

«بِسْمِ اللَّهِ»



گزارش .....

عنوان .....

ارائه دهندگان:

.....

استاد درس:

.....

زمستان ۱۳۹۹

## چکیده

سرطان سینه یکی از علل اصلی مرگ و میر زنان در کشورهای توسعه یافته و همچنین در حال توسعه است. تشخیص و طبقه بندی سرطان سینه در مراحل اولیه گسترش آن ممکن است به بیماران امکان درمان را بدهد. در این مقاله، یک چارچوب یادگیری عمیق جدید برای تشخیص و طبقه بندی سرطان پستان در تصاویر سیتولوژی پستان با استفاده از مفهوم یادگیری انتقالی پیشنهاد شده است. برخلاف یادگیری کلاسیک که به صورت مجزا توسعه می یابند و نتیجه می دهند، یادگیری انتقالی به دنبال استفاده از دانش اولیه به دست آمده در حین حل یک مسئله است. در چارچوب پیشنهادی، ویژگی های تصاویر با استفاده از معماری های CNN از پیش آموزش دیده استخراج می شوند، یعنی GoogLeNet، شبکه گروهی هندسه بصری (VGGNet) و شبکه های باقی مانده (ResNet) که به یک لایه کاملاً متصل برای طبقه بندی سلول های بدخیم و خوش خیم وارد می شوند. برای ارزیابی عملکرد چارچوب پیشنهادی، آزمایش ها بر روی مجموعه داده های معیار استاندارد انجام می شوند. مشاهده شده است که چارچوب پیشنهادی از نظر دقت در تشخیص و طبقه بندی تومور پستان در تصاویر سیتولوژی از تمام معماری های یادگیری عمیق دیگر برتری دارد.

**کلیدواژه:** یادگیری عمیق، تشخیص الگوی هوشمند، یادگیری انتقالی، سرطان سینه

## فهرست مطالب

صفحه	عنوان
ب	فهرست جدول‌ها
ج	فهرست شکل‌ها
۴	۱- مقدمه
۷	۲- روش پیشنهادی
۷	۱-۲- پیش‌پردازش داده‌ها و پردازش اضافه
۸	۲-۲- معماری از پیش آموزش‌دیده‌ی CNN برای استخراج ویژگی
۸	۱-۲-۲- Googlenet
۹	۲-۲-۲- VGGNet
۱۰	۳-۲-۲- Resnet
۱۰	۳-۲- Transfer learning یا یادگیری انتقالی
۱۲	۳- نتایج تجربی و بحث
۱۲	۱-۳- دیتاست
۱۲	۲-۳- نتایج و آنالیز
۱۳	۳-۳- تحلیل مقایسه‌ای دقت با روش‌های دیگر
۱۴	۴- نتیجه‌گیری
۱۵	فهرست مراجع

## فهرست جدول‌ها

صفحه

عنوان

---

جدول ۱- تجزیه و تحلیل و مقایسه روش پیشنهادی با حالت‌های مختلف CNN ..... ۱۳	
جدول ۲- تجزیه و تحلیل مقایسه‌ای چارچوب مبتنی بر اسپلیت پیشنهادی با سایر معماری‌های CNN <b>Error! Bookmark not defined.</b> ....	
جدول ۳- تحلیل مقایسه‌ای با روش‌های دیگر ..... ۱۳	

## فهرست شکل‌ها

صفحه	عنوان
۷.....	شکل ۱- بلوک دیاگرام چارچوب پیشنهادی یادگیری عمیق.....
۹.....	شکل ۲- معماری پایه GoogLeNet.....
۹.....	شکل ۳- معماری پایه VGGNet.....
۱۰.....	شکل ۴- معماری پایه ResNet.....

## ۱- مقدمه

در تحقیقات زیست پزشکی، تجزیه و تحلیل تصاویر میکروسکوپی نشان دهنده اندام‌ها و بافت‌های مختلف انسان نقش مهمی در درک فعالیت‌های مختلف بیولوژیکی ایفا می‌کند. در میان آزمایش‌های بررسی تصویر میکروسکوپی، طبقه‌بندی تصاویر (بافت‌ها، اندام‌ها و غیره) از اهمیت زیادی برخوردار است. کاربردهای مختلف شناسایی شده با طبقه‌بندی تصویر میکروسکوپی توسعه یافته است. سرطان سینه شایع‌ترین و اصلی‌ترین علت مرگ و میر در زنان بین ۲۰ تا ۵۹ سال در سراسر جهان است [۱]. اگر در مراحل اولیه تشخیص داده شود، میزان بقای سرطان سینه ممکن است تا ۸۰ درصد افزایش یابد [۲].

دو روش رایج تشخیصی که برای تشخیص سرطان پستان استفاده می‌شود، ماموگرافی و بیوپسی هستند. در ماموگرافی، تصاویر پستان برای تشخیص علائم اولیه سرطان در زنان توسط رادیولوژیست استفاده می‌شود. مشاهده شده است که به دلیل استفاده از ماموگرافی برای تشخیص سرطان، نسبت مرگ و میر کاهش یافته است [۳]. بیوپسی یکی دیگر از روش‌های تشخیصی کارآمد و دقیق برای تشخیص سرطان سینه است. در این روش، یک نمونه بافت از ناحیه آسیب‌دیده پستان توسط پاتولوژیست برای تشخیص و طبقه‌بندی تومور در زیر میکروسکوپ تجزیه و تحلیل می‌شود. در حال حاضر، بیوپسی نقش حیاتی در سرطان سینه و همچنین در سایر انواع تشخیص سرطان دارد [۴].

