

توسعه و ارزیابی روشی جدید مبتنی بر شبکه‌های عصبی انتشار به عقب برای افزایش دقت تشخیص سرطان ریه

محسن محرابی^{*}، امیرمحمد بیگزاده و هادی اردینی

پژوهشکده کاربرد پرتوها، پژوهشگاه علوم و فنون هسته‌ای، سازمان انرژی اتمی، تهران، ایران.
^{*} تهران، تهران، پژوهشکده کاربرد پرتوها، پژوهشگاه علوم و فنون هسته‌ای، کدپستی: ۸۴۸۶-۱۱۳۶۵.
پست الکترونیکی: msmehrabi@aeoi.org.ir

چکیده

در این مقاله، با استفاده از شبکه‌های عصبی مصنوعی، روشی برای طبقه‌بندی تصاویر مقطع نگاری رایانه‌ای ریه با هدف تشخیص زودهنگام سرطان ارائه شده است. برای این منظور، با استفاده از تصاویر مقطع نگاری رایانه‌ای، کل ریه قطع‌بندی شده و پارامترهای آماری همچون میانگین، انحراف معیار، چولگی، کشیدگی، گشتاور مرکزی مرتبه پنجم و گشتاور مرکزی مرتبه ششم از روی تصاویر قطع‌بندی شده محاسبه می‌شوند. در فرایند طبقه‌بندی از شبکه‌های عصبی پیشخور انتشار به عقب استفاده شده است. نتایج نشان می‌دهد در میان توابع آموزشی موجود برای آموزش شبکه‌های عصبی انتشار به عقب، بهترین دقت طبقه‌بندی با استفاده از تابع آموزشی Traingdx و با دقت ۹۱/۱٪ حاصل شده است. همچنین، دو تابع آموزشی جدید نیز در این مقاله معرفی شده‌اند که یکی از آن‌ها با دقت ۹۳/۳٪، تشخیص ۱۰۰٪، حساسیت ۹۱/۴٪ و حداقل میانگین مربعات خطای ۰/۹۹۸ و دیگری با دقت ۹۳/۳٪ و حداقل میانگین مربعات خطای ۰/۰۹۴۲ به نتایج قابل قبولی دست یافته‌اند. به‌طور کلی، تشخیص زودهنگام سرطان با استفاده از شبکه‌های عصبی مصنوعی امیدوارکننده‌ترین راه برای افزایش شانس زنده ماندن بیماران است.

کلیدواژگان: مقطع نگاری رایانه‌ای، طبقه‌بندی تصاویر، انحراف معیار، کشیدگی، شبکه‌های عصبی پیشخور.

۱. مقدمه

یکی از علل اصلی مرگ و میر ناشی از سرطان در زنان و مردان، سرطان ریه^۱ است. به‌طور تخمینی، تعداد افراد درگیر با این بیماری هر ساله در حدود ۱/۲ میلیون نفر تشخیص داده می‌شود (۱۲/۳٪ از کل افراد مبتلا به سرطان، به سرطان ریه مبتلا هستند) و هر ساله حدود ۱/۱ میلیون نفر از این افراد فوت می‌کنند (۱۷/۸٪ از کل مرگ و میر ناشی از سرطان متعلق به مبتلایان به سرطان ریه است) [۱]. اگر سرطان ریه است) [۱]. اگر سرطان در مراحل اولیه تشخیص داده شود، شانس زنده ماندن بیشتر است؛ اما تشخیص زودهنگام سرطان ریه کار ساده‌ای نیست. به‌طور کلی در حدود ۸۰٪ از مبتلایان به سرطان ریه، بیماری‌شان در مراحل میانی یا پیشرفته تشخیص داده می‌شود [۲]. سیستم تشخیص رایانه‌ای (CAD)^۲ برای تشخیص زودهنگام و سریع‌تر این بیماری بسیار مفید

² Computer-aided diagnosis system

¹ Lung cancer

است [۳]. رادیولوژیست‌ها پیش از آن‌که برای تشخیص این بیماری تست بیوپسی را تجویز نمایند، از سیستم تشخیص رایانه‌ای استفاده می‌کنند و در صورت عدم حصول نتیجه، به عنوان روش تشخیصی دوم به تست بیوپسی می‌اندیشند [۴].

