

بررسی شبکه های عصبی کانولوشن عمیق جهت تشخیص سرطان پستان در تصاویر ترموگرافی

محمد حسین قلی زاده^۱، حسین قیومی زاده^{۲*}، حسن فاتحی معراج^۱، نسرین احمدی نژاد^۳

چکیده

زمینه و هدف: سیستم های تشخیص Computer-aided design به طور گسترده در تشخیص افتراقی سرطان سینه استفاده می شوند. بنابراین بهبود دقت یک سیستم CAD به یکی از حوزه های مهم تحقیقاتی تبدیل شده است. در این مقاله به بررسی سیستم های CAD مبتنی بر شبکه های عصبی عمیق از نوع کانولوشن در جهت تشخیص سرطان پستان در تصاویر ترموگرافی پرداخته شد.

روش بررسی: برای تحلیل مدل ها از پایگاه داده "Database For Mastology Research" استفاده شده است. تعداد افراد مورد بررسی ۱۹۶ نفر، که شامل ۴۱ مورد سرطانی و ۱۵۵ مورد سالم بوده است. هر فرد دارای ۱۰ تصویر ترموگرافی است. جمعاً تعداد تصاویر آنالیز شده ۱۹۶۰ تصویر ترموگرافی می باشد. طبقه بندی تصاویر حرارتی شامل سرطانی و سالم بر اساس ۳ نوع شبکه عصبی کانولوشن عمیق شامل google net، resnet18 و vgg16 انجام شده است.

یافته ها: میزان دقت و ویژگی نتایج به دست آمده با استفاده از مدل های شبکه های عصبی عمیق از پیش آموزش داده شده google net، resnet18 و vgg16 به ترتیب برابر ۸۵/۰۳٪ - ۸۹/۷٪، ۸۳/۸٪ - ۹۱/۹٪ و ۹۱/۰۱٪ - ۸۵/۰۳٪ هست. مدل ارائه شده قادر است با مورفولوژی های متفاوت بافت پستان، پاسخ قابل توجهی ارائه دهد.

نتیجه گیری: مدل شبکه عصبی مصنوعی عمیق می تواند به عنوان یک روش کارآمد و هوشمند برای تشخیص سرطان در تصاویر حرارتی خام بدون استخراج ویژگی به کار گرفته شود. با این حال مطالعه و پژوهش های بیشتری برای طراحی مدل های دیگر از شبکه های عصبی مصنوعی بر اساس یادگیری عمیق جهت تشخیص بدخیم یا خوش خیم بودن سرطان در تصاویر حرارتی نیاز است.

واژگان کلیدی: سرطان پستان، تصاویر حرارتی، شبکه عصبی عمیق، طبقه بندی.

۱-استادیار گروه مهندسی برق.

۲- استادیار گروه مهندسی پزشکی.

۳-دانشیار گروه رادیولوژی.

۱-گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه ولی عصر (عج) رفسنجان، رفسنجان، ایران.

۳-گروه رادیولوژی، مرکز تحقیقات رادیولوژی نوین و تهاجمی، دانشگاه علوم پزشکی تهران، تهران، ایران.

* نویسنده مسئول:

حسین قیومی زاده؛ گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه ولی عصر (عج) رفسنجان، رفسنجان، ایران.

تلفن: ۰۰۹۸۹۱۲۳۴۰۳۶۱۵

Email: h.ghayoumizadeh@vru.ac.ir

مقدمه

یون‌ساز یا روش‌های تهاجمی اضافی ندارد، از این رو در حین معاینه به بیمار هیچ‌گونه آزاری را تحمیل نمی‌کند. روش ترموگرافی به دلیل حساسیت و ویژگی بالا به‌طور گسترده به‌عنوان یک ابزار غربالگری کمکی مورد استفاده قرار می‌گیرد (۸). تشخیص ناهنجاری‌های پستان در ترموگرافی حداقل در حدود ۸-۱۰ سال پیش ممکن است (۱). ترموگرافی نقشه دمایی سطح پوست را به‌صورت کیفی و کمی نشان می‌دهد. قادر است تغییرات دمایی کوچکی از الگوهای عروقی غیرطبیعی را کمی‌سازی کند، و نواحی رگ زایی را به‌خاطر سرطان پستان، منعکس کند (۹). با توجه به اینکه تغییرات شیمیایی و فعالیت‌های مخازن خونی در بافت سرطانی نسبت به مناطق مجاور، بالاتر است، بافت‌های سرطانی پستان به‌عنوان نقطه دمای بالا در ترموگرافی دیده می‌شوند (۵).

در چند دهه گذشته، تکنیک‌های پردازش تصویر و هوش مصنوعی در زمینه تشخیص سرطان پستان بر روی تصاویر ترموگرافی ارائه شده است. که درمان را می‌تواند کم‌هزینه‌تر و مؤثرتر نماید. تفسیر بالینی تصاویر گرمایی پستان عمدتاً به تحلیل ذهنی الگوی حرارتی نامتقارن بستگی دارد. این الگوهای گرمایی در هر دو پستان به‌صورت متقارن توزیع می‌شوند. از این رو، تجزیه و تحلیل نامتقارن دو طرفه، در مطالعات گذشته به‌طور گسترده مورد بررسی قرار گرفته است و روش تشخیص کلاسیک غربالگری پستان در ترموگرافی هست (۱۰). توزیع درجه حرارت نامتقارن دو سینه با نقاط داغ نشان داده می‌شود که به دلیل رشد غیرطبیعی عروق خونی می‌باشد (۱). تحلیل کمی چنین نقاط داغی اطلاعات مفیدی را در مورد آسیب‌شناسی ناحیه پستان فراهم می‌کند، اما لازمه این امر این است که ویژگی‌هایی از نواحی چپ و راست پستان برای انجام تحلیل عدم تقارن، استخراج شوند (۱۱). ویژگی‌های استخراج‌شده معمولاً گشتاورهای اول مانند میانگین، انحراف معیار، تفاوت بین حداکثر و حداقل دما در

سرطان سینه شایع‌ترین سرطان زنان است و دومین سرطان در میان دیگر انواع سرطان‌ها است. مشخص شده است که در هر سال تعداد موارد سرطان پستان افزایش می‌یابد (۱). تقریباً یک نفر در ۸ زن در ایالات متحده آمریکا و ۲ نفر از ۵ نفر در سطح جهانی، سرطان دارند (۲). پیش‌بینی می‌شود که تعداد موارد جدید تشخیص داده شده تا سال ۲۰۳۰ به ۲٫۱ میلیون نفر افزایش یابد (۳). بین سال‌های ۲۰۰۸ و ۲۰۱۰، متوسط هزینه سالانه مراقبت‌های بهداشتی برای یک بیمار جدید مبتلابه سرطان در ایالات متحده ۲۱٫۲۲۲ دلار بود (۴). از طرفی دیگر به همین دلیل، تشخیص زودهنگام برای درمان مناسب و افزایش نرخ بقا مورد نیاز است (۵).

