



دانشگاه کاشان  
University of Kashan

مجله محاسبات نرم

## SOFT COMPUTING JOURNAL

تارنمای مجله: [scj.kashanu.ac.ir](http://scj.kashanu.ac.ir)



### تشخیص سرطان سینه با استفاده از شبکه بهبودیافته ZFNet-ELM با الگوریتم بهینه‌سازی COA<sup>1</sup>

سارا خسروی<sup>1\*</sup>، استادیار

<sup>1</sup> گروه کامپیوتر، دانشکده فنی و مهندسی، دانشگاه پیام نور، تهران، ایران.

#### چکیده

#### اطلاعات مقاله

تاریخچه مقاله:

دریافت 1 مهر ماه 1403

پذیرش 30 آذر ماه 1403

کلمات کلیدی:

یادگیری عمیق

هوش مصنوعی

تشخیص سرطان سینه

شبکه عصبی کانولوشن عمیق

الگوریتم بهینه‌سازی کواتی (COA)

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 بر اساس 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 زمان بر 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 پیشنهاد شده است. در شبکه پیشنهادی (Enhanced ZFNet)، در لایه‌های کانولوشنی شبکه ZFNet، فیلترهای اندازه بزرگ با دو سری فیلتر اندازه 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 پیش‌آموزش‌دیده توسط شبکه یادگیری افراطی (ELM) جایگزین شد. در انتها نیز قابلیت تعمیم ELM با استفاده از بروزرسانی وزن‌ها و بایاس‌های لایه و روی ELM توسط الگوریتم بهینه‌سازی کواتی (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، F1-score و MCC به ترتیب مقادیر 93/98، 96/42، 98/28، 97/15، 95/70، 97/97 درصدی را به دست آورده است. نتایج به دست آمده افزایش دقت، بهبود کارایی، کاهش چشمگیر زمان محاسبات و سطح عملکردی بالای سیستم پیشنهادی را نسبت به روش‌های موجود نشان می‌دهد.

© 1403 نویسندگان. مقاله با دسترسی آزاد تحت مجوز CC-BY

#### 1. مقدمه

در سال‌های اخیر، سرطان سینه<sup>1</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،

✦ نوع مقاله: پژوهشی

\* نویسنده مسئول

پست(های) الکترونیک: [khosravi\\_un@pnu.ac.ir](mailto:khosravi_un@pnu.ac.ir) (خسروی)

<sup>1</sup> Breast Cancer

وضوح 50 در 50 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 [8]. محاسبات و تجزیه و تحلیل سیستم‌های تشخیصی به طور قابل توجهی به ROI های تعیین شده نیز بستگی دارد. بنابراین، توصیف ROI های برچسب‌گذاری شده<sup>9</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 [8].

در چندین مطالعه تحقیقاتی صورت گرفته از جمله مرجع [9]، 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. به تازگی، روش‌های جدید مبتنی بر یادگیری عمیق<sup>10</sup> (DL) برای بررسی و تشخیص سرطان از تصاویر ماموگرافی معرفی شده است. در این مطالعات، ویژگی‌های مورد نظر 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 برچسب‌دار و بدون برچسب برای بهبود دقت طبقه‌بندکننده‌های<sup>11</sup> سرطان سینه، که بر اساس وضعیت سرطان تصاویر هستند، امری مهم است. اکثر این سیستم‌ها به این دلیل که بیشتر استراتژی‌های یادگیری عمیق موجود بر شبکه عصبی کانولوشن<sup>12</sup> (CNN) تکیه کرده‌اند، عملکرد طبقه‌بندی بهتری نسبت به روش‌های مرسوم دارند [7].

به پزشکان کمک می‌کند که از پیشرفت این بیماری جلوگیری کرده و یک برنامه درمانی موثر را برای درمان آن انتخاب کنند و همچنین هزینه‌های ناشی از درمان نیز کاهش یابد [1] - [4]. از اینرو، 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 می‌توان به تصویربرداری تشدید مغناطیسی<sup>1</sup> (MRI) [2]، توموگرافی کامپیوتری<sup>2</sup> (CT) [4]، فناوری اولتراسوند<sup>3</sup> (US) [5] و ماموگرافی<sup>4</sup> (X-ray) [6]، اشاره کرد. 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 به دست آمده از ماموگرافی اغلب شامل انواع ناهنجاری‌ها و اختلالاتی است که تشخیص دقیق و زود هنگام سرطان در مراحل اولیه را عملاً دشوار می‌کند [7].

در حال حاضر، از روش تشخیصی هیستوپاتولوژیک<sup>5</sup> و استفاده از تکنیک H&E<sup>6</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>7</sup> و الگوی رشد سلول‌ها تعیین می‌کنند [7]. با توجه به اینکه تومورها خود بخش کوچکی از تصویر را تشکیل می‌دهند، ممکن است تشخیص سرطان سینه در مراحل پیش بالینی آن با آزمایش ماموگرافی دشوار باشد. وضوح تصاویر ماموگرافی دیجیتال به طور معمول 5000 در 4000 پیکسل است. با این حال، منطقه مورد نظر<sup>8</sup> (ROI) مشکوک ممکن است

<sup>1</sup> Magnetic Resonance Imaging

<sup>2</sup> Computed Tomography

<sup>3</sup> Ultrasound Technology

<sup>4</sup> Mammography

<sup>5</sup> Histopathological

<sup>6</sup> Hematoxylin & Eosin

<sup>7</sup> Cytoplasm

<sup>8</sup> Region of Interest

<sup>9</sup> Labeled

<sup>10</sup> Deep Learning

<sup>11</sup> Classifiers

<sup>12</sup> Convolutional Neural Network

مورد ارزیابی قرار می‌گیرد. مشارکت های اصلی مقاله به شرح زیر می‌باشد:

- تصاویر ماموگرام به طور معمول دارای نویز و مصنوعات رادیولوژی هستند. بدین منظور ابتدا در فاز پیش پردازش، نویز، برچسب‌های 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>6</sup>، از لایه‌های کانولوشنی با دو سری فیلتر اندازه کوچک‌تر، به جای یک سری فیلتر اندازه 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 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 مرجع [14] 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

در صورت عدم دسترسی به مجموعه داده‌های آموزشی بزرگ و جامع در روش‌های یادگیری عمیق می‌توان با استفاده از مرحله پیش‌آموزش<sup>1</sup>، آموزش طبقه‌بند را امکان‌پذیر کرد. نمونه‌ای از پیش‌آموزش لایه‌ای برای پیش‌آموزش پارامترهای وزن یک شبکه باور عمیق<sup>2</sup> (DBN) با سه لایه پنهان در مرجع [10] استفاده شده است. بر اساس 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 [11]. 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 بهبود یافته ZFNet (EZFNet) برای استخراج خودکار ویژگی‌ها در ترکیب با ماشین یادگیری افراطی<sup>3</sup> (ELM) برای تشخیص و طبقه‌بندی بلادرنج 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 [12]، به عنوان یک روش آموزش به جای لایه تمام متصل<sup>4</sup> (FC) استفاده شده است تا کاستی‌هایی را که پیش از این ذکر شد، برطرف سازد. بنابراین، اولین کاری که باید انجام شود، آموزش شبکه EZFNet است که به عنوان یک استخراج‌کننده خودکار ویژگی عمل می‌کند [13]. 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>5</sup> (COA) [14] بهبود داده خواهد شد. در نهایت عملکرد شبکه عمیق پیشنهادی EZFNet-ELM-COA بر روی دو پایگاه داده تصاویر ماموگرافی و هیستوپاتولوژی

