

## مروری بر سیستم‌های یادگیری عمیق کمک‌یار ماموگرافی: مقاله مروری

### چکیده

دریافت: ۱۴۰۰/۰۱/۲۱ ویرایش: ۱۴۰۰/۰۱/۲۸ پذیرش: ۱۴۰۰/۰۴/۲۵ آنلاین: ۱۴۰۰/۰۵/۰۱

علی عامری<sup>۱</sup>، محمود شیری<sup>۱\*</sup>،

معصومه گیتی<sup>۲</sup>، محمد علی اخایی<sup>۳</sup>

۱- گروه مهندسی و فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران.

۲- گروه رادیولوژی، دانشکده پزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران.

۳- گروه مهندسی برق، دانشکده مهندسی برق، دانشگاه تهران، تهران، ایران.

\* نویسنده مسئول: تهران، دانشگاه علوم پزشکی شهید بهشتی، دانشکده پزشکی، گروه مهندسی پزشکی.

تلفن: ۰۲۱-۲۲۴۳۹۹۶۱

E-mail: m.shiri@sbmu.ac.ir

**کلمات کلیدی:** سرطان پستان، سیستم کامپیوتری کمک‌یار پزشکی، یادگیری عمیق، ماموگرافی.

سرطان پستان یکی از شایع‌ترین سرطان‌ها در زنان است. ماموگرافی غربال‌گری یک روش تصویربرداری اشعه ایکس با دوز پایین است که برای تشخیص سرطان پستان در مراحل اولیه به کار می‌رود. برای کمک به رادیولوژیست در خواندن ماموگرام سیستم‌های کمک‌یار (CAD) ساخته شده‌اند که نرم‌افزارهایی هستند که می‌توانند نواحی سرطانی را در ماموگرام تشخیص دهند. با پیشرفت‌های نرم‌افزاری و سخت‌افزاری اخیر که منجر به تکامل الگوریتم‌های یادگیری عمیق (DL) گردیده، انقلابی در رشته‌های مختلف مهندسی و همچنین فناوری‌های پزشکی به وجود آمده است. اخیراً، مدل‌های DL در سیستم‌های کمک‌یار ماموگرافی مورد استفاده قرار گرفته‌اند و به عملکرد بالایی دست پیدا کرده‌اند. روش‌های DL برخلاف روش‌های سنتی یادگیری ماشین، نیازی به فرایند مشکل و زمان‌بر مهندسی ویژگی‌ها ندارند و می‌توانند به‌طور خودکار، ویژگی‌های مورد نیاز را از روی تصویر یاد گرفته و استخراج کنند. یکی از پرکاربردترین الگوریتم‌های DL، شبکه عصبی کانولوشنال (CNN) می‌باشد. برای تشخیص ضایعات سرطانی در ماموگرام، CNN باید در یک الگوریتم مبتنی بر ناحیه مانند R-CNN، Fast R-CNN، Faster R-CNN و YOLO به کار گرفته شود. برای آموزش مدل‌های DL، نیاز به حجم زیادی از تصاویر ماموگرافی است که ضایعات سرطانی در آن‌ها توسط یک رادیولوژیست مجرب، مشخص شده باشند. به همین دلیل، تهیه و جمع‌آوری یک مجموعه داده بزرگ ماموگرافی مارک شده، برای ساخت یک سیستم کمک‌یار با دقت بالا، ضروری می‌باشد. این مقاله با هدف گردآوری وضعیت بهره‌مندی و پیشرفت‌های تکنولوژی یادگیری عمیق در سیستم‌های کمک‌یار ماموگرافی نوشته شده است.

گروه‌بندی صحیح و شناسایی ضایعات مشکوک خوش‌خیم و بدخیم در نحوه مواجهه و اجرا و طراحی فرایند درمانی مهم است. از سوی دیگر تشخیص نادرست می‌تواند آثار منفی در اجرای فرایند درمان، هزینه، زمان و نیز ایجاد استرس‌های روحی برای بیمار داشته باشد. تشخیص زود هنگام سرطان پستان، شانس مواجهه و درمان مناسب و در نتیجه ادامه زندگی را افزایش می‌دهد.<sup>۱</sup> راه قطعی تشخیص سرطان پستان، انجام آزمایش بایوپسی (Biopsy) می‌باشد، اما توصیه به انجام آن فقط در مراحلی که احتمال وجود سرطان بالا باشد، می‌گردد.<sup>۲</sup>

سرطان پستان از شایع‌ترین سرطان‌های عامل مرگ زنان در دنیا است. خودآزمایی و معاینه بالینی، شروع بررسی وضعیت سلامت بافت پستان است. روش‌های متداول تشخیص سرطان پستان، ماموگرافی، سونوگرافی و در مراحل پسین MRI می‌باشند. تحلیل تصاویر ماموگرافی برای غربال‌گری افراد سالم، مبتلا و مشکوک به سرطان یک روش متداول تشخیصی است. عملکرد مناسب در کاهش خطا،

در اصل برای کمک به مبارزه با خستگی و خطای انسان در جست‌وجو برای تغییرات ظریف در پس‌زمینه پیچیده بافت پستان در ماموگرافی بهینه شده بودند.

نسخه اولیه سیستم‌های کمک‌یار ماموگرافی در سال ۱۹۹۸ توسط سازمان غذا و داروی ایالات متحده تایید شد. تا سال ۲۰۰۲ استفاده از CAD برای مراکز خدمات پزشکی تایید شد.<sup>۶</sup> سیستم‌های کمک‌یار در آمریکا در ۷۴٪ کل ماموگرافی‌های غربال‌گری تا سال ۲۰۰۸ و در ۹۲٪ کل ماموگرافی‌های غربال‌گری تا سال ۲۰۱۶ استفاده شده است.<sup>۷</sup> علی‌رغم برخی نقایص در مورد کارایی آن در شکل فعلی، سیستم‌های کمک‌یار تاکنون بخشی جدایی‌ناپذیر از غربال‌گری ماموگرافی است.