انواع روش‌های تصویربرداری باهدف بهبود حساسیت و ویژگی تشخیص سرطان پستان ابداع شده‌اند (۴). روش‌های مرسوم غربالگری شامل روش‌های تصویربرداری پیچیده هستند. همچنین این روش‌ها دارای محدودیت‌هایی هستند، مانند ماموگرافی که دردناک هست، همچنین قرار گرفتن در معرض تابش برای مدت طولانی، و هزینه بالای روش‌های تصویربرداری ناراحت‌کننده است (۳). حساسیت ماموگرافی به‌طور عمده به وجود فیزیک تومور بستگی دارد و برای زنان جوان‌تر با بافت‌های متراکم پستان بسیار کم‌تر است. روش دیگر غربالگری سرطان پستان، سونوگرافی است. این روش به‌طور عمده در زنان جوان باهدف کاهش تابش دریافت شده مورد استفاده قرار می‌گیرد. باین وجود، در این روش بایستی به مواردی اعم از شرایط نويز و تخصص اپراتور در تصویربرداری توجه نمود. این مشکلات منجر به شکست این تکنیک در هنگام تلاش برای کشف میکرو بافت عمیق سینه می‌شود (۶). در نهایت روش ترموگرافی نیز موجود می‌باشد. تصویربرداری مادون‌قرمز یک روش غیر تماسی می‌باشد، که در سالیان اخیر در جامعه پزشکی مورد استفاده قرار گرفته است (۷). تصویربرداری مادون‌قرمز نیازی به استفاده از پرتوی

تکنیک عدم تقارن است که روش اصلی در ترموگرافی می‌باشد. اگر ناحیه سینه به‌درستی انتخاب و جداسازی نگردد، نمی‌توان آنالیزهای از قبیل گشتاورهای مرتبه اول و یا دوم را با استفاده از تکنیک عدم تقارن پیاده‌سازی نمود، یا نتایجی که حاصل می‌گردد موجب کاهش حساسیت و دقت در کلاستر بندی نتایج از نظر بیمار بودن، یا سالم بودن نمونه خواهد شد. با توجه به مطالب ارائه‌شده و شناخت نویسندگان مقاله در کارهای گذشته از جمله (۸، ۲۴، ۲۵) که در زمینه ترموگرافی سرطان سینه انجام داده‌اند، پیشنهاد شده است که از جداسازی سینه و استخراج ویژگی پرهیز شود و تشخیص بر مبنای تصویر خام حرارتی صورت پذیرد. یادگیری عمیق تکنیک جدیدی است که به‌صورت قابل توجهی می‌تواند این مهم را فراهم سازد. معماری‌های مختلفی برای شبکه‌های عمیق در مسائل دسته‌بندی تصویر پیشنهاد شده است. که در این کار، با بررسی چند روش یادگیری عمیق به تشخیص سرطان پستان در تصاویر حرارتی پرداخته می‌شود.

دو طرف پستان می‌باشد (۱۲). در برخی مطالعات از اطلاعات مورفولوژی از قبیل تعداد رگ‌ها با دمای بالاتر، ویژگی‌های بافت، یا تعداد نقاط گرم، هندسه مرکز گرم و هیستوگرام دمایی تصاویر استفاده شده است (۱۳). در نهایت ویژگی‌های استخراج شده توسط الگوریتم‌های هوش مصنوعی طبقه‌بندی می‌شوند. برخی از الگوریتم‌هایی که بدین منظور در مطالعات گذشته استفاده شده‌اند شامل: طبقه‌بندی فازی، شبکه بی‌زی، ماشین بردار پشتیبان، شبکه‌های عصبی، تبدیل موجک هستند (۱۴) (۱۳) (۱۵). خلاصه‌ای از کارهای موجود در مورد آنالیز عدم تقارن پستان در جدول ۱ نشان داده شده است.

بامطالعه دقیق مقالات گذشته در زمینه ترموگرافی پستان به چند محدودیت خواهیم رسید که می‌توان به: عدم دسترسی محققان و به‌خصوص مهندسان پردازش تصویر به پایگاه‌های داده آزاد، وجود تصاویر اندک در پایگاه داده، و مهمتر از همه موارد مورفولوژی‌های مختلف پستان (شکل‌های هندسی متفاوت) در افراد، اشاره کرد. علت این اهمیت نیز مربوط به

جدول ۱: خلاصه‌ای از تجزیه و تحلیل نامتقارن دوطرفه پستان مبتنی بر روش‌های تشخیص غربالگری از ترموگرافی

پایگاه داده	ویژگی	حساسیت	دقت	نوع طبقه بند	روش	نویسنده
۱۴۶	-	-	٪۸۰	طبقه‌بندی کننده مبتنی بر قانون فازی هیبرید	ویژگی‌های آماری و بافت	Schaefer et al.(16)
۸۲	٪۸۸/۲۰	٪۸۱/۲۰	٪۸۰/۹۵	شبکه‌های عصبی پایه شعاعی	داده‌های دما و بالینی بیمار	Ng et al (17)
۵۰	٪۱۰۰	٪۸۶/۷۰	٪۹۳/۳۰	درخت تصمیم	ویژگی‌های بافت و DWT	Mookiah et al (18)
۵۰	٪۱۰۰	٪۸۵/۷۱	٪۸۸/۱۰	ماشین بردار پشتیبان	ویژگی‌های بافت	Acharya et al(13)
۲۲	٪۱۰۰	٪۸۱/۸۲	٪۹۰/۹۱	ماشین بردار پشتیبان	ویژگی‌های آماری و بافت	Francis et al (19)
۵۰	٪۸۶/۵۰	٪۸۵/۷۰	-	طبقه‌بندی کننده مبتنی بر فاصله	ویژگی‌های نمادین فاصله زمانی دما	Araujo et al (20)

Zadeh et al (21)	گشتاورهای مرتبه اول	شبکه‌های عصبی خودسازمان‌ده	%۷۰	%۵۰	%۷۵	۲۰۰
Sathish et al (22)	ویژگی‌های آماری و بافت	ماشین بردار پشتیبان	%۹۰	%۸۷/۵	%۹۲/۵	۸۰
Borchardt et al (12)	گشتاورهای مرتبه اول ویژگی‌های آماری،	ماشین بردار پشتیبان	%۸۵/۷۱	%۹۵/۸۳	%۲۵	۲۸
Lashkari et al (23)	مورفولوژیکی، فرکانس دامنه، هیستوگرام	آدابوست	%۸۵/۳۳	%۶۳/۳۳	%۹۰/۸۳	۶۷
Gogoi et al (10)	singular values	ماشین بردار پشتیبان	%۹۸	%۹۸	%۹۸	۱۴۵

روش بررسی

سرطانی و ۱۵۵ مورد سالم بوده است. بنابراین هر فرد دارای ۱۰ تصویر ترموگرافی، و جمعاً تعداد تصاویر آنالیز شده ۱۹۶۰ تصویر ترموگرافی می‌باشد. با بررسی تصاویر پایگاه، می‌توان در قالب شش الگو تصاویر را تقسیم‌بندی نمود که در شکل ۱ نمایش داده شده است.

