

ارائه معماری مبتنی بر اینترنت اشیا جهت پایش فعالیت های بیماری با استفاده از یادگیری عمیق

روزبه لطیفی عزیزی، دکتر سمیه جعفرعلی جاسبی

دانشگاه آزاد اسلامی، واحد علوم و تحقیقات (تهران)

چکیده

در دنیای امروزی، سرطان سینه یکی از دلایل مرگومیر و از وحشتناک ترین بیماری ها شناخته شده است، که یکی از علل بالقوه مرگ در زنان است. با اینکه یکی از قابل درمان ترین بیماری ها محسوب می شود اما مهم این است که با تشخیص به هنگام آن می توان میزان مرگومیر در طولانی مدت را کاهش داد. به عنوان راه حلی برای پیش بینی و درمان این بیماری، سیستم تشخیص خودکار بیماری در تشخیص و تجزیه و تحلیل به حوزه پزشکی کمک شایانی می کند که پاسخ سریع، قابلیت اطمینان، اثربخشی و همچنین کاهش خطر مرگ را ارائه می دهد. لذا در این مقاله از الگوریتم حافظه کوتاه مدت طولانی^۱ (LSTM) که یک الگوریتم یادگیری است استفاده شد، چراکه منجر به مدل هایی پایدارتر و با دقت بیشتر می شود. نتایج شبیه سازی و مقایسه با دیگر مقالات نشان داد که استفاده از این الگوریتم موجب بهبود دقت و حساسیت در تشخیص سرطان سینه شده و توانستیم با کمک الگوریتم LSTM به تشخیص اینکه آیا منطقه مشکوک نازول است یا خیر برسیم. ارزیابی ها نشان می دهد که حساسیت روش پیشنهادی به خصوص در برخورد با نازول های کوچک بسیار مطلوب است. نرخ خطای مثبت برآورد شده برای روش پیشنهادی 16.67٪ است که نسبت به کارهای دیگر کمتر است.

کلمات کلیدی: سرطان سینه، الگوریتم LSTM، یادگیری ماشین، تشخیص، پیش بینی، دقت

¹ Long Short-Term Memory (LSTM)

1- مقدمه

در حال حاضر سرطان جز بیماری های پراهمیت محسوب می شود که با شیوع نامناسب سلول ها ایجاد می گردد. به طوری که سرطان سینه یکی از پرتوجه ترین سرطان ها شناخته شده است متأسفانه در مراحل اولیه بدون علامت است، اگرچه برخی از علائم در زمان بعدی ظاهر می شوند، اما در مرحله علامتی درمان ممکن است پیچیده یا حتی غیرممکن شود و در نتیجه منجر به فوت شود. از این رو ارزیابی صحیح ریسک در کاهش مرگومیر بسیار مهم است. یکی از مهم ترین اقدامات در مبارزه با سرطان سینه، تشخیص زودهنگام و دقیق است. از آنجایی که شیوع این بیماری در سال های اخیر افزایش چشمگیری داشته است، سیستم های خبره و تکنیک های یادگیری ماشینی برای حل این مشکل مورد توجه بسیاری از محققان قرار گرفته است. یادگیری با نظارت یکی از زیرمجموعه های یادگیری ماشینی است که در آن به یک سیستم، زیرمجموعه ای از جفت های ورودی خروجی داده ها داده شده و سیستم تلاش می کند تا با بررسی این اطلاعات مدلی جهت رسیدن از ورودی به خروجی بسازد. از آنجاکه خروجی مورد انتظار در این نوع داده ها مشخص است، از باقیمانده داده ها جهت تست مدل استفاده خواهد شد [5-1]. الگوریتم های LSTM یکی از روش های پرکاربرد یادگیری با نظارت برای ساخت مدل و طبقه بندی داده ها است. این شبکه ها نوع خاصی از شبکه های عصبی بازگشتی هستند که توانایی یادگیری وابستگی های بلندمدت را دارند. در حقیقت یک معماری از شبکه عصبی بازگشتی مصنوعی است که در زمینه یادگیری عمیق مورد استفاده قرار می گیرد این شبکه ها نه تنها می تواند نقاط داده های واحد مانند (تصاویر) را پردازش کند بلکه دنباله های کل داده ها (مانند صدا یا فیلم) را نیز پردازش می کند [9 و 10]. استفاده از الگوریتم های یادگیری عمیق برای انتخاب ساختار بهینه می تواند بسیار مفید باشد. با بررسی تحقیقات انجام شده استفاده از الگوریتم های یادگیری در انتخاب ویژگی های مناسب در تشخیص بیماری سرطان سینه موجب بهبود دقت تشخیص آن می شود [11]؛ لذا در این تحقیق نیز از الگوریتم یادگیری عمیق مشابه با این تحقیقات یعنی LSTM استفاده خواهد شد و انتظار می رود که استفاده از این الگوریتم موجب بهبود دقت و حساسیت در تشخیص سرطان سینه گردد. هدف ما بهره مندی از الگوریتم LSTM است تا بتوان دقت تشخیص بیماری سرطان سینه را بهبود داد؛ چراکه استفاده از این الگوریتم موجب بهبود حساسیت طبقه بندی در تشخیص بیماری سرطان سینه می گردد و با کمک این الگوریتم می توان ویژگی های مناسب برای آموزش طبقه بندی در تشخیص بیماری سرطان سینه را انتخاب کرد. در روش پیشنهادی پس از بارگذاری داده ها از پایگاه داده، استخراج ویژگی ها انجام می شود. سپس ویژگی های استخراج شده با کمک الگوریتم LSTM انتخاب می گردند. در نهایت جهت ارزیابی، روش پیشنهادی با تحقیقات و مقالات قبلی مقایسه خواهد شد و نتایج در قالب نمودار و جداول به نمایش گذاشته می شوند.

2- سرطان سینه و پردازش تصویر

سرطان سینه نوعی بیماری است که مشخصه آن رشد کنترل نشده سلول در بافتهای سینه است. اگر این بیماری درمان نشود رشد سلولی می تواند در یک فرایند گسترش پیدا کند و به بافتهای اطراف یا سایر اعضای بدن برسد اکثر سرطان هایی که از سینه شروع می شوند، به نام سرطان های ابتدایی، کارسینوماهایی هستند که از بافت پوششی نشأت می گیرند [10]. در اکثر مواقع تا زمانی که سرطان سینه پیش روی نکرده باشد علائمی ایجاد نخواهد کرد؛ اما در برخی افراد مبتلا به سرطان سینه علائم اولیه ظاهر خواهد شد و می توان به تشخیص سرطان رسید. علائم اولیه سرطان سینه ممکن است برآمدگی، وجود توده های ریز، قرمزی مثل جوش و ... (یکی از شایع ترین اثرات سرطان، کم خونی است که باعث خستگی در فرد می شود، احساس ضعف پایین آمدن وزن و کم اشتها) به طور کلی کاهش وزن شدید و بدون علت از علائم بارز سرطان می باشد؛ اما زمانی که سرطان پیش روی کند و یا شدیدتر باشد علائم متفاوت و عارضه هایی را به همراه دارد از جمله: زردی پوست و چشم تغییرات در سیستم عصبی مانند سرگیجه، تشنج، سردرد، بی حسی و ... درد در استخوان ها ایجاد توده هایی در بدن، مشکلات قلبی، گره های لنفاوی بزرگ و غیره [9]. به توده های کوچک متشکل از بافت نازول گفته می شود نازول ممکن است خوش خیم (غیرسرطانی) یا پیش سرطانی باشد به نازولی پیش سرطانی می گوئیم که امکان تبدیل شدن به سرطان را دارد. گاهی توده یا نازول یک نازول متاستازی است وقتی سلول های سرطانی از عضو اصلی که سرطان در آنجا آغاز شده حرکت می کنند و در جای دیگری از بدن، توده سرطانی (از همان نوع اول) به وجود می آورند، به آن متاستاز گفته می شود [10].

درمان سرطان به نوع سلول، وسعت گسترش آن و وضعیت عملکردی بیمار بستگی دارد. درمان های رایج شامل مراقبت تسکینی، جراحی، شیمی درمانی و پرتودرمانی می باشد [11 و 13].

پردازش تصاویر دارای دو شاخه عمده بهبود تصاویر و بینایی ماشین است. بهبود تصاویر دربرگیرنده روش هایی چون استفاده از فیلتر محوکننده و افزایش تضاد برای بهتر کردن کیفیت دیداری تصاویر و اطمینان از نمایش درست آن ها در محیط مقصد (مانند چاپگر یا نمایشگر رایانه) است، درحالی که بینایی ماشین به روش هایی می پردازد که به کمک آن ها می توان معنی و محتوای تصاویر را درک کرد تا از آن ها در کارهایی چون رباتیک استفاده شود در معنای خاص آن پردازش تصویر عبارت است از هر نوع پردازش سیگنال که ورودی یک تصویر است مثل عکس یا صحنه ای از یک فیلم و خروجی پردازشگر تصویر می تواند یک تصویر یا یک مجموعه از ویژگی ها یا متغیرهای مربوط به تصویر باشد [15]. علم پردازش تصویر یکی از علوم پرکاربرد در مهندسی است که اخیراً پیشرفت قابل توجهی داشته است. یکی از مسائلی که در عوامل این علم وجود دارد حذف اختلالات ناخواسته نظیر انواع نویزهای متعدد در تصاویر است که اغلب به عنوان مرحله پیش پردازش در پردازش تصویر مورد استفاده قرار می گیرد [16].

استخراج این ویژگی ها نمایش و تحلیل صحنه های تصویر را آسان تر می سازد. یک تصویر از لحظه ورود به سیستم پردازش تصویر تا تولید تصویر خروجی به ترتیب مراحل زیر را طی می کند [12]:

مرحله اول دریافت تصویر ورودی می باشد که در این مرحله تصویر از ورودی خوانده شده وارد سیستم می شود که شامل دریافت تصویر و پردازش مقدماتی آن است دریافت تصویر درواقع تبدیل سیگنال الکترونیکی قسمت حسگر (مشاهده گر به شکل عددی است دریافت رقمی کردن (دیجیتال) تصویر با تقسیم یک ناحیه به تعداد مقتضی پیکسل صورت می گیرد طبیعی است ارزش هر پیکسل صفر یا یک است و در صورتی که بخواهیم محدوده روشنایی را بیان کنیم به صورت عددی بین صفر و یک بیان می کنیم البته در مورد تصاویر رنگی برای تعریف هر رنگ اصلی در هر پیکسل، روند کمی پیچیده تر می شود هموار کردن تصویر و پردازش مقدماتی آن به معنی حذف انحرافات شدید در تصویر ورودی است. پردازش اولیه با تصحیح تغییرات ناخواسته، هندسی حذف پارازیت تصحیح سطح خاکستری، تصحیح تیرگی و تشدید ویژگی های مهم موردنظر در داده های خام تصاویر اولیه به بهبود کیفیت تصاویر اولیه کمک می کند.