در سال‌های اخیر استفاده از شبکه‌های عصبی به دلیل قابلیت یادگیری عمیق و پردازش داده‌های پیچیده، در تشخیص سرطان استفاده گسترده‌ای شده است. با استفاده از این شبکه‌ها، می‌توان اطلاعات بیشتر و دقیق‌تری از داده‌های بالینی به دست آورد و در تشخیص سرطان بهبود بخشید. شبکه‌های عصبی جهت تشخیص سرطان معمولاً با استفاده از داده‌های بالینی بهینه شده و به صورت خودکار، الگوهایی را که به تشخیص سرطان کمک می‌کنند، شناسایی می‌کنند. برای استفاده از شبکه‌های عصبی در تشخیص سرطان، ابتدا باید داده‌های بالینی را جمع آوری و آن‌ها را پردازش نمود. سپس با استفاده از الگوریتم‌های یادگیری، شبکه‌های عصبی با دقت بالا به تشخیص سرطان می‌پردازند.

در پژوهش‌های اخیر مشاهده شده است که مفاهیم اصولی شبکه‌های عصبی به‌طور گسترده‌ای برای تشخیص سرطان ریه از روی تصاویر پزشکی، مورد استفاده قرار گرفته‌اند [۵]. در این پژوهش‌ها برای طبقه‌بندی سرطان ریه براساس شبکه عصبی، چند روش گزارش شده است.

عبداله^۱ و همکارانش [۶] یک سیستم تشخیص رایانه‌ای را پیشنهاد داده‌اند که با استفاده از شبکه‌های عصبی مصنوعی به طبقه‌بندی سرطان ریه می‌پردازد. ویژگی‌های مورد استفاده آن‌ها برای انجام این طبقه‌بندی عبارتست از: منطقه^۲، محیط^۳ و شکل^۴. حداکثر دقت طبقه‌بندی در این روش برابر با ۹۰٪ است.

کامارلینگی^۵ و همکارانش [۷] برای شناسایی خودکار سرطان ریه، یک الگوریتم تشخیص رایانه‌ای را پیشنهاد دادند که حساسیت به‌دست آمده از این روش ۸۰٪ است که در هر اسکن، تنها سه تشخیص مثبت کاذب^۶ خواهد داشت. الکادی^۷ و همکارانش [۸] بر مبنای ویژگی‌های بافتی فراکتال، روشی را برای طبقه‌بندی این بیماری پیشنهاد دادند. در این روش، دقت دسته‌بندی برابر با ۸۳٪ است. ون‌گینکن^۸ و همکارانش [۹] برای تشخیص توده‌های ریوی به مقایسه و ترکیب شش الگوریتم تشخیص رایانه‌ای پرداختند. ترکیب این شش الگوریتم قادر است که ۸۰٪ از کل توده‌های ریوی را به درستی تشخیص دهد و در هر اسکن، تنها دو تشخیص مثبت کاذب خواهد داشت؛ به‌طوری که از میان ۶۵٪ از کل توده‌های تشخیص داده شده، تنها ۰/۵ تشخیص مثبت کاذب وجود دارد. کاسیو^۹ و همکارانش [۱۰] یک سیستم تشخیص رایانه‌ای را پیشنهاد دادند که در تصاویر مقطع نگاری رایانه‌ای (CT)^{۱۰} توده‌های ریوی را تشخیص می‌دهد. نرخ تشخیص سیستم عبارتست از ۸۸/۵٪ با ۶/۶ تشخیص مثبت کاذب در هر اسکن. در این روش پیشنهادی با کاهش به اندازه ۲/۴۷ تشخیص مثبت کاذب در هر اسکن به بهره‌وری ۸۰٪ دست یافته‌اند.

با توجه به اهمیت تشخیص زودهنگام سرطان ریه و تأثیر آن بر افزایش شانس بقای بیماران، این تحقیق با هدف بهبود دقت، حساسیت و تشخیص از طریق استفاده از شبکه‌های عصبی مصنوعی انجام می‌شود. روش‌های سنتی و سیستم‌های تشخیص رایانه‌ای موجود، با وجود پیشرفت‌های قابل توجه، همچنان با چالش‌هایی مانند دقت و حساسیت پایین در مراحل اولیه مواجه هستند. این مشکلات می‌توانند منجر به آزمایش‌های غیرضروری

