

یادگیری عمیق U-Net بهبود یافته با خوشه بندی مبتنی بر الگوریتم ترکیبی کرم شب تاب و بهینه سازی ازدحام ذرات در تشخیص سرطان سینه در تصاویر ماموگرافی

نجمه سادات بنی حسینی^۱، وحید قدس^۲*

۱- دانشجوی دکتری کامپیوتر، واحد سمنان، دانشگاه آزاد اسلامی، سمنان، ایران پست الکترونیکی: Melikahosseini@yahoo.com

۲- دانشیار گروه برق، واحد سمنان، دانشگاه آزاد اسلامی، سمنان، ایران پست الکترونیکی: V.ghods@semnaniau.ac.ir

چکیده: سرطان سینه از بیماری‌های مهم عصر حاضر است که تشخیص درست و زودهنگام آن می‌تواند به روند بهبود بیماری و جلوگیری از مرگ و میر منجر شود. یادگیری عمیق در پردازش تصاویر پزشکی راهکار موثری در کمک به پزشکان در تشخیص این سرطان و شرایط تومور می‌باشد. زیرا تراکم بالای بافت سینه یکی از محدودیت‌ها در تشخیص این بیماری از روی تصاویر ماموگرافی است. در این پژوهش، روشی جدید با استفاده از شبکه عمیق U-Net در ترکیب با خوشه‌بندی فازی و الگوریتم ترکیبی کرم شب تاب و ازدحام ذرات جهت شناسایی، قطعه بندی تومور سرطان سینه ارائه شده است. روش پیشنهادی بر روی مجموعه داده‌های تصاویر ماموگرافی استاندارد شامل DDSM و INbreast مورد بررسی و تحلیل قرار گرفته است. نتایج، نشان دهنده آن است که شبکه عصبی کانال‌لوشن به دقت ۹۷.۵٪، روش U-Net به دقت ۹۹.۵٪، روش بهبود یافته U-Net با خوشه بندی فازی و ازدحام ذرات (PSO-FCM-U-Net) به دقت ۹۹.۶٪ و روش بهبود یافته U-Net با خوشه‌بندی فازی و کرم شب تاب و ازدحام ذرات (FFPSO-FCM-U-Net) به دقت ۹۹.۸٪ رسیده است. در حالت کلی، نتایج دقت تشخیص سرطان سینه با مدل پیشنهادی U-Net بهبود یافته پیشنهادی، نتایج نویدبخشی را ثمر داد.

واژه‌ی کلیدی- یادگیری عمیق U-Net، سرطان سینه، ماموگرافی، خوشه بندی، الگوریتم کرم شب تاب

Improved U-Net deep learning using clustering based on firefly and particle swarm optimization in breast cancer detection and classification in mammography images

NajmehSadat BaniHoseini¹, Vahid Ghods^{2*}

1-PhD student, Semnan Branch, Islamic Azad University, Semnan, Iran. Email: Melikahosseini@yahoo.com

2-Department of Electrical and Computer Engineering, Semnan Branch, Islamic Azad University, Semnan, Iran. Email: v.ghods@semnaniau.ac.ir

Abstract: Breast cancer is one of the important diseases of today's age, which correct and early diagnosis can lead to the process of improving the disease and preventing mortality. Deep learning in medical image processing is an effective solution to help doctors diagnose this cancer and tumor conditions, because the high density of breast tissue is one of the limitations in diagnosing this disease in mammography images. In this research, a new method using the U-Net deep network in combination with fuzzy clustering and the hybrid algorithms of firefly and particle swarm optimization is presented to recognize and segment the breast cancer tumor. The proposed method was analyzed on the real dataset of valid and standard DDSM and INbreast mammography images. The results of convolutional neural network method with 97.5% accuracy, U-Net method with 99.5% accuracy, improved method with particle swarm optimization PSO-FCM-U-Net with 99.6% accuracy and the proposed FFPSO-FCM-U-Net method with 99.8% accuracy have been accompanied. In general, the results of breast cancer detection accuracy with the proposed improved U-Net model yielded promising results.

Keywords: U-Net deep learning, Breast cancer, Mammography, Clustering, Firefly algorithm.

تاریخ ارسال مقاله: ۱۴۰۱/۰۸/۲۲

تاریخ اصلاح مقاله: ۱۴۰۱/۱۲/۱۳

تاریخ پذیرش مقاله: ۱۴۰۲/۰۱/۱۶

نام نویسنده مسئول: وحید قدس

نشانی نویسنده مسئول: واحد سمنان، دانشگاه آزاد اسلامی، سمنان، ایران



۱- مقدمه

به طور کلی، سرطان سینه دومین سرطان شایع در زنان در سراسر جهان است. همچنین، از نظر میزان مرگ و میر، سرطان سینه پنجمین علت شایع مرگ و میر است [۱]. در دهه‌های گذشته، علاقه به تشخیص خودکار سرطان سینه منجر به ارائه سیستم‌های تشخیصی با کمک یادگیری ماشین شده است و البته هنوز استفاده از سیستم‌های تشخیصی با کمک کامپیوتر یک چالش بوده و نیازمند دقت زیاد است [۲]. در این مقاله، به تشخیص خودکار سرطان سینه در تصاویر ماموگرافی با استفاده از یادگیری عمیق U-Net به صورت بهبود یافته در دو نسخه شامل یادگیری عمیق U-Net ترکیبی با خوشه بندی فازی و ازدحام ذرات که تا پیش از این برای تشخیص آلزایمر استفاده شده بود [۲] و دیگری یادگیری عمیق U-Net ترکیبی با خوشه بندی فازی و کرم شب تاب و ازدحام ذرات پرداخته شده است.