همان‌طور که قابل مشاهده است تصاویر در قالب ۶ نوع الگو می‌باشند که به صورت تک‌به‌تک آنالیز می‌نماییم. تصاویری همچون شکل ۱-a، که ناحیه سینه به صورت متقارن است و حالت بیضوی دارد که در مقالات گذشته با تکنیک‌های جداسازی سهموی و یا روش‌های همچون درخت تصمیم جداسازی نموده‌اند. تصاویری در قالب شکل ۱-b، که ناحیه سینه به صورت کروی بوده و می‌توان با تکنیک‌هایی از قبیل هاف دایروی و یا کانتور فعال جداسازی نمود. اما برخی از تصاویر هستند مانند شکل ۱-c و یا شکل ۱-d که از نظر مورفولوژی به صورت متقارن نبوده و امکان دارد یک تکنیک مشابه، همزمان بر روی سینه راست و چپ پاسخ مناسب ندهد. تصاویری نیز وجود دارند همچون شکل ۱-e که ناحیه سینه به درستی قابل تشخیص نیست. تصاویری نیز مانند شکل ۱-f وجود دارند که ممکن است بی‌پسی شده،

در این مطالعه، از تصاویر ترموگرافی پستان از پایگاه داده <http://visual.ic.uff.br/proeng/> استفاده شده است (۲۶). این تصاویر با استفاده از دوربین FLIR ThermaCam S45 ضبط شده و توسط کمیته اخلاقی دانشگاه فدرال تأیید شده است. تصاویر ترموگرافی در بیمارستان دانشگاهی جمع‌آوری و در وزارت بهداشت برزیل ثبت شده‌اند. تصاویر این پایگاه داده از بین بیماران و داوطلبان بالای ۳۵ سال گرفته شده، و سپس بر مبنای رطوبت نسبی و دمای اتاق اصلاح شده‌اند. جهت تصویربرداری از بیمار خواسته شده است به مدت ۱۰ دقیقه استراحت نماید، تا به یک تعادل حرارتی لازم برسد. پس از تصویربرداری، تصاویری که در پایگاه قرار گرفته‌اند توسط یک رادیولوژیست آموزش دیده، به‌طور دستی بخش‌بندی شده است (۲۷). در این پایگاه برای هر فرد معمولاً بین صفر (در برخی موارد تصویر ترموگرافی موجود نیست) تا ۳۰ تصویر گرفته شده است. تصاویر به صورت مستقیم و یا با زاویه از بیمار گرفته شده است. در این مقاله از تصاویری افرادی استفاده شده است که دارای حداقل ۱۰ تصویر در پروفایل خود می‌باشند. به عبارت دقیق‌تر، تعداد افراد مورد بررسی ۱۹۶ نفر، که شامل ۴۱ مورد

می‌شود. بعد از تکرار تعداد مناسبی از این مراحل آموزش شبکه پایان می‌یابد.

حال اگر طبق این پیش آموزش‌ها، بخواهیم روند را انجام دهیم بایستی به صورت مراحل زیر پیاده‌سازی نماییم. در مرحله اول تصویر ورودی به شبکه اعمال می‌شود اما قبل از اینکه تصاویر به عنوان ورودی به شبکه‌های کانولوشنی داده شوند، باید پیش پردازش بر روی آن‌ها صورت گرفته و آماده پردازش شوند. این آماده‌سازی می‌تواند شامل برش، تغییر اندازه، نرمالیزه‌سازی تصویر، صفر گذاری و باشد. به همین منظور در ابتدا باید تصویر ورودی، در صورت لزوم تغییر اندازه داده شود و منطبق بر ابعاد لایه ورودی شبکه گردد. لذا در مرحله اول تصاویر ورودی باید به اندازه استاندارد این شبکه‌های پیش آموزش دیده دربیانند. در این مرحله تصاویر رنگی جمع آوری شده را به اندازه $۲۲۴ \times ۲۲۴ \times ۳$ تغییر اندازه می‌دهیم. بُعد سوم مربوط به کانال‌های رنگ‌های پایه قرمز، سبز و آبی می‌باشد. هر کدام از درایه‌های این ماتریس سه‌بعدی مقداری بین ۰ تا ۲۵۵ دارند. که ۰ نشان‌دهنده کمترین میزان روشنایی و ۲۵۵ نشان‌دهنده بیشترین مقدار روشنایی هست.

پس از اینکه پیش پردازش بر روی تصویر انجام شد و تصاویر به اندازه استاندارد تغییر داده شدند، تصویر به ورودی لایه اول کانولوشنی داده می‌شود. حالا باید در مرحله دوم با کرنل‌های کانولوشنی لایه اول کانوالو شوند. هر لایه کانولوشنی شامل سه زیر لایه می‌باشد. در زیر لایه اول تصویر پیش پردازش شده با کرنل‌های کانولوشنی از پیش تعیین شده کانوالو می‌شود. مقدار و ابعاد این کرنل‌های کانولوشنی بسته به نوع شبکه کانولوشنی مورد استفاده با یکدیگر متفاوت می‌باشد. همچنین بسته به تعداد صفر گذاری تصویر، ابعاد خروجی می‌تواند هم اندازه تصویر ورودی باشد و یا کوچک‌تر و بزرگ‌تر باشد. همچنین می‌توان در اینجا از چند

یا در فاصله زمانی کم از تصویر برداری، تحت عمل جراحی قرار گرفته باشد که نیازمند قرارگیری پانسمانی بر روی ناحیه سینه باشد که در این صورت عدم تقارن پاسخگو نخواهد بود.

شبکه‌های عصبی کانولوشن یکی از مهم‌ترین روش‌های یادگیری عمیق هستند که در آن‌ها چندین لایه با روشی قدرتمند آموزش می‌بینند (۲۸). این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی کامپیوتر است. تصویر کلی یک معماری شبکه عصبی کانولوشن در شکل ۲ نمایش داده شده است. به طور کلی، یک شبکه عصبی کانولوشن از سه لایه اصلی تشکیل می‌شود که عبارت‌اند از: لایه کانولوشن، لایه Pooling و لایه تماماً متصل. لایه‌های مختلف وظایف مختلفی را انجام می‌دهد. در هر شبکه عصبی کانولوشن دو مرحله feed forward و پس انتشار برای آموزش وجود دارد (۲۹).