از طریق بیوپسی، پاتولوژیست می‌تواند دو نوع ضایعه را تعیین کند: خوش‌خیم و بدخیم. ضایعه خوش‌خیم سرطانی نیست. این در مواقع ناهنجاری‌های سلول‌های اپیتلیال است و بیشتر این ناهنجاری‌ها نمی‌توانند به منبع سرطان سینه تبدیل شوند. سلول‌های بدخیم یا سرطانی آن دسته از سلول‌ها هستند که به‌طور غیرطبیعی شروع به تقسیم می‌کنند و به‌طور نامنظم رشد می‌کنند. تجزیه و تحلیل دستی تصاویر میکروسکوپی به دلیل ظاهر نامنظم سلول‌های خوش‌خیم و بدخیم یک کار بسیار پیچیده و چالش‌برانگیز است [۵، ۶].

در چند دهه گذشته، محققان راه‌حل‌های مختلفی را برای طبقه‌بندی خودکار سلول‌ها برای تشخیص سرطان در پستان پیشنهاد کرده‌اند. برخی از محققان بر روی تجزیه و تحلیل هسته‌ها با استخراج ویژگی‌هایی از هسته‌ها کار کرده‌اند تا اطلاعات قابل توجهی برای طبقه‌بندی سلول‌ها به خوش‌خیم و بدخیم ارائه دهند [۷]. به‌طور مشابه، الگوریتم‌های مبتنی بر خوشه‌بندی همراه با تبدیل هاف دایره‌ای و ویژگی‌های آماری مختلف نیز برای تقسیم‌بندی و طبقه‌بندی هسته‌ها مورد استفاده قرار می‌گیرند [۸-۱۰].

در تجزیه و تحلیل تصویر پزشکی، الگوریتم‌ها برای تصاویر هیستوپاتولوژیک به سرعت در حال توسعه هستند، اما همچنان، داشتن یک سیستم خودکار برای به دست آوردن نتایج کارآمد و بسیار دقیق بسیار مورد نیاز است [۱۱-۱۳]؛ بنابراین، چنین تکنیک‌هایی مورد نیاز است که جهت‌گیری صحیح را به سمت محصولات کیفی برای تشخیص، بهبود می‌دهد. ماهیت پیچیده وظایفی مانند پیش‌پردازش، تقسیم‌بندی، استخراج ویژگی و غیره در رویکردهای یادگیری ماشین کلاسیک، عملکرد سیستم را از نظر کارایی و دقت کاهش می‌دهد.

برای غلبه بر مشکلات تکنیک‌های یادگیری ماشین سنتی، مفهوم یادگیری عمیق برای استخراج اطلاعات مربوطه از تصاویر خام و استفاده کارآمد از آن برای فرآیند طبقه‌بندی معرفی شده است [۱۴، ۱۵]. در یادگیری عمیق، ویژگی‌ها به صورت دستی تنظیم نمی‌شوند، در عوض یادگیری از مجموعه داده‌ها با کمک رویکرد یادگیری همه‌منظوره انجام می‌شود [۱۴]. در چند سال اخیر، یادگیری عمیق مبتنی بر شبکه عصبی کانولوشنال (CNN) در زمینه‌ی تجزیه و تحلیل تصاویر پزشکی مانند تشخیص سلول‌های میتوز از تصاویر میکروسکوپی [۱۶، ۱۷] تشخیص تومور [۱۸]، تقسیم‌بندی غشای عصبی [۱۹]، بیماری پوستی و طبقه‌بندی آن [۲۰]، تشخیص و طبقه‌بندی سلول‌های ایمنی [۲۱] و کمی‌سازی توده در ماموگرافی [۲۲] به موفقیت زیادی دست یافته است.

اگرچه روش CNN روی مجموعه داده‌های بزرگ بسیار خوب کار می‌کند، اما در مجموعه داده‌های کوچک نمی‌تواند به دستاوردهای قابل توجهی دست یابد. به منظور دستیابی به دقت تشخیص بالاتر و کاهش هزینه‌های محاسباتی، می‌توان از مفهوم یادگیری انتقال برای بهبود عملکرد معماری‌های CNN معمولی با ترکیب دانش آن‌ها استفاده کرد [۲۳، ۲۴]. در این راستا، مجموعه‌ای از ویژگی‌ها از مجموعه داده‌های تصویر عمومی با استفاده از CNN عمیق از پیش آموزش‌دیده استخراج می‌شود و سپس به طور مستقیم برای مجموعه داده‌های خاص و کوچک‌تر دامنه اعمال می‌شود [۲۵]. مفهوم یادگیری مبتنی بر زمینه، جهت جدیدی به یادگیری انتقال می‌دهد که در آن، CNN در دو مرحله برای تکه‌های تکی و همپوشانی آموزش داده می‌شود و در تشخیص و طبقه‌بندی سرطان سینه بسیار خوب عمل می‌کند [۲۶]. ترکیب چندین معماری CNN عملکرد یادگیری انتقالی را افزایش می‌دهد و ممکن است جایگزین استفاده از معماری سنتی CNN شود. به طور مشابه، ترکیب ResNet50، InceptionV2 و InceptionV3 از قبل در ImageNet آموزش دیده‌اند که یک مدل سریع و دقیق برای طبقه‌بندی تصاویر مبتنی بر سلول تولید می‌کند [۲۷، ۲۸].

