Intelligent Information Systems Journal
Islamic Azad University, Hamedan Branch

سیستم های اطلاعاتی هوشمند
نشریه علمی دانشگاه آزاد اسلامی
مجلد 3شماره6
صفحات44-37
مقاله عادی

Detection of Benign and Malignant Breast Cancer with Deep Learning and Artificial Attention Networks

Elham Kiani kakaei & Maryam Bayati[2]*

1- Faculty of Computer Engineering, University of Sepahan, Esfehan, Iran.

2*- Faculty of Computer Engineering, University of Sepahan, Esfehan, Iran.

[1] kianielham@yahoo.com, [2*]m.bayati@sepahan.ac.ir

Corresponding author's address: Maryam Bayati, Faculty of Computer Engineering, University of Sepahan, Esfehan, Iran.

Abstract

Breast cancer is one of the most common and deadly types of cancer in women, and mammography is a reliable diagnostic method for early detection of breast cancer. In this research, we set out to use machine learning and neural networks to find a reliable solution to diagnose benign and malignant breast cancer. Because human diagnosis includes errors, and it is also used to avoid paying high medical costs, ease the work of eliminating human resources, and also to diagnose taste and prevent wasting time of doctors in viewing images and presenting results by them. Artificial intelligence excels in data recognition in large volumes, extracting relationships between them and discovering complex features that cannot be understood by the human brain. For this reason, every day is used more than the previous day in the diagnosis and treatment of the disease. In this research, by using CBMA, we increased the representational power of a convolutional neural network by drawing attention both in terms of channel and space in order to focus on informational regions and features and improve its recognition ability and overall performance. By using the proposed solution, we reached 63% and 0.09 percent of the recall accuracy criterion and F1 criterion.

.

Keywords: Neural Network, Machine Learning, Body damage

Intelligent Information Systems Journal
Islamic Azad University, Hamedan Branch

سیستم های اطلاعاتی هوشمند
نشریه علمی دانشگاه آزاد اسلامی
مجلد3،شماره6
صفحات44-37
مقاله عادی

تشخیص سرطان خوش خیم و بدخیم پستان با یادگیری عمیق و شبکه های مصنوعی توجه

الهام کیانی[1]، مریم بیاتی[2*]

1- کارشناسی ارشد، دانشکده مهندسی کامپیوتر، موسسه آموزش عالی علوم و فناوری سپاهان، اصفهان، ایران
2- استادیار، دانشکده مهندسی کامپیوتر، موسسه آموزش عالی علوم و فناوری سپاهان، اصفهان، ایران
[1]kianielham@yahoo.com, [2*]m.bayati@sepahan.ac.ir

چکیده

سرطان پستان یکی از شایع‌ترین و مهلک‌ترین نوع سرطان در زنان است و ماموگرافی، روش تشخیص معتبر برای تشخیص زودهنگام سرطان پستان می‌باشد. در این پژوهش بر آن شدیم تا با استفاده از روش یادگیری ماشین و شبکه‌های عصبی، به راهکاری مطمئن جهت تشخیص سرطان خوش‌خیم و بدخیم پستان برسیم. هوش مصنوعی در تشخیص داده‌ها در حجم زیاد، استخراج روابط بین آن‌ها و کشف ویژگی‌های پیچیده‌ای که توسط مغز انسان قابل‌درک نیست، برتری دارد. به همین دلیل، هرروز بیشتر از روز قبل در تشخیص و درمان بیماری به کار می‌رود. در این پژوهش، مجموعه داده مورداستفاده با تغییر اندازه تصاویر به ابعاد 512 پیکسل و بارگیری اطلاعات مربوطه از یک فایل CSV، شامل شناسه بیمار و سایر فیلدها، تهیه شد. مجموعه داده شامل 54706 نمونه با عدم تعادل طبقه قابل‌توجهی بود که در آن 53548 نمونه 0 (عدم سرطان) و 1158 نمونه به‌عنوان 1 (وجود سرطان) برچسب‌گذاری شدند. برای اطمینان از ارزیابی بی‌طرفانه، مجموعه داده به یک مجموعه آموزشی از 8938 نمونه و یک مجموعه آزمایشی از 2975 نمونه تقسیم شد. مدل Self Attention-based CNN با لایه‌های کانولوشن و ادغام برای استخراج ویژگی و لایه‌های کاملاً متصل برای طبقه‌بندی طراحی‌شده است. این مدل بر روی مجموعه داده آموزشی آموزش داده شد و با استفاده از معیارهای مختلف مانند دقت، یادآوری و امتیاز F1 برای ارزیابی عملکرد آن بر روی‌داده‌های دیده نشده ارزیابی شد. کتابخانه TensorFlow و tf.data.Dataset API برای بارگذاری و پیش‌پردازش تصاویر ماموگرافی استفاده شد. این تکنیک‌ها به مدل کمک کرد تا بهتر تعمیم یابد و عملکرد خود را بر روی‌داده‌های دیده نشده بهبود بخشد. معیارهای ارزیابی مختلفی مانند دقت، یادآوری و امتیاز F1 برای ارزیابی اثربخشی مدل در طبقه‌بندی موارد سرطان محاسبه می‌شوند. علاوه بر این، تکنیک‌های زمان‌بندی نرخ یادگیری و افزایش داده‌ها برای افزایش عملکرد مدل و توانایی تعمیم استفاده می‌شوند. نتایج نشان می‌دهد که مدل Self Attention-based CNN با توجه به خود به عملکرد بهتری در مقایسه با مدل‌های سنتی CNN دست می‌یابد که پتانسیل خود را برای طبقه‌بندی دقیق سرطان با استفاده از تصاویر ماموگرافی نشان می‌دهد. با استفاده از CBMA (ماژول توجه بلوک کانولوشن)، قدرت بازنمایی یک شبکه عصبی کانولوشنال با جلب‌توجه هم ازنظر کانال و هم ازنظر فضایی، افزایش داده شد تا بر مناطق و ویژگی‌های اطلاعاتی تمرکز شود و توانایی تشخیص و عملکرد کلی آن بهبود یابد. با استفاده از راهکار پیشنهادی به معیار دقت، صحت، فراخوانی و معیار F1، 63 درصد و 0/09 به دست آمد.