در ابتدا، سیستم‌های CAD برای ماموگرافی مبتنی بر روش‌های سنتی یادگیری ماشین (ML) و پردازش تصویر بوده‌اند.<sup>۸،۹،۱۰</sup> از سال ۲۰۱۲، با پیشرفت سرعت پردازش رایانه‌ها و قابلیت ذخیره‌سازی بیشتر و نیز در دسترس بودن داده‌های بزرگ، پیشرفت‌های فراوانی در زمینه الگوریتم‌های یادگیری عمیق انجام شده است و در حوزه‌های مختلفی از جمله مهندسی پزشکی به‌کار رفته است.<sup>۱۱،۱۲</sup> در سال ۲۰۱۶، پروژه‌های هوش مصنوعی (AI) در حوزه مراقبت‌های بهداشتی، سرمایه‌گذاری بیشتری نسبت به پروژه‌های AI در بخش‌های دیگر اقتصاد جهانی به خود جلب کرده‌اند.<sup>۱۳</sup> با پیشرفت‌های چشم‌گیر در حوزه AI، سیستم‌های کمک‌یار نیز از مرحله فقط آشکارسازی ضایعات، وارد گام جدیدی جهت تشخیص بیماری‌ها شدند. از دو دسته عمده CADها، می‌توان نوع آشکارسازی CADe، و نوع تشخیصی CADx را نام برد. این دسته‌بندی در شکل ۲ مشخص شده است.

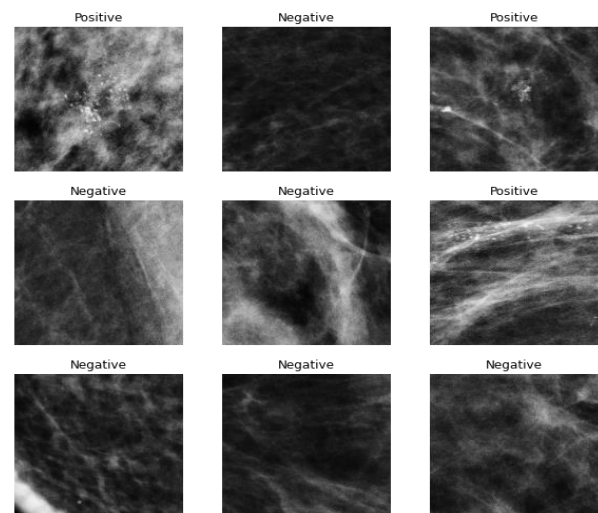
سیستم‌های جدید کمک‌یار ماموگرافی، از الگوریتم‌های یادگیری عمیق برای تشخیص بیماری استفاده می‌کنند و دقت بالاتری نسبت به سیستم‌هایی که از الگوریتم‌های سنتی پردازش تصویر و یادگیری ماشین استفاده می‌کنند، دارند. شبکه‌های (CNN) Convolutional Neural Network از رایج‌ترین الگوریتم‌های یادگیری عمیق هستند که استفاده از آن‌ها در چند سال اخیر به دلیل پیشرفت‌های نرم‌افزاری و سخت‌افزاری و دسترسی به مجموعه داده‌های بزرگ (مثلاً از طریق سیستم PACS)، عملی شده است.

فرایند آزمایش بایوپسی از یک طرف به دلیل تهاجمی بودن، برای بیمار مطلوب نیست و همچنین برای بیمار آثار روحی و اقتصادی به‌همراه دارد.

پس از ماموگرافی، در صورت مشاهده بافت مشکوک به سرطان، ارزیابی‌های کلینیکی و بایوپسی انجام می‌شود.<sup>۳</sup> در بین زنانی که تحت غربال‌گری سرطان پستان قرار می‌گیرند، حدود ۱۰٪ جهت ارزیابی دوباره فراخوانده می‌شوند که از بین آن‌ها معمولاً حدود ۱۰٪-۸ مشکوک به یافته‌های غیرعادی در تصویر ماموگرافی هستند که برای آن‌ها بایوپسی انجام می‌شود.<sup>۴</sup> بیشتر ضایعات در بافت پستان که می‌توانند نشانه‌هایی از سرطان پستان را داشته باشند کلسیفیکیشن (Calcification) و توده می‌باشند.


کلسیفیکیشن‌ها از مشتقات رسوبات کلسیم هستند و توده‌ها تراکم ناحیه‌ای بافت پستان می‌باشند.<sup>۵</sup> شکل ۱ چند نمونه از بافت پستان که حاوی توزیع خوشه‌های کلسیفیکیشن است را در مقایسه با بافت نرمال نمایش می‌دهد.

تشخیص پزشکی با Computer-aided detection (CAD) for mammography برای رادیولوژیست‌های پستان آشناست. مفاهیم اولیه استفاده از رایانه برای تشخیص خودکار ناهنجاری‌های ماموگرافی به دهه ۱۹۶۰ برمی‌گردد و




شکل ۱: نمونه بافت نرمال (Negative) و حاوی ضایعات کلسیفیکیشن (Positive)


تصویر ماموگرافی خام بدون هیچ پیش‌پردازشی به‌عنوان ورودی به CNN داده می‌شود و CNN می‌تواند از طریق لایه‌های کانولوشنی ویژگی‌های مورد نیاز را برای تشخیص ضایعات سرطانی از تصویر استخراج کند (شکل ۳). به همین دلیل، مزیت بالایی نسبت به الگوریتم‌های سنتی دارد که در آن‌ها ویژگی‌ها از تصویر به‌صورت دستی استخراج می‌گردید.<sup>۱۴</sup> ظرفیت بازخورد و یادگیری مداوم این امکان را می‌دهد که عملکرد CNN با گذشت زمان و دریافت داده‌های متنوع‌تر بهبود یابد. سیستم‌های کمکیار برپایه CNN به دقت‌های بالای ۹۰٪ در تشخیص ضایعات سرطانی دست یافته‌اند. شکل ۴ محل کلسیفیکیشن‌ها که به‌وسیله یک CNN تشخیص داده شده را نشان می‌دهد.