در چارچوب پیشنهادی، یادگیری انتقالی برای غلبه بر کمبودهای سیستم‌های موجود برای تشخیص و طبقه‌بندی تومور سرطانی مورد بهره‌برداری قرار گرفته است. سهم اصلی در این مقاله را می‌توان در موارد زیر خلاصه کرد:

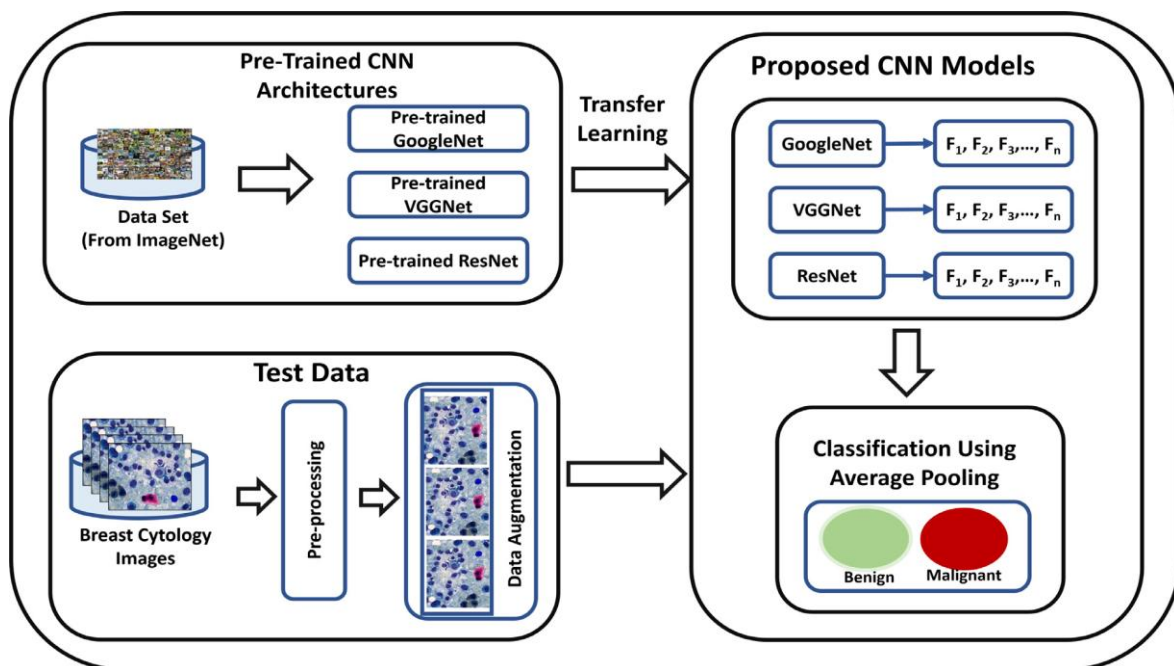
- ارائه چارچوبی مبتنی بر معماری یادگیری عمیق برای تشخیص و طبقه‌بندی سرطان پستان.
- تجزیه و تحلیل مفهوم یادگیری انتقالی بر روی سه معماری مختلف یادگیری عمیق.
- ارائه یک تحلیل مقایسه‌ای از هر معماری یادگیری عمیق با توجه به دقت درزمینه‌ی یادگیری انتقالی.

بقیه مقاله به شرح زیر سازمان‌دهی شده است: بخش ۲ تجزیه و تحلیل مفصلی از رویکرد پیشنهادی ارائه می‌دهد که شامل بخش‌های فرعی مانند پیش‌پردازش داده‌ها و افزایش داده‌ها، معماری‌های CNN از پیش آموزش‌دیده و یادگیری انتقالی است. به‌طور مشابه، بخش ۳ نتایج تجربی به‌دست‌آمده پس از اعمال رویکرد پیشنهادی را همراه با ارزیابی عملکرد آن مورد بحث قرار می‌دهد. درنهایت، بخش ۴ نتیجه‌گیری مقاله و پیشنهادهای آینده را ارائه می‌دهد.



## ۲- روش پیشنهادی

در این بخش، چارچوب پیشنهادی مبتنی بر معماری CNN برای تشخیص و طبقه‌بندی سلول‌های بدخیم در تصاویر سیتولوژی پستان توضیح داده می‌شود. در چارچوب پیشنهادی، ویژگی‌های سطح پایین مختلف به‌طور جداگانه توسط سه معماری معروف CNN GoogLeNet، VGGNet و ResNet استخراج می‌شوند. ویژگی‌های ترکیبی به یک لایه کاملاً متصل برای کار طبقه‌بندی، همان‌طور که در شکل ۱ نشان داده شده است، وارد می‌شوند. جزئیات مربوط به هر مرحله از معماری پیشنهادی در بخش‌های فرعی زیر آورده شده است.