<sup>1</sup> Pre-training

<sup>2</sup> Deep Belief Network

<sup>3</sup> Extreme learning machine

<sup>4</sup> Fully Connected Layer

<sup>5</sup> Coati Optimization Algorithm

<sup>6</sup> Multi-Scale

## 2.2. روش‌های مبتنی بر یادگیری عمیق

با ظهور روش‌های یادگیری ماشین<sup>6</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 زود هنگام کمک کرده و دقت غربالگری ماموگرافی و سایر انواع تصاویر پزشکی را بهبود می‌بخشد [6]. در مقایسه با رویکردهای ML [18]، روش‌های DL عملکرد موثرتری در حل مسائل پیچیده و زمینه‌های مختلف از جمله تجزیه و تحلیل تصویر، تشخیص 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 [19]. علاوه بر این، از این تکنیک‌ها می‌توان برای یادگیری مناسب‌ترین ویژگی‌ها و یافتن الگوها در داده‌های پردازش نشده نیز استفاده کرد [18].

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>7</sup> (TL) که شامل شبکه‌های عصبی آموزش‌دیده قبلی مانند AlexNet، ResNet، و VGG است، در تشخیص سرطان سینه استفاده کرده‌اند [18]. 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 [20]. DCNN‌ها به طور معمول الگوریتم‌های پردازش داده دوبعدی<sup>8</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، DCNN

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.

## 2. کارهای مرتبط

تشخیص زود هنگام سرطان یکی از روش‌های پیشگیری از تکثیر سریع سلولی تومورهای خوش‌خیم و تبدیل آن به تومور بدخیم است. همان‌طور که در مرجع [15] 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 که در ادامه مورد بحث قرار گرفته است.

### 1.2. روش‌های مبتنی بر یادگیری ماشین

در بیشتر مطالعات انجام شده در زمینه BC در حدود سال 2012، از شبکه‌های عصبی کلاسیک<sup>1</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 موثر 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>2</sup> و ویژگی‌های ریخت‌شناسی<sup>3</sup> برای تقسیم‌بندی<sup>4</sup> و طبقه‌بندی<sup>5</sup> تصاویر استفاده می‌کردند [16]. با این حال، سیستم‌های طراحی سنتی به کمک رایانه عموماً به ویژگی‌های ایجاد شده دستی بستگی دارند و بنابراین عملکرد کلی را تضعیف می‌کنند [17]. در مرجع [16]، به طور جامع روش‌های موجود مبتنی بر ML برای تشخیص سرطان سینه بر اساس پردازش تصویر مورد بررسی و ارزیابی قرار گرفته است.

<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

<sup>7</sup> Transfer Learning

<sup>8</sup> Dimensional

اخیراً برای رفع این چالش، در [7] و [28] از تکنیک ELM برای کاهش زمان محاسبات آموزش و آزمایش در معماری شبکه استفاده شده است که نتایج به دست آمده عملکرد موفقیت‌آمیز این روش را نشان می‌دهد. در حال حاضر، با توجه به کاربردهای طبقه‌بندی و تشخیص تصویر، انواع مختلفی از ELM ها در دسترس هستند. با این وجود، این نوع شبکه‌ها با مسائل مهمی مانند انتخاب نوع تابع فعال‌ساز<sup>5</sup> و تعداد زیاد گره پنهان<sup>6</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>7</sup> و هم برای وزن‌های ورودی<sup>8</sup> که در تولید وزن‌های خروجی بکار 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>9</sup> کامل ستون را منعکس کند و در نتیجه راه‌حل‌های غیربهبوده توسط ماتریس‌های نامطلوب ایجاد می‌شوند [28]. بنابراین، برای پیشگیری از این مشکل و بهبود شرطی‌سازی و افزایش قابلیت‌های تعمیم ELM و همچنین تضمین نتایج بهینه، در مراجع [7] و [28] از الگوریتم‌های بهینه‌سازی هوشمند استفاده شده است.

### 3. پایگاه داده و پیش‌پردازش

در این مقاله، از پایگاه‌داده دیجیتال غربالگری ماموگرافی با زیرمجموعه تصاویر سینه انتخاب شده (CBIS-DDSM)<sup>10</sup> [29] و همچنین پایگاه داده هیستوپاتولوژی مجرای تهاجمی سرطان (IDC)<sup>11</sup> [30]، استفاده شده است.

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 [21].

دقت طبقه‌بندی<sup>1</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 [22] طبقه‌بندی ماموگرافی به تومورهای توده‌ای بدخیم و خوش‌خیم با استفاده از DCNN و ماشین بردار پشتیبان<sup>2</sup> (SVM) بررسی شده است. هدف این کار استخراج ویژگی‌های تصویر با استفاده از ROI و آستانه‌ها بود و آخرین لایه تمام متصل<sup>3</sup> DCNN با SVM جایگزین شد که در نهایت منجر به افزایش دقت به 87/2 درصد گردید. در مرجع [23]، بافت‌های تومور در تصاویر ماموگرافی با استفاده از تکنیک Chan-Vese برای استخراج کانتور<sup>4</sup> و DCNN ها برای یادگیری ویژگی‌های خاص از کانتور، مدل‌سازی شدند که با دقت کلی 85% عملکرد بهتری نسبت به دیگر الگوریتم‌ها داشته است. همچنین در یک مطالعه مقایسه‌ای [24]، در مورد تشخیص تصویر ماموگرافی با استفاده از DCNN، دقت 60% برای همه طبقه‌بندی‌ها و 75% برای دسته توده‌ها به دست آمد که برای یک طرح درمانی کافی نیست. در مرجع [25] نیز از شبکه عصبی LeNet برای تشخیص سرطان سینه استفاده شده است که نتایج به دست آمده میزان دقت 89/91 درصدی را نشان می‌دهد.

از آنجایی که DCNN ها 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 [26]. 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 [27].

<sup>5</sup> Activation Function

<sup>6</sup> Hidden Node

<sup>7</sup> Hidden Biases

<sup>8</sup> Input Weights

<sup>9</sup> Rank

<sup>10</sup> Curated Breast Imaging Subset-Digital Database Screening Mammography

<sup>11</sup> Invasive Ductal Carcinoma


<sup>1</sup> Classifier

<sup>2</sup> Support Vector Machine

<sup>3</sup> Fully Connected Layer

<sup>4</sup> Contour

بالقوه در تصویر ماموگرافی وجود داشته باشد نشان داده شده است. بدین منظور ابتدا در فاز پیش‌پردازش، نویز، برجسب‌های رادیولوژی، 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.



