



بررسی و مقایسه عملکرد شبکه‌های کانولوشنی و شبکه‌های عمیق در تشخیص و طبقه‌بندی سرطان پستان با استفاده از تصاویر ترموگرافی

عاطفه نورمحمدی^۱، منوچهر نحوی^۲

^۱دانشگاه گیلان

Atefehnm185@gmail.com

^۲دانشگاه گیلان،

Nahvi@guilan.ac.ir

صدها هزار بیمار در سراسر جهان می‌شود [۲] مطالعات نشان داده است که تشخیص این بیماری در مراحل اولیه، زمانی که اندازه تومور کمتر از ۱۰ mm است، با احتمال ۹۸ درصد موجب نجات جان بیمار و درمان او می‌شود. [۴]. از این رو در سراسر جهان همواره بر غربالگری منظم خانم‌ها برای شناسایی زودهنگام بیماری تاکید می‌شود، غالباً در غربالگری‌ها، زمانی که اندازه تومور ۲۰ mm است سرطان تشخیص داده می‌شود که در این حالت نیز احتمال درمان بیماری ۷۰ درصد است [۶].

در حال حاضر، تصویربرداری ماموگرافی به عنوان روش غربالگری استاندارد و برتر جهت تشخیص زودهنگام بیماری شناخته شده است [۸]. با این حال روش ماموگرافی یک روش تهاجمی و با استفاده از اشعه x-ray است و انجام مکرر آن می‌تواند خود سبب افزایش احتمال بروز سرطان سینه شود [۱۰]. علاوه بر این مطالعات نشان داده است که تشخیص سرطان با این روش، در سینه با بافت متراکم و فیبروکیستیک بسیار دشوار است زیرا برای تشخیص موثر، تراکم بافت توده باید بیش‌تر از بافت اطراف آن باشد بنابراین، این روش بیشتر در خانوم‌های بالای ۴۵ سال موثر است [۸]. تصویربرداری حرارتی به عنوان یک روش کم‌هزینه، کاملاً غیرتهاجمی و بدون درد، می‌تواند جهت غربالگری مداوم و حتی خود غربالگری و تشخیص زودهنگام بیماری مورد استفاده قرار گیرد [۸، ۱۱]. تحقیقات در این زمینه هنوز در مراحل ابتدایی است و نتایج نسبت به نتایج حاصل از تصاویر ماموگرافی ضعیف‌تر بوده است و غالباً تنها به طبقه‌بندی تصاویر به دو کلاس سالم و سرطانی پرداخته شده است [۹، ۱۲] و طبقه‌بندی جزئی‌تر، کم‌تر

چکیده- امروزه با پیشرفت تکنولوژی و کاهش هزینه‌های تصویربرداری ترموگرافی، استفاده از این روش تصویربرداری در تشخیص زودهنگام سرطان مورد توجه قرار گرفته است. با این وجود هنوز پایگاه‌های داده استاندارد و در اختیار عموم در این زمینه محدود است. در این مقاله با استخراج حداکثر اطلاعات از پایگاه‌داده عمومی DMR و به کارگیری شبکه‌های عمیق از پیش آموزش‌دیده و بهینه‌سازی شبکه‌های کانولوشنی ساده، کارایی تصاویر ترموگرافی در تشخیص سرطان و طبقه‌بندی بیمارانی به سه دسته سالم، خوش‌خیم و بدخیم مورد آزمایش قرار داده شده است. طبقه‌بندی به سه دسته بر روی این پایگاه‌داده برای اولین بار انجام شده است. در این مقاله با رفع مشکل بیش‌برازش ناشی از مشابهت در داده‌ها و انجام آزمایش روی حداکثر تصاویر موجود در این پایگاه‌داده نتایج آزمایشات صحت ۹۳/۷۵٪ برای طبقه‌بندی به دو گروه سالم و ناسالم و صحت حداکثر ۸۳٪ در طبقه‌بندی به سه گروه را نشان می‌دهد. اگرچه نتایج بدست آمده ضعیف‌تر از نتایج ارائه شده در برخی مطالعات است اما در این پژوهش نتایج بر روی بخش وسیع‌تری از پایگاه‌داده نسبت به سایر کارها مورد تست قرار داده شده است و تقسیم‌بندی صحیح، قابلیت اطمینان نتایج را افزایش داده است.

کلمات کلیدی- تصاویر ترموگرافی، سرطان پستان، شبکه‌های عمیق، طبقه‌بندی، یادگیری انتقالی

۱. مقدمه

بنا به گزارش سازمان بهداشت جهانی، سرطان پستان شایع‌ترین سرطان در بین زنان است و سالانه این بیماری باعث مرگ



تصاویر هستند. با این وجود این دسته از روش‌ها دارای محدودیت‌هایی نیز هستند، مانند نیاز به سخت‌افزار قوی جهت تنظیم پارامترها و آموزش شبکه، و پایگاه داده گسترده جهت آموزش به منظور دستیابی به بهترین عملکرد این شبکه‌ها. با توجه به این محدودیت‌ها تاکنون مقالات محدودی در این زمینه ارائه شده‌است و نتایج ارائه شده هنوز کامل نیستند. بر این اساس در این پژوهش با استخراج حداکثر اطلاعات موجود در پایگاه داده عمومی DMR و تنظیم پارامترهای شبکه کانولوشنی با تعداد لایه‌های محدود و استفاده از شبکه‌های کانولوشنی عمیق به عنوان استخراج‌گر ویژگی، کارایی هر یک از این ساختارهای کانولوشنی برای دو هدف طبقه‌بندی دودویی و طبقه‌بندی سه‌کلاسه بیماران براساس تصاویر ترموگرافی مورد بررسی قرار داده شده‌است.