در مرحله دوم تصویر پیش پردازش می شود یعنی تصویر ارتقا می یابد و مؤلفه های غیرضروری از تصویر حذف می شود. مرحله سوم: همان پردازش تصویر است که هدف کلی در این مرحله شناسایی ویژگی های مانند نقاط ویژه و انحنای است که از آن ها بتوان برای کاربرد موردنظر استفاده کرد. در مرحله بعد تصویر با استفاده از ویژگی های استخراج شده از آن با روش هایی مانند استفاده از شبکه های عصبی مصنوعی آنالیز می شود.

LSTM – 3

LSTM در سال 1994، پژوهشی با عنوان "یادگیری وابستگی های طولانی با کاهش گرادیان سخت است" توسط Yoshua Bengio و دیگران معرفی شد. این پژوهش به معرفی مدلهایی با نام "شبکه های حافظه کوتاه مدت بلند" یا به اختصار LSTM منجر شد. در واقعیت، LSTM مدل های پیشرفته تری نسبت به شبکه های RNN ساده می باشند. زمانی که ما با داده های دنباله ای طولانی سر و کار داریم، گاهی اوقات برای به دست آوردن خروجی مطلوب نیاز است به داده های اخیر توجه کنیم. LSTM قادر است این نوع وابستگی های طولانی را مدیریت کند و با دقت به ورودی های اخیر نگاه دارد. این به این معناست که LSTM قادر است هر دنباله ای با هر طولی را پردازش کند. برای مثال، در تصویری که ارائه شده، توانایی LSTM در پردازش دنباله های طولانی نمایش داده شده است. به عنوان مثال، اطلاعات در بازه زمانی اول وجود دارد و در بازه زمانی 500 استفاده خواهد شد. LSTM در واقع بازه زمانی اول را یاد می گیرد و اطلاعات را تا بازه زمانی 500 ذخیره می کند تا در مورد نیاز به آنها استفاده کند. برای انجام کارهایی مانند پیش بینی فروش پودر رنگی در هند که در زمان هولی رخ می دهد، به نیاز است که به داده های سابق نگاه کرد. در این موارد، باید اطلاعاتی را فراموش کنیم و اطلاعات مهم را برای مراحل آینده ذخیره کنیم. LSTM به وسیله واحدهای حافظه به نام "حالت سلولی" این قابلیت را ارائه می دهد. این واحدهای حافظه به LSTM این امکان را می دهند که وابستگی های طولانی مدت را شناسایی کند و اطلاعات مهم را از مراحل قبلی نگه دارد تا بتواند در مراحل آینده پیش بینی کند. به طور ساده، LSTM تغییرات کوچکی در داده ها ایجاد می کند که با جمع یا ضرب ساده انجام می شود و به خاطر می آورد کدام اطلاعات مهم هستند و کدام اطلاعات می توانند فراموش شوند. این به LSTM این امکان را می دهد که وابستگی های طولانی مدت را بهتر مدیریت کند

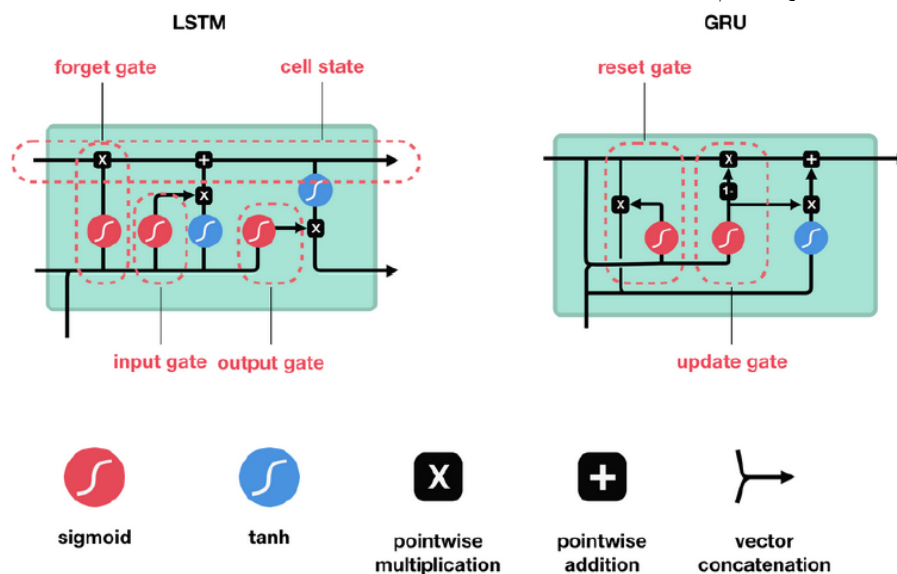
و از مزیت های برتری نسبت به شبکه های RNN ساده بهره مند شود. اگر بخواهیم به عنوان مثال تغییرات دوره ای در یک تقویم را پیش بینی کنیم، LSTM قادر است این کار را با دقت انجام دهد. در این رویکرد، ما فرض می کنیم که سه مرحله زمانی قبلی به عنوان ورودی برای مدل استفاده می شوند. این ورودی ها به تدریج از واحدهای LSTM عبور می کنند و اطلاعات اولین واحد به واحد بعدی منتقل می شود. این فرآیند به صورت تکراری انجام می شود.

LSTM در علم یادگیری عمیق به عنوان یک نوع ویژه از شبکه های عصبی بازگشتی مورد استفاده قرار می گیرند. این شبکه ها توانایی یادگیری و تشخیص وابستگی های بلندمدت را دارند و به خصوص در پردازش داده های دنباله ای و سری زمانی بسیار موثر هستند. از آنجایی که LSTM قادر به پردازش دنباله های کل داده ها (مانند ویدئوها و صداها) نیز هستند، در بسیاری از برنامه ها و وظایف پردازش سیگنال و داده های زمانی مورد استفاده قرار می گیرند.

یکی از ویژگی های مهم LSTM، مقاومت نسبی آن در برابر مشکلات گرادیان ناپدید شده است. این به معنای این است که در آموزش شبکه های LSTM، مشکلاتی که در شبکه های عصبی بازگشتی معمولاً به عنوان مشکل گرادیان ناپدید شده شناخته می شوند، به میزان کمتری بروز می کنند. این ویژگی باعث می شود که LSTM به خوبی برای مسائلی که وابستگی های طولانی مدت دارند، مناسب باشند. همچنین یکی از ویژگی های دیگر LSTM، عدم حساسیت نسبی به طول فاصله است. این به معنای این است که LSTM قادر به مدیریت و پردازش داده ها با طول متغیر و ناشناخته است. این ویژگی مهم برای پردازش دنباله ها و سری های زمانی است که ممکن است طول متغیر داشته باشند و از آنجا که LSTM می تواند اطلاعات وابستگی های بلندمدت را نگه دارد، بهترین تجزیه و تحلیل داده ها را ارائه می دهد. به طور خاص، واحد LSTM از چهار گیت تشکیل شده است: (الف) دروازه forget، (ب) دروازه ورودی، (ج) دروازه خروجی و (د) وضعیت سلول. حالت سلولی (C) مسئول جریان اطلاعات بین واحدها است.

LSTM و GRU به عنوان یک راه حل

گیت های بازگشتی واحد^۱ (GRU) و LSTM به عنوان راهلی برای حافظه کوتاه مدت ایجاد شدند. آنها مکانیسم های درونی به نام گیت دارند که می توانند جریان اطلاعات را تنظیم کنند.



شکل ۱: LSTM و GRU

¹ Gate Return Unit (GRU)

LSTM از اهمیت ویژه‌ای برخوردارند زیرا توانایی حفظ اطلاعات وابستگی‌های بلندمدت را دارند و می‌توانند از این اطلاعات برای پیش‌بینی‌ها و پردازش‌های پیچیده استفاده کنند. این ویژگی‌ها باعث می‌شود که LSTM در بسیاری از برنامه‌ها و وظایف مختلف مورد استفاده قرار گیرند. در کل، LSTM به عنوان یکی از مدل‌های برجسته در علم یادگیری عمیق و پردازش داده‌های دنباله‌ای و سری زمانی به‌طور گسترده مورد استفاده قرار می‌گیرد و در بسیاری از برنامه‌ها و وظایف مختلف به تحلیل و پردازش داده‌ها کمک می‌کند.

3- مرور ادبیات

مطالعه‌های زیادی در شناسایی سرطان با به‌کارگیری رویکردهای گوناگون پیشنهاد و پیاده‌سازی شده است. در ادامه به بررسی این مطالعات خواهیم پرداخت.

پلاسیدو همکاران در سال 2023، یک الگوریتم یادگیری عمیق برای پیش‌بینی خطر سرطان پانکراس از مسیر بیماری را معرفی کردند. در این مطالعه، روش‌های هوش مصنوعی را برای داده‌های بالینی 6 میلیون بیمار (24000 مورد سرطان پانکراس) در دانمارک (ثبت ملی بیماران دانمارکی^۱ (DNPR)) و از 3 میلیون بیمار (3900 مورد) در ایالات متحده (امور کهنه سربازان ایالات متحده^۲ (US-VA)) به کار بردند. آن‌ها مدل‌های یادگیری ماشینی را بر روی توالی کدهای بیماری در تاریخچه‌های بالینی آموزش داده و پیش‌بینی وقوع سرطان را در پنجره‌های زمانی افزایشی (CancerRiskNet)^۳ آزمایش کردند. برای وقوع سرطان در عرض 36 ماه، عملکرد بهترین مدل DNPR دارای مساحت زیر منحنی مشخصه عملکرد گیرنده $AUROC = 0.88$ است و زمانی که رویدادهای بیماری در عرض 3 ماه قبل از تشخیص سرطان از آموزش حذف شوند، به $AUROC(3m) = 0.83$ کاهش می‌یابد البته با خطر نسبی تخمینی 59 برای 1000 بیمار با بالاترین خطر بالای 50 سال. این نتایج توانایی طراحی برنامه‌های نظارت واقع‌بینانه برای بیماران در معرض خطر را بهبود می‌بخشد که به‌طور بالقوه با تشخیص زودهنگام این سرطان تهاجمی، طول عمر و کیفیت زندگی را به همراه خواهد داشت.

بوالحسنی و همکاران در سال 2023، یک شتاب‌دهنده یادگیری عمیق برای طبقه‌بندی تصاویر آندوسکوپی (DLA-E) معرفی کردند. برخی از برنامه‌های پزشکی بلادرنگ هستند و ممکن است در دستگاه‌های تعبیه‌شده پیاده‌سازی شوند. در این موارد، دستیابی به بالاترین سطح دقت تنها نگرانی نیست. زمان اجرای محاسبات و مصرف انرژی نیز به‌عنوان مهم‌ترین شاخص‌های عملکرد در نظر گرفته می‌شود. این پارامترها عمدتاً در مرحله طراحی سخت‌افزار ارزیابی می‌شوند. در این تحقیق، یک شتاب‌دهنده یادگیری عمیق کارآمد انرژی برای طبقه‌بندی تصاویر آندوسکوپی پیشنهاد شده است. این شتاب‌دهنده را می‌توان در تجهیزات تصویربرداری آندوسکوپی آینده برای کمک به پزشکان متخصص در حین آندوسکوپی یا کولونوسکوپی به‌منظور تصمیم‌گیری سریع‌تر و دقیق‌تر پیاده‌سازی کرد. DLA-E پیشنهادی شامل 256 عنصر پردازش با شبکه 1000 bps بر روی پهنای باند تراشه است. بر اساس نتایج شبیه‌سازی این تحقیق، بهترین جریان داده برای این شتاب‌دهنده به دست آمد که بهترین نتیجه در مقایسه با سایر ترکیبات CNN و جریان داده است.