شکل (1): بخش‌های مختلف تصویر ماموگرافی

در روش پیشنهادی، طی سه مرحله کلیدی که در شکل (2) 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:

- 1- حذف خطوط سیاه-سفید افقی و عمودی: با استفاده از روش تشخیص خطوط هاف<sup>6</sup> [31]، خطوط افقی و عمودی سیاه رنگ و یا سفید رنگ در صورت وجود شناسایی و سپس حذف می‌شوند.
- 2- حذف مصنوعات و نویزهای پس‌زمینه: در ابتدا تصویر را با آستانه<sup>7</sup> مشخص باینری می‌کنیم. مقدار آستانه به روش آزمون و خطا برابر مقدار 0/02 تعیین شد. سپس کانتورهای<sup>8</sup> تصویر باینری را مشخص کرده و ماسک بزرگترین کانتور را به عنوان بافت سینه در نظر می‌گیریم.

<sup>6</sup> Hough Line Detection

<sup>7</sup> Threshold

<sup>8</sup> Contours

### 1.3. پایگاه داده CBIS-DDSM

پایگاه داده DDSM اصلی شامل 2620 مطالعه موردی از مجموعه تصاویر ماموگرافی دیجیتالی است که شامل موارد طبیعی، خوش‌خیم و بدخیم و اطلاعات مربوط به آسیب‌شناسی می‌باشد. با توجه به گستردگی پایگاه‌داده و در دسترس بودن برجسب<sup>1</sup>، DDSM ابزاری موثر برای ایجاد و ارزیابی سیستم‌های پشتیبانی تصمیم‌گیری<sup>2</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 10239 تصویر کوچک شده در فرمت استاندارد DICOM است که از طریق آدرس اینترنتی<sup>3</sup> ارائه شده در پاورقی در دسترس می‌باشد.

### 2.3. پایگاه داده IDC

این پایگاه داده شامل 162 تصویر اسلاید کامل از نمونه‌های هیستوپاتولوژی سرطان سینه است که در وضوح 40 برابر اسکن شده‌اند. از این مجموعه تصاویر تعداد 277524 تصویر کوچک<sup>4</sup> با اندازه 50×50 استخراج شده است که تعداد 198738 تصویر مربوط به موارد طبیعی و تعداد 78786 تصویر مربوط به موارد سرطانی می‌باشد. این پایگاه داده از طریق آدرس اینترنتی<sup>5</sup> ارائه شده در پاورقی در دسترس می‌باشد.

### 3.3. پیش‌پردازش

در صورت استفاده از تکنیک‌های CAD، با استفاده از پیش‌پردازش ماموگرافی، امکان تشخیص ناهنجاری‌هایی که قابل مشاهده یا قابل احساس نیستند، فراهم می‌شود [28]. تصاویر ماموگرام به طور معمول دارای نویز و مصنوعات رادیولوژی است. در شکل (1) انواع مختلفی از نویز که ممکن است به طور

<sup>1</sup> Ground Truth

<sup>2</sup> Decision Support Systems

<sup>3</sup> <https://wiki.cancerimagingarchive.net/display/Public/CBIS-DDSM>

<sup>4</sup> Patch

<sup>5</sup> <https://www.kaggle.com/datasets/paultimothymooney/breast-histopathology-images>

تمایزتری با معماری جدید ZFNet ایجاد کرد که باعث بهبود دقت و عملکرد در شبکه‌های CNN شد [34].

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 4 به 2 تغییر یافته است. همچنین AlexNet از نرمال‌سازی پاسخ محلی استفاده می‌کند، در حالی که در ZFNet از نرمال‌سازی کنتراست محلی استفاده شده است [34]. 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 [34].

## 2.4. شبکه EZFNet

همان‌طور که در مقاله [25] نشان داده شده است؛ چنانچه در معماری شبکه عمیق از لایه‌های کانولوشنی با مقیاس‌های بزرگ (5، 7، 9، 11 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 [35] 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>4</sup> در یکدیگر با هم الحاق<sup>5</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>6</sup> هستند که در نتیجه باعث بهبود دقت نهایی شبکه می‌شود.

با این کار پس‌زمینه و برجسب‌های رادیولوژی حذف می‌شوند.

3- حذف بخش ماهیچه‌ای سینه<sup>1</sup> (PMR): در این مرحله با استفاده از تکنیک نقشه توپوگرافی و سیلوئت تغییر شکل<sup>2</sup> بافت ماهیچه‌ای سینه را حذف می‌کنیم. این تکنیک به صورت کامل در مرجع [32] توضیح داده شده است.

4- 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 [33] و اعمال روش تصحیح گاما<sup>3</sup> جهت بهبود کیفیت تصاویر.

شکل (3) مراحل مختلف پیش‌پردازش را نشان می‌دهد.

## 4. روش 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 آزمون، 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.

## 1.4. شبکه ZFNet

در سال 2013 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

<sup>4</sup> Multiple


<sup>5</sup> Concat

<sup>6</sup> Multi scale


<sup>1</sup> Pectoral Muscle Removal

<sup>2</sup> Topographic Map And Shape-Shifting Silhouette

<sup>3</sup> Gamma Correction



شکل (2): مراحل اصلی در فرآیند پیش پردازش



شکل (3): نتایج روش پیش پردازش پیشنهاد

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

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. رابطه (2)، شکل ماتریسی رابطه (1) را نشان می‌دهد.

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

که در آن، ماتریس  $Z^T$  ترانهاده<sup>3</sup> ماتریس  $Z$  است و  $H$  و  $Q$  به صورت رابطه‌های (3) و (4) 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 به طور 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 رابطه (5) آموزش داده شده و نتیجه با استفاده از رابطه (6) به دست می‌آید.

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

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

که در آن،  $H^+$  ماتریس معکوس مور-پنروز<sup>4</sup> تعمیم‌یافته ماتریس  $H$  است [36].

#### 4.4 الگوریتم بهینه‌سازی COA

الگوریتم بهینه‌سازی کوتای در واقع یک الگوریتم فراابتکاری مبتنی بر جمعیت است که برای حل مسائل بهینه‌سازی پیاده‌سازی شده است. از مزایای الگوریتم COA می‌توان به عدم وجود پارامتر کنترلی، همگرایی سریع و عملکرد موثر و قدرتمند این الگوریتم در مدیریت انواع مسائل بهینه‌سازی پیچیده با ابعاد بالا در دنیای واقعی اشاره کرد [14].

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 (4) نشان داده شده است. در روش پیشنهادی به دلیل استفاده از ELM، از شبکه کانولوشنی از قبل آموزش دیده شده استفاده می‌کنیم. اما به دلیل جایگزین کردن فیلترهای شبکه ZFNet امکان فرآیند transfer learning در شبکه EZFNet وجود ندارد و باید شبکه یکبار با تعداد تکرار کم (10 تکرار) آموزش ببیند تا وزن‌ها و بایاس‌های شبکه در محدوده مناسب قرار بگیرند و سپس از این شبکه پیش‌آموزش دیده شده در روش پیشنهادی استفاده گردد.

#### 3.4 ماشین یادگیری بی‌نهایت (ELM)

در اغلب کاربردهای یادگیری ماشین از شبکه‌های عصبی با یک لایه مخفی<sup>1</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 [36].