۲- مروری بر روش‌های مرتبط

اگرچه غربالگری ماموگرافی منجر به پیشرفت چشمگیر در تشخیص زودهنگام سرطان سینه شد، اما همچنان در تشخیص سرطان سینه در زنان با سینه‌های متراکم و بسیار متراکم کم تاثیر است. با این حال، زنان با سینه‌های متراکم یک عامل پرخطر در ابتلا به سرطان سینه را در مراحل بعدی زندگی خود دارند [۳-۶]. افزایش تراکم ماموگرافی (MD)، یک عامل خطرساز سرطان پستان است. ماموگرافی سینه متراکم دشوار است؛ زیرا، ممکن است حاوی ساختارهای غیر طبیعی اما مشابه با بافت طبیعی سینه باشد [۷-۱۰].

در دو دهه اخیر، روش‌های متعددی برای تشخیص توده‌های غیرطبیعی در ماموگرافی پیشنهاد شده است [۱۱-۱۳]. با این حال، این روش‌ها به شدت به مجموعه‌ای از پارامترها وابسته هستند که بسته به پایگاه داده مورد استفاده باید به‌طور متفاوتی تنظیم شوند و در واقع هنگامی که یکی از پارامترها تغییر کند یا از یک پایگاه داده جدید استفاده شود، می‌تواند منجر به نتایج متفاوتی شود. با این حال، روش‌های یادگیری عمیق رویکردی انعطاف‌پذیر ارائه می‌دهند، زیرا آموزش آن‌ها مانند تنظیم وزن‌ها و لایه‌ها، می‌تواند با استفاده از پایگاه‌های داده جدید بازآموزی شود. از این نظر، بسیاری از محققان مدل‌های یادگیری عمیق را برای قطعه‌بندی توده‌های غیرطبیعی در پستان یا برای قطعه‌بندی معنایی توده‌ها پیشنهاد کردند که شامل تشخیص، قطعه بندی و طبقه‌بندی توده‌های سینه است.

به عنوان مثال، در تحقیق [۱۴] روشی مبتنی بر یادگیری عمیق برای قطعه‌بندی و طبقه‌بندی توده‌ها در ماموگرافی دیجیتال، تشخیص سرطان بدخیم یا خوش‌خیم ارائه شده است. روش این تحقیق شامل مدل‌های یادگیری عمیق آبشاری است، یکی برای قطعه‌بندی توده‌ها و دومی برای طبقه‌بندی توده‌های قطعه بندی‌شده، که از یک طبقه‌بند ResNet استفاده شده است. عملکرد این مدل‌ها با استفاده از معیارهای مختلف و برای دسته بندی‌های مختلف تراکم سینه ارزیابی می‌شود. با این حال، این عملکرد را می‌توان با تنظیم دقیق مدل‌های قطعه بندی و طبقه‌بندی بهبود بخشید.

در تحقیق [۱۵]، یک مدل یادگیری عمیق مبتنی بر روش YOLO برای تشخیص و طبقه‌بندی توده‌ها در ماموگرافی پیشنهاد شده است. در آن تحقیق، یک مرحله پیش پردازش قبل از مراحل قطعه بندی و طبقه بندی وجود دارد و تصاویر پیش‌پردازش شده به مدل YOLO داده می‌شود تا توده‌های غیرطبیعی را به خوش‌خیم یا بدخیم تشخیص داده و طبقه بندی کند.

در تحقیق [۱۶]، سیستمی برای تشخیص و طبقه‌بندی توده‌ها در پستان پیشنهاد شده است. سیستم پیشنهادی در دو سطح کار می‌کند. ابتدا تصاویر ماموگرافی به روش YOLO برای قطعه بندی داده می‌شود. سپس ضایعات شناسایی شده بر اساس طبقه‌بندی‌های مختلف، شبکه عصبی کانالوشن، ResNet-50 و InceptionResNet-V2 به خوش‌خیم و بدخیم طبقه‌بندی می‌شوند. روش پیشنهادی به نتایج خوبی نسبت به روش‌های قبلی توسط همان نویسندگان دست یافته است. در [۱۷]، همین نویسندگان روش دیگری را پیشنهاد کردند که شامل سه مرحله تشخیص، قطعه بندی و طبقه‌بندی است. برای هر یک از این مراحل، یک مدل یادگیری عمیق استفاده می‌شود. نویسندگان از مدل YOLO برای تشخیص توده‌های غیر طبیعی در پستان استفاده کردند. سپس، یک شبکه کانولوشن با وضوح کامل برای بخش‌بندی توده‌های شناسایی‌شده استفاده می‌شود که از لایه های کانولوشنی و لایه های کاملاً متصل برای استخراج ویژگی و طبقه‌بندی توده‌های تقسیم شده به خوش‌خیم و بدخیم استفاده کردند.

در [۱۸]، با استفاده از یک مدل یادگیری عمیق، رویکردی برای قطعه بندی توده‌ها در پستان پیشنهاد شده است. آن‌ها از یک شبکه هرمی تو در تو چند سطحی استفاده کردند که شامل یک رمزگذار و یک رمزگشا است. رمزگذار اطلاعات معنایی متنی و سطح بالا را بر اساس یک مازول هرم، استخراج ویژگی می‌کند. در حالی که رمزگشا از یک سری عملیات دوخطی برای اصلاح مرزهای توده‌های تقسیم شده استفاده می‌کند. نویسندگان عملکرد روش پیشنهادی خود را با

استفاده از ضریب تاس ارزیابی کردند. با این حال، ارزیابی عملکرد بخش‌بندی معنایی به معیارهای بیشتری برای اندازه‌گیری عملکرد مراحل قطعه‌بندی و طبقه‌بندی نیاز دارد.

در [۱۹]، یک سیستم یادگیری عمیق پیشنهاد شده است که توده‌ها را در ماموگرافی دیجیتال شناسایی، بخش‌بندی و طبقه‌بندی می‌کند. قبل از قطعه‌بندی توده‌ها از یک الگوریتم پیش‌پردازش استفاده شده است و این به حذف نویز و اطلاعات نامربوط از ماموگرافی کمک می‌کند و عملکرد الگوریتم‌های قطعه‌بندی را در مرحله بعدی افزایش می‌دهد. سپس، مدل‌های FCNN و DeepLab برای قطعه‌بندی و طبقه‌بندی توده‌های غیرطبیعی در پستان روی ماموگرافی‌های از پیش پردازش شده اعمال می‌شوند و نتایج دقت خوبی حاصل شده است.