نسیف و همکاران در سال 2022، به تشخیص سرطان سینه با استفاده از تکنیک‌های هوش مصنوعی پرداختند که درواقع مروری بر ادبیات سیستماتیک این حوزه است. از آنجاکه سرطان سینه را می‌توان با استفاده از زن‌ها یا تصویربرداری هیستوپاتولوژیک تشخیص داد. تجزیه و تحلیل در سطح ژنتیکی بسیار پرهزینه است، بنابراین تصویربرداری هیستوپاتولوژیک رایج‌ترین روش مورد استفاده برای تشخیص سرطان سینه است. در این کار تحقیقاتی، به‌طور سیستماتیک کارهای قبلی انجام شده در مورد تشخیص و درمان سرطان سینه را با استفاده از توالی یابی ژنتیکی یا تصویربرداری هیستوپاتولوژیک با کمک یادگیری عمیق و یادگیری ماشین مرور کردند. همچنین توصیه‌هایی را به محققانی که در این زمینه کار خواهند کرد ارائه می‌دهند.

¹ Danish National Patient Register (DNPR)

² United States Veterans Affairs (US-VA)

³ Cancer Occurrence within Incremental Time Windows (CancerRiskNet)

کوه و همکاران در سال 2022، به بررسی هوش مصنوعی و یادگیری ماشین در تصویربرداری سرطان پرداختند. امروزه مجموعه‌ای از ابزارها با استفاده از هوش مصنوعی^۱ و یادگیری ماشینی^۲ برای تصویربرداری سرطان در حال توسعه است؛ توسعه یک ابزار بهینه نیازمند مشارکت چند رشته‌ای است تا اطمینان حاصل شود که مورد استفاده مناسب برآورده شده است و همچنین برای انجام توسعه و آزمایش قوی قبل از پذیرش آن در سیستم‌های مراقبت‌های بهداشتی. این مقاله چند رشته‌ای پیشرفت‌های کلیدی در این زمینه را برجسته می‌کند. محققین این مقاله در مورد چالش‌ها و فرصت‌های هوش مصنوعی و یادگیری ماشین در تصویربرداری سرطان بحث کردند و ملاحظات را برای توسعه الگوریتم‌ها به ابزارهایی که می‌توانند به‌طور گسترده مورد استفاده و انتشار و توسعه اکوسیستم مورد نیاز برای ترویج رشد هوش مصنوعی و یادگیری ماشین در تصویربرداری سرطان قرار گیرند را بیان کردند.

بوالحسنی و همکاران در سال 2022، یک شتاب‌دهنده یادگیری عمیق برای طبقه‌بندی تصاویر هیستوپاتولوژیک (DLA-H) معرفی کردند. از منظر معماری، مقدار زیادی از عملیات محاسباتی منجر به مصرف انرژی بالا و زمان اجرای محاسبات می‌شود. این امر منجر به ظهور شتاب‌دهنده‌های یادگیری عمیق شد که عمدتاً برای بهبود عملکرد و بهره‌وری انرژی طراحی شده‌اند. استفاده مجدد و محلی سازی داده‌ها دو فرصت عالی برای دستیابی به محاسبات انرژی کارآمد با زمان اجرا کمتر است. جریان داده‌ها عمدتاً بر اساس این پارامترهای مهم طراحی می‌شوند. در این مقاله، DLA-H و BJS، یک شتاب‌دهنده یادگیری عمیق و جریان داده‌های آن برای طبقه‌بندی تصویر هیستوپاتولوژیک پیشنهاد شده است. نتایج شبیه‌سازی با ابزار MAESTRO 756 چرخه برای کل زمان اجرا و 106×3.21 GFLOPS خط سقف را نشان داد که در مقایسه با شتاب‌دهنده‌های یادگیری عمیق و جریان داده‌های عمومی منظوره فعلی، یک بهبود عملکرد فوق‌العاده است.

بوالحسنی و همکاران در سال 2020، مجموعه داده‌های تصویری هیستوپاتولوژیک برای درجه‌بندی کارسینوم های مجرای مهاجم پستان را ارائه دادند. کارسینوم مجرای مهاجم (IDC)^۳ شایع‌ترین نوع سرطان پستان است که حدود 80 درصد از تمام موارد تشخیص داده‌شده را دارد. تشخیص دقیق زودهنگام نقش مهمی در انتخاب برنامه درمانی مناسب و بهبود میزان بقا در بین بیماران دارد. یک مجموعه داده مناسب اولین قدم ضروری برای دستیابی به چنین هدفی است. این مقاله یک مجموعه داده تصویر میکروسکوپی هیستوپاتولوژیک از 922 تصویر مربوط به 124 بیمار مبتلا به IDC را معرفی می‌کند. مجموعه داده منتشر شده است و از طریق وب در آدرس: <http://databiox.com> قابل دسترسی است. ویژگی متمایز این مجموعه داده در مقایسه با موارد مشابه این است که شامل تعداد مساوی نمونه از هر یک از سه درجه IDC است که منجر به تقریباً 50 نمونه برای هر درجه می‌شود.

بوالحسنی و جاسبی در سال 2020، پس از بررسی پیشنهادی‌های یادگیری عمیق، یک معماری شتاب‌دهنده معروف به نام MAERI (موتور چندگانه انباشته با اتصالات قابل تنظیم مجدد)^۴ بررسی کردند که عملکرد یک کار یادگیری عمیق در دو استراتژی مختلف جریان داده اندازه‌گیری و مقایسه می‌شود: NLR (بدون استفاده مجدد محلی)^۵ و NVDLA (شتاب‌دهنده یادگیری عمیق NVIDIA)^۶، با استفاده از یک ابزار منبع باز به نام MAESTRO (مدل‌سازی کارایی شتاب‌دهنده از طریق اشغال منابع فضایی-زمانی)^۷. در این مقاله شاخص‌های عملکرد اندازه‌گیری معماری بهینه‌شده جدید را با استفاده مجدد از محاسبات و زمان اجرا کل کمتر را در مقایسه با دیگری نشان می‌دهند.

آنیشا و همکاران در سال 2021، در مقاله‌ای به تشخیص زودهنگام پیش‌بینی سرطان پستان با استفاده از طبقه‌بندی تصادفی جنگل پرداختند. در این مقاله، توضیح می‌دهند که چگونه سرطان سینه را می‌توان با استفاده از تکنیک یادگیری ماشینی به نام طبقه‌بندی جنگل تصادفی پیش‌بینی کرد. این طبقه‌بندی داده‌ها را در درختان متعددی ساختار می‌دهد و نتیجه نهایی را به دست می‌آورد، یعنی اینکه آیا فرد در معرض خطر ابتلا به سرطان سینه است یا خیر. دقت این مدل 98 درصد است.

¹ Artificial Intelligence (AI)

² Machine Learning (ML)

³ Invasive Ductal Carcinoma (IDC)

⁴ MAERI (Multiply-Accumulate Engine with Reconfigurable interconnects)

⁵ NLR (No Local Reuse)

⁶ NVDLA (NVIDIA Deep Learning Accelerator)

⁷ MAESTRO (Modeling Accelerator Efficiency via Spatio-Temporal Resource Occupancy)

دای و همکاران در سال 2019، از الگوریتم جنگل تصادفی برای تجزیه و تحلیل تشخیص موارد پزشکی سرطان پستان استفاده کردند. در زمینه مراقبت های بهداشتی فعلی، بهره مندی از ارائه داده های بزرگ پزشکی، یادگیری ماشینی می تواند برای به دست آوردن دانش از داده ها استفاده شود. روش های یادگیری ماشینی می توانند موارد را از دیدگاه عینی توصیف کنند و پیش بینی های نتایج تشخیصی را می توان از ترکیبی از عوامل آسیب شناختی مرتبط ایجاد کرد. معرفی ماشین یادگیری برای روش تشخیص پزشکی و دقت تشخیص، تغییر عمده و جهت اجتناب ناپذیر مدل پزشکی آینده است. در این مقاله از الگوریتم جنگل تصادفی برای تجزیه و تحلیل تشخیص موارد پزشکی سرطان پستان استفاده شده است. الگوریتم جنگل تصادفی می تواند ویژگی های مقادیر ویژه چندگانه را ترکیب کند و نتایج ترکیبی درخت های تصمیم چندگانه را می توان برای بهبود دقت پیش بینی استفاده کرد. بر اساس روش یادگیری گروهی جنگل های تصادفی، نتایج طبقه بندی کننده های ضعیف متعدد را می توان برای تولید نتایج طبقه بندی دقیق ترکیب کرد. در این مقاله، از یک الگوریتم جنگل تصادفی برای بحث در مورد تشخیص مورد سرطان پستان و به دست آوردن دقت پیش بینی بالا استفاده شده که برای تشخیص پزشکی کمکی اهمیت عملی دارد.

نوید در سال 2022، در مقاله خود برای پیش بینی سرطان پستان از جنگل تصادفی استفاده کرد. 8 درصد از زنان مبتلا به سرطان سینه تشخیص داده می شوند. (پیش از میلاد) قبل از میلاد دومین علت شایع در کشورهای توسعه یافته و توسعه نیافته است. BC با جهش ژن ها، درد مداوم، تغییر در اندازه، رنگ (قرمزی) و بافت پوست سینه ها مشخص می شود. طبقه بندی سرطان پستان، آسیب شناسان را به یافتن یک پیش آگهی سیستماتیک و عینی سوق می دهد. به طور کلی، رایج ترین طبقه بندی باینری (خوش خیم/بدخیم) است. تکنیک های یادگیری ماشینی به طور گسترده در طبقه بندی سرطان سینه استفاده می شود. آن ها دقت طبقه بندی بالا و قابلیت های تشخیصی مؤثر را ارائه می دهند. سرطان سینه یکی از بیماری های مهمی است که سالانه هزاران تشخیص را در زنان به دنبال دارد. هوش مصنوعی برای شناسایی سریع و دقیق تومورهای سینه و برای تشخیص زودهنگام استفاده شده است. هدف این مقاله تحقیق، تعیین و طبقه بندی این تومورها است. الگوریتم یادگیری ماشینی مانند جنگل تصادفی برای طبقه بندی تصاویر پزشکی به بدخیم و خوش خیم استفاده می شود. علاوه بر این، یادگیری ماشین اخیراً برای همین هدف به کار گرفته شده است.