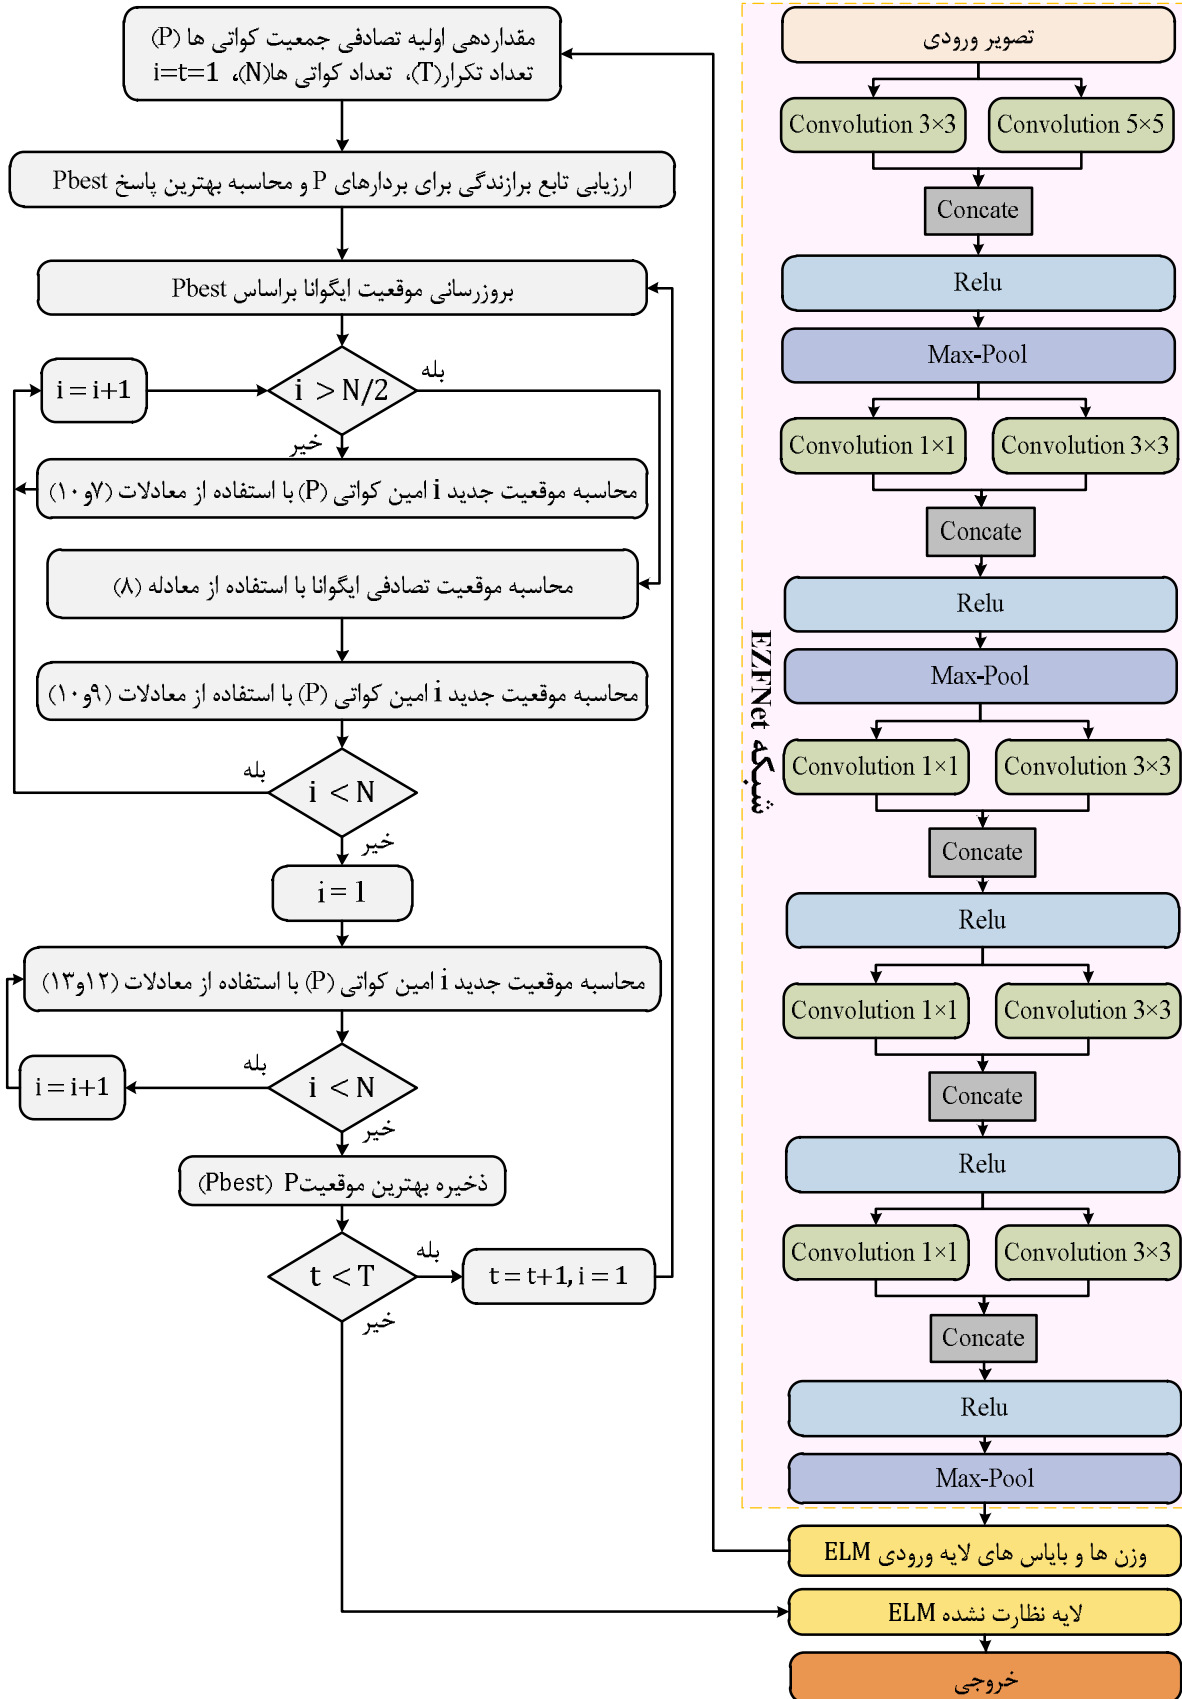
اگر مقدار نورون‌ها در لایه ورودی با  $n$  و تعداد نورون‌های لایه پنهان و لایه خروجی به ترتیب با  $L$  و  $m$  نشان داده شوند، تابع فعال‌ساز<sup>2</sup> توسط رابطه (1) به دست می‌آید:

<sup>3</sup> Transpose

<sup>4</sup> Moore-Penrose

<sup>1</sup> Hidden Layer

<sup>2</sup> Activation Function



شکل (4): بلوک دیاگرام EZFNET-ELM-COA

که در آن،  $X_i^{P2}$  موقعیت جدید محاسبه شده برای  $i$  امین کواتی بر اساس مرحله دوم COA،  $x_{i,j}^{P2}$  بعد  $j$  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>6</sup> محلی و کران بالایی<sup>7</sup> محلی متغیر تصمیم<sup>8</sup>  $j$  ام هستند. همچنین  $lb_j$  و  $ub_j$  نیز به ترتیب کران پایین و کران بالای  $j$  امین متغیر تصمیم می‌باشند. در الگوریتم (1)، شبه‌کد COA توضیح داده شده است [14].