شکل ۲: دسته‌بندی سیستم‌های CAD



شکل ۳: ساختار یک سیستم کمکیار مبتنی بر CNN



شکل ۴: تصویر راست، محل کلسیفیکیشن را به‌صورت قطعه‌های روشن‌تر در ماموگرام نشان می‌دهد. تصویر چپ، تصویر اصلی ماموگرام می‌باشد.

جهت به آموزش و یادگیری آن‌ها یادگیری عمیق گفته می‌شود. در واقع فرایند یادگیری، پیدا کردن ارتباط بین داده‌های ورودی و خروجی می‌باشد.

مهمترین قسمت CNN، لایه‌های کانولوشنال هستند که به صورت سری بر داده‌های ورودی شبکه (در اینجا تصاویر ماموگرافی) اعمال می‌شوند، به طوری که خروجی هر لایه، به عنوان ورودی لایه پسین مورد استفاده قرار می‌گیرد. به این ترتیب، ویژگی‌های مناسب از تصویر استخراج می‌شود که می‌تواند ضایعات بدخیم را تشخیص دهد. شکل ۵ عملکرد یک لایه کانولوشنال را نمایش می‌دهد که در این مثال یک فیلتر  $3 \times 3$  بر تصویر ورودی اعمال می‌شود و حاصل کانولوشن، نقشه ویژگی در خروجی لایه می‌باشد.

اما برای این که محل ضایعه در تصویر مشخص شود، باید CNN در قالب یک الگوریتم شناسایی ناحیه استفاده شود. از اولین الگوریتم‌های شناسایی ناحیه، در سال ۲۰۱۴ با عنوان R-CNN ارایه شد.<sup>۱۶</sup>

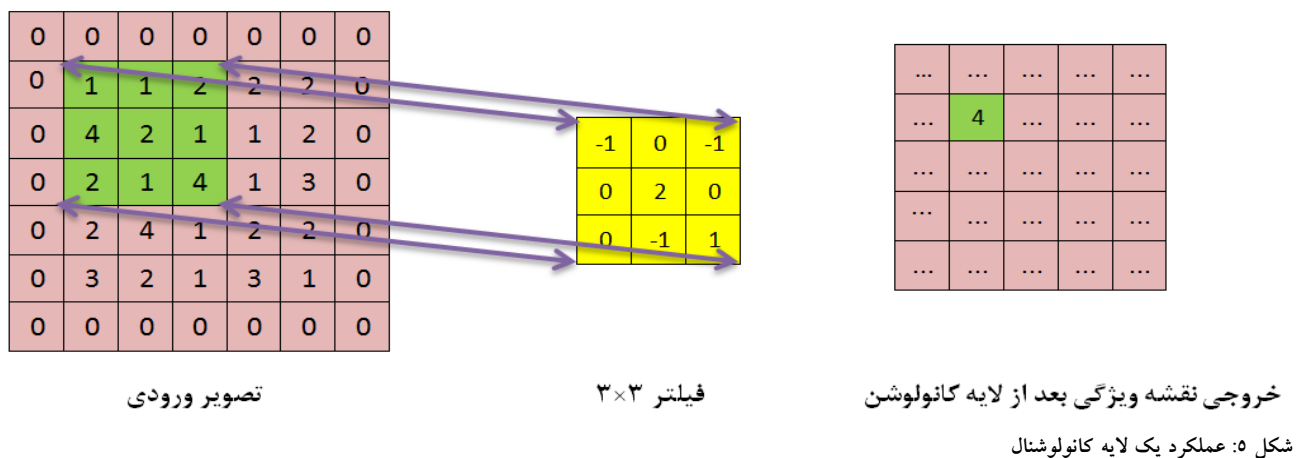
در این روش، ابتدا هر تصویر به تعداد زیادی (مثلاً ۲۰۰۰) زیر-تصویر افراز می‌شود. در مرحله دوم یک CNN ویژگی‌های هر ناحیه را استخراج می‌کند و در مرحله سوم با استفاده از یک دسته‌بند (مثلاً ماشین بردار پشتیبان) کلاس هر زیر-تصویر (مثلاً نرمال یا سرطانی) مشخص می‌شود. در سال ۲۰۱۵، الگوریتم Fast R-CNN معرفی شد که با افزایش سرعت و دقت، معایب R-CNN را برطرف کرد.<sup>۱۷</sup>

توسعه سیستم‌های جدید کمک‌یار مبتنی بر یادگیری عمیق بدون چالش نیست. یادگیری عمیق به پایگاه داده‌های بزرگی احتیاج دارد که جمع‌آوری آن‌ها هزینه‌بر است. تکنیک‌هایی مانند انتقال یادگیری و افزایش مصنوعی داده‌ها برای کاهش اثر چالش نیاز به مجموعه دیتای بزرگ، استفاده می‌شوند. مجموعه داده‌های تایید و آزمایش شده موجود در اینترنت، در حال حاضر بدون استاندارد هستند. این نقصان باعث می‌شود که تکرار نتایج منتشر شده و مقایسه الگوریتم‌ها دشوار شود.<sup>۱۵</sup>

با ورود الگوریتم‌های یادگیری عمیق به حوزه تشخیص‌های پزشکی، چالش‌هایی مانند ملاحظات نظارتی و پزشکی، و همچنین حریم خصوصی بیمار و امنیت داده‌ها، به صورت فزاینده‌ای نمایان خواهد شد و به یک دیدگاه و نظارت یک‌پارچه از سوی دولت‌ها نیاز دارد.

برای استخراج و مشخص کردن نواحی ضایعات مشکوک به سرطان شامل توده و کلسیفیکیشن در تصاویر ماموگرافی، الگوریتم‌های متنوعی مبتنی بر یادگیری عمیق ارایه شده است که با دقت‌های مناسب محل ضایعه مورد نظر را در تصویر مشخص می‌کنند.