مینور و باس در سال 2023 به آموزش و ارزیابی مدل های یادگیری ماشینی نظارت شده برای تشخیص دقیق و کارآمد سرطان سینه پرداختند. سرطان سینه در سال 2020 بیشترین نوع سرطان تشخیص داده شده بود. تشخیص زودهنگام سرطان سینه منجر به بهبود قابل توجهی در میزان بقای طولانی مدت می شود. روش های فعلی نیاز به مشاوره با متخصصان دارد که گران و زمان بر است و بنابراین ممکن است برای همه قابل دسترسی نباشد. این مقاله به دنبال آموزش و ارزیابی مدل های یادگیری ماشینی نظارت شده برای تشخیص دقیق و کارآمد سرطان سینه است. مجموعه داده پایگاه داده سرطان سینه ویسکانسین 30 ویژگی هسته سلولی را توصیف می کند که شامل شعاع، بافت و تقعر آن ها می شود، اما محدود به آن ها نیست. این شامل 569 مورد است که 212 مورد آن تومورهای بدخیم هستند. الگوریتم جنگل تصادفی در طبقه بندی تومورهای پستان به عنوان بدخیم یا خوش خیم از سایر الگوریتم ها بهتر عمل می کند و بنابراین به عنوان مدل اولیه ما انتخاب می شود. بر روی دو زیرمجموعه مختلف از مجموعه داده آموزش داده شده است که به ترتیب دارای 16 و 8 ویژگی هستند که با کمک روش های انتخاب ویژگی چندگانه شناسایی شده اند. مدل های جنگل تصادفی پس از تنظیم فرا پارامتر بر روی یک مجموعه نگهدارنده و دقت های 100٪ و 99.30٪ به ترتیب آزمایش می شوند. این مدل ها همچنین با چهار الگوریتم طبقه بندی یادگیری ماشین دیگر مقایسه می شوند: ماشین بردار پشتیبان، درخت تصمیم، پرسپترون چندلایه و K-نزدیک ترین همسایه ها. نتایج تأیید می کند که جنگل تصادفی روش برتر برای تشخیص سرطان سینه است.

ماسالای و همکاران در سال 2021، به پیش بینی خطر سرطان سینه در زنان آفریقایی با استفاده از طبقه بندی جنگل تصادفی پرداختند. در این کار، یک مدل پیش بینی ریسک سفارشی برای زنان آفریقایی با استفاده از تکنیک یادگیری ماشینی طبقه بندی جنگل تصادفی پیشنهاد کردند که در مجموع 180 نفر مورد مطالعه قرار گرفتند که 90 مورد تأیید شده سرطان پستان و 90 نفر خوش خیم بودند. بیست و پنج عامل خطر شامل سیگار کشیدن، مصرف الکل، خطرات شغلی و سن یائسگی بودند. چهار رویکرد به طور تجربی در انتخاب ویژگی مورد استفاده قرار گرفت، این ها استفاده از Chi-Square، به دست آوردن اطلاعات متقابل، همبستگی و کل ویژگی ها هستند. برای توسعه مدل پیش بینی از

الگوریتم RFC استفاده شد. آن‌ها دریافتند که سابقه خانوادگی سرطان پستان، پستان متراکم، سقط عمدی، سن در اولین فرزند، مصرف میوه ورزش منظم از عوامل پیش‌بینی کننده سرطان پستان هستند. مدل RFC دقت 91.67٪، حساسیت 87.10٪، ویژگی 96.55٪ و ناحیه تحت منحنی^۱ (AUC) 92٪ را هنگامی که همه عوامل خطر در مدل گنجانده شده بودند، درحالی که دقت 96.67٪، حساسیت 93.75٪ بود. زمانی که ویژگی‌های انتخاب شده با همبستگی در مدل گنجانده شد، ویژگی 100٪ و AUC 97٪ به دست آمد. ویژگی‌های انتخاب شده به Chi-Square بهترین عملکرد را با دقت 98.33٪، حساسیت 100٪، ویژگی 96.55٪ و AUC 98٪ ارائه کردند. ویژگی انتخاب شده به دست آوردن اطلاعات متقابل نتایج مشابه ویژگی‌های انتخاب شده Chi-Square داد. طبقه‌بندی تصادفی جنگل پتانسیل خوبی در پیش‌بینی خطر ابتلا به سرطان سینه در زنان آفریقایی دارد. این مطالعه به شناسایی عوامل خطر سرطان سینه در زنان آفریقایی کمک کرد. این اطلاعات ارزشمندی است که می‌تواند به زنان آفریقایی کمک کند تا به این عوامل خطر باهدف کاهش بروز سرطان سینه در آفریقا توجه کنند.

کامرون ولف در سال 2018، در تحقیق خود به آموزش یک جنگل تصادفی برای شناسایی تومورهای بدخیم سرطان پستان پرداختند که از کتابخانه Sklearn Python استفاده کردند که شامل گروهی از چندین مجموعه داده نمونه است. در میان این مجموعه داده‌ها، مجموعه داده‌های سرطان پستان طبقه‌بندی باینری است که از مشاهدات انجام شده در ایالت ویسکانسین استخراج شده است. کار بر روی این مجموعه داده را انتخاب کردند زیرا هدف آموزش یک مدل طبقه‌بندی برای شناسایی بدخیم‌ها بود. آن‌ها تومورهای سرطان سینه با دقت بیش از 95٪ مجموعه داده را وارد کردند و برای ساخت مدل پایه، به توزیع مشاهدات "بدخیم" (با برچسب 1) و "خوش‌خیم" (با برچسب 0) در مجموعه داده نگاه کردند، بسته به اینکه کدام یک از این دسته‌بندی‌های طبقه‌بندی محتمل‌تر است (یا وقوع بالاتری دارد).

در جدول 1 خلاصه‌ای از مزایا و معایب مربوط به روش‌های معرفی شده در بخش قبل نمایش داده شده است.

جدول 1: مزایا و معایب روش‌های پیشنهادی

نویسنده	مرجع	سال	تکنیک	مزایا	معایب
پلاسیدو همکاران	[1]	2023	الگوریتم یادگیری عمیق برای پیش‌بینی خطر سرطان پانکراس	بهبود برنامه‌های نظارت واقع‌بینانه برای بیماران در معرض خطر	سرعت پایین تشخیص
بوالحسنی و همکاران	[2]	2023	شتاب‌دهنده یادگیری عمیق برای طبقه‌بندی تصاویر آندوسکوپی	رسیدن به بهترین جریان داده برای این شتاب‌دهنده	عملکرد ضعیف به نسبت دیگر الگوریتم‌ها
نسیف و همکاران	[3]	2022	تشخیص سرطان سینه با استفاده از تکنیک‌های هوش مصنوعی	مروری بر ادبیات سیستماتیک	---
کوه و همکاران	[4]	2022	بررسی هوش مصنوعی و یادگیری ماشین در تصویربرداری سرطان	بحث در مورد چالش و فرصت‌های هوش مصنوعی و یادگیری ماشین در تصویربرداری سرطان	---
بوالحسنی و همکاران	[5]	2022	معرفی شتاب‌دهنده یادگیری عمیق برای طبقه‌بندی تصاویر هیستوپاتولوژیک	بهبود عملکرد فوق‌العاده	استفاده از فقط یک مجموعه داده ماموگرافی
بوالحسنی و همکاران	[6]	2020	ارائه مجموعه داده‌های تصویری هیستوپاتولوژیک برای درجه‌بندی کارسینوم های مجرای مهاجم پستان	برتری این کار: شامل تعداد مساوی نمونه از هر یک از سه درجه IDC	---
بوالحسنی و جاسبی	[7]	2020	معماری شتاب‌دهنده معروف به نام MAERI	استفاده مجدد از محاسبات و زمان اجرا کل کمتر را در مقایسه با	عدم پیش‌پردازش

¹ Area under the curve (AUC)

					دیگری
آنیشا و همکاران	[8]	2021	تشخیص زودهنگام پیش‌بینی سرطان پستان با استفاده از طبقه‌بندی تصادفی جنگل	دقت این مدل 98 درصد	تشخیص سرطان سینه با درصد پایین
دای و همکاران	[9]	2019	تشخیص موارد پزشکی سرطان پستان با الگوریتم جنگل تصادفی	دقت پیش‌بینی بالا	پیچیدگی محاسباتی
نوبد	[10]	2022	پیش‌بینی سرطان پستان از جنگل تصادفی	شناسایی سریع و دقیق تومورهای سینه و برای تشخیص زودهنگام	زمان بالای آموزش
مینور و باس	[11]	2023	آموزش و ارزیابی مدل‌های یادگیری ماشینی نظارت‌شده برای تشخیص دقیق و کارآمد سرطان سینه	مقایسه و بررسی چندین الگوریتم-جنگل تصادفی روش برتر برای تشخیص سرطان سینه	معیارهای ارزیابی کمتر
ماسالای و همکاران	[12]	2021	پیش‌بینی خطر سرطان سینه در زنان آفریقایی با استفاده از طبقه‌بندی جنگل تصادفی	دقت بالا	وجود خطا
کامرون ولف	[13]	2018	آموزش یک جنگل تصادفی برای شناسایی تومورهای بدخیم سرطان پستان	تشخیص زودهنگام تومورهای خوش خیم و بدخیم	مجموعه داده‌های محدود
روش پیشنهادی: استفاده از الگوریتم LSTM جهت تشخیص سرطان سینه			بهبود دقت و حساسیت	—	—

4- مدل پیشنهادی

در این بخش مدل پیشنهادی جهت تشخیص سرطان سینه که بهره‌مندی از الگوریتم LSTM است به‌طور کامل و با جزئیات بیان خواهد شد. متأسفانه سرطان سینه در مراحل اولیه بدون علامت است، اگرچه برخی از علائم در زمان بعدی ظاهر می‌شوند، اما در مرحله علامتی درمان ممکن است پیچیده یا حتی غیرممکن شود و در نتیجه منجر به مرگ شود. از این‌رو ارزیابی صحیح ریسک در کاهش مرگ‌ومیر بسیار مهم است. یکی از مهم‌ترین اقدامات در مبارزه با سرطان سینه، تشخیص زودهنگام و دقیق است. از آنجایی که شیوع این بیماری در سال‌های اخیر افزایش چشمگیری داشته است، سیستم‌های خبره و تکنیک‌های یادگیری ماشینی به این مشکل نیز مورد توجه بسیاری از محققان قرار گرفته است. در روش پیشنهادی پس از بارگذاری داده‌ها از پایگاه داده، استخراج ویژگی‌ها انجام می‌شود. سپس ویژگی‌های استخراج‌شده با کمک الگوریتم LSTM انتخاب می‌گردند. در نهایت جهت ارزیابی، روش پیشنهادی با تحقیقات و مقالات قبلی مقایسه خواهد شد و نتایج در قالب نمودار و جداول به نمایش گذاشته می‌شوند.