U-Net، یک شبکه از پیش آموزش داده شده است که یکی از شناخته شده ترین ساختار شبکه عصبی کانالوشن جهت قطعه‌بندی تصاویر پزشکی می‌باشد. شبکه‌های از پیش آموزش دیده طوری بهینه سازی شده‌اند، که امکان پیشرفت سریع یا بهبود عملکرد را هنگام مدل سازی فراهم آوردند، همچنین این امکان را می‌دهند تا از دانش به دست آمده از سایر کارها استفاده شود و برای مسائل جدید اما مشابه قابل تعمیم باشد.

در پژوهش [۲۰]، از مدل U-Net برای تشخیص سرطان از روی تصاویر ماموگرافی استفاده شده است و نتایج مطلوبی داشته است. از طرفی در بهبودهای U-Net برای حوزه‌های تشخیص بیماری دیده می‌شود که در تشخیص آلزایمر [۲۱] از U-Net بهبود یافته با خوشه بندی فازی و الگوریتم بهینه سازی ازدحام ذرات استفاده شده است و نتایج آن نسبت به سایر مدل‌های U-Net برتری داشته است. از طرفی نشان داده شده است که قدرت روش‌های تکاملی به صورت ترکیبی در حوزه پردازش تصویر می‌تواند افزایش یابد که از آن جمله ترکیب الگوریتم کرم شب تاب و بهینه سازی ازدحام ذرات در حوزه فشرده سازی است [۲۲].

۳- مدل پیشنهادی

مدل پیشنهادی، یک شبکه عصبی کانالوشن سه بعدی عمیق با استفاده از معماری U-Net است که در آن طبقه بندی با استفاده از خوشه بندی فازی (C-means) و الگوریتم ترکیبی کرم شب تاب و ازدحام ذرات انجام می‌شود تا خطای آموزشی حداقل شده و شبکه وزن‌ها را تنظیم کند. آزمایش و تحلیل با ارزیابی تصاویر ورودی (داده‌های آزمون) مربوط به بیمار سرطان پستان انجام شده است.

در واقع، هدف لایه خوشه بندی مبتنی بر فازی و الگوریتم ترکیبی کرم شب تاب و بهینه سازی ازدحام ذرات (FFPSO)، تعریف کلاس‌هایی است که اشیاء شناسایی شده به آنها تعلق دارند. خوشه بندی فازی اطلاعات بیشتری را در مورد تصویر تقسیم بندی شده ارائه می‌دهد. در صورتی که اطلاعات همسایه‌ها در خوشه‌بندی نادیده گرفته شوند و یا مرکز اولیه خوشه بد انتخاب شود، خوشه‌بندی فازی نیاز به بهبود دارد و این می‌تواند با استفاده از الگوریتم‌های تکاملی محقق شود. بنابراین پیشنهاد الگوریتم ترکیبی کرم شب تاب و ازدحام ذرات را داده‌ایم.

ایده اصلی روش پیشنهادی، یادگیری ویژگی‌ها از تصاویر ماموگرافی سینه و استفاده از آن برای تشخیص تومور است. به طور معمول، در طبقه‌بندی، تبدیل یک تصویر به یک بردار و سپس تحلیل این ویژگی ها انجام می‌شود. اما، در مدل پیشنهادی این مقاله، ابتدا تصاویر سینه بخش‌بندی می‌شوند. سپس، به ترتیب طبقه‌بندی شده تا بخش‌های نشان‌دهنده ناهنجاری‌ها تشخیص داده شوند. به همین دلیل است که از U-Net بهبود یافته که تصویر را به یک بردار تبدیل می‌کند، استفاده شده است. بنابراین، این یادگیری نگاشت مشخصات تصویر را امکان پذیر می‌سازد. سپس، شبکه این نقشه را برای تهیه یک تصویر بخش بندی شده به کار می‌برد. این روش ساختار یکپارچه تصویر را ممکن می‌سازد. مدل پیشنهادی مبتنی بر مفاهیم زیر است:

- تابع فعال سازی باعث می‌شود تا تبدیل از ورودی به خروجی بطور غیرخطی ممکن شود. بنابراین، تسهیل در تبدیل با اصلاح کننده واحد خطی (ReLU) انجام شده و رسیدن به بهترین نتایج با توجه به توابع سیگموئید تضمین می‌شود.
- تجمع^۱ باعث کاهش اندازه می‌شود. از این رو باعث کاهش بار محاسباتی پردازش تصویر به لطف کاهش بعد می‌شود. به علاوه، امکان استخراج ویژگی‌های غالب^۲ ارائه یک نمایش ثابت تر و متراکم تر از تغییراتی که ممکن است در تصویر رخ دهند را ایجاد می‌کند و بهبود یادگیری موثر مدل را فراهم می‌کند.
- تنظیم^۳ باعث تغییرات اندک در یادگیری می‌شود به طوری که مدل تعمیم پذیری بهتری برای تحلیل داده‌هایی دارد که قبلاً پردازش نشده‌اند. این تنظیم، بیش برآزش را کاهش داده و عملکرد مدل را افزایش می‌دهد.