هسته اصلی این الگوریتم‌ها، شبکه عصبی کانولوشنال عمیق می‌باشد. هر شبکه عمیق کانولوشنال از اجزا و زیرساختارهایی به صورت سری شده تشکیل شده است. هرچه تعداد لایه‌ها بیشتر باشند مدل پیچیده‌تر می‌شود. شبکه‌های عصبی که بیشتر از یک لایه میانی یا پنهان دارند به آن‌ها شبکه عصبی عمیق گفته می‌شود. از این



گام استخراج ویژگی باعث می‌شود حجم محاسباتی الگوریتم یادگیری افزایش یابد و متکی بر تجربه و تبحر نیروی انسانی برای طراحی ویژگی‌ها باشد. زیرا بیشتر ویژگی‌های استخراج شده از داده‌ها، به دانش توصیفی کافی با توجه به ساختارهای مختلف هندسی و مورفولوژیکی بستگی دارد. علاوه بر این ممکن است برخی از ویژگی‌های مهم و پنهان مورد استفاده قرار نگیرند.<sup>۲۰</sup>

ویژگی‌های مهم مثل محیط، شکل، اندازه و توزیع ضایعات در مراحل مختلف پیشرفت سرطان تغییر می‌کنند. حال آن‌که در یادگیری عمیق، شبکه به صورت اتوماتیک، ویژگی‌های مورد نیاز را از روی داده خام (در اینجا تصویر ماموگرافی) یاد گرفته و استخراج می‌کند. به این توانایی، یادگیری ویژگی‌ها می‌گویند.

چندین مطالعه در سال‌های اخیر، بر روی سیستم‌های کمک‌یار ماموگرافی مبتنی بر یادگیری عمیق انجام شده است. به طور مثال، در مطالعه‌ای که به منظور آشکارسازی و دسته‌بندی ضایعات ماموگرام با استفاده از الگوریتم R-CNN انجام شد، AUC برابر ۸۵٪ به دست آمد.<sup>۲۱</sup> از مجموعه دیتای INbreast در این مطالعه برای آموزش و تست مدل استفاده شد.<sup>۲۲</sup> شکل ۶ یک نمونه از تصاویر مجموعه دیتای INbreast را نمایش می‌دهد. این مجموعه دیتا، قابل دسترس برای عموم می‌باشد.



شکل ۶: تصویر پستان چپ با زاویه مایل از مجموعه دیتای INbreast

در این روش به جای آن‌که شبکه CNN به هر زیر-تصویر برای استخراج ویژگی اعمال شود که عملی زمان‌بر است، CNN فقط یک بار به تصویر اصلی اعمال می‌شود و از روی نقشه ویژگی‌های حاصل شده، زیر-تصویرها انتخاب و به لایه‌های تمام وصل شده و Softmax یک CNN برای انتخاب کلاس زیر-تصویرها وارد می‌شوند.

پیشنهاد نواحی در عملکرد Fast R-CNN از نظر زمانی، سرعت الگوریتم را پایین می‌آورد و بر عملکرد آن اثر می‌گذارد. در نسخه Faster R-CNN که در سال ۲۰۱۵ ارایه شد، الگوریتم جست‌وجوی نواحی حذف می‌شود و به جای آن یک شبکه جهت استخراج نواحی از نقشه ویژگی به نام RPN (Region Proposal Network) آموزش داده می‌شود.

شبکه RPN با ابعاد مشخص روی نقشه ویژگی شبکه اولیه، اسکن انجام می‌دهد. در هر گام از اسکن تعداد مشخصی مستطیل ارایه می‌شوند. هر یک از آن‌ها دارای امتیازی هستند که نشان می‌دهد آیا شی درون آن است یا پس‌زمینه تصویر می‌باشد و همزمان مختصات نیز ارایه می‌شود.

در تمام الگوریتم‌های تشخیص ناحیه پیشین، نواحی مورد جست‌وجو با تقسیم شدن و یا اسکن شدن تصویر آشکار می‌شوند. به عبارت دیگر به تصویر یک نگاه کلی نمی‌شود. برخی از نواحی تصویر احتمال بیشتری از حضور شی مورد جست‌وجو دارند.

الگوریتم YOLO یک شبکه CNN است که احتمال کلاس نواحی افزاز شده در تصویر را پیش‌بینی می‌کند.<sup>۱۸</sup>

YOLO یک تصویر را می‌گیرد و آن‌را به یک شبکه  $N \times N$  تقسیم می‌کند. داخل هر شبکه مربع‌هایی که احتمال حضور شی در آن‌ها بیشتر است متصل در نظر گرفته می‌شوند. خروجی یک مستطیل مشخص‌کننده و احتمال کلاسی آن است. محدودیت الگوریتم YOLO در تشخیص اشیای کوچک درون تصویر است که به دلیل محدودیت کارکرد الگوریتم می‌باشد.

نمونه کارهای مرتبط در زمینه ماموگرافی و غربال‌گری سرطان سینه که بر پایه یادگیری عمیق انجام شده است، موید پیشرفت و پاسخ‌های مناسب‌تر نسبت به تکنیک‌های سنتی ML است. مهمترین ضعف روش‌های یادگیری ماشین متداول، گام استخراج دستی و مهندسی ویژگی‌ها است. این ویژگی‌ها ترکیبی از توصیف‌گرهای جست‌وجو و ریاضی می‌باشند. پس از آن ویژگی‌های استخراج شده به یک طبقه‌بند داده می‌شوند تا در کلاس‌های مورد نظر طبقه‌بندی شده، بیان شوند.<sup>۱۹</sup>

است. یک شبکه با ابعاد ورودی و عمق مشخص در صورتی که ابعاد ورودی آن بزرگتر شود نیاز به عمق و اندازه فیلترهای متفاوت دارد.<sup>۳۱</sup> علاوه بر این، صحت و پیش‌پردازش داده و برچسب‌گذاری صحیح از چالش‌های اساسی این حوزه می‌باشد. حجم و تعداد داده مناسب برای داشتن دقت و قدرت تفکیک خوب به پارامترهایی چون تعداد کلاس و کیفیت و تباین ضایعه در تصویر مورد استفاده برای آموزش و نیز ساختار شبکه یادگیری عمیق و تنظیم پارامترهای آن مرتبط است.