شکل ۱- بلوک دیاگرام چارچوب پیشنهادی یادگیری عمیق

### ۲-۱- پیش‌پردازش داده‌ها و پردازش اضافه

مرحله پیش‌پردازش در تصاویر بافت برای حذف انواع مختلف نویزها ضروری است. در رویکرد پیشنهادی، تصاویر بافت رنگ‌آمیزی میکروسکوپی H&E با استفاده از روش پیشنهادی در [۲۹] نرمال می‌شوند. برای دستیابی به دقت بالاتر، CNN به مجموعه داده‌های بزرگی نیاز دارد. علاوه بر این، عملکرد CNN با مجموعه داده‌های کوچک به دلیل بیش‌برازش بدتر می‌شود. این بدان معناست که شبکه در داده‌های آموزشی بسیار خوب عمل می‌کند اما در داده‌های آزمایشی عملکرد ضعیفی دارد.


در چارچوب پیشنهادی، تکنیک افزایش داده برای افزایش مجموعه داده‌ها و کاهش مشکلات بیش برآزش اعمال می‌شود [۳۰، ۳۱]. در روش افزایش داده‌ها، تعداد نمونه‌ها با اعمال تبدیل‌های هندسی به مجموعه داده‌های تصویر با استفاده از تکنیک‌های ساده پردازش تصویر افزایش می‌یابد. در این راستا، مجموعه داده‌های تصویر با پردازش رنگ، تبدیل (ترجمه، مقیاس بندی و چرخش)، چرخش و اختلال نويز افزایش می‌یابد. از آنجایی که تصاویر میکروسکوپی از نظر چرخشی ثابت هستند، آسیب‌شناس به‌راحتی می‌تواند تصاویر میکروسکوپی سرطان پستان را از زوایای مختلف بدون هیچ‌گونه تغییری در تشخیص تجزیه و تحلیل کند [۳۲].

## ۲-۲- معماری از پیش آموزش دیده‌ی CNN برای استخراج ویژگی

در ابتدا، از معماری‌های CNN جداگانه برای استخراج ویژگی استفاده می‌شود که در یک لایه کاملاً متصل برای وظایف طبقه‌بندی ترکیب می‌شوند. ویژگی‌های ترکیبی ممکن است حاوی چندین ویژگی استخراج شده از توصیفگر واحد باشند، این ویژگی‌ها ممکن است نمایانگر توصیف‌کننده شکل مانند دایره‌ای، گردی، فشردگی و غیره باشند. در چارچوب پیشنهادی، سه معماری عمیق CNN جدید و به‌روز وجود دارد: GoogLeNet [۳۳]، شبکه گروهی هندسه بصری (VGGNet) [۳۴] و شبکه‌های باقیمانده (ResNet) [۳۵] به‌عنوان استخراج‌کننده ویژگی برای طبقه‌بندی سرطان پستان در تصاویر سیتولوژی استفاده می‌شوند. این معماری‌ها برای توصیف‌کننده‌های مختلف تصویر از پیش آموزش داده شده‌اند و به دنبال آن ویژگی‌های مربوطه از تصاویر میکروسکوپی بر اساس تئوری یادگیری انتقال استخراج می‌شوند [۳۶]. ساختار اساسی هر یک از معماری‌های CNN اتخاذ شده در بخش‌های فرعی زیر توضیح داده شده است.

### ۲-۲-۱- Googlenet

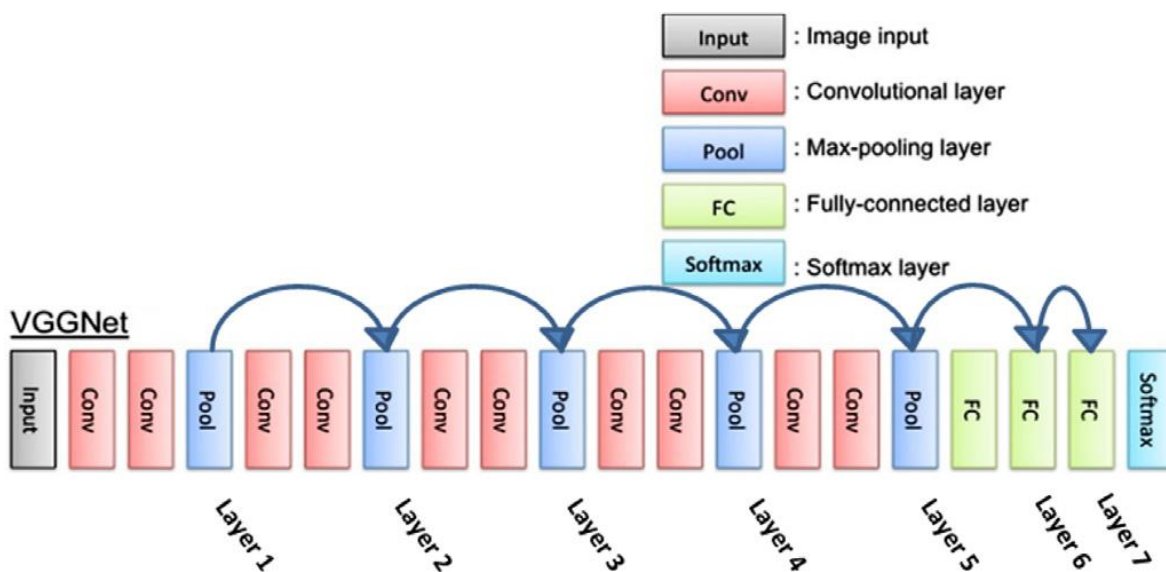
این یک شبکه کوچک متشکل از سه لایه کانولوشنال، لایه‌های عملیات خطی اصلاح شده، لایه‌های ادغام و دو لایه کاملاً متصل است. با استفاده از معماری GoogLeNet، ما مدلی را پیشنهاد کردیم که فیلترهای کانولوشنال مختلف با اندازه‌های مختلف را در یک فیلتر واحد جدید ترکیب می‌کند که نه تنها تعداد ابعاد را کاهش می‌دهد، بلکه پیچیدگی محاسباتی را نیز به حداقل می‌رساند. معماری زیربنایی GoogLeNet در شکل ۲ نشان داده شده است.