4-1- جامعه آماری

برای انجام این تحقیق داده‌های مورد نیاز خود را از مجموعه داده‌های بخش دیتاست یادگیری ماشین دانشگاه کالیفرنیا تهیه خواهیم کرد که در پایگاه داده UCI [16] قابل دسترسی می‌باشد. این مجموعه داده شامل اطلاعات ۵۶۹ فرد است که هر کدام ۳۰ ویژگی دارند. در این مجموعه داده تعداد ۲۱۲ بیمار دچار تومور بدخیم سرطان سینه و ۳۵۷ فرد سالم (تومور خوش‌خیم) وجود دارد. همچنین داده‌های که در مجموعه داده JSRT موجود است، متشکل از عکس‌هایی به اندازه 2048 در 2048 پیکسل هستند که مقدار هر پیکسل نشان‌دهنده سطح خاکستری در بازه 0 تا 4095 است. تشخیص ناژول از عکس‌های خام برای پزشکان متخصص این حوزه هم خیلی دشوار است و نیازمند تجربه و دقت زیاد است. ارزیابی بعدی هم با کمک مجموعه داده IDRI انجام می‌شود. پایگاه داده مورد استفاده و یک مجموعه داده‌های عمومی مرسوم مورد استفاده در زمینه تشخیص ناژول می‌باشد و به‌عنوان یک منبع قابل دسترسی بین‌المللی جهت توسعه، آموزش و ارزیابی سیستم‌های CAD (طراحی به کمک رایانه)^۱، جهت تشخیص و شناسایی سرطان سینه در تصاویر CT scan تهیه شده است [35].

¹ Computer Aided Design (CAD)

4-2- پارامترهای ارزیابی

برای مدل پیشنهادی، یک مسئله 2 حالتی وجود دارد که نتایج آزمون را می توان در 4 دسته تقسیم نمود:

- مثبت درست^۱ (TP) مواردی که ندول^۲ سرطانی هستند و به عنوان ندول سرطانی طبقه بندی می شوند را نشان می دهد.
 - مثبت نادرست^۳ (FP) ناشی از گزارش نادرست موارد غیر ندول به عنوان ندول است.
 - منفی درست^۴ (TN) مواردی است که ندول غیر سرطانی است و به عنوان ندول غیر سرطانی طبقه بندی می شوند.
 - درنهایت، منفی نادرست^۵ (FN) مواردی هستند که واقعاً ندول هستند، اما به عنوان ندول طبقه بندی نمی شوند.
- با استفاده از این مفاهیم طبقه بندی های درست و نادرست متمایز شده و می توان مقادیر مختلف برای ارزیابی عملکرد یک طبقه بند را تعریف کرد.

حساسیت نسبت بین نمونه های مثبت که درست پیش بینی شده اند و تعداد کل از نمونه های مثبت است و در ادبیات این مقدار Recall نیز نامیده می شود.

$$\text{SENSITIVITY} = \text{TP} / (\text{TP} + \text{FN})$$

خاصیت بیان نسبت بین نمونه های منفی به درستی پیش بینی و تعداد کل نمونه های منفی است:

$$\text{SPECIFICITY} = \text{TN} / (\text{TN} + \text{FP})$$

با استفاده از نمادهای بالا، صحت به صورت نسبت بین تعدادی از نمونه های صحیح طبقه بندی شده به تعداد کل نمونه ها تعریف می شود:

$$\text{ACCURACY} = (\text{TP} + \text{TN}) / (\text{TP} + \text{FP} + \text{TN} + \text{FN})$$

یا به عبارتی دیگر،

دقت: عبارت است از تعداد نمونه هایی که به درستی تشخیص داده می شوند، نسبت به کل نمونه ها.

حساسیت: احتمال پیش بینی درست توسط الگوریتم ها (مثبت واقعی تقسیم بر منفی کاذب + مثبت واقعی).

ویژگی: احتمال پیش بینی درست عدم تشخیص توسط الگوریتم ها (منفی واقعی تقسیم بر مثبت کاذب + منفی واقعی).

TP: تعداد نمونه هایی که به درستی مثبت تشخیص داده می شوند.

TN: تعداد نمونه هایی که به درستی منفی تشخیص داده می شوند.

FP: تعداد نمونه هایی که به اشتباه مثبت تشخیص داده می شوند.

FN: تعداد نمونه هایی که به اشتباه منفی تشخیص داده می شوند.

رابطه زیر نحوه محاسبه معیار شباهت دایس را نشان می دهد. معیارهای دایس به بررسی شباهت ندول پیش بینی شده توسط شبکه با ندول حقیقی می پردازد. همان گونه که در این رابطه مشاهده می کنیم، نمونه های منفی درست (TN) یعنی نواحی غیر ندول نقشی در محاسبه معیار دایس ندارند. هرچه معیار دایس بالاتر باشد، نشان از دقت تر بودن ندول پیش بینی شده دارد.

$$\text{DSC} = 2\text{TP} / (\text{TP} + \text{FP}) + (\text{TP} + \text{FN})$$

4-3 LSTM

LSTM به عنوان یکی از ابزارهای مهم واقع در زمینه یادگیری عمیق و پردازش داده های دنباله ای و سری زمانی شناخته می شود و در بسیاری از برنامه ها و وظایف مختلف مورد استفاده قرار می گیرد؛ به این صورت کار می کند: کلمات اول به بردارهای قابل خواندن با ماشین

¹ True Positive (TP)

² ندول یک توده کوچک، گرد و کدر رنگ است که در داخل بافت ایجاد می شود. درواقع ندول ها کدورت های رادیوگرافیک کروی با قطر کمتر از سی میلی متر هستند [48].

³ False Positive (FP)

⁴ True Negative (TN)

⁵ False Negative (FN)

تبدیل می شوند سپس دنباله بردارها را یک به یک پردازش می کند. در حین پردازش، حالت پنهان قبلی را به مرحله بعدی دنباله منتقل می کند. حالت پنهان به عنوان حافظه در شبکه های عصبی عمل می کند. اطلاعات مربوط به داده های قبلی را که شبکه قبلاً دیده بود، در اختیار دارد. یک سلول به عنوان یکی از مهم ترین مؤلفه های شبکه عصبی بازگشتی به کار می رود و نقش بسیار اساسی در پردازش داده های دنباله ای دارد. در این سلول، ابتدا حالت پنهان قبلی با ورودی فعلی ترکیب می شوند. این ترکیب معمولاً به صورت عملیات جمع وزن دار انجام می شود. در واقع، حالت پنهان قبلی که حاوی اطلاعاتی از ورودی های گذشته است، با ورودی فعلی که اطلاعاتی از وضعیت فعلی دارد، ترکیب می شوند. این عملیات ترکیب باعث می شود که سلول اطلاعات مربوط به حالت قبلی و ورودی جدید را در خود نگه دارد. سپس، بردار ترکیب شده از تابع تانژانت عبور می کند. تابع تانژانت به عنوان یک تابع غیرخطی عمل می کند و از این رو به شبکه عصبی امکان می دهد که اطلاعات را به صورت غیرخطی پردازش کند. این اهمیت دارد زیرا مسائل واقعی و پیچیده اغلب خصوصیات غیرخطی دارند. در نهایت، خروجی این تابع تانژانت به عنوان حالت پنهان جدید یا حافظه شبکه شناخته می شود. این حالت پنهان جدید اطلاعات مهمی از ورودی ها و حالت های قبلی را در خود ذخیره می کند و می تواند به عنوان وضعیت فعلی شبکه مورد استفاده قرار گیرد و یا به مراحل بعدی انتقال داده شود. این عملیات به شبکه عصبی بازگشتی امکان می دهد که الگوها و وابستگی های پیچیده در داده های دنباله ای را کشف کند و در مسائلی مانند ترجمه ماشینی، مدل های زبانی، و پیش بینی دنباله ها عملکرد بهتری داشته باشد.

❖ تابع تانژانت

تابع تانژانت به عنوان یک تابع فعال سازی^۱ معمولاً استفاده نمی شود تا مقادیر را جمع نکند و بین ۱ و -۱ تنظیم نشوند. به جای تابع تانژانت، توابع دیگری مانند تابع فعال سازی^۲ (ReLU)، تانژانت هایپربولیک^۳، و تابع فعال سازی سیگموئید^۴ استفاده می شوند. در این شبکه، ورودی های متوالی به شبکه داده می شوند و در هر مرحله از آموزش و پیش بینی، یک ماتریس وزن نیز وجود دارد. فرض می شود مقدار یکی از وزن های این ماتریس به طور غیرمنتظره ای بسیار بزرگ شود، به عنوان مثال 10000. در مراحل مختلف محاسبات، این وزن بزرگ بارها در عملیات ماتریسی مورد استفاده قرار می گیرد. به علت این وزن بزرگ، مقدار گرادیان ها نیز بسیار بزرگ می شود. حال اگر مقدار گرادیان ها به اندازه ای این بزرگی باقی بماند و به مراحل بعدی منتقل شود، پدیده انفجار گرادیان رخ می دهد. به منظور جلوگیری از انفجار گرادیان، می توان از تکنیک هایی مانند محدود سازی گرادیان^۵ استفاده کرد که مقادیر گرادیان ها را در یک محدوده مشخص نگه می دارد. این به شبکه اجازه می دهد که به صورت معقول تری آموزش ببیند و از انفجار گرادیان جلوگیری کند. تابع تانژانت تضمین می کند که مقادیر بین ۱ تا ۱ باقی بماند بنابراین خروجی شبکه عصبی را تنظیم می کند.

❖ سیگموئید

توابع فعال سازی مانند سیگموئید به شبکه های عصبی امکان می دهند که اطلاعات را با دقت مدیریت کنند و تصمیم گیری های مرتبط با اهمیت داده ها را انجام دهند. این توابع فعال سازی به شبکه ها کمک می کنند تا اطلاعات مهم را حفظ کنند و از اطلاعات ناچیز گذشته یا بی اهمیت صرف نظر کنند. توابع فعال سازی مانند سیگموئید، با تبدیل ورودی های شبکه به مقادیر بین 0 و 1، می توانند اطلاعات را فیلتر کرده و به شبکه امکان می دهند تا تصمیم گیری کنند کدام اطلاعات باید در نظر گرفته شوند و کدام اطلاعات باید نادیده گرفته شوند. این ویژگی ها معمولاً در شبکه های عصبی بازگشتی مانند LSTM و GRU نیز بهره برداری می شوند تا به خوبی با داده های دنباله ای کار کنند و از پدیده هایی مانند ناپدید شدن یا انفجار گرادیان جلوگیری کنند.

❖ گیت فراموشی

گیت فراموشی در یک شبکه عصبی بازگشتی نقش مهمی ایفا می کند. این گیت تصمیم می گیرد که اطلاعاتی که در حالت پنهان قبلی و اطلاعاتی که از ورودی فعلی به شبکه می آید، کدام اطلاعات باید در حافظه ماندگار (حافظه کوتاه مدت) نگهداری شوند و کدام اطلاعات باید

¹ Activation Function

² Rectified Linear Unit (ReLU)

³ Hyperbolic Tangent

⁴ Sigmoid

⁵ Gradient Clipping

فراموش شوند. این تصمیم‌گیری با استفاده از تابع سیگموئید انجام می‌شود که مقادیر را به فرمتی بین ۰ تا ۱ تنظیم می‌کند. مقادیر نزدیک به صفر نمایانگر فراموش کردن کامل اطلاعات می‌باشند، در حالی که مقادیر نزدیک به ۱ نمایانگر حفظ اطلاعات می‌باشند.