در مرحله اول تصویر ورودی به شبکه وارد می‌شود و این عمل، ضرب نقطه‌ای بین ورودی و پارامترهای هر نرون و نهایتاً اعمال عملیات کانولوشن در هر لایه است، سپس خروجی شبکه محاسبه می‌شود. در اینجا به منظور تنظیم پارامترهای مربوط به آموزش شبکه، از نتایج خروجی شبکه جهت محاسبه میزان خطای شبکه استفاده می‌شود. برای این کار خروجی شبکه را با استفاده از یک تابع خطا با پاسخ صحیح (پاسخ مطلوب) مقایسه کرده و میزان خطا محاسبه می‌شود. در مرحله بعد بر اساس میزان خطای محاسبه شده، مرحله پس انتشار آغاز می‌شود. در این مرحله گرادیانت (Gradient) هر پارامتر با توجه به قاعده chain rule محاسبه می‌شود و تمامی پارامترها با توجه به تأثیری که بر خطای ایجاد شده در شبکه دارند تغییر پیدا می‌کنند. بعد از به-روز رسانی شدن پارامترها مرحله feed-forward شروع

تمایل به استفاده از تابع یکسوساز نسبت به دیگر توابع غیرخطی بیشتر است زیرا تابع یکسوساز نحوه محاسبه ساده‌ای دارد و منابع محاسباتی زیادی را درگیر نمی‌کند و درعین حال تجربه نشان داده است که استفاده از این تابع منجر به رسیدن به دقت‌های قابل قبولی می‌گردد (۳۱). رابطه زیر تعریف تابع یکسوساز را نمایش می‌دهد:

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ 0 & \text{else} \end{cases}$$

درنهایت، مقادیر حاصل‌شده به زیرلایه سوم برای انجام عملیات ادغام داده می‌شود. در زیرلایه ادغام، خلاصه آماری پیکسل‌های همسایه پیکسل مرکزی، جایگزین مقدار پیکسل مرکزی پنجره ادغام می‌شود. اعمال ادغام باعث پایدارتر شدن ویژگی‌ها و کاهش حساسیت نسبت به تغییرات ناخواسته می‌باشد. ابعاد داده خروجی این زیرلایه بسته به مقدار ابر پارامترهای گام و صفر گذاری می‌تواند برابر با ابعاد داده ورودی باشد و یا اینکه دارای ابعاد متفاوتی باشد. از این رو اگر کاهش ابعادی در مرحله ادغام صورت بگیرد، می‌توان کاربرد دیگر این زیرلایه را نگه داشتن ویژگی‌های ارزشمندتر و دور ریختن ویژگی‌های کم‌اهمیت دانست. نوع‌های مختلفی از ادغام وجود دارد که محبوب‌ترین آن‌ها ادغام نوع max pooling می‌باشد، که می‌توان به صورت زیر بیان نمود:

$$y_{ijk} = \max\{y_{i'j'k'} : i \leq i' < i + p, j \leq j' < j + p\}$$

اکنون یک لایه کانولوشنی به‌طور کامل بر روی تصویر پیش‌پردازش شده اعمال شده است. حال بسته به نوع شبکه کانولوشنی مورد استفاده این مرحله به تعداد معینی، تکرار می‌شود. بعد از اتمام لایه‌های کانولوشنی می‌توان از یک یا چند لایه تمام-متصل برای نگاشت نهایی ویژگی‌ها به دست آمده استفاده کرد. یک لایه تمام متصل دقیقاً مانند یک لایه کانولوشنی است با این تفاوت که در اینجا تعاملات پراکنده صورت نمی‌گیرد و دقیقاً مانند شبکه‌های عصبی سنتی

کرانل کانولوشنی استفاده نمود. عملگر کانولوشن برای داده‌ها در اینجا به معنی عملگری است که محلی بوده و تغییرناپذیر با جابجایی باشد (۳۱). نگاشت ورودی به خروجی برای عملگر کانولوشنی در اینجا با رابطه زیر نشان داده شده است:

$$f: R^{M \times N \times K} \rightarrow R^{M' \times N' \times K'}$$

همان‌طور که دیده می‌شود عملگر کانولوشن در اینجا یک نگاشت از یک داده سه‌بعدی به یک داده سه‌بعدی دیگر و در مجموعه اعداد حقیقی می‌باشد. رابطه زیر نحوه اعمال عملگر کانولوشن مورد استفاده را به صورت ریاضی نمایش می‌دهد:

$$y_{i'j'k'} = \sum_{ijk} w_{ijk} x_{i+i', j+j', k}$$

در اینجا w بانک فیلتر کانولوشنی است و یک داده چهاربعدی است. در حقیقت بعد چهارم شماره فیلتر در بانک فیلتر است و خود فیلتر یک توده وزنی سه‌بعدی است. به عبارت بهتر، در ابتدا فیلتر شماره اول سه‌بعدی کانولوشنی بر روی داده سه‌بعدی می‌لغزد و در هر موقعیتی که قرار گرفت بین درایه‌های متناظر ضرب نقطه‌ای صورت گرفته و حاصل تمام ضرب‌ها با یکدیگر جمع می‌شود. با هر موقعیت قرارگیری تنها مقدار یک پیکسل به دست می‌آید، لذا با لغزش فیلتر شماره یک بر روی کل داده یک نقشه ویژگی دوبعدی حاصل می‌شود. به همین ترتیب فیلترهای بعدی اعمال شده و به ازای هر کدام از آن‌ها یک نقشه ویژگی دوبعدی به دست می‌آید که با پشت سر هم قرار دادن این نقشه ویژگی‌ها در بعد سوم، نقشه ویژگی نهایی که سه‌بعدی است حاصل خواهد شد (۳۱).

بعد از اعمال زیرلایه اول کانولوشنی، خروجی زیرلایه اول به زیرلایه غیرخطی داده می‌شود. در این مرحله تابع فعال‌ساز غیرخطی برای به دست آوردن ویژگی‌های سطح بالاتر بر روی مقادیر به دست آمده اعمال خواهد شد. در تمامی این سه مدل از تابع یکسوساز به عنوان تابع غیرخطی استفاده شده است. به‌طور کلی در شبکه‌های کانولوشنی عمیق

