applications*, vol. 34, no. 3, pp. 1815-1836, 2022.
  - [21] L. Abdelrahman, M. Al Ghamdi, F. Collado-Mesa, and M. Abdel-Mottaleb, "Convolutional neural networks for breast cancer detection in mammography: A survey," *Computers in biology and medicine*, vol. 131, p. 104248, 2021.
  - [22] P. Kaur, G. Singh, and P. Kaur, "Intellectual detection and validation of automated mammogram breast cancer images by multi-class SVM using deep learning classification," *Informatics in Medicine Unlocked*, vol. 16, p. 100151, 2019.
  - [23] E. L. Omonigho, M. David, A. Adejo, and S. Aliyu, "Breast cancer: tumor detection in mammogram images using modified alexnet deep convolution neural network," in *2020 international conference in mathematics, computer engineering and computer science (ICMCECS)*, 2020: IEEE, pp. 1-6.
  - [24] S. Maqsood, R. Damaševičius, and R. Maskeliūnas, "TTCNN: A breast cancer detection and classification towards computer-aided diagnosis using digital mammography in early stages," *Applied Sciences*, vol. 12, no. 7, p. 3273, 2022.
  - [25] S. Balasubramaniam, Y. Velmurugan, D. Jaganathan, and S. Dhanasekaran, "A Modified LeNet CNN for Breast Cancer Diagnosis in Ultrasound Images," *Diagnostics*, vol. 13, no. 17, doi: 10.3390/diagnostics13172746.
  - [26] Y. Wang, N. Xu, A.-A. Liu, W. Li, and Y. Zhang, "High-order interaction learning for image captioning," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 32, no. 7, pp. 4417-4430, 2021.
  - [27] Z. Gao et al., "Automatic interpretation and clinical evaluation for fundus fluorescein angiography images of diabetic retinopathy patients by deep learning," *British Journal of Ophthalmology*, vol. 107, no. 12, pp. 1852-1858, 2023.
  - [28] C. Junyue, D. Q. Zeebaree, C. Qingfeng, and D. A. Zebari, "Breast cancer diagnosis using hybrid AlexNet-ELM and chimp optimization algorithm evolved by Nelder-mead simplex approach," *Biomedical Signal Processing and Control*, vol. 85, p. 105053, 2023/08/01/ 2023, doi: <https://doi.org/10.1016/j.bspc.2023.105053>.
  - [29] R. S. Lee, F. Gimenez, A. Hoogi, K. K. Miyake, M. Gorovoy, and D. L. Rubin, "A curated and T. Tan, "Computer aided detection in automated 3-D breast ultrasound images: a survey," *Artificial Intelligence Review*, vol. 53, pp. 1919-1941, 2020.
  - [6] K. Rautela, D. Kumar, and V. Kumar, "A systematic review on breast cancer detection using deep learning techniques," *Archives of Computational Methods in Engineering*, vol. 29, no. 7, pp. 4599-4629, 2022.
  - [7] L. Qian, J. Bai, Y. Huang, D. Q. Zeebaree, A. Saffari, and D. A. Zebari, "Breast cancer diagnosis using evolving deep convolutional neural network based on hybrid extreme learning machine technique and improved chimp optimization algorithm," *Biomedical Signal Processing and Control*, vol. 87, p. 105492, 2024.
  - [8] Q. Yuan, B. Kato, K. Fan, and Y. Wang, "Phased array guided wave propagation in curved plates," *Mechanical Systems and Signal Processing*, vol. 185, p. 109821, 2023/02/15/ 2023, doi: <https://doi.org/10.1016/j.ymsp.2022.109821>.
  - [9] J. Ao et al., "Stimulated Raman scattering microscopy enables gleason scoring of prostate core needle biopsy by a convolutional neural network," *Cancer Research*, vol. 83, no. 4, pp. 641-651, 2023.
  - [10] S. Ronoud and S. Asadi, "An evolutionary deep belief network extreme learning-based for breast cancer diagnosis," *Soft Computing*, vol. 23, pp. 13139-13159, 2019.
  - [11] R. Cong, H. Sheng, D. Yang, Z. Cui, and R. Chen, "Exploiting Spatial and Angular Correlations With Deep Efficient Transformers for Light Field Image Super-Resolution," *IEEE Transactions on Multimedia*, 2023.
  - [12] X. Deng, E. Liu, S. Li, Y. Duan, and M. Xu, "Interpretable Multi-modal Image Registration Network Based on Disentangled Convolutional Sparse Coding," *IEEE Transactions on Image Processing*, vol. 32, pp. 1078-1091, 2023.
  - [13] F. Liu, X. Zhao, Z. Zhu, Z. Zhai, and Y. Liu, "Dual-microphone active noise cancellation paved with Doppler assimilation for TADS," *Mechanical Systems and Signal Processing*, vol. 184, p. 109727, 2023.