شکل ۲- معماری پایه GoogLeNet [۳۳]


### VGGNet -۲-۲-۲

VGGNet شبیه AlexNet است؛ البته با لایه‌های کانولوشن اضافی. VGGNet متشکل از ۱۳ کانولوشن، اصلاح، ادغام و ۳ لایه کاملاً متصل است [۳۴]. شبکه کانولوشن از فیلتر اندازه پنجره  $3 \times 3$  و شبکه جمع‌آوری  $2 \times 2$  استفاده می‌کند. VGGNet به دلیل معماری ساده‌اش در مقایسه با AlexNet بهتر عمل می‌کند. معماری زیربنایی VGGNet در شکل ۳ نشان داده شده است.



شکل ۳- معماری پایه VGGNet [۳۴]

ResNet یک شبکه باقیمانده بسیار عمیق است و نتایج خوبی را در کار طبقه‌بندی در ImageNet به دست می‌آورد [۳۷]. ResNet فیلترهای کانولوشن چند اندازه را ترکیب کرده است که مشکل تخریب را مدیریت می‌کند و زمان آموزش را که به دلیل ساختارهای عمیق آن رخ می‌دهد کاهش می‌دهد. معماری زیربنایی ResNet در شکل ۴ نشان داده شده است.



شکل ۴- معماری پایه ResNet [۳۵]

### ۳-۲-۲ Transfer learning یا یادگیری انتقالی

در عمل، برای آموزش یک CNN داده‌های زیادی نیاز است، اما در برخی موارد، تهیه یک مجموعه داده بزرگ و در اکثر برنامه‌های کاربردی در دنیای واقعی به دست آوردن داده‌های آموزشی و آزمایشی کار دشواری است؛ بنابراین مفهوم یادگیری انتقالی معرفی شده است. یادگیری انتقالی یکی از شناخته‌شده‌ترین روش‌های یادگیری ماشینی است که دانشی که برای حل یک مسئله به کار می‌رود را یاد می‌گیرد و روی مسائل دیگر دوباره استفاده می‌کند. در ابتدا، شبکه پایه برای یک کار خاص در مجموعه داده، آموزش داده می‌شود و سپس به هدف آموزش به مجموعه داده [۳۸] منتقل می‌شود. فرآیند یادگیری انتقال را می‌توان به دو مرحله اصلی تقسیم کرد. انتخاب مدل از پیش آموزش‌دیده، اندازه مسئله و شباهت. انتخاب مدل از پیش آموزش داده‌شده بر اساس مسئله مرتبط باهدف انجام می‌شود. اگر اندازه مجموعه داده‌های هدف کوچک‌تر (کمتر از ۱۰۰۰ تصویر) و مشابه مجموعه داده‌های آموزشی منبع (مجموعه داده‌های پزشکی، مجموعه داده‌های دست‌نوشته، مجموعه داده‌های مرتبط با بیومتریک و غیره) باشد، احتمال بیش برآزش زیاد است. به‌طور مشابه، اگر اندازه داده‌های هدف بزرگ‌تر و شبیه به مجموعه داده‌های منبع باشد، احتمال بیش برآزش کم است و فقط به تنظیم مدل از قبل آموزش داده‌شده نیاز دارد.

در روش پیشنهادی، از سه روش CNN (GoogLeNet، VGGNet و ResNet) برای به اشتراک گذاشتن ویژگی‌ها در یادگیری انتقال و تنظیم استفاده می‌شود. سه معماری CNN توسط تصاویر نمونه از مجموعه داده ImageNet آموزش داده شده و یادگیری انتقال روی آن‌ها انجام شده است که باعث می‌شود این روش بدون نیاز به آموزش جدید ویژگی‌های عمومی را از مجموعه داده‌های دیگر بیاموزد. تعداد ویژگی‌های استخراج شده به طور مستقل از روش CNN مربوطه در لایه کاملاً متصل برای طبقه‌بندی سلول‌های بدخیم<sup>۱</sup> و خوش‌خیم<sup>۲</sup> با استفاده از طبقه‌بندی ادغام متوسط<sup>۳</sup> ترکیب می‌شود.