کلیدواژه‌ها: سرطان پستان، یادگیری ماشین، شبکه‌های عصبی کانولوشن، تشخیص سرطان خوش‌خیم و بدخیم

1-مقدمه

سرطان پستان، یکی از شایع‌ترین و مهلک‌ترین سرطان‌ها در زنان است. این بیماری از سلول‌های پستان شروع‌شده و به بافت‌های اطراف آن‌ها و حتی سایر بخش‌های بدن گسترش می‌یابد. تشخیص زودهنگام سرطان پستان باعث می‌شود تا پزشکان بتوانند از پیشرفت بیماری جلوگیری کنند. ماموگرافی، یک روش تشخیصی معتبر و پراستفاده برای تشخیص زودهنگام سرطان پستان است. بااین‌حال، مشکلاتی مانند خراب شدن فیلم‌ها و تفسیر ناصحیح تصاویر می‌تواند به وجود آید. شبکه‌های عصبی مصنوعی، به‌عنوان روشی نوین در یادگیری ماشینی، می‌توانند به پزشکان در تشخیص سرطان پستان کمک کنند و دقت تشخیص را افزایش دهند. از طریق ترکیب بینایی رایانه‌ای و ابزارهای یادگیری ماشینی، رایانه‌ها قادر به درک و تشخیص هوشمند ویژگی‌ها و اشیاء در تصاویر ماموگرافی می‌شوند. استفاده از سیستم‌های تشخیصی کامپیوتری در تشخیص سرطان پستان می‌تواند بهبود قابل‌توجهی در تشخیص این بیماری داشته باشد.

بهترین روش برای کاهش مرگ‌ومیر ناشی از سرطان پستان، تشخیص زودهنگام آن جهت درمان آن است. تشخیص زودهنگام نیازمند یک روش تشخیصی دقیق و قابل‌اطمینان است. از میان روش‌های مختلف تشخیص سرطان پستان، ماموگرافی به‌عنوان روشی با مقبولیت بسیار بالا، بسیار رایج و متداول است [5-1]. غربالگری سیستماتیک جامعه زنان به‌وسیله دستگاه‌های ماموگرافی و تشخیص زودهنگام سرطان پستان در مراحل اولیه می‌تواند شانس زنده ماندن بیمار و اثرات جانبی منفی ناشی از درمان‌های لازم را نیز کاهش دهد. این نتایج در صورتی امکان‌پذیر است که کیفیت خدمات ارائه‌شده به بهترین شکل ممکن باشد [11-6]. از طرفی، تشخیص سرطان پستان از روی فیلم ماموگرافی دارای اشکالاتی است. در برخی موارد احتمال خراب شدن فیلم یا مناسب نبودن تصویر برای تشخیص وجود دارد [15-11]. در ضمن، فیلم به‌مرورزمان مستهلک‌شده و امکان بازبینی کم می‌شود. از سوی دیگر، تنها ابزار پزشک برای تشخیص ضایعه از روی فیلم مشاهده بصری است. استفاده پزشک از مشاهدات چشمی برای تشخیص ضایعه منجر به دو خطا می‌شود؛ خطای اول اینکه یک تصویر رادیولوژی در دو نوبت به یک پزشک یا رادیولوژیست نشان داده می‌شود. درصورتی‌که وی نداند که هر دو تصویر یکسان است، ممکن است تشخیص وی متفاوت باشد و خطای دیگر ناشی از نشان دادن یک تصویر به دو پزشک یا دو رادیولوژیست است که تشخیص هر یک با دیگری غیرهمسان است. باوجوداینکه ماموگرافی به‌طورمعمول بهترین روش برای تشخیص سرطان پستان است، ولی 20٪ موارد سرطانی با این روش تشخیص داده نمی‌شوند [21-16]. شبکه‌های عصبی

مصنوعی یا به زبان ساده‌تر شبکه‌های عصبی، سیستم‌ها و روش‌های محاسباتی نوین برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به‌دست‌آمده در جهت پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده هستند [22]. ایده اصلی این‌گونه شبکه‌ها (تا حدودی) الهام گرفته از شیوه کارکرد سیستم عصبی زیستی برای پردازش داده‌ها و اطلاعات به‌منظور یادگیری و ایجاد دانش می‌باشند. عنصر کلیدی این ایده، ایجاد ساختارهایی جدید برای سامانه پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده به‌هم‌پیوسته با نام نورون تشکیل‌شده که برای حل یک مسئله باهم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند. در این شبکه‌ها اگر یک سلول آسیب ببیند، بقیه سلول‌ها می‌توانند نبود آن را جبران کرده و در بازسازی آن سهیم باشند. این شبکه‌ها قادر به یادگیری هستند [25-23]. بینایی رایانه‌ای یا بینایی کامپیوتری یا بینایی ماشینی یکی از شاخه‌های مدرن و پرتنوع هوش مصنوعی است که با ترکیب روش‌های مربوط به پردازش تصاویر و ابزارهای یادگیری ماشینی، رایانه‌ها را در دیدن اشیاء و مناظر و "درک" هوشمند ویژگی‌های گوناگون آن‌ها توانمند می‌گرداند. ماموگرافی یک عکس رادیوگرافی ساده از پستان و ابزاری برای کشف زودرس سرطان‌های غیرقابل لمس پستان است. متخصصین پزشکی، این تصاویر را بررسی و تفسیر می‌کنند. متأسفانه تصاویر ماموگرافی از روشنایی پایینی برخوردار هستند و نیز به دلیل تفاوت در انواع بافت‌ها جزو مشکل‌ترین تصاویر پزشکی جهت خواندن محسوب می‌شوند [25-33]. همچنین، ثابت‌شده که خواندن و تفسیر تصاویر توسط دو پزشک دقت را افزایش داده ولی هزینه اضافی در بردارد. با ارائه روشی مناسب برای تشخیص تومورهای موجود در پستان توسط سیستم‌های تشخیصی کامپیوتری، به تشخیص پزشک کمک بزرگی خواهد شد.

1-1- محدوده مقاله

این مقاله، یک روش تشخیص سرطان خوش‌خیم و بدخیم پستان با استفاده از تکنیک شبکه‌های عصبی توجه در یادگیری عمیق ارائه خواهد شد. اصلی‌ترین و اولین نوآوری این مقاله استفاده از تکنیک شبکه‌های عصبی توجه در یادگیری عمیق است که مطالعات مختلف نشان می‌دهد تاکنون تشخیص سرطان خوش-خیم و بدخیم پستان با این روش انجام‌نشده است. اهداف پژوهش این مقاله عبارتنداز: ارائه یک مدل تشخیص سرطان خوش‌خیم و بدخیم پستان با استفاده از تکنیک شبکه‌های عصبی توجه در یادگیری عمیق. ارتقاء دقت تشخیص سرطان خوش‌خیم و بدخیم پستان. ارتقاء صحت تشخیص سرطان خوش‌خیم و بدخیم پستان.