^۱Pooling

^۲Dominant

^۳Regularization

رمزگذار به صورت یک مسیر متراکم ساز عمل می‌کند. در اصل، شامل جمع تکرار شونده کانولوشن‌هاست که هر یک با یک فعالساز ReLU و سپس عملیات بیشترین تجمع دنبال می‌شود. هنگام فرآیند متراکم سازی، اطلاعات فضایی تصویر کاهش یافته و اطلاعات ویژگی افزایش می‌یابد. اساساً، رمزگشا مسیر بسط دهنده‌ای است که اطلاعات فضایی و مشخصه‌های تصویر را ترکیب می‌کند و با استفاده از دنباله‌ای از کانولوشن‌های صعودی، الحاق با ویژگی‌هایی با رزولوشن بالا، رمزگذار را تضمین می‌کند. رمزگشا نگاشت‌های مشخصات لایه متراکم کننده مربوط در رمزگذار را در نظر می‌گیرد. این قسمت، یادگیری مشخصات متراکم تصویر برای بازسازی آن بعد از نمایش داده‌های بخش بندی شده را تضمین می‌کند.

در شبکه رمزگشا، نمونه برداری افزایشی روی نگاشت‌های ویژگی ورودی با استفاده از اندیس‌های بیشترین تجمع که قبلاً ذخیره شده اند انجام می‌شود. با استفاده از بانکی از فیلترهای قابل آموزش، این نگاشت‌ها کانولوشن می‌شوند. به علاوه، عملیات متراکم سازی برای کاهش عمق نگاشت‌های ویژگی ورودی انجام می‌شود تا با عمق لایه‌های رمزگذار مطابقت داشته باشد. سپس، در انتهای هر لایه کانولوشن رمزگشا، تثبیت ورودی با فعالساز ReLU اعمال می‌شود تا تکه‌ها نرمال شوند. در نهایت، به جای استفاده از تابع SoftMax، برای خوشه بندی احتمال تعلق اشیاء به کلاس‌ها، از خوشه‌بندی بهبود یافته پیشنهادی FFCM-FFSO استفاده شده است.

این لایه خوشه بندی، احتمال طبقه بندی در برچسب کلاس‌ها را از طریق خوشه بندی بررسی کرده و تصاویر برچسب دار را به عنوان خروجی برمی‌گرداند. در حقیقت، پیشبینی بهتر برای هر پیکسل با استفاده از شبکه رمزگذار-رمزگشا تضمین می‌شود. کدگذار تصویر ورودی را تحلیل می‌کند، در حالی که رمزگشا اطلاعات به دست آمده از کدگذاری را برای تولید نتیجه بخش‌بندی نهایی ترکیب می‌کند.

طبقه‌بندی مشخصات یک تصویر، به صورت مساله نگاشت درست ویژگی‌ها در نظر گرفته می‌شود. برای این منظور، تمایز عضویت یک مشخصه به یک کلاس مشخص، تشخیص بافت سالم از بافت آسیب دیده در تصویر سینه را ممکن می‌کند.

در واقع، هدف این لایه تعریف کلاس‌هایی است که اشیاء شناسایی شده به آن‌ها تعلق دارند. در شکل ۳، نحوه تعیین مراکز خوشه در خوشه‌بندی فازی توسط الگوریتم ترکیبی تکاملی آمده است.

- تقویت^۱ باعث افزایش اندازه داده‌های آموزشی برای کاهش بیش برآزش می‌شود. بدین ترتیب ایجاد نسخه‌های اصلاح شده تصویر در مجموعه داده به منظور تنظیم و بهبود عملکرد شبکه امکان پذیر می‌شود.
- خوشه بندی فازی بهبود یافته با الگوریتم کرم شب تاب و بهینه سازی ازدحام ذرات (FFPSO^۲) یک روش طبقه بندی بهبود یافته است تا بهترین جواب را با تصحیح تمام مقادیر وزنی تعیین کند.

مدل پیشنهادی، شبکه یادگیری است که می‌تواند تصاویر ماموگرافی را بخش‌بندی کند و مبتنی بر معماری U-Net است. اما، برای بهتر شدن تحلیل‌ها، تغییراتی در نمایش معماری شبکه اعمال شده است.

مساله تومور سینه به عنوان یک مساله بخش‌بندی معنایی بررسی می‌شود. برای تامین نیازهای سیستم تشخیص، معماری پیشنهادی شامل یک شبکه U-Net است که دارای یک رمزگذار و یک رمزگشا با اندازه یکسان، مبتنی بر الگوریتم کرم شب تاب و بهینه سازی ازدحام ذرات و خوشه بندی فازی می‌باشد.


این معماری نشان می‌دهد که تمام ویژگی‌های نگاشت شده در لایه‌های رمزگذار به لایه رمزگشای متناظر ارسال می‌شوند. به علاوه، تمام این ویژگی‌های ارسال شده با نگاشت‌های ویژگی نمونه‌برداری شده تجمع یا ادغام می‌شوند. این مکانیزم باعث می‌شود یادگیری به رمزگشا بازگردد و تا زمانی که معماری پیشنهادی به دنبال پردازش درست تصاویر سینه است، تحلیل صحت انجام می‌شود تا اشیاء ناشناخته تشخیص داده شده، مکان و موقعیت آن‌ها کشف شده و بنابراین بیماری سرطان پستان تشخیص داده شود.

در شکل ۱، فلوچارت مدل پیشنهادی آمده است. در شکل ۲ لایه‌های U-NET و در شکل ۳ مرحله خوشه‌بندی فازی آمده است.


شکل ۲ معماری شبکه U-NET را نشان می‌دهد که شامل مسیرهای نمونه‌برداری کاهشی (فشرده سازی) و نمونه بردارهای افزایشی (بسط دادن) است. سیزده لایه کانولوشن، رمزگذار مبتنی بر ساختار شبکه VGG 16 را تشکیل می‌دهد. VGG16 مبتنی بر فیلترهای کانولوشن کوچک است که لایه‌های وزنی بیشتری فراهم می‌کند. البته لایه‌های بیشتر تضمین کننده بهبود عملکرد هستند

در شبکه رمزگذار، هر رمزگذار یک کانولوشن، با استفاده از بانکی از فیلترها انجام می‌دهد تا تولید نگاشت‌ها، تمام ویژگی‌ها را تسهیل کند.