آموزش شبکه به شکل نظارت شده انجام می‌شود، یعنی برای آموزش شبکه، باید تصاویر آموزشی، برچسب‌گذاری شوند و در الگوریتم‌های ناحیه، محل قرار گرفتن ضایعه مشخص شده باشند. این کار، باید توسط رادیولوژیست مجرب انجام شود تا شبکه بر مبنای اطلاعات درست آموزش داده شود. نوع تصاویر ماموگرافی و کیفیت دستگاه می‌تواند موثر بر نتایج باشد.

تا پیش از سال ۲۰۰۰ میلادی مرجع اصلی داده تحقیقات یادگیری ماشین در حوزه ماموگرافی و سرطان پستان، DDSM بود. این تصاویر اسکن شده کلیشه‌های ماموگرافی هستند که در مقایسه با تصاویر دیجیتال که امروزه وجود دارند، کیفیت بسیار پایین‌تری دارند. به‌طور طبیعی دقت شبکه در تشخیص سرطان در تصاویر با کیفیت افزایش می‌یابد. مرحله پیشرفت سرطان در صحت تشخیص سیستم اثرگذار است، چراکه هر چقدر سرطان پیشرفته‌تر باشد، ضایعات سرطانی بزرگ‌تر هستند و تشخیص آن‌ها در عکس راحت‌تر است. برای تشخیص زود هنگام سرطان با دقت بالا، شبکه برای آموزش به تصاویر ماموگرافی زیادی در مراحل اولیه سرطان نیاز دارد. در ستون تعداد تصاویر در جدول ۱، حجم دیتا در مطالعه‌های پیشین مشخص شده است. طبیعتاً هر چقدر حجم داده بیشتر باشد، شبکه بهتر آموزش داده می‌شود و به‌نظر می‌رسد که برای آموزش شبکه‌ای که بتواند انواع مختلفی از سرطان را شناسایی کند به هزاران تصویر برای آموزش نیاز دارد. مهمترین چالش، نبود یک مجموعه دیتای بزرگ و جامع در دسترس عموم می‌باشد. ایجاد این مجموعه دیتا، نیاز به ساعت‌ها کار یک یا چند رادیولوژیست برای برچسب‌گذاری داده‌ها دارد. با ایجاد چنین مجموعه دیتایی، و آموزش یک شبکه عمیق بر روی آن، می‌توان به یک سیستم کمک‌یار قدرتمند دست یافت. این هدف، کانون تمرکز تحقیقات پیش رو می‌باشد.

ضایعات منجر به سرطان پستان در ماموگرام دارای مورفولوژی محدود و مشخص هستند. تغییرات بدون ملاحظه در مرحله پیش‌پردازش باعث تغییر نامناسب در خروجی فیلترهای لایه شبکه آموزش و نهایتاً تغییر اشتباه کلاس خواهد شد. مقایسه منطقی و مناسب نتایج نیاز به دیتای یکسان و مشترک دارد.

در سال ۲۰۱۸ در دانشگاه استنفورد، Esteva و همکاران، یک روشی مبتنی بر CNN که بر روی ۱۳۰۰۰۰ داده تصویری که از بیمارستان‌های مختلف در آمریکا جمع‌آوری شده بود و آموزش داده شده بود را ارائه دادند. عملکرد این سیستم در تشخیص ضایعات سرطانی به دقتی بالاتر از تشخیص ۲۱ رادیولوژیست شرکت‌کننده در این مطالعه دست یافت.<sup>۳۳</sup>

اهمیت این مطالعه به این دلیل است که حجم دیتای مورد استفاده در این آزمایش، دو برابر مجموعه داده‌های کارهای پیشین بود. از آنجا که دقت CNN با افزایش حجم دیتا به شکل چشمگیری افزایش می‌یابد، این مطالعه نشان داد که با آموزش سیستم بر روی حجم مناسبی از داده، می‌توان به دقتی بالاتر از رادیولوژیست دست یافت. متأسفانه، داده‌های این مطالعه در دسترس عموم قرار ندارد.

همچنین در سال ۲۰۱۹، Shen L. و همکاران با ارائه یک الگوریتم مبتنی بر CNN که بر روی مجموعه دیتای DDSM آموزش دیده بود، توانستند به AUC برابر ۰/۸۸ دست یابند.<sup>۲۴</sup>

هم‌اکنون، مجموعه داده DDSM مهمترین مجموعه داده ماموگرافی است که شامل ۲۶۰۰ تصویر می‌باشد و در دسترس عموم قرار دارد. مقایسه مستقیم نتایج برای تحقیقات انجام شده در حوزه هوش مصنوعی ماموگرافی و سرطان پستان صحیح نیست. علت اصلی آن عدم یکسان بودن مجموعه داده تصویر و مرجع اعتبارسنجی است.

در جدول ۱ سعی شده با ایجاد عنوان ستون‌های مدل شبکه عمیق، تعداد مجموعه داده تصویر، عملکرد روش، نوع نمونه ضایعه، نام مجموعه داده، نوع اعتبارسنجی و مرجع استاندارد، یک مقایسه کلی از مطالعات پیشین ارائه شود.

با توجه به نوع کاربردی که از یک شبکه یادگیری عمیق انتظار می‌رود طراحی ساختار آن متفاوت است. به‌عنوان مثال در مواردی که ابعاد تصویر بزرگ می‌باشد و ضایعه مورد جست‌وجو کوچک، به داده بیشتر و عمق و ابعاد فیلترهای بزرگتر جهت داشتن دقت مناسب‌تر نیاز