1-2- مشارکت‌های اصلی

سهم اصلی این مقاله به شرح زیر است:

(1) استفاده از تکنیک شبکه‌های عصبی توجه در یادگیری عمیق می‌تواند باعث بهبود دقت و صحت در تشخیص سرطان خوش‌خیم و بدخیم پستان شود.

(2) از چهار مرحله پیش‌پردازش، تقسیم مناطق استخراج و انتخاب ویژگی‌ها و در آخر، طبقه‌بندی تشکیل می‌شود.

1-3- ساختار مقاله

ساختار این مقاله به این صورت است که در ادامه با معرفی نویسه‌ها و تعاریف مفید در بخش 2 شروع‌شده است. سپس از بخش 3 برای بحث در مورد کارهای مربوطه و روش‌های موجود با استفاده از طبقه‌بندی اصلی خود استفاده‌شده است. در بخش 4 ما به ارائه روش پیشنهادی می‌پردازیم. در بخش 5 به‌مرور نتایج تجربی و مجموعه داده محک خواهیم پرداخت. در بخش 6 به موضوع چالش‌ها و همچنین فرصت‌های جالب برای کارهای آینده می‌پردازیم.

2- مروری بر تعاریف مسئله

در این قسمت ما به بررسی تعاریف و نشانه‌گذاری‌هایی می‌پردازیم که در این مقاله از آن استفاده‌شده است.

تعریف 1. precision نسبت مثبت‌های واقعی به مثبت‌های پیش‌بینی‌شده است. کسری از عناصر مثبت واقعی تقسیم‌بر تعداد کل واحدهای پیش‌بینی‌شده مثبت (مجموع ستونی موارد مثبت پیش‌بینی‌شده) است و مثبت واقعی عناصری هستند که توسط مدل به‌عنوان مثبت برچسب‌گذاری شده‌اند و درواقع مثبت هستند. درحالی‌که مثبت کاذب عناصری هستند که توسط مدل به‌عنوان مثبت برچسب‌گذاری شده‌اند اما درواقع منفی هستند. معادله (2-1) این نسبت را نشان می‌دهد:

$$\text{precision} = \text{TP}/\text{TP} + \text{FP} \qquad (2\text{-}1)$$

تعریف 2. recall کسری از عناصر مثبت واقعی است که بر تعداد کل واحدهای طبقه‌بندی‌شده مثبت (مجموع ردیف‌های مثبت واقعی) تقسیم می‌شود. منفی کاذب عناصری هستند که توسط مدل به‌عنوان منفی برچسب‌گذاری شده‌اند اما درواقع مثبت هستند. درواقع recall نسبت True Positives به actual Positives را بیان می‌کند. معادله (2-2) این نسبت را نشان می‌دهد:

$$\text{recall} = \text{TP}/\text{TP} + \text{FN} \qquad (2\text{-}2)$$

تعریف 3. pFBeta که معیاری است که دقت و یادآوری را برای ارزیابی عملکرد یک مدل طبقه‌بندی، به‌ویژه در مجموعه داده‌های نامتعادل، ترکیب می‌کند. امتیاز pFBeta با در نظر گرفتن میانگین هارمونیک آن‌ها، دقت و یادآوری را در یک مقدار واحد ترکیب می‌کند. معادله (2-3) این نسبت را نشان می‌دهد:

$$\text{pFBeta} = (\text{precision} * \text{recall}/\text{Beta}^2 * \text{precision} + \text{recall}) \qquad (2\text{-}3)$$

تعریف 4. F1-Score به معنی میانگین هارمونیک (مقدار میانگین) است که ترکیبی از recall و precision است که در معادله (2-4) نشان داده‌شده است.

$$\text{F1} - \text{Score} = 2 \times (\text{P} \times \text{R}/\text{P} + \text{R}) \qquad (2\text{-}4)$$

تعریف 5. دقت کلی طبقه‌بندی‌شده برابر نسبت نمونه‌هایی که به‌درستی طبقه‌بندی‌شده‌اند به همه نمونه‌ها است که آن را به‌صورت معادله (2-5) نشان

می‌دهد:

$$accuracy = TP + TN/TP + TN + FP + FN \quad (5\text{-}2)$$

3- کارهای مرتبط

3-1- شبکه‌های عصبی کانولوشنال *CNN* با مکانیسم‌های توجه *AMs*

مدلی را برای تشخیص سرطان پستان بر اساس شبکه‌های عصبی عمیق با AMs با استفاده از تصاویر حرارتی از پایگاه داده تحقیقات ماستولوژی با تصویر مادون‌قرمز DMR-IR ارائه می‌کند. این مدل ازنظر دقت، حساسیت و ویژگی ارزیابی می‌شود و با روش‌ها پیشرفته تشخیص سرطان پستان مقایسه می‌شود. MAها با مدل CNN به نرخ‌های دقت تست دلگرم‌کننده 99/46٪، 99/37٪ و 99%/30 در مجموعه داده حرارت سینه دست یافتند. دقت تست CNNهای بدون AM 92%/32 بود. درحالی‌که CNN با Ams بهبود دقت 7٪ دست یافتند.

3-2- استفاده از تکنیک *SVM*

یک الگوریتم تشخیص تومور از ماموگرافی را ارائه می‌دهد. سیستم پیشنهادی بر حل دو مشکل تمرکز دارد. یکی این است که چگونه برای تشخیص تومور به‌عنوان مناطق مشکوک با بسیار ضعیف است در تضاد با پس‌زمینه آن‌ها و دیگری نحوه استخراج ویژگی‌هایی است که تومورها را طبقه‌بندی می‌کند. روش تشخیص تومور از طرح (الف) افزایش ماموگرافی پیروی می‌کند، (ب) تقسیم ناحیه تومور، ج) استخراج ویژگی‌ها از ناحیه تومور تقسیم‌شده، (د) استفاده از طبقه‌بندی کننده.