#### 5.4 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.

$$P = [W_{11}, W_{12}, \dots, W_{nT}, b_1, b_2, \dots, b_T] \quad (14)$$

که در آن،  $W_{ij}$  وزن بین گره ورودی  $j$ -امین ELM و ورودی  $i$ -ام از آخرین لایه ادغام<sup>9</sup> 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>10</sup> یا تابع هدف نیاز دارد. ما در اینجا برای افزایش دقت طبقه‌بندی، میانگین مربعات خطا<sup>11</sup> (MSE) را به عنوان تابع

معادلات (7) تا (10) شبیه‌سازی الگوریتم بهینه‌سازی کواتی را به صورت ریاضی نشان می‌دهند.

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

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

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

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

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

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

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

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>5</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  $[\cdot]$  نیز نماد تابع جزء صحیح است [14]. فرآیند به‌روزرسانی موقعیت کواتی‌ها در فضای جستجو به صورت ریاضی توسط رابطه‌های (11) تا (13) مدل‌سازی شده است.

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

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

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

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

<sup>6</sup> Lower Bound

<sup>7</sup> Upper Bound

<sup>8</sup> Decision Variable

<sup>9</sup> Pooling Layer

<sup>10</sup> Fitness

<sup>11</sup> Mean Square Error

<sup>5</sup> Objective Function

تناسب در نظر می‌گیریم که به صورت زیر تعریف می‌شود: 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.

$$Cost Function = MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2 \quad (15)$$

#### الگوریتم (1): شبه‌کد COA

1. ورود و تنظیم پارامترهای مساله بهینه‌سازی
2. تنظیم تعداد تکرار (T) و تعداد کوتاهی‌ها (N)
3. مقداردهی اولیه موقعیت‌های همه کوتاهی‌ها و ارزیابی تابع برازندگی برای این جمعیت اولیه.
4. شروع حلقه: برای  $t = 1:T$  انجام بده:
  5. موقعیت ایگوانا را بر اساس مکان بهترین عضو جمعیت به‌روز کنید
  6. # فاز 1: استراتژی شکار و حمله به ایگوانا (فاز اکتشاف)
  7. شروع حلقه: برای  $i = 1:[N/2]$  انجام بده:
    8. محاسبه موقعیت جدید  $i$  امین کوتاهی با استفاده از رابطه (7)
    9. بروزرسانی موقعیت جدید  $i$  امین کوتاهی با استفاده از رابطه (10)
    10. پایان حلقه
    11. شروع حلقه: برای  $i = 1 + [N/2]:N$  انجام بده:
      12. محاسبه موقعیت تصادفی ایگوانا با استفاده از رابطه (8)
      13. محاسبه موقعیت جدید  $i$  امین کوتاهی با استفاده از رابطه (9)
      14. بروزرسانی موقعیت جدید  $i$  امین کوتاهی با استفاده از رابطه (10)
      15. پایان حلقه
      16. # فاز 2: فرآیند فرار از دست شکارچیان (فاز بهره برداری)
      17. محاسبه مرزهای محلی متغیرها با استفاده از رابطه (11)
      18. شروع حلقه: برای  $i = 1:N$  انجام بده:
        19. محاسبه موقعیت جدید  $i$  امین کوتاهی با استفاده از رابطه (12)
        20. بروزرسانی موقعیت جدید  $i$  امین کوتاهی با استفاده از رابطه (13)
        21. پایان حلقه
        22. ذخیره موقعیت و برازندگی بهترین پاسخی که تاکنون پیدا شده است
        23. پایان حلقه
        24. استفاده از بهترین راه‌حل به دست آمده توسط COA برای مساله بهینه‌سازی

## 5. نتایج و بحث

نیز معیارهای منفی هستند که به ترتیب موارد مثبت و منفی کاذب را نشان می‌دهند (یعنی تعداد نمونه‌هایی که سیستم آنها را اشتباه تشخیص داده است) [3].

## 2.5. 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>20</sup> (ChOA) [37]، بهینه‌ساز کوسه سفید<sup>21</sup> (WSO) [38]، الگوریتم بهینه‌سازی کرکس‌های آفریقایی<sup>22</sup> (AVOA) [39] و الگوریتم مرغ مگس خوار مصنوعی<sup>23</sup> (AHA) [40] نیز بررسی می‌شود. پارامترها و مقادیر اولیه مورد استفاده در روش پیشنهادی و سایر الگوریتم‌های بهینه‌سازی مورد مقایسه در جدول (1) و پارامترهای مربوط به آموزش شبکه EZFNet-ELM در جدول (2) آورده شده است.

جدول (1): پارامترهای اولیه تکنیک‌های مختلف

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

جدول (2): 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 گره های پنهان ELM	500

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 با پردازنده مرکزی Intel Xeon (R) 2.20 GHz و ظرفیت حافظه 13 GB تحت سیستم عامل Ubuntu 18.04 پیاده‌سازی شده است.

## 1.5. معیارهای ارزیابی

به منظور انجام تحلیل و بررسی عملکرد پروتکل پیشنهادی و مطالعه تطبیقی آن با سایر پروتکل‌های دیگر، از شش معیار ارزیابی شامل دقت<sup>12</sup>، صحت<sup>13</sup>، تشخیص‌پذیری<sup>14</sup>، حساسیت<sup>15</sup>، معیار MCC و F1-score مطابق با رابطه‌های (16) تا (21) استفاده کردیم [7].

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (16)$$

$$Precision = \frac{TP}{TP + FP} \quad (17)$$

$$Specificity = \frac{TN}{FP + TN} \quad (18)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (19)$$

$$MCC = \frac{TP \times TN - TP \times FN}{\sqrt{(FP + TP)(FP + TN)(FN + TP)(FN + TN)}} \quad (20)$$

$$F1 - Score = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \quad (21)$$

که در آنها، TP، FP، TN و FN به ترتیب مخفف مثبت صحیح<sup>16</sup>، مثبت کاذب<sup>17</sup>، منفی صحیح<sup>18</sup> و منفی کاذب<sup>19</sup> هستند. همچنین TP و TN دو معیار مثبت هستند که به ترتیب تعداد موارد مثبت و منفی واقعی را نشان می‌دهند (یعنی تعداد نمونه‌هایی که سیستم آنها را درست تشخیص داده است). FP و FN

<sup>12</sup> Accuracy<sup>13</sup> Precision<sup>14</sup> Specificity<sup>15</sup> Sensitivity<sup>16</sup> True Positive<sup>17</sup> False Positive<sup>18</sup> True Negative<sup>19</sup> False Negative<sup>20</sup> Chimp Optimization Algorithm<sup>21</sup> White Shark Optimizer<sup>22</sup> African Vultures Optimization Algorithm<sup>23</sup> Artificial Hummingbird Algorithm

جدول (4): نتایج دو شبکه ZFNet-ELM-COA و EZFNet-ELM-COA پیشنهادی در فرآیند تشخیص سرطان سینه

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

### 5.5. ارزیابی نتایج الگوریتم‌های بهینه‌سازی مختلف

نتایج عملکرد الگوریتم‌های بهینه‌سازی WSO، ChOA، COA، AHA و AVOA، بر روی شبکه EZFNet-ELM در تشخیص تصاویر سرطان سینه، در جدول (5) مقایسه شده است. با توجه به نتایج حاصله 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 به دست آورده است.