^۱Reinforcement^۲FireflyPSO



شکل ۱: مرحله کلی روش پیشنهادی



شکل ۲: معماری لایه های U-Net پیشنهادی

ترکیبی کرم شب تاب و بهینه‌سازی ازدحام ذرات، هر جمعیت شامل مجموعه‌ای از بردارها است. هر بردار در الگوریتم بهینه‌سازی ازدحام ذرات می‌تواند موقعیت خود را در تصویر تغییر دهد. بردار در الگوریتم ترکیبی کرم شب تاب و بهینه‌سازی ازدحام ذرات تمام همسایه‌های خود را در تشخیص مرکز خوشه بندی اولیه در نظر می‌گیرد.

در لایه خوشه‌بندی، با استفاده از یک تصویر دو بعدی، در مرحله آموزش مدل، مجموعه داده‌ها برای تطبیق پیکسل ارزیابی می‌شود. بدین صورت که خروجی قطعه بندی، به صورت رنگی کردن پیکسل‌ها است. به طور مثال، در این تحقیق، پیکسل‌های تومور را رنگ آبی (بدخیم) یا سبز (خوش‌خیم) می‌کند. این پیکسل‌ها به کلاس‌های جداگانه تقسیم می‌شوند.


برای محاسبه برازندگی هر بردار در الگوریتم ترکیبی کرم شب تاب و بهینه‌سازی ازدحام ذرات از تابع هدف استفاده می‌شود. تابع هدف به صورت معادله ۱ تعریف می‌شود:

$$O_f = \sum_{i=1}^c \sum_{j=1}^n [\mu_j(x_i)]^b \|x_i - m_j\|^2 \quad (1)$$

- c نشان دهنده تعداد مشخص برچسب کلاس‌هاست.
- x نشان دهنده نمونه ای از فضای متشکل از n نمونه است.
- m مرکز هر کلاس است.
- b نشان دهنده ثابت درجه ابهام است.
- μ درجه عضویت است.

بعد از تعیین کلاس، از تابع خطا برای ارزیابی وزن‌ها استفاده می‌شود. این فرآیند، امکان به روزرسانی شبکه را فراهم می‌کند و مجموعه داده‌های جدید می‌توانند با صحت بالا ارزیابی شوند. همان‌طور که قبلاً گفته شد، شبکه پیشنهادی تصاویر ماموگرافی را بخش‌بندی می‌کند و سپس اشیاء شناسایی شده طبقه‌بندی می‌شوند و سه کلاس اصلی نرمال، خوش‌خیم و بدخیم را تشخیص می‌دهد.

در واقع، مدل پیشنهادی تصویر ورودی را دریافت کرده و پس از استخراج ویژگی‌های مهم، تصاویر برچسب گذاری می‌شوند و به شبکه آموزش داده می‌شود. به طوریکه تصویر ورودی به یکی از کلاس‌های اصلی یا زیرکلاس‌های خروجی سرطان سینه طبقه‌بندی می‌شود. تابع خطا برای تخمین نرخ خطای مدل و تضمین اینکه وزن‌های بروز شده، نرخ خطا را در ارزیابی بعدی کاهش می‌دهند، به کار می‌رود. مدل، نگاهی از ورودی‌ها و خروجی‌هاست. بنابراین، تابع خطا باید با چارچوب مساله مطابقت داشته باشد. U-Net پیشنهادی از روش وزن دهی خطا برای هر پیکسل استفاده می‌کند تا بیشترین وزن‌ها، وزن‌هایی باشند، که اشیای تشخیص داده شده را تشکیل می‌دهند. این روش وزن‌دهی خطا امکان می‌دهند تا سلول‌های اشیای تشخیص داده



شکل ۳: تعیین مراکز خوشه توسط الگوریتم تکاملی ترکیبی

خوشه بندی فازی (FCM)، جزئیات بیشتری را در مورد تصویر تقسیم شده ارائه می‌دهد. با این حال، این خوشه بندی دارای دو مشکل اساسی است. (۱) الگوریتم می‌تواند به نتایج ضعیف برسد، اگر اطلاعات همسایه‌ها نادیده گرفته شوند. (۲) اگر مرکز اولیه خوشه بد انتخاب شود، کل سیستم می‌تواند به بهینه محلی همگرا شود. همان‌طور که توضیح داده شد، برای غلبه بر این مشکلات، از الگوریتم ترکیبی کرم شب تاب و بهینه‌سازی ازدحام ذرات استفاده شده است که تشخیص درست مراکز اولیه طبقه بندی را از طریق خوشه بندی ممکن ساخته و باعث کیفیت خوب نتایج می‌شود. در الگوریتم



شکل ۴: نمایی از سه کلاس در تشخیص سرطان سینه

۴-۲- تنظیمات شبیه سازی

جهت شبیه سازی از نرم افزار متلب ۲۰۱۹ استفاده شده است. تنظیمات مختلف در آزمایشات نسخه بهبود یافته شبکه U-Net مبتنی بر خوشه بندی فازی میانگین و الگوریتم ترکیبی کرم شب تاب و بهینه سازی ازدحام ذرات با تعداد ۱۰۰ جواب اولیه و پارامترهای حرکتی پیش فرض در هر الگوریتم مطابق مرجع [۲۵ و ۲۶] است.

۴-۳- نحوه ارزیابی

با توجه به کارهای انجام شده در حوزه تشخیص بیماری سرطان سینه مشاهده می شود که بیشترین نحوه ارزیابی در مقالات با استفاده از میزان دقت دسته بندی بوده که در این مقاله از این معیار استفاده شده است. از جمله دقت از رابطه ۲، حساسیت از رابطه ۳، تشخیص پذیری از رابطه ۴ استفاده می شود. همچنین از AUC^6 یا سطح زیر نمودار ROC^7 استفاده شده است.