3-3- تشخیص توده‌های سرطانی بر اساس میدان تصادفی مارکوف

نتایج استفاده از این روش نشان می‌دهد که حساسیت 90 درصدی در تشخیص توده‌های سرطانی دارد ولی در تشخیص توده‌هایی با سایز کمتر از 510 میلی‌متر موفق نبوده است. تکنیکی برای تشخیص تومورها پیشنهادشده است. در ماموگرافی دیجیتال تشخیص در دو مرحله انجام می‌شود: تقسیم‌بندی و طبقه-بندی در تقسیم‌بندی. ابتدا مناطق موردنظر با استفاده از آستانه تطبیقی از تصاویر استخراج می‌شوند. تقسیم‌بندی قابل‌اعتماد بیشتر توسط مارکوف اصلاح‌شده به دست می‌آید روش مبتنی بر مدل میدان تصادفی. در طبقه‌بندی، مناطق تقسیم‌شده MRF به دودسته suspiCwus و نرمال طبقه‌بندی می‌شوند و توسط یک درخت تصمیم‌گیری باینری فازی بر اساس یک سری رادیوگرافی، ویژگی‌های مرتبط با تراکم مجموعه‌ای از نرمال (50) و غیرطبیعی (45) ماموگرافی صفحه/فیلم مورد آزمایش قرار گرفت. دومی شامل 48 بود بیوپسی اثبات‌شده بود؛ توده‌های بدخیم با انواع مختلف و ظریف. دقت تشخیص الگوریتم با ابزار، مورد ارزیابی قرار گرفت. یک منحنی مشخصه عملکرد گیرنده پاسخ آزاد که رابطه بین تشخیص مثبت واقعی را نشان می‌دهد. توده‌ها و تعداد آلارم‌های مثبت کاذب در هر تصویر را نتایج حاکی از آن است که حساسیت 90 درصدی را می‌توان در آن به دست آورد.

4- روش پیشنهادی

روش پیشنهادی یک مدل تشخیصی برای سرطان خوش‌خیم و بدخیم پستان معرفی می‌کند. برای دستیابی به این هدف، مدل ارائه‌شده، پیش‌پردازش داده‌های را در مراحل مختلف انجام می‌دهد تا کیفیت داده‌ها را افزایش دهد. به دنبال آن، وجود ویژگی‌های متعدد در داده‌های تحت فرآیند انتخاب ویژگی با استفاده از مدل cnn قرار می‌گیرد و منجر به زیرمجموعه‌های ویژگی بهینه می‌شود. سپس، داده‌ها را می‌توان با استفاده از مدل حافظه طولانی‌مدت که در آن فرا پارامترهای مدل cnn با استفاده از ویژگی‌های استخراج‌شده تنظیم می‌شوند و درنهایت در تشخیص سرطان خوش‌خیم و بدخیم سرطان پستان مؤثر است.

شکل 1- فرآیند کلی روش پیشنهادی.

شکل 1 فلوچارت کلی مدل پیشنهادی را در روش cnn نشان می‌دهد. روش پیشنهادی به‌وسیله پردازش تصویر و استفاده از Cnn می‌پردازد که در حقیقت این ترکیب یک راهکار بهبودیافته و مناسب برای تشخیص سرطان خوش‌خیم یا بدخیم پستان است. روش پیشنهادی به‌منظور افزایش دقت و کارایی تشخیص سرطان پستان ارائه‌شده است که در آن ابتدا از تصاویر کاگل و داده‌های pace جهت وروی برای cnn استفاده کرده است. Cnn تصاویر را به‌صورت لایه‌ای به مدل می‌دهد تا مرحله آموزش تکمیل‌شده و روش پیشنهادی آمادگی تشخیص را داشته باشد. بعد از مرحله آموزش، زمان آزمایش فرامی‌رسد و مدل بر اساس تصاویر جدید مورد آزمایش قرار می‌گیرد. نتایج حاصله منجر به طبقه‌بندی تصاویر به سرطان خوش‌خیم و بدخیم شده و معیارهای دقت، صحت، فراخوانی و معیار F1 را نمایش می‌دهد.

حال در ادامه در قسمت‌های 4-1، 4-2 و 4-3 به معرفی این بخش‌ها خواهیم پرداخت.

4-1- مدل‌سازی روش پیشنهادی

یک مدل شبکه عصبی کانولوشن برای طبقه‌بندی سرطان با استفاده از تصاویر ماموگرافی توسعه یافت. اندازه تصاویر به ابعاد 512 پیکسل تغییر داده شد تا از ثبات در کل مجموعه داده اطمینان حاصل شود. اندازه تصاویر به ابعاد 512 پیکسل تغییر داده شد تا از ثبات در کل مجموعه داده اطمینان حاصل شود. علاوه بر تصاویر، یک فایل CSV حاوی اطلاعات مرتبط مانند شناسه بیمار، سن، بیوپسی و سایر فیلدها با استفاده از کتابخانه پانداها بارگذاری شد. فایل

CSV به مسیرهای تصویر مربوطه پیوند داده شد و یک مجموعه داده یکپارچه برای آموزش و ارزیابی ایجاد کرد. از مجموع 54706 نمونه، 53548 نمونه با علامت صفر نشان‌دهنده عدم وجود سرطان و 1158 نمونه به‌عنوان 1 نشان داده‌شده که نشان‌دهنده وجود سرطان است. این توزیع نشان‌دهنده عدم تعادل طبقاتی ذاتی در تشخیص سرطان است که در آن موارد بدون سرطان به‌طور قابل‌توجهی بیشتر از موارد مبتلا به سرطان شایع است. برای اطمینان از ارزیابی بی‌طرفانه عملکرد مدل، مجموعه داده به یک مجموعه آموزشی متشکل از 8938 نمونه و یک مجموعه آزمایشی متشکل از 2975 نمونه تقسیم شد. این تقسیم‌بندی امکان آموزش مدل را در بخش بزرگی از داده‌ها فراهم می‌کند و درعین‌حال یک زیرمجموعه مستقل را برای ارزیابی نهایی حفظ می‌کند. سپس مدل CNN با استفاده از مجموعه داده‌های آموزشی طراحی و آموزش داده شد. معماری CNN چندین لایه کانولوشن و ادغام را در خود جای‌داده است که برای استخراج ویژگی‌های معنی‌دار از تصاویر مناسب هستند. این مدل همچنین، شامل لایه‌های کاملاً متصل برای طبقه‌بندی بر اساس ویژگی‌های استخراج‌شده است. پس از آموزش مدل، با استفاده از مجموعه داده آزمایشی برای ارزیابی عملکرد آن بر روی‌داده‌های دیده نشده مورد ارزیابی قرار گرفت. معیارهای مختلفی مانند دقت، یادآوری و امتیاز F1 برای ارزیابی اثربخشی مدل در طبقه‌بندی موارد سرطان محاسبه شد. این معیارها بینش‌هایی را در مورد توانایی مدل در شناسایی صحیح موارد سرطانی و غیر سرطانی ارائه می‌دهند. در بخش‌های بعدی، معماری دقیق مدل CNN ارائه می‌شود و نتایج به‌دست‌آمده از ارزیابی آن را موردبحث قرار می‌گیرد. این یافته‌ها اثربخشی مدل را در طبقه‌بندی دقیق موارد سرطان با استفاده از تصاویر ماموگرافی روشن می‌کند و بینش‌های ارزشمندی را برای تحقیقات آینده و کاربردهای بالینی ارائه می‌دهد. شکل 2 مدل‌سازی روش پیشنهادی را نشان می‌دهد