2. شبکه‌های کانولوشنی

شبکه‌های کانولوشنی از دو بخش لایه‌های استخراج‌گر ویژگی و لایه‌های تمام متصل تشکیل می‌شوند. بخش اول متشکل از بلوک‌های کانولوشنی است که در آن‌ها از لایه‌های کانولوشنی، فعال‌ساز و ادغام استفاده می‌شود. در هر لایه کانولوشنی تعدادی فیلتر با ابعاد مشخص در نظر گرفته می‌شود و خروجی از کانولوشن ورودی با فیلترها محاسبه می‌شود رابطه زیر نحوه اعمال عملگر کانولوشنی را به صورت ریاضی نمایش می‌دهد [۵]:

$$F_{i'j'k'} = \sum_{ijk} w_{ijk} x_{i+i'', j+j'', k} \quad (1)$$

در این رابطه x ورودی لایه کانولوشنی است، $F_{i'j'k'}$ خروجی لایه کانولوشنی و یک داده سه بعدی است که به آن نقشه ویژگی نیز گفته می‌شود، w بانک فیلتر و یک داده ۴ بعدی و k' نشان‌دهنده شماره فیلتر است. خروجی لایه کانولوشنی معمولاً به یک تابع غیرخطی داده می‌شود. استفاده از تابع یکسوساز در بخش استخراج‌گر ویژگی مرسوم‌تر است و در این پژوهش نیز از این تابع استفاده شده‌است. در انتهای بلوک کانولوشنی معمولاً یک لایه ادغام قرار داده می‌شود که می‌تواند بصورت ادغام حداکثر و یا ادغام میانگین تعریف شود. هدف از این لایه کاهش ابعاد نقشه ویژگی خروجی و کاهش احتمال بیش‌برازش است. خروجی لایه ادغام حداکثر، بصورت زیر تعریف می‌شود [۵]:

$$F'_{ijk} = \max\{F_{i',j',k} : i \leq i' \leq i+p, j \leq j' \leq j+p\} \quad (2)$$

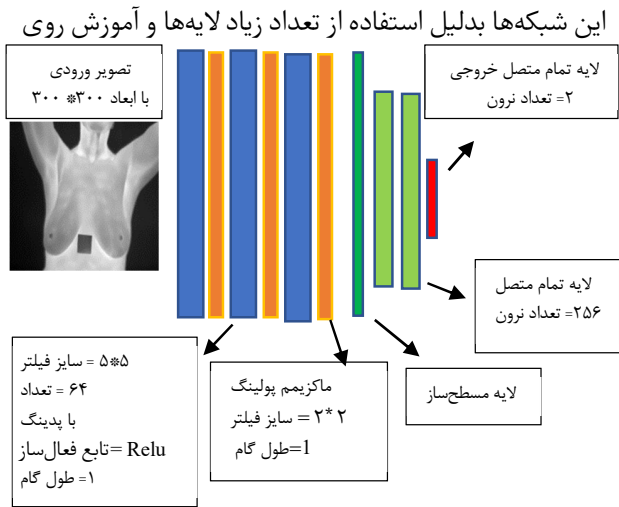
که در آن p نشان‌دهنده سایز فیلتر ادغام است.

نقشه ویژگی بدست‌آمده از بخش اول که بصورت یک تانسور سه بعدی است ابتدا توسط یک لایه مسطح‌ساز به یک بردار ویژگی

مورد توجه قرار داده شده‌است. روش‌های ارائه شده در زمینه طبقه‌بندی دودویی به دو گروه سالم و ناسالم به دو دسته تقسیم می‌شوند که عبارتند از روش‌های مبتنی بر استخراج ویژگی‌های دستی به خصوص ویژگی‌های آماری و روش‌های مبتنی بر شبکه‌های عصبی کانولوشنی ساده و عمیق [۱۳]. در مطالعات انجام شده در روش‌های دسته اول صحت حداکثر ۹۶٪ [۱] و برای روش‌های دسته دوم صحت حداکثر ۱۰۰ درصد [۹] بر روی پایگاه داده عمومی DMR ارائه شده‌است. با وجود اینکه این روش‌ها روی پایگاه داده عمومی، تست شده‌است اما در مقالات مختلف از حجم متفاوتی از این پایگاه داده استفاده شده‌است. علاوه بر این در اکثر روش‌های مبتنی بر شبکه‌های عصبی کانولوشنی ساده و عمیق، از هر ۲۰ تصویر موجود در هر پرونده استفاده شده‌است [۹] اما توضیح دقیقی درخصوص نحوه تقسیم‌بندی داده‌ها در آن‌ها ارائه نشده‌است. در صورتی که تقسیم‌بندی بصورت تصادفی روی تمامی تصاویر انجام شود، این امر موجب همپوشانی مجموعه‌های تست و آموزش شده و اعتبار نتایج را درخصوص پرونده‌های جدید از بین می‌برد، این امر در [۱۳] نشان داده شده‌است. در [۹] از یادگیری انتقالی روی انواع شبکه‌های از پیش آموزش دیده استفاده شده است اما به وضوح توضیح داده نشده است که چه تعداد از لایه‌های این شبکه‌ها تحت آموزش مجدد روی پایگاه داده ترموگرافی قرار داده شده است. در [۵] نیز عملکرد سه ساختار عمیق کانولوشنی Goolenet [۱۴]، VGG16 [۱۵] و Resnet [۱۶] در طبقه‌بندی تصاویر ترموگرافی مورد بررسی قرار داده شده‌است. در روش ارائه شده در [۵] تنها لایه آخر شبکه‌های از پیش آموزش دیده با یک لایه تمام متصل دارای ۲ نرون جایگزین شده‌است و تنها این لایه با داده‌های ترموگرافی آموزش داده شده‌است. در آموزش و تست این شبکه‌ها به تعادل تعداد داده‌های گروه‌های سالم و ناسالم توجه نشده‌است به همین دلیل معیار حساسیت بدست آمده در این روش پایین و برابر با ۶۵/۴۸ بوده‌است.