---

<sup>1</sup> Malignant

<sup>2</sup> Benign

<sup>3</sup> Average pooling classification

## ۳- نتایج تجربی و بحث

### ۳-۱- دیتاست

برای ارزیابی عملکرد روش پیشنهادی از دو مجموعه داده تصویر میکروسکوپی سینه استفاده می‌شود. اولی یک مجموعه داده معیار استاندارد [۳۹] است و دیگری به صورت محلی در بیمارستان LRH پیشاور، پاکستان جمع‌آوری شده است. برای هر دو مجموعه داده، اولین روش تقویت با مقیاس بندی، چرخش، انتقال و مدل‌سازی رنگ‌ها برای تولید ۸۰۰۰ تصویر اعمال می‌شود. در این ۸۰۰۰ تصویر، ۶۰۰۰ تصویر برای آموزش و ۲۰۰۰ تصویر برای آزمودن مدل استفاده شده است. در هر دو مجموعه داده، تصاویر توسط میکروسکوپ با بزرگنمایی‌های مختلف گرفته می‌شود. در روش پیشنهادی از تصاویر بزرگ‌نمایی شده مختلف (100X، 140X، 200X و 500X) برای ارزیابی دقیق استفاده می‌شود. در طول اجرای روش پیشنهادی، ۷۵ درصد از مجموعه داده‌ها برای اهداف آموزشی و ۲۵ درصد از مجموعه داده‌ها برای آزمایش دقت استفاده می‌شود. علاوه بر این، برای کنترل بیش‌برازش، معیارهای توقف اولیه طراحی شده است که مبتنی بر اعتبار سنجی عملکرد<sup>۱</sup> است، یعنی زمانی که سیستم پس از ۱۰۰۰ تکرار، هیچ بهبودی نشان نمی‌دهد، فرآیند آموزش را متوقف می‌کند.

### ۳-۲- نتایج و آنالیز

روش پیشنهادی بر روی سه حالت مختلف CNN، یعنی GoogLeNet، VGGNet و ResNet، به صورت جداگانه آموزش داده می‌شود و سپس داده‌ها را با استفاده از یادگیری انتقال به استخراج ویژگی‌های ترکیبی منتقل می‌کند. نتایج به دست آمده از CNN منفرد با ویژگی‌های ترکیبی همراه با تکنیک‌های مختلف مقایسه می‌شود. جدول ۱ نتیجه هر روش را به صورت جداگانه در اندازه‌های بزرگ‌نمایی مختلف و همچنین رویکرد یادگیری انتقالی پیشنهادی را نشان می‌دهد.

همان‌طور که در جدول ۱ نشان داده شده است، روش GoogLeNet، VGGNet و ResNet به ترتیب میانگین دقت طبقه‌بندی ۹۳/۵، ۹۴/۱۵ و ۹۴/۱۵ درصد را ارائه می‌دهد، درحالی‌که روش پیشنهادی دقت ۹۷/۵۲ درصد را ارائه می‌دهد. این نتایج نشان می‌دهد که روش پیشنهادی از نظر دقت در تشخیص و طبقه‌بندی تومور سرطان سینه در مقایسه با سه روش دیگر، عملکرد بالایی دارد.

---

<sup>1</sup> Performance Validation

در جدول ۲، نوع کلاس نشان‌دهنده نوع سرطان (B یا M) که در آن B نشان‌دهنده خوش‌خیم و M نشان‌دهنده بدخیم و پارامترهای گزارش‌شده صحت<sup>۱</sup>، Recall، امتیاز F1<sup>۲</sup> و دقت<sup>۳</sup> است. همچنین دقت متوسط هر روش را بر اساس اسپلیت ارائه می‌دهد. می‌توان اشاره کرد که روش پیشنهادی دقت بالاتری در طبقه‌بندی سلول‌های سرطانی در تصاویر سیتولوژی سینه در مقایسه با روش‌های منفرد ارائه می‌دهد.

جدول ۱- تجزیه و تحلیل و مقایسه روش پیشنهادی با حالت‌های مختلف CNN

CNN Architectures	Lens				Average Classification Accuracies
	100X	140X	200X	500X	
GoogLeNet	90.4	93.7	95.3	94.6	94.15
VGGNet	90.8	94.8	96.7	94.2	94.15
ResNet	91.5	93.3	95.4	97.2	94.35
Proposed Framework	96.8	96.9	97.8	98.6	97.52

### ۳-۳- تحلیل مقایسه‌ای دقت با روش‌های دیگر

به‌طور مشابه، یک تجزیه و تحلیل مقایسه‌ای از نتایج به‌دست‌آمده با استفاده از روش پیشنهادی با چهار روش شناخته‌شده انجام شده است تا قدرت روش پیشنهادی را همان‌طور که در جدول ۳ ارائه شده است، نشان دهد. از جدول ۳ قابل مشاهده است که روش‌های [۲۵-۲۸] به ترتیب دقت ۹۲/۶۳، ۹۰/۰، ۹۷/۰ و ۹۷/۵ درصد را ارائه می‌دهند، درحالی‌که نتایج به‌دست‌آمده با استفاده از روش پیشنهادی، دقت ۹۷/۵۲ درصد را ارائه می‌دهد که بالاتر از همه است.