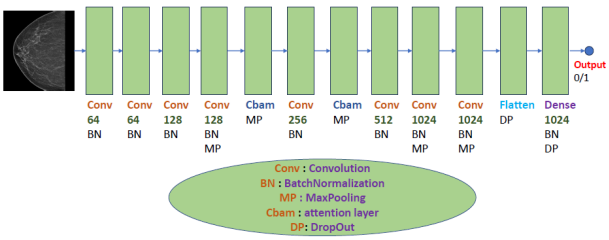

شکل 2- مدل‌سازی روش پیشنهادی.

4-2- زمان‌بندی میزان یادگیری

نرخ یادگیری یک فرا پارامتر است که اندازه مرحله‌ای را که پارامترهای مدل در طی فرآیند آموزش به‌روز می‌شوند را تعیین می‌کند و نقش مهمی در آموزش شبکه‌های عصبی دارد؛ زیرا بر سرعت همگرایی و کیفیت نمایش‌های آموخته‌شده تأثیر می‌گذارد. یک نرخ یادگیری مناسب به مدل اجازه می‌دهد تا به یک‌راه حل بهینه به‌طور مؤثر همگرا شود. درحالی‌که نرخ یادگیری نامناسب می‌تواند منجر به همگرایی کند یا حتی از همگرایی به‌طور کلی جلوگیری کند. زمان‌بندی نرخ یادگیری تکنیکی است که برای تنظیم نرخ یادگیری به‌صورت پویا در طول فرآیند آموزش استفاده می‌شود. ایده پشت زمان‌بندی نرخ یادگیری این است که با نرخ یادگیری نسبتاً بالا شروع شود تا در مراحل اولیه آموزش زمانی که پارامترهای مدل از مقادیر بهینه فاصله‌دارند، به‌روزرسانی‌های بزرگ انجام شود. با پیشرفت آموزش، نرخ یادگیری به‌تدریج کاهش می‌یابد تا مدل به‌دقت تنظیم شود و همگرایی بهبود یابد. در اجرای خود، از یک استراتژی زمان‌بندی نرخ یادگیری خاص استفاده شد.

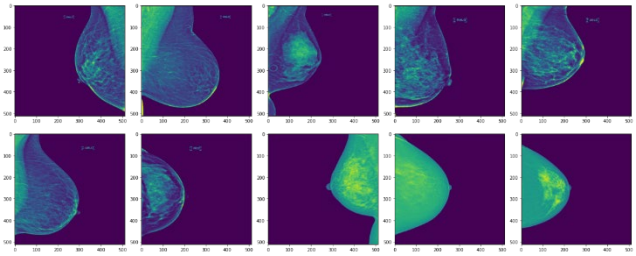

شکل 3: نمونه‌ای تصاویر با اندازه 512×512.

با استفاده از زمان‌بندی نرخ یادگیری، می‌توان تعادلی بین اکتشاف سریع فضای پارامتر در مراحل اولیه آموزش و تنظیم دقیق برای همگرایی بهتر در آینده ایجاد کرد. این رویکرد اجازه می‌دهد تا از منابع محاسباتی استفاده مؤثری شود و ازنظر سرعت آموزش و دقت مدل به عملکرد بهتری دست پیدا شود. در بخش‌های بعدی، جزئیات بیشتری در مورد فرآیند آموزش، ازجمله انتخاب بهینه‌ساز، عملکرد از دست دادن و هر تکنیک اضافی به‌کاررفته برای تنظیم و بهبود عملکرد ارائه خواهد شد. شکل 4 زمان‌بندی نرخ یادگیری را نشان می‌دهد

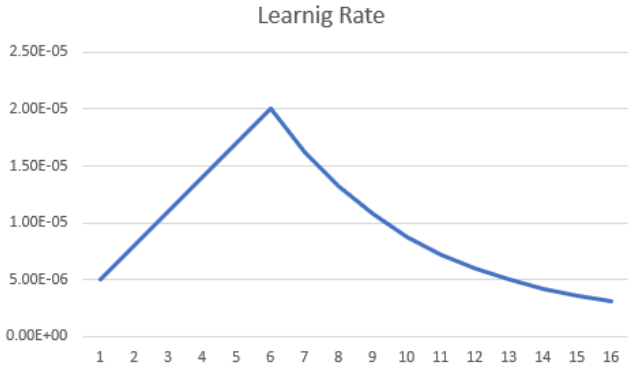

شکل 4: زمان‌بندی نرخ یادگیری (در ابتدا زیاد و به‌تدریج کاهش می‌یابد)

5- نتایج تجربی

در این بخش، ما آزمایش‌هایی را برای اعتبارسنجی اثربخشی و کارایی روش پیشنهادی در یک شبکه منتسب به عکس‌های واقعی انجام می‌دهیم.