⁶ False Positive

⁷ Al-Kadi

⁸ van Ginneken

⁹ Cascio

¹⁰ Computed Tomography

¹ Abdulla

² Area

³ Perimeter

⁴ Shape

⁵ Camarlinghi

۲. روش کار

۱.۲. قطعه‌بندی تصویر

تصاویر CT مورد نیاز برای این مقاله از پایگاه‌داده‌ی LIDC^۱ (کنسرسیون پایگاه‌داده تصاویر ریه) گردآوری شده است که مربوط به ۱۵۵ بیمار زن و مرد است. میانگین سنی بیماران مورد مطالعه ۶۴/۲ سال است که جوان‌ترین بیمار ۱۸ ساله و مسن‌ترین بیمار ۸۵ ساله است. تصاویر CT اسکن با دز پایین در توزیع پیک کیلو ولتاژ حدود ۱۲۰ KVP تا ۱۴۰ KVP و با جریان بین ۲۵ mAs تا ۴۰ mAs، براساس سن بیمار تعیین می‌شود. همچنین قطر بازسازی از ۲۶۰ mm تا ۴۰۰ mm متغیر است و ضخامت مقاطع بین ۰/۷۵ mm تا ۱/۲۵ mm خواهد بود. تعداد کل توده‌هایی که در این مطالعه مورد بررسی قرار گرفتند برابر است با ۱۱۰ و اندازه‌ی آن‌ها از ۳ mm بزرگ‌تر است؛ این توده‌ها توسط دو رادیولوژیست تشخیص داده شده‌اند. پاسخ نهایی، تصمیم مشترک این دو رادیولوژیست است. این دو رادیولوژیست، تصاویر سی‌تی‌اسکن موجود در پایگاه‌داده‌ی LIDC را بدون در نظر گرفتن حاشیه‌نویسی‌های موجود در این پایگاه‌داده، مورد استفاده قرار دادند. در این پژوهش برای هر توده‌ی سرطانی در طبقه‌بندی اولیه و ثانویه (هر توده سرطانی براساس اندازه‌ای که دارد توسط هر دو رادیولوژیست طبقه‌بندی می‌شود؛ یعنی دوبار طبقه‌بندی می‌شود)، چهار نوع مختلف در نظر گرفته می‌شود که عبارتند از: توده‌های خوش‌خیم^۲، توده‌های عروقی^۳، توده‌های Juxta-pleural و توده‌های Pleural-tail [۱۱].

در شکل ۱، تصویر سی‌تی‌اسکن ریه با نواحی سرطانی نشان داده شده است.

و نگرانی‌های بیمار شوند و همچنین باعث شوند که بسیاری از بیماران در مراحل پیشرفته‌تر بیماری تشخیص داده شوند.

پژوهش‌های صورت گرفته در این زمینه، به‌طور عمده بر بهبود دقت تشخیص متمرکز بوده‌اند، اما بسیاری از آن‌ها در تحلیل ویژگی‌های پیچیده تصاویر پزشکی محدودیت دارند. این محدودیت‌ها به دلیل استفاده ناکافی از تکنیک‌های یادگیری عمیق و تحلیل داده‌های پیچیده است. در این تحقیق، با توسعه و ارزیابی الگوریتم‌های جدید مبتنی بر شبکه‌های عصبی، تلاش می‌شود تا قابلیت تحلیل و دقت تشخیص و نیز حساسیت سیستم‌های موجود بهبود یابد. این رویکرد نوین می‌تواند محدودیت‌های موجود را برطرف کرده و دقت کلی تشخیص را افزایش دهد.

مدل‌های آموزشی پیشنهادی در این پژوهش از شبکه‌های عصبی پیشرفته برای افزایش دقت و حساسیت در تشخیص سرطان ریه استفاده می‌کنند. این مدل‌ها با استفاده از الگوریتم‌های یادگیری عمیق، قادر به تحلیل پیچیده داده‌های تصویربرداری مانند CT هستند و ویژگی‌های پنهان و مهمی را استخراج می‌کنند که در روش‌های سنتی نادیده گرفته می‌شوند.

از جمله ویژگی‌های کلیدی این مدل‌ها می‌توان به استفاده از الگوریتم‌های بهینه‌سازی مانند کاهش گرادیان با نرخ یادگیری تطبیقی و گشتاور اشاره کرد که موجب بهبود همگرایی و افزایش دقت تا بیش از ۹۰٪ می‌شوند. همچنین، این مدل‌ها، حساسیت تشخیص را بهبود می‌بخشند و می‌توانند با دقت بالاتری توده‌های سرطانی را از ساختارهای نرمال ریوی تمایز دهند. این پیشرفت‌ها می‌تواند به‌طور قابل توجهی شانس زنده‌ماندن بیماران را افزایش دهد و نیاز به آزمایش‌های تشخیصی اضافی را کاهش دهد.