### 3.5. بررسی انواع فیلترهای بهبود کیفیت تصاویر در

#### مرحله پیش پردازش

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 (3)، 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 به دست 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.

### 4.5. 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 است و نتایج عملکرد این دو روش در جدول (4) مقایسه شده است. با توجه به نتایج، استفاده از دو فیلتر کوچک‌تر با مقیاس‌های 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 (3): 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	97.97
Precision (%)	87.75	93.82	94.01	95.70
Sensitivity (%)	90.02	90.33	90.62	97.15
Specificity (%)	95.10	97.58	97.55	98.28
F1 score (%)	88.87	92.04	92.29	96.42
MCC (%)	81.49	85.57	85.71	93.98

جدول (5): 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	97.97
Precision (%)	92.04	91.20	92.13	92.37	95.70
Sensitivity (%)	97.41	97.43	97.26	97.54	97.15
Specificity (%)	96.73	96.39	96.79	96.89	98.28
F1 score (%)	94.65	94.21	94.62	94.88	96.42
MCC (%)	91.70	91.14	91.62	92.07	93.98
پایگاه داده IDC					
Accuracy (%)	96.65	96.72	96.84	97.23	97.82
Precision (%)	91.62	91.39	91.59	92.93	94.97
Sensitivity (%)	96.90	97.31	97.55	97.47	97.43
Specificity (%)	96.56	96.49	96.57	97.14	97.98
F1 score (%)	94.19	94.26	94.48	95.15	96.18
MCC (%)	90.88	91.17	91.55	92.40	93.76

این الگوریتم استفاده شده است. استفاده از لایه ELM به جای لایه FC و تنظیم وزن‌های و بایاس‌های لایه ELM با استفاده از الگوریتم COA در پایگاه داده CBIS-DDSM، باعث افزایش دقت و کاهش قابل توجه سرعت آموزش و آزمون شبکه شده است. در پایگاه داده IDC این روش تاثیری در افزایش دقت نداشته اما باعث کاهش قابل توجه سرعت آموزش و آزمون شبکه شده است.



شکل (5): منحنی‌های همگرایی الگوریتم‌های بهینه‌سازی مختلف در

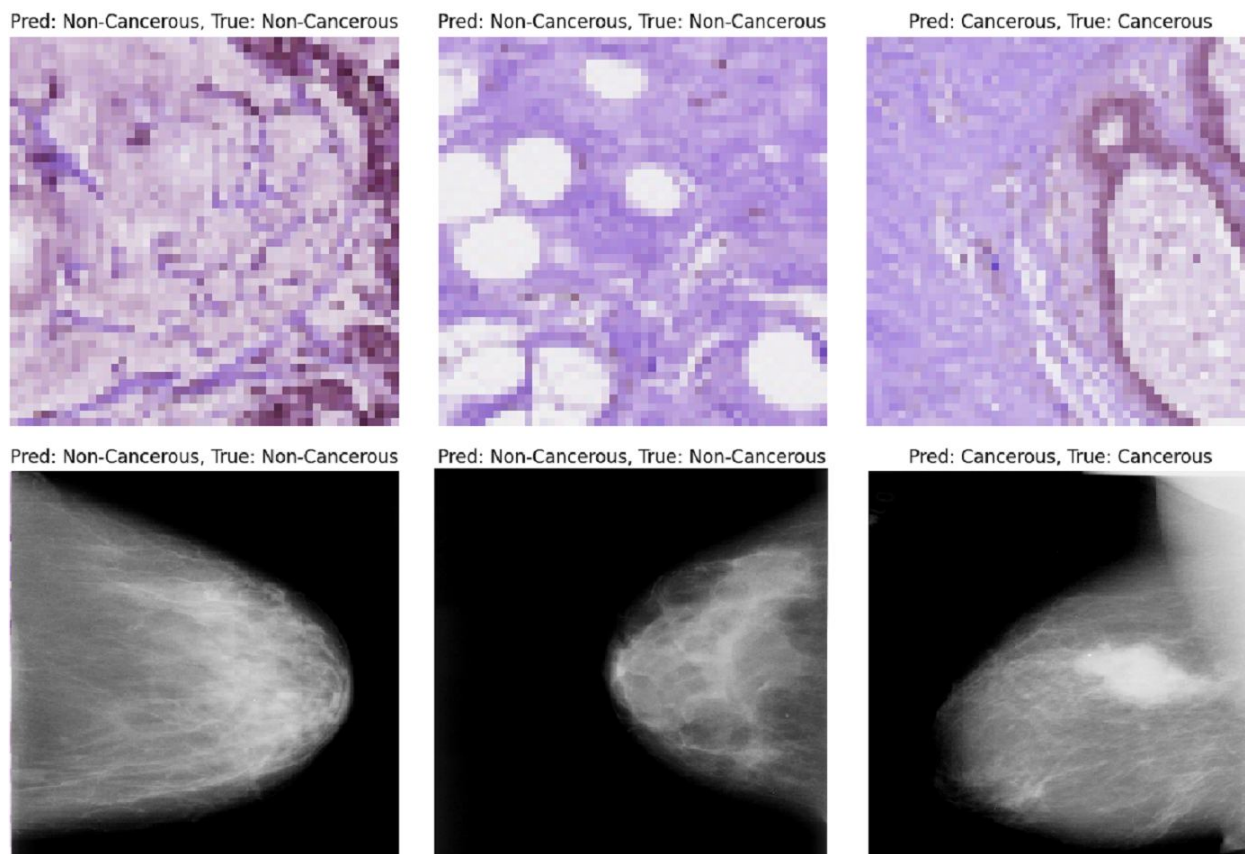
بروزرسانی وزن‌های شبکه EZFNET-ELM

یک معیار مقایسه مهم در الگوریتم‌های مبتنی بر جمعیت، سرعت همگرایی الگوریتم است که بررسی آن در سیستم‌های بلادرنگ بسیار ضروری است. با مقایسه مدل پیشنهادی EZFNet-ELM- COA با چهار الگوریتم دیگر در شکل (5) می‌توان نتیجه گرفت که الگوریتم COA نسبت به سایر الگوریتم‌های بهینه‌سازی دیگر، از سرعت همگرایی بالاتر و مقدار بهینه عمومی مطلوبتری برخوردار است و می‌تواند به طور قابل توجهی موفق‌تر از سایر الگوریتم‌های بهینه‌سازی در به‌روزرسانی وزن‌ها و بایاس‌های شبکه عمل کند. شکل (6) چند نمونه از تصاویر خروجی شبکه پیشنهادی به همراه برچسب آنها را در دو پایگاه داده IDC و CBIS-DDSM نشان می‌دهد.