5-1- مجموعه داده ارزیابی

بیمارستان سید الشهداء (ع) اولین بیمارستان تخصص در اصفهان می‌باشد که در زمینه سرطان و بیمارهای خاص در حال خدمت‌رسانی است. در مرحله اول، 500 تصویر ماموگرافی سینه از سیستم پکس خلیج‌فارس استخراج شد و تمامی تصاویر به خوش‌خیم و بدخیم دسته‌بندی شد و برای دستیابی به این هدف، فرآیند تبدیل

عکس‌ها به فرمت png، برچسب‌گذاری تصاویر با کد ملی و نرمال‌سازی حداقل و حداکثر برای بهبود کیفیت داده‌های تجاری انجام گرفت. فرآیند تبدیل داده‌ها شامل تبدیل مقادیر بازه‌ای به مقادیر عددی است. سپس، نمونه‌های تصاویر به برچسب‌های کلاس مناسب در فرآیند برچسب‌گذاری کلاس اختصاص داده می‌شوند. نرمال‌سازی چیزی جز فرآیند استانداردسازی داده‌ها برای تحلیل صحیح یا مدل‌سازی پیش‌بینی نیست. نرمال‌سازی بخشی از مقیاس‌بندی داده‌ها است و یا می‌توان گفت اولین و اساسی‌ترین مرحله مقیاس بندی داده‌ها برای رسیدن به فرم استاندارد مناسب است. سطح پیشرفته مقیاس‌بندی داده‌ها استانداردسازی داده‌هایی است که داده‌ها را به‌صورت میانگین برابر با صفر (میانگین=0) غیر سرطان و واریانس برابر یک (واریانس =1) سرطان تبدیل می‌کند. نرمال‌سازی فرآیندی است که داده‌ها را به شکل نرمال درمی‌آورد که به معنای ایجاد تعادل مناسب در داده‌ها با استفاده از یک رویکرد ریاضی متفاوت است. داده‌ها پس از نرمال‌سازی می‌توانند در یک نمودار کامل پخش شوند که می‌توان به‌راحتی با استفاده از نمودار پراکندگی آن‌ها را تجسم نمود. این بهترین رویکرد برای درک داده‌های نرمال‌شده است. نرمال‌سازی داده‌ها برای یادگیری ماشین، فرآیند مقیاس بندی داده‌ها از محدوده صفرتا یک است که داده‌ها را برای تجزیه‌وتحلیل متعادل می‌کند.

5-2- ابزارها و پارامترها

پارامترهای روش پیشنهادی را تجزیه‌وتحلیل می‌کنیم. درنهایت، تفاوت بین روش پیشنهادی و روش‌های دیگر را نشان داده‌ایم. هر مجموعه داده به‌صورت دستی به‌طور دقیق نشانه‌گذاری شده است. علاوه بر این، هدف‌داریم تا دانش کارشناسان حوزه را در طول این فرآیند نشانه‌گذاری دستی در نشانه‌گذاری‌ها ثبت کنیم. نسبت آموزش را به 80 درصد تنظیم کردیم. نتایج اولیه با مجموعه اعتبارسنجی 10 درصدی به‌طور قابل‌توجهی بستگی به مجموعه اعتبارسنجی انتخاب‌شده قبلی داشت.

جدول 5-1: پارامترهای پیاده‌سازی الگوریتم در پایتون

نام پارامتر	مقدار پارامتر
تعداد همسایگان	15
تعداد نورون‌های سه لایه	1024
نرخ یادگیری	000005
تکرار شبکه	1000
تابع بهینه‌ساز	Adam
سایز دسته داده	16

افزایش مجموعه اعتبارسنجی به 20 درصد، وابستگی بین عملکرد و مجموعه اعتبارسنجی انتخاب‌شده قبلی را حذف می‌کند.

در این مقاله برای پیاده‌سازی و ارزیابی مدل‌ها از سیستمی با مشخصات سخت‌افزاری و نرم‌افزاری زیر استفاده‌شده است. پارامترهای موردنیاز برای پیاده‌سازی مدل در جدول زیر گزارش‌شده است: (الف) سخت‌افزار: پردازنده: Core i-9 4.2 GHz، حافظه موقت: 18 گیگابایت. (ب) نرم‌افزار پیاده‌سازی: نرم‌افزار پایتون.

5-3- نتایج تجربی

در این بخش، ماتریس confiusion جدولی است که خلاصه‌ای جامع از عملکرد یک مدل طبقه‌بندی ارائه می‌دهد. معمولاً برای ارزیابی دقت و اثربخشی مدل با مقایسه برچسب‌های پیش‌بینی‌شده با برچسب‌های واقعی یک مجموعه داده استفاده می‌شود. ماتریس سردرگمی نتایج را در چهار دسته سازمان‌دهی می‌کند: مثبت‌های واقعی (TP)، منفی‌های واقعی (TN)، مثبت‌های کاذب (FP) و منفی‌های کاذب (FN). نتایج ارائه‌شده نشان‌دهنده معیارهای عملکرد برای دو کلاس (0 و 1) بر اساس ماتریس سردرگمی است:

الف) برای کلاس (0): Precision = 0/60 :Precision دقت پیش‌بینی‌های مثبت کلاس 0 را اندازه‌گیری می‌کند. در این مورد، 60٪ از نمونه‌های پیش‌بینی‌شده به‌عنوان کلاس 0 درواقع درست هستند.

Recall =0/77: یادآوری، همچنین به‌عنوان حساسیت یا نرخ مثبت واقعی شناخته می‌شود و نشان‌دهنده نسبت نمونه‌های کلاس 0 واقعی است که به‌درستی توسط مدل شناسایی‌شده‌اند. در اینجا، مدل به‌درستی ٪77 از نمونه‌های کلاس 0 واقعی را شناسایی می‌کند.

0/68 = امتیاز F1: امتیاز F1 میانگین هارمونیک دقت و یادآوری است که معیاری کلی از دقت مدل برای کلاس 0 ارائه می‌کند. در این مورد، امتیاز F1، 0/68 است.

ب) برای کلاس (1): Precision = 0/68: دقت برای کلاس 1 نشان می‌دهد که 68٪ از نمونه‌های پیش‌بینی‌شده به‌عنوان کلاس 1 صحیح هستند.

Recall =0/48: فراخوانی برای کلاس 1 نشان می‌دهد که مدل تنها 48 درصد از نمونه‌های کلاس 1 واقعی را به‌درستی شناسایی می‌کند.

0/56 = امتیاز F1: امتیاز F1 برای کلاس 1، 0/56 است که هم دقت و هم یادآوری را در نظر می‌گیرد.

این معیارها بینش‌هایی را در مورد عملکرد مدل برای هر کلاس ارائه می‌کنند و توانایی آن را در طبقه‌بندی صحیح نمونه‌ها و شناسایی الگوهای مرتبط برجسته می‌کنند.

جدول 5-2: کارایی روش پیشنهادی.

متریک	CNN	CNN (focal loss)	CNN (balance)	CNN (Self attention)
Accuracy	0/54	0/62	0/63	**0/63**
Pfbata (f1)	0/03	0/04	0/08	**0/09**

ارزیابی عملکرد مدل‌های یادگیری انتقالی مورداستفاده در این مقاله با استفاده

از سه معیار مختلف: Accuracy، Pfbata، انجام می‌شود. مدلی که دارای معیارهای بالاتری است، بهترین مدل است.