در میان روش‌های استخراج ویژگی، ویژگی‌های آماری و انواع ویژگی‌های بافتی در مقالات زیادی مورد توجه قرار گرفته است [۸]. در مقالات اخیر انواع توصیف‌گرهای بافت و لبه برای استخراج ویژگی‌ها پیشنهاد شده‌است مانند [۱، ۱۷]. اما این ویژگی‌ها به شدت تحت تاثیر نویز و ناهمگونی تصاویر هستند.

روش‌های مبتنی بر شبکه‌های کانولوشنی در زمینه طبقه‌بندی تصاویر ترموگرافی پستان در سال‌های اخیر بیشتر مورد توجه قرار گرفته است. بطور کلی شبکه‌های کانولوشنی و کانولوشنی عمیق به دلیل استفاده از فیلترهای مختلف در لایه‌های متعدد و یادگیری وزن‌های بهینه برای فیلترها قادر به استخراج ویژگی‌های عمیق در



شکل ۱: ساختار و پارامترهای شبکه کانولوشنی مورد استفاده

پایگاه‌های داده عظیم قادر به استخراج ویژگی‌های عمیق در تصاویر هستند که این امر موجب دقت و قدرت بالای آن‌ها در طبقه‌بندی تصاویر می‌شود. آموزش مجدد و استفاده از این شبکه‌ها برای کاربردهای مختلف طبقه‌بندی تصاویر نیازمند وجود پایگاه‌های داده عظیم است که در بسیاری از موارد چنین پایگاه داده‌ای وجود ندارد و علاوه بر این تهیه سخت‌افزار مورد نیاز برای بازآموزی این شبکه‌ها نیز هزینه‌بر است. براین اساس روش‌های یادگیری انتقالی و استفاده از این شبکه‌ها به عنوان استخراج‌گر ویژگی پیشنهاد شده‌است. در روش‌های یادگیری انتقالی لایه آخر شبکه‌ها که مربوط به طبقه‌بندی تصاویر است با لایه یا لایه‌های مورد نیاز جایگزین می‌شود و برای بخش بزرگی از این شبکه‌ها از وزن‌های بدست آمده روی پایگاه داده عظیم مانند ImageNet [۱۸] بصورت ثابت استفاده می‌شود و بخش دیگر شبکه روی پایگاه داده جدید آموزش می‌بیند. در این پژوهش از شبکه‌های بسیار عمیق آموزش دیده Resnet50 [۱۶]، Mobilnetv2 [۱۹] و VGG16 [۱۵] به عنوان لایه استخراج‌گر ویژگی استفاده شده‌است و لایه آخر این شبکه‌ها با یک لایه مسطح‌ساز از نوع ادغام میانگین سراسری و سه لایه تماماً متصل جایگزین شده‌است. لایه‌های تمام‌متصل بصورت دو لایه با تعداد ۱۰۲۴ نرون و لایه آخر با تعداد دو نرون برای طبقه‌بندی دودویی و سه نرون برای طبقه‌بندی سه کلاس در نظر گرفته شده‌است. و در فرایند آموزش تنها بخش طبقه‌بندی که به شبکه‌های عمیق اضافه شده‌است روی پایگاه داده ترموگرافی آموزش داده شده‌است.

شبکه VGG جز اولین ساختارهای عمیق موفق ارائه شده‌است که به دلیل ساختار خوب، سادگی و تعداد لایه‌های کم‌تر نسبت به سایر ساختارها هنوز هم در بسیاری از کاربردها مورد توجه

تبدیل می‌شود و سپس جهت طبقه‌بندی به بخش دوم داده می‌شود. بخش دوم شبکه‌های کانولوشنی لایه‌هایی با نرون‌های تماماً متصل هستند که کار طبقه‌بندی را براساس بردار ویژگی انجام می‌دهند. تعداد نرون لایه آخر این بخش در طبقه‌بندی دودویی بصورت یک و یا دو نرون و در طبقه‌بندی چند کلاس برابر با تعداد کلاس‌ها در نظر گرفته می‌شود. در صورتی که در لایه آخر بیش از یک نرون داشته باشیم از تابع غیرخطی بیشینه هموار به عنوان تابع فعال‌ساز نرون‌ها استفاده می‌شود. در نهایت خروجی نشان دهنده احتمال تعلق ورودی به کلاس‌های مختلف است.

تاکنون روش‌های مختلفی برای بهینه‌سازی وزن‌های شبکه پیشنهاد شده‌است که از جمله پرکاربردترین آنها روش گرادینت نزولی تصادفی و نسخه تعمیم‌یافته آن روش آدم است. در زیر رابطه بهینه‌سازی وزن‌ها در هر گام با استفاده از الگوریتم گرادینت نزولی آورده شده‌است:

$$w_i^l = w_{i-1}^l - \alpha \frac{\partial (loss)}{w_{i-2}^l} \quad (3)$$

در این رابطه $loss$ تابع خطا، وزن‌های لایه l ام در گام i ام و α نرخ یادگیری است که تعیین مقدار مناسب آن در همگرایی الگوریتم و سرعت همگرایی الگوریتم نقش بسزایی دارد.

با توجه به این موارد طراحی یک شبکه کانولوشنی برای کاربرد-های مختلف نیازمند تعیین پارامترهایی مانند تعداد بلوک‌های کانولوشنی، تعداد لایه‌های کانولوشنی، تعداد و ابعاد فیلترها در هر لایه، اندازه پدینگ، طول گام فیلترها، نوع و ابعاد ادغام، تعداد لایه‌های تماماً متصل، تعداد نرون‌های هر لایه، نوع تابع غیر خطی هر لایه، الگوریتم بهینه‌سازی و پارامترهای مربوط به آن از جمله نرخ یادگیری است. در این پژوهش با در نظر گرفتن یک شبکه پایه با حداقل مقادیر برای پارامترها، سپس افزایش و بررسی تاثیر هر یک در بهبود عملکرد شبکه، یک ساختار بهینه برای طبقه‌بندی تصاویر ترموگرافی تعیین و نتایج آن با شبکه‌های بسیار عمیق مقایسه شده‌است. شکل (۱) ساختار و مقادیر پارامترهای این شبکه را نشان می‌دهد.