جدول ۱: مطالعه‌های انجام شده سیستم‌های یادگیری عمیق در ماموگرافی

عنوان مطالعه	سال مطالعه	مدل شبکه عمیق	تعداد تصاویر	عملکرد	نوع نمونه مورد بررسی	مجموعه دیتا تست و آموزش
Automated classification of malignant and benign breast cancer lesions using neural networks on digitized mammograms <sup>25</sup>	۲۰۱۹	CNN	۱۱۸	دقت ۹۵٪	کلسیفیکیشن و توده	گزارش نشده
Classification of mammogram images using multi-scale all convolutional neural network (MA-CNN) <sup>26</sup>	۲۰۲۰	Multi-Scale CNN	۳۲۲	حساسیت ۹۹٪ AUC ۹۶٪	کلسیفیکیشن	Mini-MIAS
Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system <sup>27</sup>	۲۰۱۸	YOLO	۴۱۰	دقت ۹۷٪	توده	INbreast
Detection and classification of the breast abnormalities in digital mammograms via regional convolutional neural network <sup>28</sup>	۲۰۱۷	Faster R-CNN	۱۷۰	دقت ۸۵٪	توده	Multi-Center Hospital Data Set
Detection and classification the breast tumors using mask R-CNN on sonograms <sup>29</sup>	۲۰۱۹	Mask R-CNN	۶۱	دقت ۸۵٪	کلسیفیکیشن	China Medical University Hospital
Detection and characterization of MRI breast lesions using deep learning <sup>30</sup>	۲۰۱۹	ResNet50	۱۶۸	AUC ۸۱٪	کلسیفیکیشن و توده	Journees Francophones de Radiologie ۲۰۱۸
Automatic mass detection in mammograms using deep convolutional neural networks <sup>31</sup>	۲۰۱۹	VGG16 ResNet50	۲۰۰۰	TPR/۹۸	توده	INbreast CBIS-DDSM
Deeplima: Deep learning based lesion identification in mammograms <sup>32</sup>	۲۰۱۹	Faster R-CNN Feature Pyramid Network	۲۴۱۰	TPR/۹۷	کلسیفیکیشن و توده	INbreast CBIS-DDSM in House
Deep learning for mass detection in full field digital mammograms <sup>33</sup>	۲۰۲۰	Faster R-CNN	۸۰۰۰	TPR/۹۳	توده	OPTIMAM
Breast mass detection in mammography based on image template matching and CNN <sup>34</sup>	۲۰۲۱	CNN PSO	۲۶۲۰	دقت ۸۵٪	توده	DDSM
Inconsistent performance of deep learning models on mammogram classification <sup>35</sup>	۲۰۲۰	Tree CNN Model	۳۴۰۰	AUC/۸۸	کلسیفیکیشن و توده	DDSM INbreast MIAS
Deep learning to improve breast cancer detection on screening mammography. <sup>24</sup>	۲۰۱۹	CNN	۲۶۲۰	AUC/۹۱	کلسیفیکیشن و توده	CBIS-DDSM

برچسب‌گذاری صحیح از چالش‌های اساسی این حوزه می‌باشد. حجم و تعداد داده مناسب برای داشتن دقت و قدرت تفکیک خوب به پارامترهایی چون تعداد کلاس، کیفیت و تفاوت ضایعه در تصویر مورد استفاده برای آموزش و نیز ساختار شبکه یادگیری عمیق و تنظیم پارامترهای آن مرتبط است. آموزش شبکه به شکل نظارت شده انجام می‌شود، یعنی برای آموزش شبکه، باید تصاویر آموزشی، برچسب‌گذاری شوند و در الگوریتم‌های ناحیه، محل قرار گرفتن

با توجه به نوع کاربردی که از یک شبکه یادگیری عمیق انتظار می‌رود طراحی ساختار آن متفاوت است. به‌عنوان مثال در مواردی که ابعاد تصویر بزرگ می‌باشد و ضایعه مورد جست‌وجو کوچک، به داده بیشتر و عمق و ابعاد فیلترهای بزرگ‌تر جهت داشتن دقت مناسب‌تر نیاز است. یک شبکه با ابعاد ورودی و عمق مشخص در صورتی که ابعاد ورودی آن بزرگ‌تر شود نیاز به عمق و اندازه فیلترهای متفاوت دارد.<sup>۳۶</sup> علاوه بر این صحت و پیش‌پردازش داده و

چراکه هر چقدر سرطان پیشرفته‌تر باشد، ضایعات سرطانی بزرگتر هستند و تشخیص آن‌ها در عکس راحت‌تر است. برای تشخیص زودهنگام سرطان با دقت بالا، شبکه برای آموزش به تصاویر ماموگرافی زیادی در مراحل اولیه سرطان نیاز دارد. در ستون تعداد تصاویر در جدول ۱، حجم دیتا در مطالعات پیشین مشخص شده است. طبیعتاً هر چقدر حجم داده بیشتر باشد، شبکه بهتر آموزش داده می‌شود و به‌نظر می‌رسد که برای آموزش شبکه‌ای که بتواند انواع مختلفی از سرطان را شناسایی کند به هزاران تصویر برای آموزش نیاز دارد.

ضایعه مشخص شده باشند. این کار، باید توسط رادیولوژیست مجرب انجام شود تا شبکه بر مبنای اطلاعات درست آموزش داده شود. نوع تصاویر ماموگرافی و کیفیت دستگاه می‌تواند موثر بر نتایج باشد. تا پیش از سال ۲۰۰۰ میلادی مرجع اصلی داده تحقیقات یادگیری ماشین در حوزه ماموگرافی و سرطان پستان، DDSM است. این تصاویر اسکن شده کلیشه‌های ماموگرافی هستند که در مقایسه با تصاویر دیجیتال که امروزه وجود دارند، کیفیت بسیار پایین‌تری دارند. به‌طور طبیعی دقت شبکه در تشخیص سرطان در تصاویر با کیفیت افزایش می‌یابد. مرحله پیشرفت سرطان در صحت تشخیص سیستم اثرگذار است،

جدول ۲: واژه‌های معادل

معادل	واژه انگلیسی
هوش مصنوعی	Artificial intelligence (AI)
ناحیه زیر منحنی	Area under curve (AUC)
جعبه مشخص‌کننده	Bounding box
سیستم کمک‌یار	Computer aided detection (CAD)
شبکه عصبی کانولوشنال	Convolutional neural network (CNN)
کلسیفیکیشن	Calcification
طبقه‌بند	Classifier
سیستم کمک‌یار آشکارسازی	Computer aided detection (CADe)
سیستم کمک‌یار تشخیصی	Computer aided diagnosis (CADx)
یادگیری عمیق	Deep learning (DL)
افزایش مصنوعی داده‌ها	Data Augmentation
DDSM	Digital database for screening mammography
تمام متصل شده	Fully-connected
مهندسی ویژگی	Feature engineering
یادگیری ویژگی‌ها	Feature learning
لایه میانی یا پنهان	Hidden layer
ضایعه	Lesion
یادگیری ماشین	Machine learning (ML)
توده	Mass
شبکه پیشنهاد نواحی	Region proposal network (RPN)
شبکه یادگیری عمیق مبتنی بر ناحیه	Region-based CNN (R_CNN)
ماشین بردار پشتیبان	Support vector machine (SVM)
نظارت شده	Supervised
انتقال یادگیری	Transfer learning