❖ گیت ورودی

در فرآیند به‌روزرسانی وضعیت سلول یک شبکه عصبی بازگشتی، از گیت ورودی بهره می‌بریم. ابتدا، حالت پنهان قبلی و ورودی فعلی به یک تابع سیگموئید منتقل می‌شوند. این تابع سیگموئید مسئول تصمیم‌گیری در مورد اهمیت اطلاعات است. اعداد نزدیک به صفر نمایانگر "نادیده‌گرفتن" و اعداد نزدیک به ۱ نمایانگر "نگهداشتن" اطلاعات می‌باشند.

همچنین، وضعیت پنهان و ورودی فعلی را به تابع تانژانت منتقل می‌کنیم تا مقادیر را به صورتی بین -۱ تا ۱ تنظیم کند. این اقدام به کنترل جریان اطلاعات در شبکه کمک می‌کند و از پدیده‌هایی نظیر انفجار گرادیان و ناپدید شدن گرادیان جلوگیری می‌کند.

سپس، خروجی تابع تانژانت را با خروجی تابع سیگموئید ضرب می‌کنیم. خروجی سیگموئید تصمیم می‌گیرد که آیا اطلاعات حاصل از تابع تانژانت مهم هستند یا نه. اگر خروجی سیگموئید به سمت ۱ نزدیک باشد، این به این معناست که اطلاعات مهم هستند و باید نگهداشته شوند. در غیر این صورت، اطلاعات به عنوان غیرمهم معلوم می‌شوند و فراموش می‌شوند. این ترکیب از توابع سیگموئید و تانژانت به شبکه اجازه می‌دهد تا با دقت مدیریت کند کدام اطلاعات مهم هستند و کدام اطلاعات را می‌تواند فراموش کند.

❖ سلول حالت

در فرآیند محاسبه سلول حالت در یک شبکه عصبی بازگشتی، ابتدا حالت سلولی را با وکتور فراموشی ضرب می‌کنیم. اگر مقادیر وکتور فراموشی نزدیک به صفر باشند، این به این معناست که باید اطلاعات را در سلول حالت کاهش دهیم. سپس، خروجی گیت ورودی را دریافت می‌کنیم و عمل جمع نقطه به نقطه را انجام می‌دهیم. این کار باعث به‌روزرسانی حالت سلولی می‌شود و حالت جدید سلول را به ما تحویل می‌دهد. این فرآیند به شبکه عصبی امکان می‌دهد تا اطلاعات جدید را با استفاده از خروجی گیت ورودی به حالت سلولی اضافه کند و حالت را به روز کند.

❖ گیت خروجی

در نهایت، گیت خروجی نقش مهمی در تعیین حالت پنهان بعدی دارد. حالت پنهان قبلی حاوی اطلاعاتی از ورودی‌های قبلی است و این حالت پنهان نیز برای پیش‌بینی‌های آینده مورد استفاده قرار می‌گیرد. فرآیند انجام شده به این صورت است: ابتدا، حالت پنهان قبلی و ورودی فعلی به یک تابع سیگموئید منتقل می‌شوند. سپس، حالت سلول تازه‌اصلاح شده را به تابع تانژانت منتقل می‌کنیم. خروجی تانژانت را با خروجی سیگموئید ضرب می‌کنیم تا تصمیم بگیریم که حالت پنهان باید چه اطلاعاتی را داشته باشد. نتیجه این عملیات، حالت پنهان جدید است که به مرحله بعدی منتقل می‌شود. این گیت‌ها به شبکه امکان می‌دهند تا از اطلاعات پنهان مناسبی برای پیش‌بینی‌های آینده استفاده کنند و تاثیر گذاری آن را کنترل کنند.

LSTM از یک جریان کنترل متفاوت به نام "گیت‌ها" استفاده می‌کند. این گیت‌ها شامل گیت فراموشی، گیت ورودی و گیت خروجی هستند که هر یک وظایف خاص خود را دارند. این گیت‌ها به LSTM امکان می‌دهند تا اطلاعات را در حافظه کوتاه‌مدت مدیریت کرده و تصمیم‌گیری‌هایی در مورد حفظ یا فراموش کردن اطلاعات بگیرد.

5- آزمایشات

در این بخش به بررسی روش پیشنهادی و مقایسه با مقالات و الگوریتم‌های قبلی می‌پردازیم که جهت بررسی صحت و سقم روش پیشنهادی، آزمایشات در چندین مرحله، بر روی چندین مجموعه داده و الگوریتم‌های مختلف (باتوجه به اینکه هریک از الگوریتم‌ها قبلاً بر روی کدام مجموعه داده پیاده‌سازی شده است) صورت گرفته است.

5-1- آزمایش اول

پیش پردازش تصاویر یکی از مراحل اصلی روش مورد استفاده است. داده های که در مجموعه داده JSRT موجود است، متشکل از عکس هایی به اندازه 2048 در 2048 پیکسل هستند که مقدار هر پیکسل نشان دهنده سطح خاکستری در بازه 0 تا 4095 است. تشخیص ناژول از عکس های خام برای پزشکان متخصص این حوزه هم خیلی دشوار است و نیازمند تجربه و دقت زیاد است. پارامترهای آماری برای تصاویر بخش بندی شده به عنوان ورودی به شبکه داده می شود. سپس حساسیت، خاصیت و دقت برای روش پیشنهادی محاسبه می شود. یکی از معیارهای ارزیابی هر طبقه بند ماتریس اغتشاش است. این ماتریس یک ماتریس مربعی N در N است که N همان تعداد کلاس ها در طبقه بند است. در این مسئله می خواهیم دو کلاس بیمار و غیر بیمار را طبقه بندی کنیم. پس $N=2$ است. در هر کار طبقه بندی تعدادی نمونه داریم که قرار است آن ها را به طبقه بندی دهیم و طبقه بند مشخص کند که کدام متعلق به کلاس بیمار (دارای ناژول) و کدام متعلق به کلاس غیر بیمار (فاقد ناژول) است. تعداد نمونه های آزمایشی 75 است؛ که 45 نمونه متعلق به کلاس ناژول و 30 نمونه متعلق به کلاس غیر ناژول است. جدول 2 نشان می دهد که طبقه بند ما از 30 نمونه در کلاس NON-N تعداد 25 نمونه را به درستی دسته بندی کرده است. همین طور از 45 نمونه در کلاس N تعداد 44 نمونه به درستی دسته بندی شده اند. در نتیجه صحت برابر با 69 نمونه درست تشخیص داده شده از 75 نمونه آزمون است.

جدول 2- معیارهای ارزیابی دسته بندی پیشنهادی

Non-N	N	TP	TN	FP	FN	Sen (%)	Spe (%)	Acc (%)
30	45	44	25	5	1	97.77	83.33	93

جدول 2 خلاصه ای از نتایج به دست آمده از روش پیشنهادی را نشان می دهد. نتایج به دست آمده در طول آزمایش نشان می دهد که طبقه بند روش پیشنهادی قادر به افتراق مؤثر ناژول از دیگر سازه های قطعه بندی شده است. به منظور ایجاد چشم اندازی از کیفیت نتایج، نتایج روش پیشنهادی با روش های تشخیص ناژول در تصاویر رادیوگرافی دیگر مقایسه شده است. در اینجا مهم این است که یک مقایسه عادلانه از روش های ذکر شده، انجام گیرد. علاوه بر این، برخی از پارامترهای استاندارد، مانند وضوح و بیت در هر پیکسل باید وجود داشته باشد. عامل دیگری که باید مشترک باشد، نسبت آموزش به آزمایش در ارزیابی ها است. نتایج گزارش شده در سایر کارهای مشابه مطابق جدول 3 است.

جدول 3: مقایسه روش پیشنهادی با کارهای مشابه بر روی JSRT

روش	Sensitivity (%)	Specificity (%)	Accuracy (%)
روش پیشنهادی	97	83	92
شبکه عصبی [36]	-	86	88 مبتنی بر ویژگی 96 مبتنی بر پیکسل
شبکه عصبی کانولوشنال [37]	92	-	68
K-نزدیکترین همسایه [38]	91	-	88

ارزیابی ها نشان می دهد که حساسیت روش پیشنهادی به خصوص در برخورد با ناژول های کوچک بسیار مطلوب است. نرخ خطای مثبت برآورد شده برای روش پیشنهادی 16.67٪ است که نسبت به کارهای دیگر کمتر است. در یک مقایسه کیفی، روش پیشنهادی برای تشخیص ناژول های کوچک که حتی پزشک متخصص هم نمی تواند در عکس ها تشخیص دهد، در نظر گرفته شده است. این در حالی است که در کارهای دیگر عمده نگرانی تشخیص ناژول های بزرگ تر است. تشخیص ناژول کوچک بسیار پیچیده تر از تشخیص های بزرگ تر است، چرا که آن ها سخت تر از سازه های دیگر جدا می شوند. به نظر می رسد که این واقعیت دلیل اصلی برتری نتایج در روش پیشنهادی است.

5-2- آزمایش دوم

ارزیابی مدل پیشنهادی از طریق استفاده از مجموعه داده LIDC-IDRI انجام شد. پایگاه داده مورد استفاده و یک مجموعه داده های عمومی مرسوم مورد استفاده در زمینه تشخیص نازول می باشد و به عنوان یک منبع قابل دسترس بین المللی جهت توسعه، آموزش و ارزیابی سیستم های CAD، جهت تشخیص و شناسایی سرطان سینه در تصاویر CT scan تهیه شده است [35]. این مجموعه شامل 1011 مورد است که هر یک شامل تعدادی تصاویر CT scan سینه هستند و در کنار هر یک از این موارد یک فایل XML پیوست شده است. این فایل ها حاوی اطلاعاتی از تصویر هستند که توسط چهار رادیولوژیست فراهم شده است [40].

جدول 4: مقایسه دقت داده ها در پیاده سازی های مختلف در تشخیص سرطان سینه

روش	دقت
روش پیشنهادی	98%
یادگیری عمیق [41]	78%
الگوریتم های یادگیری ماشینی [42]	83%
شبکه عصبی بازگشتی مبتنی بر توجه ^۱ [43]	92%
شبکه عصبی عمیق بهبود یافته ^۲ [44]	90%
[45] FCBF	45%
[46] MML oblique tree	86%
[47] RS/RSP	69%
[48] MAXENT-H	42%
[49] k-NN + Reduction	74%
[50] GDA-LS_SVM	89%
[51] GA-FELM	97%
[52] GA based feature selection method	98%
[53] PCA-GA_MLP	97%

نتایج ارزیابی شبکه پیشنهادی توسط معیارهای دیگر مورد استفاده در جدول زیر آورده شده است.

جدول 5: نتایج ارزیابی شبکه پیشنهادی

معیار ارزیابی	accuracy	DSC	Recall
مقدار	98.5	78	73.60

به منظور سنجش روش های پیشنهادی، نتایج به دست آمده از مدل پیشنهادی را با دیگر مقالات مشابه روی مجموعه داده گان LIDC مقایسه کردیم، نتایج این مقایسه در جدول 6 قابل مشاهده است.