۳. شبکه‌های کانولوشنی عمیق

با پیشرفت تکنولوژی و افزایش منابع سخت‌افزاری قوی شامل پردازنده‌های گرافیکی و حافظه‌های بالا، شبکه‌های کانولوشنی بسیار عمیق با ساختارهای متفاوت در زمینه طبقه‌بندی تصاویر ارائه شده و روی پایگاه‌های داده عظیم آموزش و تست شده‌است.



نمی‌باشد. در این پژوهش به منظور استفاده از حداکثر داده‌های موجود برای تست و آموزش، پس از حذف پرونده‌های با تصاویر تار یا تعداد تصاویر ناقص، پرونده‌های باقی مانده شامل ۴۳ پرونده سالم و ۴۳ پرونده ناسالم، بصورت تصادفی در سه گروه آموزش، اعتبارسنجی و تست به ترتیب با نسبت ۶۰٪، ۲۰٪ و ۲۰٪ قرار داده شده و برای هر پرونده از ۲۰ تصویر شامل ۱۹ تصویر پویا و یک تصویر ایستا فرد، که همگی تصاویر از روبرو هستند، استفاده شده است. در این شیوه تقسیم‌بندی تصاویر مربوط به یک پرونده به طور همزمان بین دو مجموعه آموزش و تست توزیع نمی‌شود. علاوه بر این، با بررسی داده‌های پزشکی پرونده‌ها، برای اولین بار داده‌های قابل طبقه‌بندی به سه گروه سالم، خوش‌خیم و بدخیم، از این پایگاه داده استخراج شده است. تعداد تصاویر استفاده شده در هر یک از سه گروه آموزش، ارزیابی و تست مربوط به طبقه‌بندی دودویی و سه‌کلاسه در جدول (۲) ارائه شده است.

جدول ۲: تعداد تصاویر استفاده شده در هر یک از سه گروه آموزش، ارزیابی و تست مربوط به طبقه‌بندی دودویی و سه‌کلاسه

	طبقه‌بندی دودویی		طبقه‌بندی سه‌کلاسه		
	سالم	ناسالم	سالم	خوش‌خیم	بدخیم
آموزش	۵۲۰	۵۲۰	۱۰۰	۱۶۰	۱۲۰
اعتبارسنجی	۱۸۰	۱۸۰	۲۰	۴۰	۴۰
تست	۱۶۰	۱۶۰	۴۰	۸۰	۶۰

۵. آزمایشات و نتایج

در این پژوهش کلیه شبیه‌سازی‌ها با استفاده از K80 GPU که بصورت رایگان در محیط google colab در دسترس است انجام شده است. در فرایند آموزش شبکه‌ها تعداد گام آموزش برابر با ۶۰ نظر گرفته شده است. به منظور ارزیابی عملکرد شبکه‌ها از معیارهای زیر استفاده شده است:

$$accuracy = \frac{TP + TN}{TN + TP + FP + FN} \quad (4)$$

$$recall = sensitivity = \frac{TP}{TP + FN} \quad (5)$$

$$precision = \frac{TP}{TP + FP} \quad (6)$$

$$F1_score = \frac{2 \times recall \times precision}{recall + precision} \quad (7)$$

که در آن‌ها accuracy معیار صحت، recall معیار فراخوانی، Precision معیار دقت و F1_score میانگین دو معیار است. TP،

محققین است عدد ۱۶ در پایان نام این ساختار نشان‌دهنده عمق شبکه یا تعداد لایه‌های کانولوشنی و تمام متصل شبکه است. معماری شبکه‌های Resnet به گونه‌ای طراحی شده است که امکان تعریف تعداد لایه‌های بسیاری بیش‌تر نسبت به معماری VGG در آن وجود دارد و آن هم به علت تعریف یک مسیر میان بر بین ورودی و خروجی هر بلوک یا لایه کانولوشنی است که این امر از صفر شدن گرادیان با افزایش تعداد لایه‌ها جلوگیری می‌کند. در این پژوهش از Resnet50 استفاده شده است که عدد ۵۰ نشان‌دهنده تعداد لایه‌ها یا عمق این شبکه است. شبکه Mobilnet برخلاف دو شبکه دیگر، یک شبکه عمیق با تعداد وزن‌های کمتر و قابل پیادسازی روی سخت‌افزارهای ضعیف‌تر مانند موبایل است. Mobilnetv2 یک نسخه اصلاح شده از Mobilnetv1 است که در آن از مسیرهای میان‌بر بین ورودی و خروجی بلوک‌ها مانند Resnet استفاده شده است. در جدول (۱) مشخصات سه شبکه عمیق مورد استفاده بطور خلاصه آورده شده است.