### جدول ۲- تحلیل مقایسه‌ای با روش‌های دیگر

Methods	Accuracy
Nguyen [25]	92.63%
Awan [26]	90.00%
Kensert [27]	97.00%
Vesal [28]	97.50%
Proposed Framework	97.52%

<sup>1</sup> Precision

<sup>2</sup> F1 Score

<sup>3</sup> Accuracy

## ۴- نتیجه‌گیری

در این مقاله، یک روش یادگیری عمیق جدید برای تشخیص و طبقه‌بندی سرطان سینه با استفاده از مفهوم یادگیری انتقالی پیشنهاد شده است. در این روش، ویژگی‌هایی از تصاویر سیتولوژی سینه با استفاده از سه روش مختلف CNN (GoogLeNet, VGGNet و ResNet) استخراج می‌شوند که با استفاده از مفهوم یادگیری انتقالی برای بهبود دقت طبقه‌بندی ترکیب شده‌اند. به‌طور مشابه، مفهوم افزایش داده را برای افزایش اندازه یک مجموعه داده برای بهبود کارایی ساختار CNN پیشنهاد کردیم. در نهایت، عملکرد روش پیشنهادی با حالت‌های مختلف CNN به‌طور مستقل و همچنین با سایر روش‌های موجود مقایسه شده است. مشاهده شد که روش پیشنهادی نتایج عالی در مورد دقت ارائه می‌دهد که کارایی طبقه‌بندی را بهبود می‌بخشد.



## فهرست مراجع

- [1] F. Bray, J. Ferlay, I. Soerjomataram, R.L. Siegel, L.A. Torre, A. Jemal, Global cancer statistics 2018: globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries, *CA Cancer J. Clin.* 68 (6) (2018) 394–424.
- [2] W.H. Organization, et al., WHO Position paper on mammography screening, World Health Organization, 2014.
- [3] A. Chetlen, J. Mack, T. Chan, Breast cancer screening controversies: who, when, why, and how? *Clin. Imaging* 40 (2) (2016) 279–282.
- [4] A. Chekkoury, P. Khurd, J. Ni, C. Bahlmann, A. Kamen, A. Patel, L. Grady, M. Singh, M. Groher, N. Navab, et al., Automated malignancy detection in breast histopathological images, in: *Medical Imaging 2012: Computer-Aided Diagnosis*, 8315, International Society for Optics and Photonics, 2012, p.831515.
- [5] C. López, M. Lejeune, R. Bosch, A. Korzynska, M. García-Rojo, M.-T. Salvadó, T. Álvaro, C. Callau, A. Roso, J. Jaén, Digital image analysis in breast cancer: an example of an automated methodology and the effects of image compression., *Stud. Health Technol. Inform.* 179 (2012) 155–171.
- [6] I. Pöllänen, B. Braithwaite, T. Ikonen, H. Niska, K. Haataja, P. Toivanen, T. Tolonen, Computer-aided breast cancer histopathological diagnosis: Comparative analysis of three dtocs-based features: Sw-dtocs, sw-wdtocs and sw-3-4-dtocs, in: *Image Processing Theory, Tools and Applications (IPTA), 2014 4th International Conference on*, IEEE, 2014, pp. 1–6.
- [7] Z. Jan, S. Khan, N. Islam, M. Ansari, B. Baloch, Automated detection of malignant cells based on structural analysis and naive bayes classifier, *Sindh University Research Journal-SURJ (Science Series)* 48 (2) (2016) 265–270.
- [8] M. Kowal, P. Filipczuk, A. Obuchowicz, J. Korbicz, R. Monczak, Computer-aided diagnosis of breast cancer based on fine needle biopsy microscopic images, *Comput. Biol. Med.* 43 (10) (2013) 1563–1572.
- [9] P. Filipczuk, T. Fevens, A. Krzyzak, R. Monczak, Computer-aided breast cancer diagnosis based on the analysis of cytological images of fine needle biopsies., *IEEE Trans. Med. Imaging* 32 (12) (2013) 2169–2178.
- [10] Y.M. George, H.H. Zayed, M.I. Roushdy, B.M. Elbagoury, Remote computer-aided breast cancer detection and diagnosis system based on cytological images, *IEEE Syst. J.* 8 (3) (2014) 949–964.
- [11] H. Irshad, A. Veillard, L. Roux, D. Racoceanu, Methods for nuclei detection, segmentation, and classification in digital histopathology: a review - current status and future potential, *IEEE Rev. Biomed. Eng.* 7 (2014) 97–114.