¹ Attention Based Recurrent Neural Network

² Improved Deep Neural Network

جدول 6: مقایسه معیار دایس مطالعه حاضر با سایر روش ها

معیار دایس	روش
78%	روش پیشنهادی
67%	جریان های ویژگی های مرتبط با وضوح چندگانه [54]
68%	یادگیری عمیق [55]
70%	CTumorGAN [56]
72%	بهبود شبکه U-NET [57]
73%	یادگیری مشترک [58]

در آزمایش آخر از روش های ناحیه بندی جهت حذف ناحیه های غیرمفید و پردازش غیرضروری اطلاعات تصویر جهت کارایی بالاتر شبکه در تشخیص و شناسایی ناژول ها استفاده شد و برای شناسایی ناژول ها روش پیشنهادی ارائه شد که کارایی خوبی برای مجموعه داده های موردنظر را نشان دادند. کارایی روش های پیشنهادی در شناسایی ناژول ها براساس دقت، حساسیت و معیار شباهت دایس در نظر گرفته شد. بررسی روی تصاویر پایگاه داده LIDC نشان داد که روش پیشنهادی کارایی و زمان پاسخگویی قابل مقایسه ای با روش های دیگر دارد.

5-3- آزمایش سوم

جدول زیر، مقایسه ی میزان دقت، حساسیت و ویژگی، بین روش پیشنهادی و چند روش پرکاربرد در حوزه مربوطه را نشان می دهد.

جدول 7: مقایسه نتایج حاصل براساس دقت، حساسیت و ویژگی

ویژگی	حساسیت	دقت	روش پیشنهادی
93%	96%	94%	LSTM
89%	94%	92%	شبکه عصبی مصنوعی
91%	94%	93%	ماشین بردار پشتیبان
92%	95%	93%	

با مقایسه و ارزیابی معیارهای ذکرشده، میزان دقت، حساسیت و سایر ویژگی های ذکرشده مشخص می گردد. براساس نتایج به دست آمده می توان مدلی ارائه نمود که بتواند در تصمیم گیری در مورد احتمال عود یا عدم عود بیماری پزشکی یا کارشناس مربوطه را یاری رساند.

6- نتیجه گیری و کارهای آتی

سرطان سینه عامل اصلی مرگ و میر ناشی از سرطان در سراسر جهان است. غربالگری افراد پرخطر از نظر سرطان سینه با سی تی اسکن با دوز کم در حال حاضر در کشورهای مختلفی اجرا می شود و انتظار می رود به زودی در کشور ما نیز دنبال شود. در غربالگری سرطان سینه سی تی، میلیون ها سی تی اسکن باید مورد تجزیه و تحلیل قرار گیرند، که بار بسیار زیادی برای رادیولوژیست ها است. بنابراین، علاقه زیادی به توسعه الگوریتم های کامپیوتری برای بهینه سازی غربالگری وجود دارد. اولین قدم حیاتی در تجزیه و تحلیل سی تی اسکن غربالگری سرطان سینه، تشخیص گره های ریوی است که ممکن است نشان دهنده سرطان سینه در مراحل اولیه باشد یا نباشد.

در روش پیشنهادی موفق شدیم به یک دسترسی سطح بالا از تشخیص ندول به وسیله روش پیشنهادی دست یابیم. برای این منظور از مجموعه ای از فرایندهای پردازش تصویر در مرحله ابتدایی برای تشخیص سرطان سینه از روی مناطق قابل مشاهده استفاده نمودیم. مرحله

دوم از الگوریتم LSTM برای تشخیص اینکه آیا منطقه مشکوک ندول است یا خیر استفاده شده است. علت استفاده از الگوریتم پیشنهادی در مرحله طبقه بندی، استخراج خودکار ویژگی و طبقه بندی به صورت همزمان است. از پیشنهادهایی که می توان به عنوان کارهای آینده نام برد، ارائه یک الگوریتم مؤثر جهت قطعه بندی ناحیه ندولار است. چنین الگوریتمی سبب افزایش توانایی سامانه خواهد شد، به طوری که با اعمال آن به نواحی کاندیدا می توان شکل فرضی ندول را به دست آورد. هم چنین می توان مرحله ی دیگری به روش پیشنهادی اضافه نمود و آن تشخیص بدخیمی و یا خوش خیمی ندول ها می باشد.

منابع

- [1] D. Placido, B. Yuan, J. X. Hjaltelin, Ch. Zheng, A. D Haue, (2023), A Deep Learning Algorithm to Predict Risk of Pancreatic Cancer from Disease Trajectories, Nat Med, <https://doi.org/10.1038/s41591-023-02332-5>
- [2] H. R. Bolhasani, S. Jafarali Jassbi, A. Sharifi, (2023), DLA-E: A Deep Learning Accelerator for Endoscopic Images Classification, Journal of Big Data, <https://doi.org/10.1186/s40537-023-00775-8>
- [3] B. Nassif, M. Abu Talib, Q. Nasir, Y. Afadar, O. Elgendy, (2022), Breast Cancer Detection using Artificial Intelligence Techniques: A Systematic Literature Review, Artificial Intelligence in Medicine, Elsevier, Vol 127, May 2022
- [4] D. M. Koh, N. Papanikolaou, U. Bick, R. Illing, Ch. E. Kahn Jr., J. Kalpathi-Cramer, C. Matos, L. Martí-Bonmatí, A. Miles, S. Ki Mun, S. Napel, A. Rockall, E. Sala, N. Strickland, F. Prior, (2022), Artificial intelligence and machine learning in cancer imaging, Communications Medicine, <https://doi.org/10.1038/s43856-022-00199-0>
- [5] H. R. Bolhasani, S. Jafarali Jassbi, A. Sharifi, (2022), DLA-H: A Deep Learning Accelerator for Histopathologic Image Classification, Journal of Digital Imaging, <https://doi.org/10.1007/s10278-022-00743-3>
- [6] H. R. Bolhasani, E. Amjadi, M. Tabatabaeian, S. Jafarali Jassbi, (2020), A Histopathological Image Dataset for Grading Breast Invasive Ductal Carcinomas, Informatics in Medicine Unlocked 19, 2020, 100341
- [7] H. R. Bolhasani, S. Jafarali Jassbi, (2020), Deep learning accelerators: a case study with MAESTRO, Journal of Big Data, <https://doi.org/10.1186/s40537-020-00377-8>
- [8] A. P. R. Kishor Kumar Reddy, C. Apoorva, K. Meghana Mangipudi, (2021), Early Diagnosis of Breast Cancer Prediction using Random Forest Classifier, IOP Conference Series: Materials Science and Engineering
- [9] D. B. Ching Chen, R. Zhi Zhu, (2019), Using Random Forest Algorithm for Breast Cancer Diagnosis, IEEE Xplore: 21 February
- [10] S. Naveed, (2022), Prediction of Breast Cancer Through Random Forest, Curr Med Imaging, 2022 Sep 30. doi: 10.2174/1573405618666220930150625
- [11] M. M. Baths, (2023), Diagnosis of Breast Cancer Using Random Forests, Procedia Computer Science, Volume 218, 2023, Pages 429-437
- [12] B. O. Macaulay, B. Segun Aribisala, S. Alabi Akande, B. Ade Akinuwa, O. Aanu Olabanjo, (2021), Breast cancer risk prediction in African women using Random Forest Classifier, Cancer Treat Res Commun, 2021;28:100396. doi: 10.1016/j.ctarc.2021.100396. Epub 2021 May 15.
- [13] R. Cameron, C. R. Wolfe, (2018), Training a Random Forest to Identify Malignant Breast Cancer Tumors, Towards Data Science
- [14] <https://www.kaggle.com/datasets/mdwaquarazam/ucidatasetlist>, <https://data.world/datasets>
- [1] [عسکری، الهام و معتمد، سارا، 1400، تشخیص سرطان سینه مبتنی بر ماشین یادگیری افراطی و منطق فازی، پنجمین همایش بین المللی دانش و فناوری مهندسی برق، کامپیوتر و مکانیک ایران، تهران، <https://civilica.com/doc/1238100>
- [2] [لطفی، فاطمه و چاله چاله، عبدالله، 1400، تشخیص بیماری سرطان سینه با استفاده از روش ترکیبی جدید انتخاب ویژگی مبتنی بر الگوریتم ازدحام ذرات و گرگ خاکستری (HPSOGWO) و روش های یادگیری ماشین KNN و SVM، پنجمین کنفرانس بین المللی تحقیقات بین رشته ای در مهندسی برق، کامپیوتر، مکانیک و مکترونیک در ایران و جهان اسلام، تهران، <https://civilica.com/doc/1306761>
- [3] [مرادیان، محمدرضا و جلالیان، حمیدرضا، 1401، تشخیص سرطان سینه با استفاده از ساختار ترکیبی پایگاه داده مبتنی بر شبکه عصبی، هشتمین کنفرانس بین المللی تحقیقات بین رشته ای در مهندسی برق، کامپیوتر، مکانیک و مکترونیک در ایران و جهان اسلام، تهران، <https://civilica.com/doc/1638042>
- [4] [قربانی مقصود بیگی، صفورا و دانش، فروزان و افسون، عصمت، 1401، تشخیص سرطان سینه با استفاده از Deep Learning، هجدهمین کنفرانس بین المللی فناوری اطلاعات، کامپیوتر و مخابرات، <https://civilica.com/doc/1636108>
- [5] [مزینانی، سید مجید و محمدالحمدی، محمد منصور و قصرانی، هنگامه، 1401، استفاده از شبکه عصبی کانولوشن و گرادیان تقویتی سریع برای تشخیص سرطان سینه، هشتمین همایش ملی مطالعات و تحقیقات نوین در حوزه علوم کامپیوتر، برق و مکانیک ایران، تهران، <https://civilica.com/doc/1620860>
- [6] [غلامی، فاطمه، 1396، تشخیص سرطان سینه با استفاده از ترکیب الگوریتم کاهش ابعاد و الگوریتم شبکه عصبی پرسپترون، دومین کنفرانس بین المللی پژوهش های دانش بنیان در مهندسی کامپیوتر و فناوری اطلاعات، تهران، <https://civilica.com/doc/1629712>
- [7] [غلامی، فاطمه، 1396، تشخیص سرطان سینه با استفاده از ترکیب الگوریتم کاهش ابعاد و الگوریتم درخت بیزین ساده، دومین کنفرانس بین المللی پژوهش های دانش بنیان در مهندسی کامپیوتر و فناوری اطلاعات، تهران، <https://civilica.com/doc/1629299>
- [8] [نصیری، حمید و قرائیان، هلیا و قرائیان، کیانا، 1400، یک رویکرد جدید مبتنی بر یادگیری عمیق و الگوریتم XGBoost به منظور تشخیص سرطان سینه خوش خیم و بدخیم، هشتمین کنگره ملی تازه های مهندسی برق و کامپیوتر ایران، تهران، <https://civilica.com/doc/1402802>
- [9] Minnoor, M. Baths, V. Diagnosis of Breast Cancer Using Random Forests, Procedia Computer Science, Volume 218, 2023, Pages 429-437