را با کمک رایانه تغییر داده است و آنرا اساسا از روش‌های سنتی متمایز می‌کند. در مواردی که روش‌های سنتی در ماموگرافی مناسب عمل نمی‌کرد، سیستم‌های جدید که از الگوریتم‌های یادگیری عمیق بهره می‌برند، عملکرد موفق‌تری دارند. با این وجود، آموزش دقیق، و سنجش عملکرد بر روی مجموعه داده‌های بزرگ برای اطمینان از موفقیت بالینی این برنامه‌ها ضروری است. سیستم‌های کمک‌یار جدید می‌توانند نحوه مراقبت از بیماران را تغییر دهند و در نتیجه، سطح خدمات سلامت، توسعه بیشتری خواهد داشت.

مهمترین چالش، نبود یک مجموعه دیتای بزرگ و جامع در دسترس عموم می‌باشد. ایجاد این مجموعه دیتا، نیاز به ساعت‌ها کار یک یا چند رادیولوژیست برای برچسب‌گذاری داده‌ها دارد. با ایجاد چنین مجموعه دیتایی، و آموزش یک شبکه عمیق بر روی آن، می‌توان به یک سیستم کمک‌یار قدرتمند دست یافت. این هدف، کانون تمرکز تحقیقات پیش رو می‌باشد.

نتیجه‌گیری: ماموگرافی در لبه توسعه سیستم‌های کمک‌یار قرار گرفته است. الگوریتم‌های یادگیری عمیق تجزیه و تحلیل ماموگرافی

## References

- Hamidinekoo A, Denton E, Rampun A, Honnor K, Zwiggelar R. Deep learning in mammography and breast histology, an overview and future trends. *Med Image Analysis* 2018;47:45-67.
- Rakhlin A, Shvets A, Iglovikov V, Kalinin AA, editors. Deep convolutional neural networks for breast cancer histology image analysis. International Conference Image Analysis and Recognition; 2018: Springer.
- Elmore JG, Jackson SL, Abraham L, Miglioretti DL, Carney PA, Geller BM, et al. Variability in interpretive performance at screening mammography and radiologists' characteristics associated with accuracy. *Radiology* 2009;253(3):641-51.
- Hamidinekoo A, Suhail Z, Qaiser T, Zwiggelar R, editors. Investigating the effect of various augmentations on the input data fed to a convolutional neural network for the task of mammographic mass classification. Annual Conference on Medical Image Understanding and Analysis; 2017: Springer.
- Mathew J, Perkins GH, Stephens T, Middleton LP, Yang W-T. Primary breast cancer in men: clinical, imaging, and pathologic findings in 57 patients. *Am J Roentgenol* 2008;191(6):1631-9.
- Pisano ED, Gatsonis C, Hendrick E, Yaffe M, Baum JK, Acharyya S, et al. Diagnostic performance of digital versus film mammography for breast-cancer screening. *New Engl J Med* 2005;353(17):1773-83.
- Keen JD, Keen JM, Keen JE. Utilization of computer-aided detection for digital screening mammography in the United States, 2008 to 2016. *J Am Coll Radiol* 2018;15(1):44-8.
- Malek M, Gity M, Alidoosti A, Oghabian Z, Rahimifar P, Ebrahimi SMS, et al. A machine learning approach for distinguishing uterine sarcoma from leiomyomas based on perfusion weighted MRI parameters. *Eur J Radiol* 2019;110:203-11.
- Lotfollahi M, Gity M, Ye JY, Far AM. Segmentation of breast ultrasound images based on active contours using neutrosophic theory. *J Med Ultrason* 2018;45(2):205-12.
- Sahba N, Tavakoli V, Ahmadian A, Giti M, editors. Mammography mass detection: a multi-stage hybrid approach. Medical Imaging 2009: Image Processing; 2009: International Society for Optics and Photonics.
- Ameri A, Akhaee MA, Scheme E, Englehart K. A deep transfer learning approach to reducing the effect of electrode shift in EMG pattern recognition-based control. *IEEE Trans Neural Syst Rehabil Eng* 2019;28(2):370-9.
- Ameri A, Akhaee MA, Scheme E, Englehart K. Regression convolutional neural network for improved simultaneous EMG control. *J Neural Eng* 2019;16(3):036015.
- Research CI. Healthcare remains the hottest AI category for deals. 2017.
- McBee MP, Awan OA, Colucci AT, Ghobadi CW, Kadom N, Kansagra AP, et al. Deep learning in radiology. *Acad Radiol* 2018;25(11):1472-80.
- Geras KJ, Wolfson S, Shen Y, Wu N, Kim S, Kim E, et al. High-resolution breast cancer screening with multi-view deep convolutional neural networks. *arXiv preprint arXiv:170307047* 2017.
- Girshick R, Donahue J, Darrell T, Malik J, editors. Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the IEEE conference on computer vision and pattern recognition; 2014.
- Girshick R, editor Fast r-cnn. Proceedings of the IEEE international conference on computer vision; 2015.
- Redmon J, Divvala S, Girshick R, Farhadi A, editors. You only look once: Unified, real-time object detection. Proceedings of the IEEE conference on computer vision and pattern recognition; 2016.
- Aichert A, editor Feature extraction techniques. Camp Medical Seminar ws0708; 2008.
- Ghosh N, Agrawal S, Motwani M, editors. A Survey of Feature Extraction for Content-Based Image Retrieval System. Proceedings of International Conference on Recent Advancement on Computer and Communication; 2018: Springer.
- Ribli D, Horváth A, Unger Z, Pollner P, Csabai I. Detecting and classifying lesions in mammograms with deep learning. *Sci Rep* 2018;8(1):1-7.
- Moreira IC, Amaral I, Domingues I, Cardoso A, Cardoso MJ, Cardoso JS. Inbreast: toward a full-field digital mammographic database. *Acad Radiol* 2012;19(2):236-48.
- Esteve A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *nature*. 2017;542(7639):115-8
- Shen L, Margolies LR, Rothstein JH, Fluder E, McBride R, Sieh W. Deep learning to improve breast cancer detection on screening mammography. *Sci Rep* 2019;9(1):1-12.
- Abdelsamea MM, Mohamed MH, Bamatraf M. Automated classification of malignant and benign breast cancer lesions using neural networks on digitized mammograms. *Cancer Inform* 2019;18:1176935119857570.
- Agnes SA, Anitha J, Pandian SIA, Peter JD. Classification of mammogram images using multiscale all convolutional neural network (MA-CNN). *J Med Syst* 2020;44(1):1-9.
- Al-Masni MA, Al-Antari MA, Park J-M, Gi G, Kim T-Y, Rivera P, et al. Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system. *Comput Methods Programs Biomed* 2018;157:85-94.
- Al-masni MA, Al-antari MA, Park J, Gi G, Kim T-Y, Rivera P, et al. editors. Detection and classification of the breast abnormalities