- [12] M. Veta, J.P. Pluim, P.J. Van Diest, M.A. Viergever, Breast cancer histopathology image analysis: a review, *IEEE Trans. Biomed. Eng.* 61 (5) (2014) 1400–1411.
- [13] M.T. McCann, J.A. Ozolek, C.A. Castro, B. Parvin, J. Kovacevic, Automated histology analysis: opportunities for signal processing, *IEEE Signal Process. Mag.* 32 (1) (2015) 78–87.
- [14] Y. LeCun, Y. Bengio, G. Hinton, Deep learning, *Nature* 521 (7553) (2015) 436.
- [15] Y. Bengio, A. Courville, P. Vincent, Representation learning: a review and new perspectives, *IEEE Trans. Pattern Anal. Mach. Intell.* 35 (8) (2013) 1798–1828.
- [16] C.D. Malon, E. Cosatto, Classification of mitotic figures with convolutional neural networks and seeded blob features, *J. Pathol. Inform.* 4 (9) (2013), doi:10.4103/2153-3539.112694.
- [17] A. Cruz-Roa, A. Basavanhally, F. González, H. Gilmore, M. Feldman, S. Ganesan, N. Shih, J. Tomaszewski, A. Madabhushi, Automatic detection of invasive ductal carcinoma in whole slide images with convolutional neural networks, in: *Medical Imaging 2014: Digital Pathology*, 9041, International Society for Optics and Photonics, 2014, p. 904103.
- [18] A.A. Cruz-Roa, J.E.A. Ovalle, A. Madabhushi, F.A.G. Osorio, A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection, in: *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, 2013, pp. 403–410.
- [19] D. Ciresan, A. Giusti, L.M. Gambardella, J. Schmidhuber, Deep neural networks segment neuronal membranes in electron microscopy images, in: *Advances in neural information processing systems*, 2012, pp. 2843–2851.
- [20] A. Esteva, B. Kuprel, S. Thrun, Deep networks for early stage skin disease and skin cancer classification, Project Report, Stanford University, 2015.
- [21] T. Chen, C. Chafd'Hotel, Deep learning based automatic immune cell detection for immunohistochemistry images, in: *International Workshop on Machine Learning in Medical Imaging*, Springer, 2014, pp. 17–24.
- [22] N. Dhungel, G. Carneiro, A.P. Bradley, Deep learning and structured prediction for the segmentation of mass in mammograms, in: *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, 2015, pp. 605–612.
- [23] A. Sharif Razavian, H. Azizpour, J. Sullivan, S. Carlsson, Cnn features off-the-shelf: an astounding baseline for recognition, in: *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 2014, pp. 806–813.

- [24] J. Donahue, Y. Jia, O. Vinyals, J. Hoffman, N. Zhang, E. Tzeng, T. Darrell, A deep convolutional activation feature for generic visual recognition. arxiv preprint. arXiv:1310.1531.
- [25] L.D. Nguyen, D. Lin, Z. Lin, J. Cao, Deep cnns for microscopic image classification by exploiting transfer learning and feature concatenation, in: Circuits and Systems (ISCAS), 2018 IEEE International Symposium on, IEEE, 2018, pp. 1–5.
- [26] R. Awan, N.A. Koohbanani, M. Shaban, A. Lisowska, N. Rajpoot, Context-aware learning using transferable features for classification of breast cancer histology images, in: International Conference Image Analysis and Recognition, Springer, 2018, pp. 788–795.
- [27] A. Kensert, P.J. Harrison, O. Spjuth, Transfer learning with deep convolutional neural network for classifying cellular morphological changes, bioRxiv (2018) 345728.
- [28] S. Vesal, N. Ravikumar, A. Davari, S. Ellmann, A. Maier, Classification of breast cancer histology images using transfer learning, in: International Conference Image Analysis and Recognition, Springer, 2018, pp. 812–819.
- [29] M. Macenko, M. Niethammer, J.S. Marron, D. Borland, J.T. Woosley, X. Guan, C. Schmitt, N.E. Thomas, A method for normalizing histology slides for quantitative analysis, in: Biomedical Imaging: From Nano to Macro, 2009. ISBI'09. IEEE International Symposium on, IEEE, 2009, pp. 1107–1110.
- [30] A. Krizhevsky, I. Sutskever, G.E. Hinton, Imagenet classification with deep convolutional neural networks, in: Advances in neural information processing systems, 2012, pp. 1097–1105.
- [31] D. Cireş, an, U. Meier, J. Schmidhuber, Multi-column deep neural networks for image classification. arXiv:1202.2745.
- [32] D.C. Cireş, an, A. Giusti, L.M. Gambardella, J. Schmidhuber, Mitosis detection in breast cancer histology images with deep neural networks, in: International Conference on Medical Image Computing and Computer-assisted Intervention, Springer, 2013, pp. 411–418.
- [33] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going deeper with convolutions, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1–9.
- [34] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition., 2014 arXiv:1409.1556.
- [35] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770–778.
- [36] J. Yosinski, J. Clune, Y. Bengio, H. Lipson, How transferable are features in deep

neural networks? in: Advances in neural information processing systems, 2014, pp. 3320–3328.

[37] Y. Yu, H. Lin, Q. Yu, J. Meng, Z. Zhao, Y. Li, L. Zuo, Modality classification for medical images using multiple deep convolutional neural networks, *J. Comput. Inf. Syst.* 11 (2015) 5403–5413.

[38] L. Yang, S. Hanneke, J. Carbonell, A theory of transfer learning with applications to active learning, *Mach. Learn.* 90 (2) (2013) 161–189.

[39] F.A. Spanhol, L.S. Oliveira, C. Petitjean, L. Heutte, A dataset for breast cancer histopathological image classification, *IEEE Trans. Biomed. Eng.* 63 (7) (2016) 1455–1462.