سطح زیر منحنی ROC عددی بین صفر و یک است و نشان می دهد قدرت تشخیص یا درستی نتایج یک آزمون چقدر می باشد. درستی نتایج آزمون به این بستگی دارد که روش آزمون چقدر توانایی تفاوت درست نشان دادن نتایج مثبت صحیح (TP) و منفی صحیح (TF) را دارد. اگر این عدد به یک نزدیک باشد، به معنای آن است که داده ها

شده را در تصاویر سینه به شیوه ای گسسته مدل کرد. این تعیین سلول ها در نگاشت، بخش بندی دودویی را ممکن می سازد که در خوشه بندی FFPSO-FCM به کار رفته است و خوشه بندی پیکسل به پیکسل را فراهم ساخته است. بنابراین، هر پیکسل در یکی از کلاس ها طبقه بندی می شود. تابع خطا مبتنی بر الگوریتم FFPSO-FCM، پیش بینی های U-Net را تصحیح می کند.

۴- پیاده سازی مدل پیشنهادی و تحلیل

نتایج


۴-۱- مجموعه داده ها

در این مقاله، از ۱۰۷۹ تصویر ماموگرافی از دو پایگاه داده، DDSM و Nbr east^۸ استفاده شده است که از این تعداد ۲۹۵ تصویر مربوط به پاتولوژی طبیعی، ۳۹۶ تصویر مربوط به موارد خوش خیم و ۳۸۸ تصویر مربوط به موارد بدخیم است. در مجموعه داده از تراکم سینه های مختلف استفاده شده است، تا مدل بتواند چهار تراکم بافت سینه، به ویژه دسته های سینه متراکم و بسیار متراکم را نیز آموزش ببیند. بنابراین، از ۱۰۷۹ تصویر به دست آمده، ۲۳۴ تصویر متعلق به دسته سینه ساینز ۱ (fatty)، ۴۴۰ تصویر مربوط به دسته سینه ساینز ۲ (fibroglandular)، ۲۷۰ تصویر مربوط به دسته سینه ساینز ۳ (متراکم) و ۱۳۵ تصویر متعلق به دسته سینه ساینز ۴ (بسیار متراکم) هستند [۲۰].

ابتدا تصاویر در اندازه ۱۲۸ در ۱۲۸ تغییر اندازه شده و به صورت سیاه سفید است. ولی برای در نظر گرفتن ویژگی های تصویر در حالت رنگی از تبدیل تصویر سیاه سفید به رنگی مطابق مرجع [۲۰] استفاده شده است و از روش intensity slicing جهت سهولت در تشخیص کلاس بندی در مدل U-Net پیشنهادی استفاده گردیده است. نمونه ای از تصویر تشخیصی در مدل پیشنهادی در سه کلاس عادی، خوش خیم و بدخیم در شکل ۴ آمده است.


^۶Area Under Curve

^۷Receiver Operating Characteristic



شکل ۵: نمایشی از نمودار ROC در روش FFPSO-FCM-U-Net

در شکل ۶، یک نمونه طبقه‌بندی که از روش CNN استفاده شده، نشان داده شده است. در این روش برای خوشه‌بندی از روش k -means استفاده شد. اما، این مدل در تشخیص دچار اشتباه شده است. نواحی آبی رنگ، به اشتباه کلاس بدخیم تشخیص داده شده است. در شکل ۷، ورودی به روش پیشنهادی FFPSO-FCM-U-Net داده شده است که به درستی بخش خوش‌خیم مشخص شده است. در شکل‌های ۸ و ۹ قطعه‌بندی و تشخیص چند نمونه متفاوت دیگر با استفاده از روش پیشنهادی FFPSO-FCM-U-Net نمایش داده شده است که به درستی نواحی و نوع آسیب تشخیص داده شده است. در جدول ۱ مقایسه بین چهار روش استفاده شده شامل روش‌های شبکه عصبی کانالوشن (CNN)، روش شبکه U-Net، روش PSO-FCM-U-Net و روش اصلی پیشنهادی (FFPSO-FCM-U-Net) آمده است، که توسط نویسندگان این مقاله انجام شده است. همچنین، در جدول ۲ مقایسه‌ای بین دقت روش پیشنهادی با روش‌های مقالات انجام شده بر روی مجموعه داده مشترک آمده است. همان‌طور که در جدول ۲ آمده است روش پیشنهادی توانسته است نسبت به سایر مدل‌های یادگیری عمیق ارائه شده در مقالات نتایج بهتری داشته باشد.



شکل ۶: کلاس خوش‌خیم تشخیص اشتباه توسط CNN

عموما در بالای خط نیم‌ساز قرار گرفته‌اند و میزان نرخ مثبت صحیح بالا است و روش آزمون از قدرت تشخیص یا درستی مناسبی برخوردار است. اعداد AUC نزدیک به ۰.۵، همان برابری نرخ مثبت صحیح و نرخ مثبت کاذب را نشان می‌دهد و اعداد کمتر از ۰.۵، بیانگر بالاتر بودن نرخ مثبت کاذب در مقایسه با نرخ مثبت صحیح است. برای تفسیر مقادیر AUC می‌توان از قوانین کلی ارائه شده استفاده نمود. این قوانین بطور عمومی در مسائل مختلف درجه بندی کیفی شده است و مقدار عددی AUC هرچه عددی نزدیکتر به ۱ باشد به این معنی است که تشخیص‌های درست بیشتری انجام شده است و می‌تواند درجه عالی داشته باشد [21].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Sensitivity = \frac{TP}{TP+FN} \quad (3)$$

$$Specificity = \frac{TN}{TN+FP} \quad (4)$$

مثبت درست (TP)، نمونه‌ای با بیماری است که به درستی در کلاس بیمار تشخیص داده شده و منفی درست (TN)، نمونه‌ای بدون بیماری است که به درستی در کلاس سالم تشخیص داده شده است. مثبت اشتباه (FP)، نمونه‌ای بدون بیماری است که به اشتباه تشخیص بیماری داده شده است. منفی اشتباه (FN)، نمونه‌ای با بیماری است که به اشتباه سالم تشخیص داده شده است.