جدول ۱: مشخصات شبکه‌های عمیق Resnet50, Mobilnet و VGG16

مدل شبکه	عمق	تعداد پارامترها (میلیون)
Resnet50	۵۰	۲۵
MobilnetV2	۱۷	۳/۴
VGG16	۱۶	۱۳۸

۴. پایگاه داده

در این پژوهش از پایگاه داده عمومی DMR [20] استفاده شده است. در این پایگاه داده تصاویر ترموگرافی ۲۸۷ بیمار به همراه ماتریس‌های حرارتی و همچنین داده‌های پزشکی آن‌ها ارائه شده است. برچسب سالم یا ناسالم مربوط به هر یک از پرونده‌ها با توجه به نتایج ماموگرافی با بیوپسی افراد تعیین شده است. تصاویر ترموگرافی این پایگاه داده بصورت تصاویر سطح خاکستری با ابعاد ۶۴۰*۶۴۰ است که تحت دو پروتکل ایستا و پویا تهیه شده است. در پروتکل ایستا، ۵ تصویر از هر فرد از ۵ جهت مختلف شامل روبرو، مایل به چپ، مایل به راست، کاملاً از چپ و کاملاً از راست گرفته شده است. و در پروتکل پویا ۲۰ تصویر با فاصله ۱۵ ثانیه از روبروی هر فرد همراه با دو عکس جانبی از هر فرد ثبت شده است. در تعداد زیادی از پرونده‌های موجود در این پایگاه داده تمامی قوانین پروتکل‌ها توسط بیماران رعایت نشده است. علاوه بر این تعدادی از پرونده‌ها دارای تصاویر تار هستند که مناسب پردازش نیستند. داده‌های پزشکی مربوط به تعدادی از پرونده‌ها نیز کامل

جدول ۳: هایپرپارامترهای بهینه شبکه کانولوشنی ساده

پارامتر	مقدار
تعداد لایه‌های کانولوشنی	۳
تعداد فیلترها در هر لایه	[۳۲, ۶۴, ۶۴]
ابعاد فیلترها در هر لایه	۵*۵
طول گام فیلترها	۱
نوع و ابعاد ادغام	ماکزیمم ادغام ۲*۲
تعداد لایه‌های تماماً متصل	۳
تعداد نرون‌های هر لایه	[۲, ۲۵۶, ۲۵۶]
نوع تابع غیر خطی هر لایه	'relu'
الگوریتم بهینه‌سازی	Adam
نرخ یادگیری	۰/۰۰۰۵
تعداد تکرار	۶۰

در انتخاب بهترین نتایج شبکه‌ها، نزدیک بودن نتایج تست و ارزیابی به‌منظور کاهش احتمال بیش‌برازش در اولویت قرار داده شده‌است. براین‌اساس بهترین نتایج برای دو شبکه Resnet و mobilnet به ازای بهینه‌سازی با روش Adam و برای شبکه vgg16 به ازای روش SGD آورده شده‌است. نتایج بدست‌آمده نشان می‌دهد، شبکه VGG16 با صحت ۹۲/۷۸ درصد روی مجموعه اعتبارسنجی و ۹۱/۸۷ درصد روی تست نسبت به دو شبکه دیگر و همچنین شبکه کانولوشنی ساده عملکرد بهتری دارد. در گام آخر نتایج سه شبکه از پیش‌آموزش دیده در طبقه‌بندی سه کلاسی مورد بررسی قرار داده شده‌است و نتایج بدست آمده برای دو مجموعه آموزش و تست به ترتیب در جدول‌های (۹) و (۱۰) ارائه شده‌است. با توجه به نتایج مشاهده می‌شود که شبکه VGG16 به خوبی با دقت و حساسیت بالا قادر به تشخیص بیماران بدخیم بوده‌است.

با توجه به اینکه در کارهای پیشین نتایجی برای طبقه‌بندی سه کلاسی ارائه نشده‌است. مقایسه عملکرد طبقه‌بند مبتنی بر شبکه عمیق پیشنهادی در طبقه‌بندی دودویی با نتایج ارائه شده در کارهای پیشین بطور خلاصه در جدول (۱۱) ارائه شده‌است. در این جدول نتایج روش پیشنهادی با انجام داده‌افزایی دو برابری روی مجموعه آموزش ارائه شده‌است. داده‌افزایی انجام شده شامل چهار عملیات افزودن نویز گوسی، چرخش تصادفی تصاویر، بزرگ‌نمایی و کوچک‌نمایی تصاویر و قرینه‌سازی افقی تصاویر بوده‌است و سبب بهبود نتایج تست و تضعیف نتایج اعتبارسنجی شده‌است.

تعداد تصاویری است که به درستی سرطانی طبقه‌بندی شده‌اند، TN تعداد تصاویری که به درستی در گروه سالم طبقه‌بندی شده‌اند، FP تعداد تصاویری است که به اشتباه سرطانی طبقه‌بندی شده‌اند و FN تعداد تصاویری است که به اشتباه سالم طبقه‌بندی شده‌اند. در تمامی نتایج ارائه شده، پرتکرارترین نتیجه به ازای ۵ بار اجرای برنامه در نظر گرفته شده‌است.

در جدول (۳) هایپرپارامترهای بهینه شبکه کانولوشنی ساده بطور خلاصه آورده شده‌است. جدول (۴)، نتایج شبکه کانولوشنی ساده نشان داده شده در شکل (۱) را به ازای مقادیر مختلف سایز کرنل در لایه‌های کانولوشنی نشان می‌دهد. سایر پارامترهای نیز با استفاده جدول‌های مشابه جدول (۴) و با ثابت نگه داشتن سایر پارامترها و تغییر پارامتر مورد نظر بدست آمده‌است. بهترین نتایج در این جدول به ازای سایز کرنل ۵*۵ برای هر سه لایه کانولوشنی بدست آمده‌است که منطبق با مقدار بهینه ارائه شده در جدول (۳) است. مقادیر قرمز رنگ بهترین نتایج در هر ستون را مشخص می‌کند.