6- نتیجه‌گیری و کارهای آینده

این مقاله به‌عنوان یک ترکیب نوآورانه از self-attention و شبکه‌های عصبی پیچشی به‌منظور تشخیص سرطان سینه بررسی‌شده است. استفاده از این ترکیب به‌منظور بهبود دقت تشخیص و کاهش تعداد خطاها واکنش‌های غلط، بسیار جالب است. در این پژوهش، مدل پیشنهادی از دو عنصر کلیدی تشکیل‌شده است. اولین عنصر، شبکه‌های عصبی پیچشی هستند که برای استخراج ویژگی‌های مهم از تصاویر ماموگرافی سینه استفاده می‌شوند. این شبکه‌ها، باقابلیت خودکار و توانایی استخراج ویژگی‌های مکانی مفید، امکان می‌دهد الگوهای پیچیده و مختلفی را در تصاویر تشخیص دهد. دومین عنصر، self-attention است که به‌عنوان مکملی برای شبکه‌های عصبی پیچشی عمل می‌کند. self-attention یک مکانیزم توجه است که به شبکه امکان می‌دهد به نقاط مهم تصویر توجه کند و از آن‌ها برای تصمیم‌گیری استفاده کند. این مکانیزم می‌تواند روابط غیرمحلی بین ویژگی‌ها را کشف کند و اطلاعات مهم را در سراسر تصویر تجمیع کند. ترکیب self-attention و CNN در مدل پیشنهادی پژوهش، امکان بهبود قابلیت تمیزدهی به تصاویر سینه را فراهم می‌کند. با استفاده از CNN، ویژگی‌های مهم تصاویر استخراج‌شده و سپس با استفاده از self-attention، به نقاط کلیدی توجه می‌شود و ارتباطات غیرمحلی مهم شناسایی می‌شوند. نتایج آزمایشات این پژوهش نشان می‌دهد که ترکیب self-attention و CNN بهبود قابل‌توجهی در دقت تشخیص سرطان سینه داشته است. این مدل، قابلیت تشخیص بهتری از سرطان خوش‌خیم و بدخیم را دارد و می‌تواند در تشخیص این بیماری مهم و حساس به‌صورت دقیق‌تر و قابل‌اعتمادتر عمل کند. به‌طورکلی، ترکیب self-attention و CNN در این پژوهش، نشان‌دهنده قدرت واکنش‌گری مدل در تشخیص سرطان سینه است. این روش می‌تواند به‌عنوان یک راهکار مؤثر در زمینه تشخیص بیماری‌های خاص مانند سرطان در بیمارستان‌ها و مراکز بهداشتی مورداستفاده قرار گیرد. همچنین، این پژوهش می‌تواند به پژوهش‌های آتی در حوزه تشخیص سرطان و استفاده از شبکه‌های عصبی و مکانیزم‌های توجه به‌عنوان روش‌های بهبوددهنده عملکرد مدل‌ها کمک کند.

این مطالعه بر توسعه و ارزیابی یک مدل شبکه عصبی کانولوشن برای طبقه‌بندی سرطان با استفاده از تصاویر ماموگرافی متمرکز بود. مجموعه داده با تغییر اندازه تصاویر و پیوند دادن آن‌ها به اطلاعات مربوطه از یک فایل CSV تهیه شد. مدل Self Attention-based CNN بر روی یک مجموعه داده با عدم تعادل طبقه قابل‌توجهی آموزش و ارزیابی شد که سناریوی واقعی تشخیص سرطان را منعکس می‌کند. معماری مدل CNN لایه‌های کانولوشن و ادغام را برای استخراج ویژگی و به دنبال آن لایه‌های کاملاً متصل برای طبقه‌بندی گنجانده است. این مدل با استفاده از مجموعه داده آموزشی آموزش داده شد و با استفاده از مجموعه داده آزمون جداگانه ارزیابی شد. معیارهای مختلفی ازجمله دقت، دقت، یادآوری و امتیاز F1 برای ارزیابی عملکرد مدل محاسبه شد. برای افزایش عملکرد مدل، چندین تکنیک به کار گرفته شد. زمان‌بندی نرخ یادگیری برای تنظیم نرخ یادگیری به‌صورت پویا در طول آموزش مورداستفاده قرار گرفت و امکان کاوش کارآمد و تنظیم دقیق فضای پارامتر را فراهم کرد. تکنیک‌های تقویت داده‌ها، مانند چرخش تصادفی و تنظیم کنتراست، برای افزایش تنوع و استحکام مجموعه داده آموزشی استفاده شد. معیارهای ارزیابی مانند امتیاز pFBeta، دقت و توقف اولیه برای ارزیابی عملکرد مدل استفاده شد. امتیاز pFBeta با در نظر گرفتن ماهیت نامتعادل مجموعه داده، ارزیابی جامعی از دقت و یادآوری ارائه کرد. دقت، صحت کلی پیش‌بینی‌ها را اندازه‌گیری می‌کرد و توقف زودهنگام از برازش بیش‌ازحد جلوگیری می‌کرد. نتایج این مقاله اثربخشی مدل Self Attention-based CNN را در طبقه‌بندی دقیق موارد سرطان با استفاده از تصاویر ماموگرافی نشان داد. معماری دقیق، روش آموزشی و معیارهای ارزیابی ارائه‌شده در این پژوهش، بینش‌های ارزشمندی را برای تحقیقات آینده و کاربردهای بالینی در تشخیص سرطان ارائه می‌دهد.

پیشنهادات برای کارهای آینده می‌توان اقداماتی به شرح زیر انجام داد:

- می‌توان از فیلترهای بیشتری در شبکه‌های مصنوعی توجه و ترکیب آن با الگوریتم‌های دیگر استفاده کرد تا به تشخیص با دقت‌های بالاتر در سرطان رسید.
- می‌توان از ویژگی‌های دیگر شبکه عصبی استفاده نمود و به تشخیص دقیق‌تر در رابطه با تشخیص سرطان پستان رسید.

مراجع

1]. Kavya N, Sriraam N, Usha N, Hiremath B, Suresh A, Sharath D, et al. Breast Cancer Lesion Detection From Cranial-Caudal View of Mammogram Images Using Statistical and Texture Features Extraction. International Journal of

Biomedical and Clinical Engineering (IJBCE) 2020;9(1):16-32.