- in digital mammograms via regional convolutional neural network. 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 2017: IEEE.
29. Chiao JY, Chen KY, Liao KY, Hsieh PH, Zhang G, Huang TC. Detection and classification the breast tumors using mask R-CNN on sonograms. *Medicine* 2019;98(19):e15200.
  30. Herent P, Schmauch B, Jehanno P, Dehaene O, Saillard C, Balleyguier C, et al. Detection and characterization of MRI breast lesions using deep learning. *Diagn Interv Imaging* 2019;100(4):219-25.
  31. Agarwal R, Diaz O, Lladó X, Yap MH, Martí R. Automatic mass detection in mammograms using deep convolutional neural networks. *J Med Imaging* 2019;6(3):031409.
  32. Cao Z, Yang Z, Zhuo X, Lin R-S, Wu S, Huang L, et al. editors. Deeplima: Deep learning based lesion identification in mammograms. Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops; 2019.
  33. Agarwal R, Díaz O, Yap MH, Lladó X, Martí R. Deep learning for mass detection in Full Field Digital Mammograms. *Comput Biol Med* 2020;121:103774.
  34. Sun L, Sun H, Wang J, Wu S, Zhao Y, Xu Y. Breast Mass Detection in Mammography Based on Image Template Matching and CNN. *Sensors* 2021;21(8):2855.
  35. Wang X, Liang G, Zhang Y, Blanton H, Bessinger Z, Jacobs N. Inconsistent performance of deep learning models on mammogram classification. *J Am Coll Radiol* 2020;17(6):796-803.
  36. Tan M, Le Q, editors. Efficientnet: Rethinking model scaling for convolutional neural networks. International Conference on Machine Learning; 2019: PMLR.

## Deep learning-based CAD systems for mammography: review article

Ali Ameri Ph.D.<sup>1</sup>  
 Mahmoud Shiri M.Sc.<sup>1\*</sup>  
 Masoumeh Gity M.D.<sup>2</sup>  
 Mohammad Ali Akhaee Ph.D.<sup>3</sup>

1- Department of Biomedical Engineering, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran.  
 2- Department of Radiology, School of Medicine, Tehran University of Medical Sciences, Tehran, Iran.  
 3- Department of Electrical Engineering, University of Tehran, Tehran, Iran.

\* Corresponding author: Department of Biomedical Engineering, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran.  
 Tel: +98-21-22439941  
 E-mail: m.shiri@sbmu.ac.ir

### Abstract

Received: 10 Apr. 2021 Revised: 17 Apr. 2021 Accepted: 16 Jul. 2021 Available online: 23 Jul. 2021

Breast cancer is one of the most common types of cancer in women. Screening mammography is a low-dose X-ray examination of breasts, which is conducted to detect breast cancer at early stages when the cancerous tumor is too small to be felt as a lump. Screening mammography is conducted for women with no symptoms of breast cancer, for early detection of cancer when the cancer is most treatable and consequently greatly reduce the death rate from the breast cancer. Screening mammography should be performed every year for women age 45-54, and every two years for women age 55 and older who are in good health. A mammogram is read by a radiologist to diagnose cancer. To assist radiologists in reading mammograms, computer-aided detection (CAD) systems have been developed which can identify suspicious lesions on mammograms. CADs can improve the accuracy and confidence level of radiologists in decision making and have been approved by FDA for clinical use. Traditional CAD systems work based on conventional machine learning (ML) and image processing algorithms. With recent advances in software and hardware resources, a great breakthrough in deep learning (DL) algorithms was followed, which revolutionized various engineering areas including medical technologies. Recently, DL models have been applied in CAD systems in mammograms and achieved outstanding performance. In contrast to conventional ML, DL algorithms eliminate the need for the tedious task of human-designed feature engineering, as they are capable of learning useful features automatically from the raw data (mammogram). One of the most common DL frameworks is the convolutional neural network (CNN). To localize lesions in a mammogram, a CNN should be applied in region-based algorithms such as R-CNN, Fast R-CNN, Faster R-CNN, and YOLO. Proper training of a DL-based CAD requires a large amount of annotated mammogram data, where cancerous lesions have been marked by an experienced radiologist. This highlights the importance of establishing a large, annotated mammogram dataset for the development of a reliable CAD system. This article provides a brief review of the state-of-the-art techniques for DL-based CAD in mammography.

**Keywords:** breast cancer, CAD, deep learning (DL), mammography.

Copyright © 2021 Ameri et al.



This work is licensed under a Creative Commons Attribution-Non-Commercial 4.0 International license (<https://creativecommons.org/licenses/by-nc/4.0/>). Non-commercial uses of the work are permitted, provided the original work is properly cited.