بهترین نتایج در این حالت دقت ۹۱ درصد و معیار فراخوانی یا حساسیت برابر با ۷۶/۸۷ درصد در مجموعه تست است. به این معنا که اگر شبکه، فردی را بیمار تشخیص دهد با احتمال ۹۱ درصد تشخیص شبکه درست بوده‌است و معیار فراخوانی یا حساسیت در مجموعه تست برابر با ۷۶/۸۷ درصد بوده‌است به عبارت دیگر از ۱۰۰ درصد افراد بیمار شبکه تنها ۷۶/۸۷ درصد افراد را می‌تواند تشخیص دهد. بدلیل کمبود داده، افزایش بیش‌تر تعداد لایه‌های شبکه کانولوشنی با بیش‌برازش همراه خواهد بود. یک راهکار برای مقابله با این مشکل استفاده از شبکه‌های از پیش آموزش دیده عمیق در بخش استخراج گر ویژگی شبکه کانولوشنی نهایی است به گونه‌ای که وزن‌های بخش استخراج گر ثابت و وزن‌های بخش طبقه‌بند با توجه به داده‌های ترموگرافی آموزش داده شود.

نتایج شبیه‌سازی سه شبکه از پیش‌آموزش دیده Resnet50، MobilenetV2 و VGG16 به ازای مقادیر مختلف نرخ یادگیری و الگوریتم‌های بهینه‌سازی مختلف به ترتیب در جدول‌های (۵)، (۶) و (۷) آورده شده‌است.

برای هر یک از شبکه‌ها سه روش بهینه‌سازی آدم، گرادیان نزولی تصادفی (SGD) و روش آدالدا به ازای نرخ یادگیری‌های مختلف ارزیابی شده‌است و صحت بدست آمده در هر حالت برای هر یک از مجموعه‌های آموزش، اعتبارسنجی و تست ثبت شده‌است. بهترین نتایج بدست آمده برای هر یک از شبکه‌ها و پارامترهای نظیر آن در جدول (۸) بطور خلاصه آورده شده‌است.



جدول ۴: نتایج شبکه کانولوشنی ساده در مجموعه‌های آموزش، اعتبارسنجی و تست به ازای مقادیر مختلف سایز کرنل

K s	Accuracy			Precision			recall			F1-measure		
	tr*	val*	te*	tr	Val	te	tr	val	te	tr	val	Te
۳.۳.۳	۱۰۰	۸۶/۶۷	۸۱/۲۵	۱۰۰	۸۵/۴۸	۹۵/۲۳	۱۰۰	۸۸/۳۳	۷۵	۱۰۰	۸۶/۸۸	۷۹/۹۹
۳.۳.۵	۱۰۰	۸۳/۳۳	۸۱/۸۸	۱۰۰	۸۲/۲۵	۸۶/۴۲	۱۰۰	۸۵	۷۵/۶۲	۱۰۰	۸۳/۶۰	۸۰/۶۶
۳.۵.۵	۱۰۰	۸۷/۵۰	۸۲/۱۹	۱۰۰	۸۶/۴۸	۸۷/۰۵	۱۰۰	۸۸/۸۸	۷۵/۶۲	۱۰۰	۸۷/۱۹	۸۰/۹۳
۵.۵.۵	۱۰۰	۸۶/۹۴	۸۴/۶۹	۱۰۰	۸۵/۵۶	۹۱/۱۱	۱۰۰	۸۸/۸۸	۷۶/۸۷	۱۰۰	۸۷/۱۹	۸۳/۳۸

tr*: مجموعه تست, val*: مجموعه اعتبارسنجی, te*: مجموعه تست

جدول ۵: نتایج شبیه‌سازی شبکه از پیش‌آموزش دیده Resnet50 به ازای مقادیر مختلف نرخ یادگیری و الگوریتم‌های بهینه‌سازی مختلف

Resnet50												
	Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۱		
	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
Adam	۱۰۰	۹۱/۶۷	۸۷/۱۹	۱۰۰	۹۲/۲۲	۸۷/۱۹	۱۰۰	۹۰/۵۶	۸۵/۶۲	۱۰۰	۹۰	۸۶/۸۷
SGD	۹۲/۰۲	۹۴/۷۲	۸۸/۷۵	۹۸/۱۷	۹۲/۵۰	۸۵	۹۹/۷۱	۸۹/۱۷	۸۷/۸۱	۹۹/۵۲	۹۵	۸۶/۲۵
Adadelta	۸۱/۹۲	۸۵/۲۸	۸۴/۶۹	۹۲/۵۰	۹۷/۷۸	۸۶/۸۷	۹۹/۷۱	۹۲/۷۸	۸۷/۱۹	۹۵/۶۷	۹۵/۲۸	۸۶/۲۵

جدول ۶: نتایج شبیه‌سازی شبکه از پیش‌آموزش دیده MobilenetV2 به ازای مقادیر مختلف نرخ یادگیری و الگوریتم‌های بهینه‌سازی مختلف

Mobilenet												
	Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۱		
	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
Adam	۱۰۰	۹۱/۹۴	۸۳/۷۵	۱۰۰	۹۱/۹۴	۸۳/۴۴	۱۰۰	۹۰/۵۶	۸۴/۰۶	۱۰۰	۹۰/۲۸	۸۷/۵۰
SGD	۸۷/۱۲	۹۰	۸۰	۹۴/۵۲	۹۷/۵۰	۸۹/۶۹	۹۹/۱۳	۹۸/۳۳	۸۵/۳۱	۹۹/۳۳	۹۷/۲۲	۸۴/۶۹
Adadelta	۵۹/۴۲	۵۵/۲۸	۶۵/۳۱	۹۵/۸۷	۸۵/۲۸	۸۷/۵۰	۹۷/۹۸	۹۵/۸۳	۸۸/۱۳	۹۹/۰۴	۹۷/۷۸	۸۵/۳۱

جدول ۷: نتایج شبیه‌سازی شبکه از پیش‌آموزش دیده VGG16 به ازای مقادیر مختلف نرخ یادگیری و الگوریتم‌های بهینه‌سازی مختلف