[2]. Ayer T, Chhatwal J, Alagoz O, Kahn Jr CE, Woods RW, Burnside ES. Comparison of logistic regression and artificial neural network models in breast cancer risk estimation. Radiographics 13-22(1)30,2010.

[3]. Stancampiano C, Boschiroli L, Campoleoni M, Vismara L. 267 Comparison of 2D synthesized mammography versus standard full-field digital mammography: Quantitative and qualitative image analysis. Physica Medica 2018;56:226-7.

[4]. Starikov A, Al'Aref SJ, Singh G, Min JK. Artificial intelligence in clinical imaging: An introduction. Clin Imaging 2018;49:vii-ix.

[5]. Tasdemir SBY, Tasdemir K, Aydin Z, editors. ROI Detection in Mammogram Images using Wavelet-Based Haralick and HOG Features. 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA); 2018: IEEE.

[6]. Barinov L, Jairaj A, Becker M, Seymour S, Lee E, Schram A, et al. Impact of data presentation on physician performance utilizing artificial intelligence-based computer-aided diagnosis and decision support systems. J Digit Imaging 2019;32(3):408-16.

[7]. Keavey E, Phelan N, Fitzpatrick P. Clinical performance of digital mammography systems in a breast screening programme–An update. Eur J Med Phys 2018;52:179-80.

[8]. Muhammad W, Hart GR, Nartowt B, Farrell JJ, Johung K, Liang Y, et al. Pancreatic cancer prediction through an artificial neural network. Front Artif Intell 2019;2:2.

[9]. Cruz-Roa A, Gilmore H, Basavanhally A, Feldman M, Ganesan S, Shih NN, et al. Accurate and reproducible invasive breast cancer detection in whole-slide images: A Deep Learning approach for quantifying tumor extent. Sci Rep 2017;7:46450.

[10]. Dong H, Yang G, Liu F, Mo Y, Guo Y, editors. Automatic Brain Tumor Detection and Segmentation Using U-Net Based Fully Convolutional Networks. Medical Image Understanding and Analysis; 2017; Cham: Springer International Publishing.

[11]. Santoro A, Raposo D, Barrett DG, Malinowski M, Pascanu R, Battaglia P, et al., editors. A simple neural network module for relational reasoning. Adv Neural Inf Process Syst 2017;4967-76.

[12]. Raba D, Oliver A, Martí J, Peracaula M, Espunya J, editors. Breast segmentation with pectoral muscle suppression on digital mammograms. Iberian conference on pattern recognition and image analysis; 2005: Springer. Robatics and Computer Vision Group, University of Girona.

[13]. Chen Y, Wang Y, Yang B, editors. Evolving hierarchical RBF neural networks for breast cancer detection. International Conference on Neural Information Processing; 2006:137-44. Springer.

[14]. Subramaniam E, Liung TK, Mashor MY, Isa NAM. Breast cancer diagnosis systems: A review.IJCIM 2006;14(2):24-35 .

[15]. Tomar RS, Singh T, Wadhwani S, Bhadoria SS, editors. Analysis of breast cancer using image processing techniques. 2009 Third UKSim European Symposium on Computer Modeling and Simulation; 2009:251-6. IEEE.

[16]. Mencattini A, Salmeri M, Lojacono R, Frigerio M, Caselli F. Mammographic images enhancement and denoising for breast cancer detection using dyadic wavelet processing. IEEE Trans Instrum Meas 2008;57(7):1422-30.

[17]. Mughal B, Muhammad N, Sharif M, Saba T, Rehman A. Extraction of breast border and removal of pectoral muscle in wavelet domain. 2017.

[18]. Liu F, Brown M, editors. Breast cancer recognition by support vector machine combined with daubechies wavelet transform and principal component analysis. International Conference on ISMAC in Computational Vision and Bio-Engineering; 2018:1921-30. Springer.

[19]. Roberts T, Newell M, Auffermann W, Vidakovic B. Wavelet-based scaling indices for breast cancer diagnostics. Stat Med 2017;36(12):1989-2000.

[20]. Gupta S, Porwal R. Combining Laplacian and Sobel Gradient for Greater Sharpening. J Image Video Process 2016;6(04):1239-43.

[21]. Kanagalakshmi K, Archana CS. An Empirical Analysis of Filtering Techniques on Fingerprint Images. J Comput Math Sci. 1931-40(12)9, 2018.

[22]. Basha SS, Prasad KS. Automatic detection of hard exudates in diabetic retinopathy using morphological segmentation and fuzzy logic. International Journal of Computer Science and Network Security 2008;8(12):211-8.

[23]. Garge D, Bapat V. A low cost wavelet based mammogram image processing for early detection of breast cancer. Indian J Sci Technol 2009;2(9):63-5.

[24]. Kardiana A, Yuliwulandari Y. Breast Cancer Diagnosis using Artificial Neural Networks with Extreme Learning Techniques. Chandra Prasetyo Utomo. Int J Advanced Research in Artificial Intelligence 2014;3.(7)

[25]. Bhardwaj A, Tiwari A. Breast cancer diagnosis using genetically optimized neural network model. Expert Syst Appl. 2015, (10)42: 4611-20.

[26]. Cheng H-D, Lui YM, Freimanis RI. A novel approach to microcalcification detection using fuzzy logic technique. IEEE Trans Med Imaging 1998;17(3):442-50.

[27]. Verma B, Zakos J. A computer-aided diagnosis system for digital mammograms based on fuzzy-neural and feature extraction techniques. IEEE Trans Inform Technol Biomed 2001;5(1):46-54.

[28]. Li H-D, Kallergi M, Clarke LP, Jain VK, Clark RA. Markov random field for tumor detection in digital mammography. IEEE Trans Med Imaging 1995;14(3):565-76.

[29]. Wang D, Shi L, Heng PA. Automatic detection of breast cancers in mammograms using structured support vector machines. Neurocomputing 2009;72(13-15):3296-302.

[30]. Rejani Y, Selvi ST. Early detection of breast cancer using SVM classifier technique. arXiv preprint arXiv:09122314 2009

[31]. Nahid A-A, Kong Y. Histopathological breast-image classification using local and frequency domains by convolutional neural network. Information 2018;9(1):19

[32]. Yektaei H, Manthouri M, Farivar F. Diagnosis of Breast Cancer Using Multiscale Convolutional Neural Network. Biomed Eng Applications, Basis and Communications 2019;31(05

[33]. Ekici S, Jawzal H. Breast cancer diagnosis using thermography and convolutional neural networks. Med Hypotheses 2020;137:109542