- [10]Dai, B. Ching Chen, R. Zhi Zhu, Sh. 2019. Using Random Forest Algorithm for Breast Cancer Diagnosis, EEE Xplore: 21 February
- [11]Naveed, S.2022. Prediction of Breast Cancer Through Random Forest, Curr Med Imaging, 2022 Sep 30. doi: 10.2174/1573405618666220930150625
- [12]Anisha, P. R. Kishor Kumar Reddy, C. Apoorva, K. Meghana Mangipudi, C. 2021. Early Diagnosis of Breast Cancer Prediction using Random Forest Classifier, IOP Conference Series: Materials Science and Engineering
- [13]Macaulay, B. O. Segun Aribisala, B. Alabi Akande, S. Ade Akinnuwesi, B. Aanu Olabanjo, O. 2021. Breast cancer risk prediction in African women using Random Forest Classifier, Cancer Treat Res Commun, 2021;28:100396. doi: 10.1016/j.ctarc.2021.100396. Epub 2021 May 15.
- [14]Cameron R. Wolfe, C. R. 2018. Training a Random Forest to Identify Malignant Breast Cancer Tumors, Towards Data Science
- [15]Nguyen, C. Wang, Y. Nguyen H. N. 2013. Random forest classifier combined with feature selection for breast cancer diagnosis and prognostic, Journal of Biomedical Science and Engineering, Vol.6 No.5(2013), Article ID:31887,10 pages
- [16]<https://www.kaggle.com/datasets/mdwaquarazam/ucidatasetlist>, <https://data.world/datasets>
- [17]Asuntha, A., Srinivasan, A. Deep learning for Cancer detection and classification. Multimed Tools Appl 79, 7731–7762 (2020). <https://doi.org/10.1007/s11042-019-08394-3>
- [18]M. Gindi, Al Attiatalla, T. A., & Sami, M.M., "A Comparative Study for Comparing Two Feature Extraction Methods and Two Classifiers in Classification of Earlystage Cancer Diagnosis of chest x-ray images," Journal of American Science, pp. 13-22, 2014.
- [19]S. Ignatious, & Joseph, R., "Computer aided lung cancer detection system," 2015 Global Conference on Communication Technologies (GCCT), 2015.
- [20]Moitra, D. and R. Kr. Mandal (2020). "Classification of non-small cell l\ung cancer using one-dimensional convolutional neural network." Expert Systems with Applications 159: 113564.
- [21]Aa. R. Padhani, G. Liu, D. Mu-Koh, T. L. Chenevert, H. C. Thoeny, T. Takahara, et al., "Diffusion-Weighted Magnetic Resonance Imaging as a Cancer Biomarker: Consensus and Recommendations," Neoplasia, vol. 11, pp. 102-125, 2009/02/01/ 2009.
- [22]Aa. S. Pathan, B.K., "Detection and classification of lung cancer using artificial neural network," International Journal on Advanced Computer Engineering and Communication Technology, 2012.
- [23]Pradhan, K. and P. Chawla (2020). "Medical Internet of things using machine learning algorithms for cancer detection." Journal of Management Analytics 7(4): 591-623.
- [24]S. Sasikumar, P. N. Renjith, K. Ramesh and K. S. Sankaran, "Attention Based Recurrent Neural Network for Cancer Detection," 2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC), 2020, pp. 720-724, doi: 10.1109/I-SMAC49090.2020.9243556.
- [25]Shakeel, P.M., Burhanuddin, M.A. & Desa, M.I. Automatic cancer detection from CT image using improved deep neural network and ensemble classifier. Neural Comput & Applic (2020). <https://doi.org/10.1007/s00521-020-04842-6>
- [26]M. S. Al-Tarawneh, " Cancer Detection Using Image Processing Techniques," 2012.
- [27]R. J. Theilmann, R. Borders, T. P. Trouard, G. Xia, E. Outwater, J. Ranger-Moore, et al., "Changes in Water Mobility Measured by Diffusion MRI Predict Response of Metastatic Breast Cancer to Chemotherapy," Neoplasia, vol. 6, pp. 831-837, 2004/11/01/ 2004.
- [28]J. J. Tomaszewski, R. G. Uzzo, and M. C. Smaldone, "Heterogeneity and renal mass biopsy: a review of its role and reliability," Cancer Biology & Medicine, vol. 11, pp. 162-172, 05/29/received 06/25/accepted 2014.
- [29]Ircancercenter. <http://www.ircancercenter.com/>. Accessed 2020.
- [30]ssu.ac.ir. <http://ssu.ac.ir/cms/index.php?id=7676>. Accessed 2020.
- [31]WHO. World Health Organization. <http://www.who.int/newsroom/fact-sheets/detail/cancer>. Accessed 26 Oct 2018. WHO2018.
- [32]Freddie Bray, Jacques Ferlay, Isabelle Soerjomataram, Rebecca L Siegel, Lindsey A Torre, and Ahmedin Jemal. Global cancer statistics 2018: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries. CA: a cancer journal for clinicians,68(6):394–424, 2018.
- [33]Kingsley Kuan, Mathieu Ravaut, Gaurav Manek, Huiling Chen, Jie Lin, Babar Nazir, Cen Chen, Tse Chiang Howe, Zeng Zeng, and Vijay Chandrasekhar. Deep learning for cancer detection: Tackling the kaggle data science bowl 2017 challenge. arXiv preprint arXiv:1705.09435, 2017.
- [34]Yun Liu, Krishna Gadepalli, Mohammad Norouzi, George E Dahl, Timo Kohlberger, Aleksey Boyko, Subhashini Venugopalan, Aleksei Timofeev, Philip Q Nelson, Greg S Corrado, et al. Detectingcancer metastases on gigapixel pathology images. arXiv preprint arXiv:1703.02442, 2017.
- [35]M. McNitt, S. Armato, et al. "The image database consortium data collection process for nodule detection and annotation", Acad Radiol, vol. 14, no. 12, pp. 1464-1474, 2007.
- [36]B. Keserci and H. Yoshida, "Computerized detection of pulmonary nodules in chest radiographs based on morphological features and wavelet snake model." Med. Image Anal. vol. 6, no. 4, pp. 431–47, 2002.

- [37]W. Shen, et. al. "Multi-crop Convolutional Neural Networks for lung nodule malignancy suspiciousness classification," Pattern Recognition, Volume 61, January 2017, pp. 663-673.
- [38]W. Zhang, X. Wang, X. Li and J. Chen, "3D skeletonization feature based computeraided detection system for pulmonary nodules in CT datasets," Computers in Biology and Medicine, Volume 92, 1 January 2018, pp. 64-72.
- [39]S. G. Armato, G. Mclellan, M. F. Mcnitt-gray, et al. "The image database consortium and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans", Med Phys, vol. 38. no. 2, pp. 915-931, 2011.
- [40]Yu L, Liu H. Feature selection for highdimensional data: A fast correlation-based filter solution. In Proceedings of the 20th international conference on machine learning (ICML-03) 2003;856-863.
- [41]Tan PJ, Dowe DL. MML Inference of Oblique Decision Trees in Lecture Notes in Artificial Intelligence, GI Webb and X. Yu, Eds., 17th Australian Joint Conf. on Advances in AI, Cairns, Australia, 2004:0302-9743.
- [42]Bostrom H. Maximizing the area under the ROC curve using incremental rediced error pruning. In: Proceedings of the ICML 2005 Workshop on ROC Analysis in Machine Learning, 2005.
- [43]Hendrickx I, van den Bosch A. Hybrid algorithms with instance-based classification. In: Proceedings of the 16th European Conf. on Machine Learning. Lect Notes Comput Sci. 2005;3720: 158– 169.
- [44]Badjio FE, Poulet F. Dimension reduction for visual data mining. In Proceedings of International symposium on applied stochastic models and data analysis, 2005.
- [45]Avci E. A new expert system for diagnosis of lung cancer: GDA—LS_SVM. J Med Syst. 2012;36(3): 2005-2009.
- [46]Daliri MR. A hybrid automatic system for the diagnosis of lung cancer based on genetic algorithm and fuzzy extreme learning machines. J Med Syst. 2012;36(2):1001-1005.
- [47]Lu C, Zhu Z, Gu X. An intelligent system for lung cancer diagnosis using a new genetic algorithm-based feature selection method. J Med Syst. 2014;38(9): 97.
- [48]Sharifi, A., Alizade, K., A novel technique based on principal component analysis and multi-layer perceptron with genetic algorithm optimization for diagnosis of lung cancer, Razi Journal of Medical Sciences.2019;26(10):48-56.
- [49]Jiang J, Hu Y-C, Liu C-J, Halpenny D, Hellmann MD, Deasy JO, Mageras G, Veeraraghavan H (2018), "Multiple resolution residually connected feature streams for automatic lung tumor segmentation from CT images", IEEE Trans Med Imaging 38(1):134–144.
- [50]Mukherjee S, Huang X, Bhagalia RR. "Lung nodule segmentation using deep learned prior based graph cut", Paper presented at: IEEE 14th international symposium on biomedical imaging (ISBI 2017); Apr. 18-21, 2017; Melbourne, Australia.
- [51]Pang S, Du A, Orgun MA, et al. "CTumorGAN: a unified framework for automatic computed tomography tumor segmentation", Eur J Nucl Med Mol Imaging. 2020; 47:2248-2268.
- [52]Tong G, Li Y, Chen H, Zhang Q, Jiang H. "Improved U-NET network for pulmonary nodules segmentation", Optik. 2018; 174:460-469.
- [53]Wu B, Zhou Z, Wang J, Wang Y, "Joint learning for pulmonary nodule segmentation, attributes and malignancy prediction", In: 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI2018), 2018. IEEE, pp 1109–1113.
- [54]ssu.ac.ir, 2020

Providing an IoT-based architecture for monitoring breast cancer activities using deep learning

Rouzbeh Latifi Azizi* - (rouzbeh.latifi@yahoo.com)

Somayyeh Jafarali Jasbi - (sjassbi@gmail.com)

Islamic Azad University, Science and Research Branch (Tehran)

Abstract

In today's world, breast cancer is one of the causes of death and one of the most terrible diseases, which is one of the potential causes of death in women. Although it is considered one of the most treatable diseases, it is important that its timely diagnosis can reduce the mortality rate in the long term. As a solution for predicting and treating this disease, the automatic disease diagnosis system in diagnosis and analysis helps the medical field greatly by providing a quick response, reliability, effectiveness, and also reducing the risk of death. Therefore, in this article, the long short-term memory (LSTM) algorithm, which is a learning algorithm, was used because it leads to more stable and accurate models. The results of simulation and comparison with other articles showed that the use of this algorithm improved the accuracy and sensitivity in diagnosing breast cancer, and we were able to determine whether the suspicious area is benign or not with the help of the LSTM algorithm. Evaluations show that the sensitivity of the proposed method is very favorable, especially when dealing with small nodules. The estimated positive error rate for the proposed method is 16.67%, which is lower than other works.

Keywords: Breast cancer, LSTM algorithm, machine learning, diagnosis, prediction, accuracy