VGG16												
	Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۵			Alfa=۰/۰۰۰۰۱		
	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
Adam	۱۰۰	۸۹/۱۷	۹۰/۳۱	۱۰۰	۸۶/۶۷	۸۸/۱۳	۱۰۰	۸۷/۷۸	۸۷/۸۱	۱۰۰	۸۸/۰۶	۹۰/۶۲
SGD	۸۲/۱۲	۸۳/۳۳	۷۲/۵۰	۹۲/۳۱	۱۰۰	۸۴/۰۶	۱۰۰	۹۲/۷۸	۹۱/۸۷	۹۹/۷۱	۸۵/۲۸	۹۱/۵۶
Adadelta	۴۶/۷۳	۴۰/۸۳	۳۵/۹۴	۸۵/۸۷	۸۷/۸۹	۸۱/۲۵	۹۸/۲۷	۹۷/۵۰	۸۷/۵۰	۹۹/۲۳	۹۳/۰۶	۸۸/۱۳

جدول ۸: بهترین نتایج و مقادیر پارامترهای بهینه

	Train	Val	Test	Alfa	Opt
Resnet50	۱۰۰	۹۲/۲۲	۸۷/۱۹	۰/۰۰۰۰۵	'Adam'
Mobilenet	۱۰۰	۹۰/۲۸	۸۷/۵۰	۰/۰۰۱	'Adam'
Vgg16	۱۰۰	۹۲/۷۸	۹۱/۸۷	۰/۰۰۵	'SGD'

با توجه به نتایج ارائه شده در جدول (۱۱)، مشاهده می‌شود، با وجود اینکه نتایج روش پیشنهادی نسبت به نتایج ارائه شده در اکثر روش‌ها ضعیف‌تر است اما روی بخش وسیع‌تری از داده‌ها مورد ارزیابی قرار داده شده است و از عدم مشابهت زیاد داده‌های تست و آموزش اطمینان حاصل شده است. تنها در [۵] از تعداد داده



جدول ۹: نتایج شبکه‌های عمیق روی مجموعه آموزش

نام روش	همه	سالم			خوش‌خیم			بدخیم		
	Accuracy	precision	Recall	F1-score	precision	Recall	F1-score	Precision	Recall	F1-score
Resnet	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
Mobilnet	۱۰۰	۹۹	۱۰۰	۱۰۰	۱۰۰	۹۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰
VGG	۱۰۰	۱۰۰	۹۹	۹۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰

جدول ۱۰: نتایج شبکه‌های عمیق روی مجموعه تست

نام روش	همه	سالم			خوش‌خیم			بدخیم		
	Accuracy	precision	Recall	F1-score	precision	Recall	F1-score	Precision	Recall	F1-score
Resnet50	۸۰	۵۰	۵۰	۵۰	۷۹	۸۰	۸۰	۱۰۰	۹۸	۹۹
Mobilnet	۷۸	۴۴	۴۰	۴۲	۷۶	۸۰	۷۸	۱۰۰	۹۸	۹۹
VGG16	۸۳	۵۵	۸۰	۶۵	۹۴	۸۰	۸۶	۹۵	۹۰	۹۲

جدول ۱۱: مقایسه بین نتایج طبقه‌بندی دودویی روش پیشنهادی همراه با داده افزایشی و سایر روش‌ها

مرجع	روش ارائه شده	پایگاه داده مورد استفاده	صحت در اعتبارسنجی	صحت	دقت	حساسیت	F1-Score
[۱]	معرفی یک ویژگی بافتی جدید و شبکه broad learning	۲۲۶ تصویر پایگاه داده DMR	-	۹۶/۹%	۹۰	۹۵/۷	۹۲/۷۶
[۳]	ویژگی‌های بافتی و طبقه‌بند SVM با کرنل RBF	۶۰ تصویر از پایگاه داده DMR	-	۹۵	۹۲/۳	۹۷/۰۵	۹۴/۶۱
[۵]	یادگیری انتقالی روی شبکه googlenet	۱۹۶۰ تصویر از پایگاه داده DMR	-	۸۵/۰۳	۶۵/۴۸	۸۹/۷	۷۵/۶۹
[۷]	یادگیری انتقالی روی شبکه‌های عمیق از پیش آموزش دیده	۱۰۰۰ تصویر از پایگاه داده DMR بدون در نظر گرفتن هم پوشانی داده‌ها	۱۰۰	۹۸/۷۵	-	-	-
[۹]	استفاده از تصاویر تقطیع شده برای آموزش شبکه CNN	۶۳ تصویر پایگاه داده DMR	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	طبقه‌بند مبتنی بر VGG پیشنهادی	۱۷۲۰ تصویر پایگاه داده DMR	۹۰	۹۳/۷۵	۹۹/۲۹	۸۸/۱۲	۹۳/۳۷

۶. نتیجه‌گیری

در این پژوهش با استخراج حداکثر اطلاعات از تنها پایگاه داده عمومی موجود در زمینه ترموگرافی پستان، کارایی شبکه‌های عصبی کانولوشنی و کانولوشنی عمیق در طبقه‌بندی به دو گروه سالم و ناسالم و همچنین طبقه‌بندی به سه گروه سالم، خوش‌خیم و بدخیم مورد بررسی قرار داده شد. مزیت اصلی روش‌های کانولوشنی، استخراج ویژگی و طبقه‌بندی به صورت یک‌پارچه و خودکار است. براین اساس شبکه‌های کانولوشنی پس از آموزش،

بیش‌تری نسبت به روش پیشنهادی استفاده شده با توجه به اینکه داده‌های اضافی تنها متعلق به گروه سالم بوده است، این امر سبب از بین رفتن توازن داده‌ها در آموزش و تست شبکه شده است و نتایج ضعیف‌تری برای شبکه در [۵] بدست آمده است.