## 6.5. مقایسه زمانی روش‌های مختلف تشخیص سرطان

### سینه بلادرنگ

جدول (6) نتایج مقایسه زمانی روش‌های مختلف تشخیص بلادرنگ سرطان سینه را بر اساس معیار ارزیابی دقت نشان می‌دهد. از مقایسه الگوریتم‌های آموزشی SGD و Adam می‌توان نتیجه گرفت که الگوریتم Adam دقت و سرعت بهتری در آموزش شبکه دارد، لذا برای مقایسه زمانی روش‌های مختلف از



شکل (6): خروجی شبکه و برجسب تصاویر سرطان سینه در دو پایگاه داده DDSM-CBIS و IDC

جدول (6): مقایسه زمانی روش‌های مختلف تشخیص بلادرنگ سرطان سینه

پایگاه داده DDSM-CBIS

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	97.97

ادامه جدول (6): مقایسه زمانی روش‌های مختلف تشخیص بلادرنگ سرطان سینه

پایگاه داده IDC				
دقت	متوسط زمان تست هر نمونه (میلی ثانیه)	زمان آموزش شبکه (دقیقه)	الگوریتم آموزشی	شبکه
90.21	30	788	SGD	AlexNet-FC
94.84	23	661	SGD	ZFNet-FC
94.88	19	665	SGD	EZFNet-FC
92.11	30	596	Adam	AlexNet-FC
95.03	23	515	Adam	ZFNet-FC
97.82	19	498	Adam	EZFNet-FC
91.62	4.6	0.4	Adam	EZFNet-ELM-RANDOM
96.65	4.6	5.6	Adam	EZFNet-ELM-AVOA
96.72	4.6	7	Adam	EZFNet-ELM-WSO
96.84	4.6	5	Adam	EZFNet-ELM-AHA
97.23	4.6	7.4	Adam	EZFNet-ELM-ChOA
97.82	4.6	5.1	Adam	EZFNet-ELM-COA (Proposed)

با توجه به اینکه مدل مرجع [28] از شبکه AlexNet در ترکیب با ELM و مدل مرجع [7] از شبکه ZFNet در ترکیب با ELM استفاده می‌کند و الگوریتم بهینه‌سازی هر دو مدل ChOA است، طبق جدول (6) روش پیشنهادی ما از نظر سرعت آموزش و آزمون نیز نسبت به دو روش دیگر بهترین عملکرد را دارد.

جدول (7): مقایسه نتایج روش‌های مختلف تشخیص بلادرنگ سرطان سینه با روش پیشنهادی در پایگاه داده CBIS-DDSM

معیار	مدل مرجع [28]	مدل مرجع [7]	پیشنهادی
Accuracy (%)	96.32	96.89	97.97
Precision (%)	96.11	96.73	95.70
Sensitivity (%)	97.03	96.87	97.15
Specificity (%)	95.60	94.98	98.28
F1 score (%)	96.49	95.99	96.42
MCC (%)	90.14	90.51	93.98

### 8.5. محدودیت‌های سیستم

با وجود برتری‌های مدل پیشنهادی و قابلیت استفاده در سایر کاربردهای یادگیری ماشینی، این سیستم در موارد زیر ممکن

### 7.5. مقایسه نتایج روش‌های مختلف تشخیص سرطان

#### سینه بلادرنگ

جدول (7) مقایسه نتایج روش‌های مختلف تشخیص بلادرنگ سرطان سینه را بر اساس شش معیار ارزیابی نشان می‌دهد. با توجه به نتایج به دست آمده، مشخص است که مدل پیشنهادی ما نسبت به مدل مرجع [28]، در معیار Accuracy افزایش 1/65 درصدی، Precision کاهش 0/41 درصدی، Sensitivity افزایش 0/12 درصدی، Specificity افزایش 2/68 درصدی، F1-score کاهش 0/07 درصدی و MCC افزایش 3/84 درصدی را به دست آورده است. همچنین نسبت به مدل ارائه شده در مرجع [7]، در معیارهای Accuracy افزایش 1/08 درصدی، Precision کاهش 1/03 درصدی، Sensitivity افزایش 0/28 درصدی، Specificity افزایش 3/30 درصدی، F1-score افزایش 0/43 درصدی و MCC افزایش 3/47 درصدی را به دست آورده است و بهترین عملکرد را در پایگاه داده CBIS-DDSM از نظر اکثر معیارهای ارزیابی دارد.

در مدل مراجع [28] و [7] نتایج مقایسه زمانی بیان نشده است،

است عملکرد کمتری داشته باشد.

- در صورتی که تعداد کلاس‌های خروجی خیلی زیاد باشد ممکن است ELM نتواند به خوبی کلاس‌ها را از یکدیگر تفکیک کند.
- در مواردی که تعداد نورون‌های 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.

## 6. نتیجه‌گیری

اخیرا مساله 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-ELM-COA طراحی و پیاده‌سازی گردید. در مدل پیشنهادی به منظور افزایش سرعت و همچنین استخراج ویژگی‌های موثرتر چند مقیاسی در شبکه EZFNet، در لایه‌های کانولوشنی، از دو سری فیلتر اندازه کوچک‌تر، به جای یک سری فیلتر اندازه بزرگ استفاده شده است. 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 بلادرنگ شود. استفاده از ELM به علت تنظیم تصادفی وزن‌ها و

## مراجع

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

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافعی ندارند.

[1] R. Taimourei-Yansary, M. Mirzarezaee, M. Sadeghi, and B. Nadjar Araabi, "Predicting Invasive Disease-Free Survival Time in Breast Cancer Patients Using Semi-Supervised Graph-Based Machine Learning Techniques," *Soft Comput. J.*, vol. 10, no. 1, pp. 48-69, 2021, doi: 10.22052/scj.2022.243330.1039 [In Persian].

[2] M. Eftekharian, A. Nodehi, and R. Enayatifar, "Improved Noise Reduction, Segmentation, and Classification of Cancer Masses by Quantum Inverse-Matched Filter, Social Spider Algorithm, and Improved ELM," *Soft Comput. J.*, vol. 10, no. 1, pp. 70-89, 2021, doi: 10.22052/scj.2022.243230.1018 [In Persian].