در نتایج ارائه شده در بخش بعدی، ۷۰ درصد داده‌ها جهت آموزش و ۱۵ درصد جهت آزمون و ۱۵ درصد جهت اعتبارسنجی در نظر گرفته شده است؛ یعنی، مجموعه داده آزمون و اعتبارسنجی متغیر بوده است و جهت تغییر آن از تقسیم بندی 10-fold استفاده شده است. میانگین و انحراف معیار در ۱۰ تقسیم متفاوت از داده‌های آزمایش و اعتبارسنجی در نظر گرفته شده است.

۴-۴- مقایسه نتایج

در سطح زیر نمودار هر کلاس (AUC)، بیشترین مقدار مربوط به کلاس عادی با مقدار سطح زیر منحنی ۰.۹۹۹ و سپس بیماری سرطان پستان خوش‌خیم با مقدار سطح زیر منحنی ۰.۹۹۶ و در آخر بدخیم با مقدار سطح زیر منحنی ۰.۹۹۴ بوده است. نتایج روش‌های شبکه عصبی کانالوشن (CNN)، روش شبکه U-Net، روش PSO-FCM-U-Net و روش پیشنهادی FFPSO-FCM-U-Net در نتایج دسته‌بندی سه کلاس M/B/N بیماری سرطان پستان بدخیم (M)، خوش‌خیم (B) و عادی (N) در نمودارهای ROC بررسی شد. در شکل ۵ نمودار ROC روش پیشنهادی آمده است.

بندی تصاویر مدل U-Net است که کاملاً مبتنی بر شبکه عصبی لایه‌های کانال‌لش می‌باشد.

در این مقاله، یک روش خودکار مبتنی بر معماری U-Net یادگیری عمیق، با استفاده از خوشه بندی C-means و الگوریتم بهینه‌سازی ترکیبی کرم شب تاب و ازدحام ذرات می باشد و امکان ایجاد پردازش تصاویر ماموگرافی و بهبود کارایی یک سیستم تشخیص ترکیبی جهت تشخیص ضایعات سینه همچنین تشخیص وجود سرطان پستان را فراهم ساخته است. مدل پیشنهادی، هر پیکسل از تصاویر ماموگرافی را به صورت طبیعی، خوش خیم و بدخیم بخش بندی و طبقه‌بندی می کند.


نتایج ارائه شده نشان می‌دهد که رویکرد پیشنهادی از روش‌های موجود عملکرد بهتری دارد. مقدار AUC برای حالت بد خیم ۹۹٫۴٪، خوش خیم ۹۹٫۶٪ و نرمال ۹۹٫۹٪ به دست آمد و دقت در روش پیشنهادی به ۹۹٫۸٪ رسیده است. این روش، احتمال طبقه بندی در برچسب کلاس‌ها را از طریق خوشه بندی بررسی کرده و تصاویر برچسب‌دار را به عنوان خروجی بر می‌گرداند. در حقیقت، پیش‌بینی بهتر برای هر پیکسل با استفاده از شبکه رمزگذار- رمزگشا تضمین می‌شود. رمزگذار تصویر ورودی را تحلیل می‌کند در حالی که رمزگشا اطلاعات به دست آمده از رمزگذاری را برای تولید نتیجه قطعه‌بندی نهایی ترکیب می‌کند. در مقایسه با مدل‌های پیشین، مدل پیشنهادی دارای دقت بالای قابل قبولی در تشخیص سرطان سینه می‌باشد.

سپاسگزاری

نویسندگان بر خود لازم می‌دارد از زحمات و حمایت‌های آقای مهندس محمد پیرنیاکان تشکر نماید.


مراجع

- [1] American Cancer Society, Global Cancer: Facts & Figures, 4th edition, 2018.
- [2] B'eatrice Lauby-Secretan, Chiara Scoccianti, Dana Loomis, Lamia BenbrahimTallaa, V'eronique Bouvard, Franca Bianchini, Kurt Straif, Breast-cancer screening — viewpoint of the IARC working group, N. Engl. J. Med. 372 (24) (2015) 2353–2358.
- [3] L. Titus-Ernstoff, A.N. Tosteson, C. Kasales, et al., Breast cancer risk factors in relation to breast density (United States), Cancer Causes Control 17 (10) (2006) 1281–1290.
- [4] Benjamin O. Anderson, –Breast cancerthinkinggloballyl, Science 343 (March 6178) (2014) 1403.
- [5] O. Ronneberger, P. Fischer, T. Brox, U-net: convolutional networks for biomedical image segmentation, in: N. Navab, J. Hornegger, W. Wells, A. Frangi (Eds.), Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science, vol 9351, Springer, 2015.
- [6] M.S. Rice, K.A. Bertrand, T.J. VanderWeele, et al., Mammographic density and breast cancer risk: a mediation analysis, Breast Cancer Res. 18 (2016) 94.




شکل ۷: کلاس خوش خیم تشخیص داده شده توسط

FFPSO-FCM-U-Net



شکل ۸: کلاس نرمال تشخیص داده شده توسط

FFPSO-FCM-U-Net



شکل ۹: کلاس بدخیم تشخیص داده شده توسط

FFPSO-FCM-U-Net

جدول ۱: مقایسه روش‌های به کار رفته در طبقه بندی M-B-N

مدل	تشخیص پذیری %	حساسیت %	دقت %	AUC M-B-N
CNN	97.6	97.4	97.5	0.974-0.976-0.975
U-Net	99.4	99.5	99.5	0.995-0.994-0.996
PSO-FCM-U-Net	99.4	99.2	99.6	0.996-0.994-0.997
FFPSO-FCM-U-Net	99.3	99.6	99.8	0.994-0.996-0.999

جدول ۲: مقایسه روش پیشنهادی با روش‌های یادگیری عمیق پیشین

مدل	دقت %
PSO-FCM-U-Net [14]	99.6
U-Net [20]	99.5
Yolo [15]	96.8
RU-Net [14]	90.5
Yolo [17]	99.2
RCNN [17]	98.2
FFPSO-FCM-U-Net (proposed)	99.8