مزیت روش پیشنهادی نسبت به روش‌های [۱] و [۳] علاوه بر تست روی مجموعه داده وسیع‌تر عدم نیاز به استخراج جداگانه ویژگی‌ها و انجام عملیات استخراج و طبقه‌بندی به صورت یک-پارچه است. علاوه بر این، معیار F1_score روش پیشنهادی بسیار نزدیک به بهترین مقدار ارائه شده توسط سایر روش‌ها است.



- detection," *IEEE Access*, vol. 8, pp. 116176-116194, 2020.
- [9] S. Tello-Mijares, F. Woo, and F. Flores, "Breast cancer identification via thermography image segmentation with a gradient vector flow and a convolutional neural network," *Journal of healthcare engineering*, vol. 2019, 2019.
- [10] P. M. Arabi, S. Muttan, and R. J. Suji, "Image enhancement for detection of early breast carcinoma by external irradiation," in *2010 Second International conference on Computing, Communication and Networking Technologies*, 2010, pp. 1-9.
- [11] E.-K. Ng, "A review of thermography as promising non-invasive detection modality for breast tumor," *International Journal of Thermal Sciences*, vol. 48, pp. 849-859, 2009.
- [12] R. Roslidar, K. Saddami, F. Arnia, M. Syukri, and K. Munadi, "A study of fine-tuning CNN models based on thermal imaging for breast cancer classification," in *2019 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom)*, 2019, pp. 77-81.
- [13] J. Zuluaga-Gomez, Z. Al Masry, K. Benagoune, S. Meraghni, and N. Zerhouni, "A CNN-based methodology for breast cancer diagnosis using thermal images," *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, vol. 9, pp. 131-145, 2021.
- [14] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, et al., "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.
- [15] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [17] M. Abdel-Nasser, A. Moreno, and D. Puig, "Breast cancer detection in thermal infrared images using representation learning and texture analysis methods," *Electronics*, vol. 8, p. 100, 2019.
- [18] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, et al., "Imagenet large scale visual recognition challenge," *International journal of computer vision*, vol. 115, pp. 211-252, 2015.
- [19] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510-4520.
- [20] L. Silva, D. Saade, G. Sequeiros, A. Silva, A. Paiva, R. Bravo, et al., "A new database for breast research with infrared image," *Journal of Medical Imaging and Health Informatics*, vol. 4, pp. 92-100, 2014.

سریع‌تر از سایر روش‌ها عمل می‌کنند و با استخراج ویژگی‌های عمیق دقت طبقه‌بندی را افزایش می‌دهند. با این‌وجود دو عامل محدودکننده در کاربردهای مختلف، محدودیت سخت‌افزاری و پایگاه داده برای آموزش بهینه این شبکه‌هاست. جهت رفع این موانع در این پژوهش ابتدا بهینه‌سازی پارامترهای ساختاری شبکه کانولوشنی ساده با تعداد لایه محدود برای طبقه‌بندی دودویی انجام شد و در گام بعدی از شبکه‌های کانولوشنی عمیق آموزش-دیده روی پایگاه‌های داده عظیم به عنوان استخراج‌گر ویژگی در طبقه‌بندی دودویی و سه کلاسی استفاده شد. بهترین عملکرد در بین شبکه‌ها، مربوط به شبکه مبتنی بر VGG16 با صحت تقریباً ۹۲ درصد بدون داده‌افزایی و ۹۳/۳۷ درصد با داده‌افزایی بود. اگرچه نتایج در مقایسه با کارهای پیشین در زمینه طبقه‌بندی دودویی ضعیف‌تر است اما روی پایگاه داده وسیع‌تری تست شده‌است و F1-Score بدست آمده با نتایج پیشین قابل‌مقایسه است. در طبقه‌بندی سه‌کلاسی نیز حداکثر صحت ۸۳ درصد برای شبکه مبتنی بر VGG16 بدست آمده‌است. در این حالت، بخش عمده خطای شبکه‌های از پیش‌آموزش‌دیده در تشخیص دو گروه سالم و خوش‌خیم بوده‌است.

مراجع

- [1] S. Pramanik, D. Bhattacharjee, M. Nasipuri, and O. Krejcar, "LINPE-BL: A Local Descriptor and Broad Learning for Identification of Abnormal Breast Thermograms," *IEEE Transactions on Medical Imaging*, vol. 40, pp. 3919-3931, 2021.
- [2] W. World Helth Organization Available: <https://www.who.int/cancer/prevention/diagnosis-screening/breast-cancer/en/>
- [3] R. Ramya Devi and G. Anandhamala, "Analysis of breast thermograms using asymmetry in infra-mammary curves," *Journal of Medical Systems*, vol. 43, pp. 1-9, 2019.
- [4] C. Nickson and A. M. Kavanagh, "Tumour size at detection according to different measures of mammographic breast density," *Journal of medical screening*, vol. 16, pp. 140-146, 2009.
- [5] عصبی ا. نژاد، "بررسی شبکه‌های و.ق. زاده، ق. زاده، ف. معراج، حسن کانولوشن عمیق جهت تشخیص سرطان پستان در تصاویر ترموگرافی"، مجله علمی پزشکی جندی شاپور، vol. 18, pp. 615-629, 2020.
- [6] S. Narod, "Tumour size predicts long-term survival among women with lymph node-positive breast cancer," *Current Oncology*, vol. 19, pp. 249-253, 2012.
- [7] F. J. Fernández-Ovies, E. S. Alférez-Baquero, E. J. de Andrés-Galiana, A. Cernea, Z. Fernández-Muñiz, and J. L. Fernández-Martínez, "Detection of breast cancer using infrared thermography and deep neural networks," in *International Work-Conference on Bioinformatics and Biomedical Engineering*, 2019, pp. 514-523.
- [8] R. Roslidar, A. Rahman, R. Muharar, M. R. Syahputra, F. Arnia, M. Syukri, et al., "A review on recent progress in thermal imaging and deep learning approaches for breast cancer