- [3] A. Arshaghi, M. Ashourian, and L. Ghabeli, "Using the Buzzard Optimization Algorithm for Multilevel Thresholding of Brain CT Images," *Soft Comput. J.*, vol. 10, no. 2, pp. 98-109, 2022, doi: 10.22052/scj.2022.243342.1027 [In Persian].
- [4] A. Khamparia et al., "Diagnosis of Breast Cancer Based on Modern Mammography Using Hybrid Transfer Learning," *Multidimens. Syst. Signal Process.*, vol. 32, no. 2, pp. 747-765, 2021, doi: 10.1007/s11045-020-00756-7.
- [5] E. Kozegar, M. Soryani, H. Behnam, M. Salamati, and T. Tan, "Computer Aided Detection in Automated 3-D Breast Ultrasound Images: A Survey," *Artif. Intell. Rev.*, vol. 53, no. 3, pp. 1919-1941, 2020, doi: 10.1007/s10462-019-09722-1.
- [6] K. Rautela, D. Kumar, and V. Kumar, "A Systematic Review on Breast Cancer Detection Using Deep Learning Techniques," *Arch. Comput. Methods Eng.*, vol. 29, no. 7, pp. 4599-4629, 2022, doi: 10.1007/s11831-022-09744-2.
- [7] L. Qian et al., "Breast Cancer Diagnosis Using Evolving Deep Convolutional Neural Network Based on Hybrid Extreme Learning Machine Technique and Improved Chimp Optimization Algorithm," *Biomed. Signal Process. Control*, vol. 87, p. 105492, 2024, doi: 10.1016/j.bspc.2023.105492.
- [8] Q. Yuan, B. Kato, K. Fan, and Y. Wang, "Phased Array Guided Wave Propagation in Curved Plates," *Mech. Syst. Signal Process.*, vol. 185, p. 109821, 2023, doi: 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 Res.*, vol. 83, no. 4, pp. 641-651, 2023, doi: 10.1158/0008-5472.CAN-22-2114.
- [10] S. Ronoud and S. Asadi, "An Evolutionary Deep Belief Network Extreme Learning-Based for Breast Cancer Diagnosis," *Soft Comput.*, vol. 23, no. 24, pp. 13139-13159, 2019, doi: 10.1007/s00500-019-03857-8.
- [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 Trans. Multimedia*, vol. 25, pp. 6239-6252, 2023, doi: 10.1109/TMM.2022.3210156.
- [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 Trans. Image Process.*, vol. 32, pp. 1078-1091, 2023, doi: 10.1109/TIP.2023.3238690.
- [13] F. Liu, X. Zhao, Z. Zhu, Z. Zhai, and Y. Liu, "Dual-Microphone Active Noise Cancellation Paved with Doppler Assimilation for TADS," *Mech. Syst. Signal Process.*, vol. 184, p. 109727, 2023, doi: 10.1016/j.ymsp.2022.109727.
- [14] M. Dehghani, Z. Montazeri, E. Trojovska, and P. Trojovsky, "Coati Optimization Algorithm: A New Bio-Inspired Metaheuristic Algorithm for Solving Optimization Problems," *Knowl.-Based Syst.*, vol. 259, p. 110011, 2023, doi: 10.1016/j.knosys.2022.110011.
- [15] T. Mahmood et al., "A Brief Survey on Breast Cancer Diagnostic with Deep Learning Schemes Using Multi-Image Modalities," *IEEE Access*, vol. 8, pp. 165779-165809, 2020, doi: 10.1109/ACCESS.2020.3022392.
- [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, doi: 10.1109/ACCESS.2020.2993788.
- [17] S. Bharati, P. Podder, and M. Mondal, "Artificial Neural Network Based Breast Cancer Screening: A Comprehensive Review," *arXiv preprint 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," *Arch. Comput. Methods Eng.*, vol. 29, no. 6, pp. 4401-4430, 2022, doi: 10.1007/s11831-022-09737-1.
- [19] L. Alzubaidi et al., "Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions," *J. Big Data*, vol. 8, p. 53, 2021, doi: 10.1186/s40537-021-00444-8.
- [20] P. Oza, P. Sharma, S. Patel, and P. Kumar, "Deep Convolutional Neural Networks for Computer-Aided Breast Cancer Diagnostic: A Survey," *Neural Comput. Appl.*, vol. 34, no. 3, pp. 1815-1836, 2022, doi: 10.1007/s00521-021-06804-2.
- [21] L. Abdelrahman, M. Al Ghamdi, F. Collado-Mesa, and M. Abdel-Mottaleb, "Convolutional Neural Networks for Breast Cancer Detection in Mammography: A Survey," *Comput. Biol. Med.*, vol. 131, p. 104248, 2021, doi: 10.1016/j.compbiomed.2021.104248.
- [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 Med. Unlocked*, vol. 16, p. 100151, 2019, doi: 10.1016/j.imu.2019.100151.
- [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 *Proc. Int. Conf. Math. Comput. Eng. Comput. Sci. (ICMCECS)*, 2020, pp. 1-6, doi: 10.1109/ICMCECS47690.2020.240847.
- [24] S. Maqsood, R. Damasevicius, and R. Maskeliunas, “TTCNN: A Breast Cancer Detection and Classification Towards Computer-Aided Diagnosis Using Digital Mammography in Early Stages,” *Appl. Sci.*, vol. 12, no. 7, p. 3273, 2022, doi: 10.3390/app12073273.
- [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, p. 2746, 2023, 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 Trans. Circuits Syst. Video Technol.*, vol. 32, no. 7, pp. 4417-4430, 2022, doi: 10.1109/TCSVT.2021.3113560.
- [27] Z. Gao et al., “Automatic Interpretation and Clinical Evaluation for Fundus Fluorescein Angiography Images of Diabetic Retinopathy Patients by Deep Learning,” *Br. J. Ophthalmol.*, vol. 107, no. 12, pp. 1852-1858, 2023, doi: 10.1136/bjo-2021-320494.
- [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,” *Biomed. Signal Process. Control*, vol. 85, p. 105053, 2023, doi: 10.1016/j.bspc.2023.105053.
- [29] R. S. Lee et al., “A Curated Mammography Data Set for Use in Computer-Aided Detection and Diagnosis Research,” *Sci. Data*, vol. 4, no. 1, p. 170177, 2017, doi: 10.1038/sdata.2017.177.
- [30] A. Janowczyk and A. Madabhushi, “Deep Learning for Digital Pathology Image Analysis: A Comprehensive Tutorial with Selected Use Cases,” *J. Pathol. Inform.*, vol. 7, no. 1, p. 29, 2016, doi: 10.4103/2153-3539.186902.
- [31] D. Dagao, X. Meng, M. Qian, H. Zhongming, and W. Yueliang, “An Improved Hough Transform for Line Detection,” in *Proc. Int. Conf. Comput. Appl. Syst. Model. (ICCA SM)*, 2010, vol. 2, pp. 354-357, doi: 10.1109/ICCA SM.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, doi: 10.1186/s12885-018-4638-5.
- [33] D. Tian, X. Zhang, and Y. Ding, “An Adaptive Primal-Dual Image Denoising Algorithm,” in *Proc. Chin. Control Decis. Conf. (CCDC)*, 2018, pp. 3307-3310, doi: 10.1109/CCDC.2018.8407695.
- [34] M. D. Zeiler and R. Fergus, “Visualizing and Understanding Convolutional Networks,” in *Computer Vision - ECCV 2014*, D. Fleet, T. Pajdla, B. Schiele, and T. Tuytelaars, Eds. Cham, Switzerland: Springer, 2014, pp. 818-833, doi: 10.1007/978-3-319-10590-1\_53.
- [35] X. Wang, A. Bao, Y. Cheng, and Q. Yu, “Weight-Sharing Multi-Stage Multi-Scale Ensemble Convolutional Neural Network,” *Int. J. Mach. Learn. Cybern.*, vol. 10, no. 7, pp. 1631-1642, 2019, doi: 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 Trans. Autom. Sci. Eng.*, vol. 20, no. 4, pp. 2482-2497, 2023, doi: 10.1109/TASE.2022.3204481.
- [37] M. Khishe and M. R. Mosavi, “Chimp Optimization Algorithm,” *Expert Syst. Appl.*, vol. 149, p. 113338, 2020, doi: 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,” *Knowl.-Based Syst.*, vol. 243, p. 108457, 2022, doi: 10.1016/j.knosys.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,” *Comput. Ind. Eng.*, vol. 158, p. 107408, 2021, doi: 10.1016/j.cie.2021.107408.
- [40] W. Zhao, L. Wang, and S. Mirjalili, “Artificial Hummingbird Algorithm: A New Bio-Inspired Optimizer with its Engineering Applications,” *Comput. Methods Appl. Mech. Eng.*, vol. 388, p. 114194, 2022, doi: 10.1016/j.cma.2021.114194.