  - [14] M. Dehghani, Z. Montazeri, E. Trojovská, and P. Trojovský, "Coati Optimization Algorithm: A new bio-inspired metaheuristic algorithm for solving optimization problems," *Knowledge-Based Systems*, vol. 259, p. 110011, 2023.
  - [15] T. Mahmood, J. Li, Y. Pei, F. Akhtar, A. Imran, and K. U. Rehman, "A brief survey on breast cancer diagnostic with deep learning schemes using multi-image modalities," *IEEE Access*, vol. 8, pp. 165779-165809, 2020.
  - [16] X. Zhou et al., "A comprehensive review for breast histopathology image analysis using classical and deep neural networks," *IEEE Access*, vol. 8, pp. 90931-90956, 2020.
  - [17] S. Bharati, P. Podder, and M. Mondal, "Artificial neural network based breast cancer screening: a comprehensive review," *arXiv preprint*

- [40] W. Zhao, L. Wang, and S. Mirjalili, "Artificial hummingbird algorithm: A new bio-inspired optimizer with its engineering applications," *Computer Methods in Applied Mechanics and Engineering*, vol. 388, p. 114194, 2022/01/01/ 2022, doi: <https://doi.org/10.1016/j.cma.2021.114194>.
- mammography data set for use in computer-aided detection and diagnosis research," *Scientific data*, vol. 4, no. 1, pp. 1-9, 2017.
- [30] A. Janowczyk and A. Madabhushi, "Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases," *Journal of Pathology Informatics*, vol. 7, no. 1, p. 29, 2016/01/01/ 2016, doi: <https://doi.org/10.4103/2153-3539.186902>.
- [31] D. Dagao, X. Meng, M. Qian, H. Zhongming, and W. Yuejiang, "An improved Hough transform for line detection," in *2010 International Conference on Computer Application and System Modeling (ICCASM 2010)*, 22-24 Oct. 2010 2010, vol. 2, pp. V2-354-V2-357, doi: [10.1109/ICCASM.2010.5620827](https://doi.org/10.1109/ICCASM.2010.5620827).
- [32] B. Mughal, N. Muhammad, M. Sharif, A. Rehman, and T. Saba, "Removal of pectoral muscle based on topographic map and shape-shifting silhouette," *BMC Cancer*, vol. 18, no. 1, p. 778, 2018/08/01 2018, doi: [10.1186/s12885-018-4638-5](https://doi.org/10.1186/s12885-018-4638-5).
- [33] D. Tian, X. Zhang, and Y. Ding, "An adaptive primal-dual image denoising algorithm," in *2018 Chinese Control And Decision Conference (CCDC)*, 9-11 June 2018 2018, pp. 3307-3310, doi: [10.1109/CCDC.2018.8407695](https://doi.org/10.1109/CCDC.2018.8407695).
- [34] M. D. Zeiler and R. Fergus, "Visualizing and Understanding Convolutional Networks," in *Computer Vision – ECCV 2014*, Cham, D. Fleet, T. Pajdla, B. Schiele, and T. Tuytelaars, Eds., 2014// 2014: Springer International Publishing, pp. 818-833.
- [35] X. Wang, A. Bao, Y. Cheng, and Q. Yu, "Weight-sharing multi-stage multi-scale ensemble convolutional neural network," *International Journal of Machine Learning and Cybernetics*, vol. 10, no. 7, pp. 1631-1642, 2019/07/01 2019, doi: [10.1007/s13042-018-0842-5](https://doi.org/10.1007/s13042-018-0842-5).
- [36] X. Shen, S.-C. Du, Y.-N. Sun, P. Z. Sun, R. Law, and E. Q. Wu, "Advance scheduling for chronic care under online or offline revisit uncertainty," *IEEE Transactions on Automation Science and Engineering*, 2023.
- [37] M. Khishe and M. R. Mosavi, "Chimp optimization algorithm," *Expert Systems with Applications*, vol. 149, p. 113338, 2020/07/01/ 2020, doi: <https://doi.org/10.1016/j.eswa.2020.113338>.
- [38] M. Braik, A. Hammouri, J. Atwan, M. A. Al-Betar, and M. A. Awadallah, "White Shark Optimizer: A novel bio-inspired meta-heuristic algorithm for global optimization problems," *Knowledge-Based Systems*, vol. 243, p. 108457, 2022/05/11/ 2022, doi: <https://doi.org/10.1016/j.knsys.2022.108457>.
- [39] B. Abdollahzadeh, F. S. Gharehchopogh, and S. Mirjalili, "African vultures optimization algorithm: A new nature-inspired metaheuristic algorithm for global optimization problems," *Computers & Industrial Engineering*, vol. 158, p. 107408, 2021/08/01/ 2021, doi: <https://doi.org/10.1016/j.cie.2021.107408>.