اما یکی از مهم‌ترین چالش‌ها در یادگیری عمیق و شبکه‌های عصبی کانولوشن آموزش آن‌ها هست. به دلیل حجم بالای لایه‌ها و وزن‌های این شبکه، آموزش آن‌ها بسیار مشکل بوده و نیاز به پردازنده‌های قوی با سرعت بالا هست. به همین منظور در حال حاضر برای استفاده از شبکه‌های یادگیری عمیق دیگر کل شبکه را از ابتدا آموزش نداده بلکه از الگوریتم‌ها و مدل‌های پیش آموزش داده شده استفاده می‌کنند. بنابراین به جای اینکه یک شبکه عصبی کانولوشن عمیق را از پایه طراحی نماییم، می‌توانیم یک شبکه پیش آموزش دیده را در نظر بگیریم و از آن به عنوان یک ویژگی ورودی برای یادگیری یک کار طبقه‌بندی استفاده کنیم. در این آموزش معمولاً بر اساس پایگاه داده موجود تعدادی از لایه‌ها که کلیات تصاویر را بیان می‌کنند به صورت یخ‌زده درآمده تا در طول آموزش وزن‌های آن‌ها تغییر نکنند. حال اگر تعداد داده‌های موجود در پایگاه داده موجود کم باشد فقط لایه آخر بلوک تمام متصل شده آموزش می‌بیند در غیر این صورت لایه‌های بیشتری آموزش از بلوک آخر آموزش پیدا می‌کنند. با پیشرفت‌های اخیر استفاده شبکه‌های عصبی کانولوشن در حوزه بینایی کامپیوتر، مدل‌های معروفی از شبکه‌های عصبی کانولوشن از جمله VGG, GoogleNet, ResNet، و غیره به وجود آمدند؛ که قادر به بارگذاری آنها هستیم. مشخصات مربوط به لایه‌های هر یک از شبکه‌های عصبی کانولوشن عمیق مورد استفاده در جدول ۲ نمایش داده شده است.

پیاده‌سازی‌های انجام شده در زبان برنامه‌نویسی Matlab بر روی سیستم پردازشی فوق سریع (High Performance Computing) که از چندین کلاستر محاسباتی تشکیل شده و یکپارچگی بین آن‌ها منجر به مدیریت کارها به صورت متمرکز می‌گردد، انجام گرفته است. سخت‌افزاری با مشخصات: تعداد نودها ۲، کارت گرافیک 2x

یک اتصال کامل بین این لایه و لایه پیش از آن برقرار می‌شود. خروجی آخرین لایه یک بردار یک‌بعدی است و تعداد اعضای این بردار برابر با تعداد کلاس‌های دسته‌بندی است. این لایه در حقیقت کار دسته‌بندی را انجام می‌دهد. در تمامی ساختارهای کانولوشنی آخرین لایه تمام متصل به یک لایه softmax متصل می‌شود. در حقیقت لایه softmax کار طبقه‌بندی در شبکه‌های کانولوشنی را انجام می‌دهد. این لایه شامل تعدادی نورون برابر با تعداد کلاس‌های مسئله دسته‌بندی است و برای نگاشت نهایی ویژگی و اعمال دسته‌بندی استفاده می‌شود (۳۱).

در اینجا به منظور تنظیم پارامترهای شبکه و یا به عبارت دیگر همان آموزش شبکه، از نتیجه خروجی جهت محاسبه میزان خطای شبکه استفاده می‌شود. برای این کار خروجی شبکه را با استفاده از یک تابع خطا با پاسخ صحیح مقایسه کرده و این‌طور میزان خطا محاسبه می‌شود. نحوه محاسبه خطای تجربی به صورت زیر می‌باشد:

$$L(w) = \frac{1}{n} \sum_{i=1}^n l(Z_i; f(X_i; w))$$


در این رابطه $l(Z; \hat{Z})$ یک تابع تلفات است که مقدار جریمه را به هنگام پیش‌بینی اشتباه \hat{Z} به جای Z تعیین می‌کند. در مرحله بعدی بر اساس میزان خطای محاسبه شده مرحله پس انتشار آغاز می‌شود. در این مرحله گرادینت هر پارامتر با توجه به قاعده chain rule محاسبه می‌شود و تمامی پارامترها با توجه به تأثیری که بر خطای ایجاد شده در شبکه دارند تغییر پیدا می‌کنند.

$$w^{t+1} = w^t - \rho_t \frac{\partial f}{\partial w}(w^t)$$


بعد از به روز رسانی شدن پارامترها مرحله بعدی feed-forward شروع می‌شود. بعد از تکرار تعداد مناسبی از این مراحل آموزش شبکه پایان می‌یابد.

روی یک سیستم HPC استفاده شده است. مشخصات مربوط به پارامترهای تنظیم شبکه عصبی در جدول ۳ نمایش داده شده است.

NVIDIA® Tesla K80 GPUs حافظه 8x16GB و پردازنده 2x Intel® Xeon® E5-2695 v3 @ 2.30 GHz انجام شده است. لازم به ذکر است، تمامی نتایج به دست آمده از روش های متفاوت، از یک مدل مشخصات بر



شکل ۱: الگوی تصاویر حرارتی در تصاویر ترموگرافی پستان در پایگاه داده مورد بررسی قرار گرفته



شکل ۲: یک طرح کلی از معماری یک شبکه عصبی کانولوشن (۳۰)

جدول ۲: مقایسه مشخصات برخی از شبکه‌های عصبی عمیق پیش آموزش دیده

مدل شبکه	عمق	تعداد پارامترها (میلیون)
Google net	۲۲	۷
resnet18	۱۸	۱۱/۷
vgg16	۱۶	۱۳۸

جدول ۳: پارامترهای تنظیم شده شبکه عصبی کانولوشن عمیق

پارامتر	مقدار
MiniBatchSize	۵
MaxEpochs	۱۰
InitialLearnRate	۰,۰۰۰۱
Iteration	۲۷۴۰
ValidationFrequency	۳
optimizer	the stochastic gradient descent with momentum

یافته‌ها

دقت بالا خواهد بود. از مجموع ۱۹۶۰ تصویر موجود ۷۰ درصد داده‌ها به عنوان داده‌های آموزش و ۳۰ درصد داده‌ها (۵۸۸ نمونه) به عنوان تست در نظر گرفته شده است. نتایج مربوط به حساسیت، صحت و ویژگی به دست آمده در داده‌های تست در جدول ۴ نشان داده شده است.

وقتی مقدار حساسیت و ویژگی تشخیصی هر دو افزایش یابند، مقدار دقت و سطح زیر منحنی ROC نیز افزایش خواهد یافت. نمودار مربوط به مقدار دقت در مورد داده‌های اعتبارسنجی برای سه مدل شبکه عصبی استفاده شده در شکل ۳ نمایش داده شده است. نمودار مربوط به مقدار خطا در مورد داده‌های اعتبارسنجی برای سه مدل شبکه عصبی استفاده شده در شکل ۴ نمایش داده شده است.