۵- نتیجه گیری

سیستم تشخیص بیماری سرطان سینه یک کار کاملاً ظریف و مستلزم تسلط کامل بر روش‌های پیشرفته مانند یادگیری عمیق است. این شبکه‌ها به دلیل توانایی بالا در حل مسائل پیچیده طبقه‌بندی و تشخیص اشیاء معروف شده‌اند. یکی از روش‌های کارا در حوزه طبقه

- [16] Mugahed A. Al-antari, Seung-Moo Han, Tae-Seong Kim, Evaluation of deep learning detection and classification towards computer-aided diagnosis of breast lesions in digital X-ray mammograms, *Comput. Methods Programs Biomed.* 196 (2020) 105584. ISSN 0169-2607.
- [17] Mugahed A. Al-antari, Mohammed A. Al-masni, Mun-Taek Choi, Seung-Moo Han, Tae-Seong Kim, A fully integrated computer-aided diagnosis system for digital Xray mammograms via deep learning detection, segmentation, and classification, *Int. J. Med. Inform.* 117 (2018) 44–54. ISSN 1386-5056.
- [18] Runze Wang, Yide Ma, Wenhao Sun, Yanan Guo, Wendao Wang, Yunliang Qi, Xiaonan Gong, Multi-level nested pyramid network for mass segmentation in mammograms, *Neurocomputing* 363 (2019) 313–320. ISSN 0925-2312.
- [19] L. Ahmed, M.M. Iqbal, H. Aldabbas, et al., Images data practices for semantic segmentation of breast Cancer using deep neural network, *J Ambient Intell Human Comput* (2020).
- [20] Soulam, K. B., Kaabouch, N., Saidi, M. N., & Tamtaoui, A., Breast cancer: One-stage automated detection, segmentation, and classification of digital mammograms using U-Net model based-semantic segmentation. *Biomedical Signal Processing and Control*, 66, (2021) 102481.
- [21] Hanane Alloui, Mohamed Sadgal, Aziz Elfazziki: Utilization of a convolutional method for Alzheimer disease diagnosis. IN: *Machine Vision and Applications*. pp. 1-14 (2020)
- [22] Rani, M. L. P., Rao, G. S., & Rao, B. P. An efficient codebook generation using firefly algorithm for optimum medical image compression. *Journal of Ambient Intelligence and Humanized Computing*. (2020)
- [23] USF Digital Mammography Home Page. (2019, August 22). Retrieved from <http://www.eng.usf.edu/cvprg/Mammography/Database.html>.
- [24] C. In'es, I.A. Moreira, I. Domingues, A. Cardoso, M.J. Cardoso, M.J.S. Cardoso, INbreast: Toward a full-field digital mammography database, *Acad. Radiol.* 19 (2)(2012) 236–248.
- [25] Yang, X. S., & He, X., Firefly algorithm: recent advances and applications. *International Journal of Swarm Intelligence*, 1(1), (2013) 36.
- [26] Bhushan, B., & Pillai, S. S. Particle Swarm Optimization and Firefly Algorithm: Performance analysis. 2013 3rd IEEE International Advance Computing Conference (IACC). (2013).
- [7] H. Sung, J. Ren, J. Li, et al., Breast cancer risk factors and mammographic density among high-risk women in urban China, *NPJ Breast Cancer* 4 (2018) 3.
- [8] Shadi Azam, Mikael Eriksson, Arvid Sjolander, Roxanna Hellgren, Marika Gabrielson, Kamila Czene, Per Hall, Mammographic density change and risk of breast Cancer, *JNCI: Journal of the National Cancer Institute* 112 (April 4) (2020) 391–399.
- [9] KhaoulaBelhaj Soulam, Naima Kaabouch, Mohamed Nabil Saidi, Ahmed Tamtaoui, An evaluation and ranking of evolutionary algorithms in segmenting abnormal masses in digital mammograms, *Multim. Tools Appl.* 79 (27- 28) (2020) 18941–18979.
- [10] KhaoulaBelhaj Soulam, Mohamed Nabil Saidi, Bouchra Honnit, Chaimae Anibou, Ahmed Tamtaoui, Detection of breast abnormalities in digital mammograms using the electromagnetism-like algorithm, *Multim. Tools Appl.* 78 (10) (2019) 12835–12863.
- [11] Ch Mamatha, T. Jagadeeswari, Katha Shekhar, Detection of masses in mammograms using bayesian method and machine learning, *International Journal of Engineering and Technology(UAE)* 7 (2018) 108–111.
- [12] Shaimaa Mostafa, Roaa Mubarak, Mohamed Eladawy, Amr Ibrahim, Mohammed Gomaa, Rasha Kamal, Breast Cancer Detection Using Polynomial Fitting Applied on Contrast Enhanced Spectral Mammography, 2019, pp. 11–16.
- [13] Nesma Elsokkary, Amany Arafa, Ahmed Asad, Hesham Hefny, Computer-Aided Detection System for Breast Cancer Based on GMM and SVM, 2019, pp. 142–150.
- [14] Dina Abdelhafiz, Sheida Nabavi, Reda Ammar, Clifford Yang, Bi. Jinbo, Residual deeplearningsystem for masssegmentation and classification in mammography, in: In 10th ACM International Conference on Bioinformatics, Computational Biology and Health Informatics (ACM-BCB' 19), September 7–10, 2019, Niagara Falls, NY, USA. ACM, New York, NY, USA, 2019, p. 10 pages.
- [15] Mohammed A. Al-masni, Mugahed A. Al-antari, Jeong-min Park, Geon Gi, TaeYeon Kim, Patricio Rivera, Edwin Valarezo, Mun-Taek Choi, Seung-Moo Han, TaeSeong Kim, Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system, *Comput. Methods Programs Biomed.* (2018).