برای تسهیل ارزیابی عملکرد سیستم تشخیص ناهنجاری پستان پیشنهاد شده ما، سه معیار ارزیابی: دقت، حساسیت و ویژگی استفاده شده است. این پارامترها به شرح زیر داده می‌شوند:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$


$$Sensitivity = \frac{TP}{TP+FN}$$

$$Specificity = \frac{TN}{TN+FP}$$


متغیرهای Sen و ACC و SPE به ترتیب حساسیت، صحت و ویژگی تشخیصی مدل می‌باشند و متغیرهای Tp، Tn، Fp، Fn به ترتیب تعداد مثبت‌های درست، منفی-های درست، مثبت‌های نادرست و منفی‌های نادرست می‌باشند. بنابراین، اگر هم حساسیت و هم ویژگی بالا باشند،

جدول ۴: ارزیابی ویژگی‌های استخراج شده با استفاده از طبقه‌کننده‌ها

مدل شبکه پیش آموزش دیده	TP	TN	FP	FN	Acc	SPE	Sen
Google net	۷۴	۴۲۶	۴۹	۳۹	٪۸۵/۰۳	٪۸۹/۷	٪۶۵/۴۸
resnet18	۸۷	۴۰۶	۳۶	۵۹	٪۸۳/۸	٪۹۱/۹	٪۵۹/۵۸
vgg16	۹۵	۴۰۵	۴۰	۴۸	٪۸۵/۰۳	٪۹۱/۰۱	٪۶۶/۴۳



شکل ۳: نمودار مقدار دقت اندازه‌گیری شده در هر مرحله از یادگیری بر روی داده‌های اعتبار سنجی



شکل ۴: نمودار مقدار خطای اندازه‌گیری شده در هر مرحله از یادگیری بر روی داده‌های اعتبار سنجی

بحث

تحلیل می‌کنند. همانند کاری که Bianco و همکارانش انجام دادند که اثر تاثیر هزینه محاسباتی را بر دقت تشخیص بررسی نمودند (۳۳).

اکنون به مقایسه و تحلیل معماری های استفاده شده در روش پیشنهادی می پردازیم. VGG16 شامل ۵ بلوک کانولوشن و یک بلوک تمام متصل شده با چهار لایه هست. این روش با جایگزینی فیلترهای بزرگ با اندازه هسته (به ترتیب ۱۱ و ۵ در لایه اول و دوم) با استفاده از فیلترهای سائز سه یکی پس از دیگری بهبود می یابد. الگوریتم VGG به دلیل الزامات محاسباتی عظیم، هم از لحاظ حافظه و هم زمان، یک مشکل است. الگوریتم ResNet نسبت به الگوریتم VGG دارای عمق بیشتری هست. الگوریتم بیان شده شامل یک فیدبک نیز هست، علت وجود این فیدبک در الگوریتم ResNet، برای الگوریتم آموزش پس انتشار خطا هست. هر چه الگوریتم عمیق تر شده و تعداد لایه ها افزایش پیدا می کند به دلیل وجود تابع گرادیانت در تابع آموزش با وارد شدن به عمق جایی ممکن است اثر وزن ها و لایه ها صفر شوند به همین منظور الگوریتم های ResNet که شامل فیدبک می باشند مطرح و مورد استفاده قرار گرفته اند (۳۴). ترتیب قرار گرفتن داده در هنگام آموزش شبکه کانولوشنی، همانند سایر شبکه های عصبی بر روی نحوه آموزش دیدن شبکه تأثیرگذار است. اساس به روزرسانی وزن ها بر پایه محاسبه خطای بین مقدار پیش بینی شده و مقدار مورد انتظار است. طبیعی است هر چه داده های آموزش شبکه بیشتر می شود، مدل بیشتر خود را بر روی داده آموزش منطبق می سازد. اگر داده هایی که پشت سر هم به شبکه داده می شوند همه متعلق به یک کلاس نباشد، شبکه در طول آموزش خودش را به گونه ای تطبیق می دهد که بتواند داده های این کلاس ها را بهتر تمیز دهد. به این دلیل پیش از اینکه داده ها به ورودی شبکه کانولوشنی داده بشوند،

مطالعه فعلی باهدف پیاده سازی و ارزیابی یک سیستم تصمیم یار جهت کمک به تشخیص پزشک در تعیین سرطان پستان با استفاده از شبکه عصبی عمیق انجام شد. استفاده از شبکه های عصبی عمیق در تشخیص سرطان پستان در تصاویر ترموگرافی را می توان در دو زمینه مورد بررسی قرار داد. یک مورد بررسی استفاده از شبکه های عصبی عمیق در مقایسه با کارهای گذشته و دیگری تحلیل خود شبکه ی عصبی عمیق می باشد.

اکثر کارهای گذشته متکی بر ترکیب ویژگی های آماری و بافت با یک طبقه بندی کننده مانند SVM (پشتیبانی از ماشین بردار پشتیبان) هستند نظیر کارهایی که Acharya و Francis ارایه دادند (۳۲) (۱۳). اگرچه مقادیر دقت بدست آمده آنها نزدیک مقاله ارایه شده می باشد اما تعداد تصاویری که آنها مورد بررسی قرار دادند به مراتب پایین تر از دیتابیس مورد استفاده در مقاله حاضر (۱۹۶۰ تصویر) می باشد. میزان صحت بدست آمده روش پیشنهادی بالاتر از مقالات (۱۶)(۲۱)(۱۷) و با درصد خطایی نزدیک، شبیه مقالات (۲۰)(۱۲)(۲۳) می باشد.

رویکرد سنتی پیش بینی ناهنجاری سینه، تحلیل عدم تقارن دو طرفه است که دقت آن به جداسازی مناسب سینه های چپ و راست از یک thermogram بستگی دارد. همانند مقالاتی که Schaefer و Ng پیشنهاد دادند که نیازمند استخراج ویژگی های دستی است که شامل یک کار سخت توسط توسعه دهنده سیستم است (۱۷)(۱۶). اما روش ارائه شده به دور از فرایند استخراج ویژگی در الگوهای حرارتی به تشخیص سرطان پستان می پردازد.

روش پیشنهادی را می توان از منظر معماری مورد ارزیابی قرار داد. مقالاتی وجود دارند که جنبه های مربوط به هزینه محاسباتی (استفاده از حافظه، زمان استنتاج و غیره) را

ترموگرافی مورد بررسی قرار داده شد. در این مقاله سعی شده است تا بتوان با استفاده از شبکه‌های عصبی عمیق و به‌دوراز استخراج ویژگی و صرفاً به کمک تصاویر خام حرارتی بهبود چشمگیری در صحت تشخیص ناهنجاری در سرطان پستان به وجود آورد. این مقاله برای طبقه‌بندی سرطان پستان در تصاویر حرارتی از ۳ معماری پیش آموزش‌دیده شامل google net، resnet18 و vgg16 استفاده کرد. نشان داده شد که معماری google net نتایج عالی در طبقه‌بندی تصاویر ترموگرافی از خود نشان می‌دهد، که پایدارترین معماری میان این سه می‌باشد. معماری Vgg عملکرد بهتری نسبت به معماری Resnet نشان می‌دهند. بنابراین cnnس برای غربالگری سرطان پستان روشی بسیار کارآمد است. مهم‌ترین نوآوری مقاله نسبت به کارهای گذشته در زمینه ترموگرافی پستان، عدم دخالت مؤثر مورفولوژی‌های متفاوت پستان در نتایج به‌دست‌آمده، و عدم استفاده دستی از استخراج ویژگی می‌باشد. تنظیم پارامترهای مناسب و انتخاب یک تابع loss function مناسب برای رسیدن به دقت خوب از دیگر کارهای انجام گرفته در مقاله می‌باشد.

پیشنهاد می‌شود که استفاده از مجموعه‌های بزرگ‌تر برای آموزش و اعتبار، دقت طبقه‌بندی را افزایش دهد، زیرا cnnس نتایج بهینه‌ای ارایه می‌دهند اگر تعداد نمونه‌های آموزشی افزایش یابد. همچنین قطعاً رویکرد یادگیری عمیق با استفاده از مجموعه داده رنگی، عملکرد خوبی را در مقایسه با مجموعه داده grayscale برای پروتکل استاتیک نشان خواهد داد.

ترتیب قرارگیری آن‌ها به‌هم‌ریخته می‌شود و تمام داده‌های یک کلاس پشت سر هم وارد نمی‌شود.

علیرغم تمام مزایایی که مدل‌های شبکه عصبی عمیق دارند، این مدل‌ها دارای محدودیت‌هایی نیز هستند. از محدودیت‌های این روش می‌توان به تنظیم دقیق پارامترها با توجه به مدت زمان هر بار اجرای برنامه، برای رسیدن به نتایج مطلوب اشاره کرد. که نویسندگان را مجبور کرد بارها برنامه را اجرا نمایند. دسترسی به یک سیستم سخت افزاری کامپیوتری با قابلیت پردازش مطلوب از دیگر امکانات مورد نیاز اینگونه کارها در زمینه شبکه‌های عصبی عمیق می‌باشد. از دیگر محدودیت‌ها دسترسی نداشتن به مجموعه داده‌ها با حجم بالا است. با در نظر گرفتن این مطلب که فقط یک دیتابیس غنی در حال حاضر با این حجم داده در دسترس عموم می‌باشد و مضاعف بر اینکه لازمه اجرای شبکه عصبی عمیق داشتن یک دیتابیس غنی است که لازمه رسیدن به یک دقت خوب در این گونه کارها می‌باشد.

نتیجه‌گیری

سرطان سینه باعث مرگ بسیاری از زنان در سراسر جهان شده‌است. در طول بررسی مقالات، آشکار شد که کار در زمینه تشخیص سرطان پستان از دیدگاه علوم کامپیوتر می‌تواند کمک ارزشمندی به این زمینه باشد. اگرچه ترموگرافی می‌تواند یک روش کمکی برای تشخیص زودهنگام سرطان پستان باشد، اما قطعاً دارای مزایا و معایبی هست. در این مقاله از معماری‌های مختلف CNN برای طبقه‌بندی بیماران مبتلا به سرطان پستان با استفاده از تصاویر

منابع

- 1-Prabha S, Sujatha C. Proposal of index to estimate breast similarities in thermograms using fuzzy C means and anisotropic diffusion filter based fuzzy C means clustering. *Infrared Physics & Technology*. 2018;93:316-25.
- 2-Díaz-Cortés M-A, Ortega-Sánchez N, Hinojosa S, Oliva D, Cuevas E, Rojas R, et al. A multi-level thresholding method for breast thermograms analysis using Dragonfly algorithm. *Infrared Physics & Technology*. 2018;93:346-61.

- 3-Suganthi S, Ramakrishnan S. Anisotropic diffusion filter based edge enhancement for segmentation of breast thermogram using level sets. *Biomedical Signal Processing and Control*. 2014;10:128-36.
- 4-Kandlikar SG, Perez-Raya I, Raghupathi PA, Gonzalez-Hernandez J-L, Dabydeen D, Medeiros L, et al. Infrared imaging technology for breast cancer detection—Current status, protocols and new directions. *International Journal of Heat and Mass Transfer*. 2017;108:2303-20.
- 5-Ng E-K. A review of thermography as promising non-invasive detection modality for breast tumor. *International Journal of Thermal Sciences*. 2009;48(5):849-59.
- 6-Kuhl CK, Schrading S, Leutner CC, Morakkabati-Spitz N, Wardelmann E, Fimmers R, et al. Mammography, breast ultrasound, and magnetic resonance imaging for surveillance of women at high familial risk for breast cancer. *Journal of clinical oncology*. 2005;23(33):8469-76.
- 7-Lahiri B, Bagavathiappan S, Jayakumar T, Philip J. Medical applications of infrared thermography: a review. *Infrared Physics & Technology*. 2012;55(4):221-35.
- 8-Ghafarpour A, Zare I, Zadeh HG, Haddadnia J, Zadeh FJS, Zadeh ZE, et al. A review of the dedicated studies to breast cancer diagnosis by thermal imaging in the fields of medical and artificial intelligence sciences. *Biomedical Research*. 2016;27(2).
- 9-Keyserlingk J, Ahlgren P, Yu E, Belliveau N, Yassa M. Functional infrared imaging of the breast. *IEEE Engineering in Medicine and Biology Magazine*. 2000;19(3):30-41.
- 10-Gogoi UR, Bhowmik MK, Bhattacharjee D, Ghosh AK. Singular value based characterization and analysis of thermal patches for early breast abnormality detection. *Australasian physical & engineering sciences in medicine*. 2018;41(4):861-79.
- 11-Borchardt TB, Conci A, Lima RC, Resmini R, Sanchez A. Breast thermography from an image processing viewpoint: A survey. *Signal Processing*. 2013;93(10):2785-803.
- 12-Borchardt TB, Resmini R, Conci A, Martins A, Silva AC, Diniz EM, et al., editors. Thermal feature analysis to aid on breast disease diagnosis. *Proceedings of 21st Brazilian Congress of Mechanical Engineering—COBEM22* ; 2011.
- 13-Acharya UR, Ng EY-K, Tan J-H, Sree SV. Thermography based breast cancer detection using texture features and support vector machine. *Journal of medical systems*. 2012;36(3):1503-10.
- 14-Nicandro C-R, Efrén M-M, María Yaneli A-A, Enrique M-D-C-M, Héctor Gabriel A-M, Nancy P-C, et al. Evaluation of the diagnostic power of thermography in breast cancer using bayesian network classifiers. *Computational and mathematical methods in medicine*. 2013;2013.
- 15-Pramanik S, Bhattacharjee D, Nasipuri M, editors. Wavelet based thermogram analysis for breast cancer detection. *Advanced Computing and Communication (ISACC), 2015 International Symposium on*; 2015: IEEE.
- 16-Schaefer G, Závisek M, Nakashima T. Thermography based breast cancer analysis using statistical features and fuzzy classification. *Pattern Recognition*. 2009;42(6):1133-7.
- 17-Ng E, Kee E. Integrative computer-aided diagnostic with breast thermogram. *Journal of Mechanics in Medicine and Biology*. 2007;7(01):1-10.
- 18-Mookiah MRK, Acharya UR, Ng E. Data mining technique for breast cancer detection in thermograms using hybrid feature extraction strategy. *Quantitative InfraRed Thermography Journal*. 2012;9(2):151-65.
- 19-Francis SV, Sasikala M, Saranya S. Detection of breast abnormality from thermograms using curvelet transform based feature extraction. *Journal of medical systems*. 2014;38(4):23.
- 20-Araújo MC, Lima RC, De Souza RM. Interval symbolic feature extraction for thermography breast cancer detection. *Expert Systems with Applications*. 2014;14(15):6728-37.
- 21-Haddadnia J, Hashemian M, Hassanpour K. Diagnosis of breast cancer using a combination of genetic algorithm and artificial neural network in medical infrared thermal imaging. *Iranian Journal of Medical Physics*. 2012;9(4):265-74.
- 22-Sathish D, Kamath S, Prasad K, Kadavigere R, Martis RJ. Asymmetry analysis of breast thermograms using automated segmentation and texture features. *Signal, Image and Video Processing*. 2017;11(4):745-52.
- 23-Lashkari A, Pak F, Firouzmand M. Full intelligent cancer classification of thermal breast images to assist physician in clinical diagnostic applications. *Journal of medical signals and sensors*. 2016;6(1):12.
- 24-Zadeh HG, Haddadnia J, Montazeri A. A model for diagnosing breast cancerous tissue from thermal images using active contour and Lyapunov exponent. *Iranian journal of public health*. 2016;45(5):657.
- 25-Ghayoumi Zadeh H, Montazeri A, Abaspor Kazerouni I, Haddadnia J. Clustering and screening for breast cancer on thermal images using a combination of SOM and MLP. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*. 2017;5(1):68-76.

- 26-PROENG. Image Processing and Image Analyses Applied to Mastology, 2012, [http://visual.ic.uff.br/en/proeng./](http://visual.ic.uff.br/en/proeng/)
- 27-Motta L, Conci A, Lima R, Diniz E, Luís S, editors. Automatic segmentation on thermograms in order to aid diagnosis and 2D modeling. Proc of 10th Workshop em Informática Médica; 2010.
- 28-Chambolle A, De Vore RA, Lee N-Y, Lucier BJ. Nonlinear wavelet image processing: variational problems, compression, and noise removal through wavelet shrinkage. IEEE Transactions on Image Processing. 1998;7(3):319-35.
- 29-Fernández-Ovies FJ, Alférez-Baquero ES, de Andrés-Galiana EJ, Cernea A, Fernández-Muñiz Z, Fernández-Martínez JL, editors. Detection of Breast Cancer Using Infrared Thermography and Deep Neural Networks. International Work-Conference on Bioinformatics and Biomedical Engineering; 2019: Springer.
- 30-Albelwi S, Mahmood A. A framework for designing the architectures of deep convolutional neural networks. Entropy. 2017;19(6):242.
- 31-Spanhol FA, Oliveira LS, Petitjean C, Heutte L, editors. Breast cancer histopathological image classification using convolutional neural networks. 2016 international joint conference on neural networks (IJCNN); 2016: IEEE.
- 32-Wakankar AT, Suresh G, editors. Automatic diagnosis of breast cancer using thermographic color analysis and SVM classifier. The International Symposium on Intelligent Systems Technologies and Applications; 2016: Springer.
- 33-Bianco S, Cadene R, Celona L, Napoletano P. Benchmark Analysis of Representative Deep Neural Network Architectures. IEEE Access. 2018;6:64270-7.
- 34-Szegedy C, Ioffe S, Vanhoucke V, Alemi AA, editors. Inception-v4, inception-resnet and the impact of residual connections on learning. Thirty-First AAAI Conference on Artificial Intelligence; 2017.

A Study of Deep Convolutional Neural Network for Diagnosing Breast Cancer in Thermographic Images

Mohammad Hossein Gholizadeh¹, Hossein Ghayoumi Zadeh^{2*},
Hassan Fatehi Marj¹, Nasrin Ahmadinejad³

1-Assistant Professor of Electrical Engineering.

2-Assistant Professor of Biomedical Engineering.

3-Associate Professor of Radiology.

1,2-Department of Electrical Engineering, Faculty of Engineering, Vali-E-Asr University of Rafsanjan, Rafsanjan, Iran.

3-Department of Radiology, School of Medicine Advanced Diagnostic and Interventional Radiology Research Center, Tehran, Iran.

*Corresponding author:

Hossein Ghayoumi Zadeh; Department of Electrical Engineering, Faculty of Engineering, Vali-E-Asr University of Rafsanjan, Rafsanjan, Iran.

Tel: +989123403615

Email: h.ghayoumizadeh@vru.ac.ir

Abstract

Background and Objectives: Computer-aided design diagnostic systems are widely used in the differential diagnosis of breast cancer. Therefore, improving the accuracy of a CAD system has become an important field of research. In this study, we investigated CAD systems based on deep neural networks of convolution type to detect breast cancer in thermographic images.

Subjects and Methods: For analyzing the proposed model, the Database for Mastology Research (DMR) database was used. The number of the participants examined were 196, including 41 cases of cancer and 155 healthy subjects. Each person had 10 images of thermography. The total number of the analyzed images included 1960 images of thermography. The classification of thermal images including cancerous and healthy images is based on three types of deep convolution neural networks including google net, resnet18 and vgg16.

Results: The accuracy and specificity of the results using a neural network models of deep pre-training on google-net, resnet18 and vgg16 was 85.03%-89.7%, 83.8% -91.9% and 85.03% -91.01% respectively. The proposed model is capable of providing a significant response to the different breast tissue morphologies.

Conclusion: The model of deep artificial neural network can be used as an efficient and intelligent way to detect cancer in original thermal images without extracting features. However, more studies are needed to design other models of artificial neural networks based on deep learning for detection of malignant or benign cancers in thermal imagery.

Key words: Breast Cancer, Thermal Images, Deep Neural Network, Classification.

►Please cite this paper as:

Hossein Gholizadeh M, Ghayoumi Zadeh H, Fatehi Marj H, Ahmadinejad N. A Study of Deep Convolutional Neural Network for Diagnosing Breast Cancer in Thermographic Images. *Jundishapur Sci Med J* 2019; 18(6):615-629

Received: Oct 29, 2019

Revised: Oct 30, 2019

Accepted: Dec 19, 2020