³ Vascularized nodules

¹ Lung Image Database Consortium


² Wellcircumscribed nodules

برای تبدیل تصویر سطح خاکستری به تصویر باینری، از عملگر مورفولوژیک باز استفاده می‌شود که از طریق یک عنصر ساختاری^۲ بر روی تصویر اعمال می‌شود. منظور از ساختار، شکلی است که به منظور تنظیم نمودن و یا حذف نمودن آن از تصویر داده شده، می‌بایست ارتباطش با تصویر داده شده بررسی شود. عنصر ساختاری مورد استفاده "دوره‌ای"^۳ است (ثابت نیست) که یک عنصر ساختاری مسطح شامل $(P + 1) \times 2$ عضو است. مقدار P اندازه‌ی عنصر ساختاری را تعیین می‌کند. شکل ۳، تصویر خروجی را بعد از اعمال عملگر مورفولوژیک نشان می‌دهد.



شکل (۳): خروجی تصویر باینری شده پس از اعمال عملگر مورفولوژیک باز.

پس از اعمال عملگر مورفولوژیک، تصویر حاصله معکوس می‌شود و عملیات پاک‌سازی مرز انجام می‌شود. عملیات پاک‌سازی مرز، ساختارهایی را که از محیط اطرافشان روشن‌تر هستند و به مرز تصویر متصل می‌باشند را حذف می‌کند. روش قطعه‌بندی تصویر، تنها از عملگرهای مورفولوژیک استفاده می‌کند و به طور متوسط ۹۸٪ از تصاویر را به درستی قطعه‌بندی می‌کند. تصاویر قطعه‌بندی شده، به صورت جداگانه توسط دو رادیولوژیست مورد استفاده قرار می‌گیرند. مزیت اصلی عملگرهای مورفولوژیک سرعت و سادگی آنها است. شکل ۴، خروجی نهایی روش قطعه‌بندی را نشان می‌دهد.



شکل (۱): تصویر CT ریه مبتلا به سرطان.

تصاویر CT با استفاده از عملیات مورفولوژیک^۱ قطعه‌بندی می‌شوند و بدین ترتیب ریه قابل تشخیص است. در گام نخست، تصویر سطح خاکستری به تصویر باینری تبدیل می‌شود. تمام پیکسل‌های موجود در تصویر ورودی که مقادیر شدت روشنایی آنها بزرگ‌تر از حد آستانه است با مقدار "۱" و تمام پیکسل‌هایی که مقادیر شدت روشنایی آنها کوچک‌تر از حد آستانه است با مقدار "۰" جایگزین می‌شوند. سطح حد آستانه با استفاده از روش Otsu محاسبه می‌شود [۱۲]. روش Otsu به منظور به حداقل رساندن واریانس درونی پیکسل‌های سیاه و سفید، از سطح حد آستانه استفاده می‌کند. در شکل ۲ تصویر سطح خاکستری تبدیل یافته به تصویر باینری، نشان داده شده است.



شکل (۲): تصویر CT باینری شده.

¹ Morphological operations

² Structuring Element

³ Periodicline

۳.۲.۲. چولگی

چولگی که با S نشان داده می‌شود، درجه‌ی عدم تقارن بیکسلی را نشان می‌دهد که در یک پنجره‌ی مشخص در اطراف میانگین μ توزیع شده است. چولگی یک عدد خالص است که صرفاً شکل توزیع را مشخص می‌کند.

$$S = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N \left[\frac{p(i,j) - \mu}{\sigma} \right]^3 \quad (3)$$

۴.۲.۲. کشیدگی

کشیدگی که با K نشان داده می‌شود، معیاری است که میزان برجستگی^۲ یا مسطح بودن توزیع مورد نظر را در مقایسه با توزیع نرمال نشان می‌دهد.

$$K = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N \left[\frac{p(i,j) - \mu}{\sigma} \right]^4 \quad (4)$$

۵.۲.۲. گشتاور مرکزی مرتبه پنجم و ششم

گشتاور مرکزی مرتبه پنجم و ششم به ترتیب عبارتند از:

$$\text{گشتاور مرکزی مرتبه پنجم} = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N \left[\frac{p(i,j) - \mu}{\sigma} \right]^5 \quad (5)$$

$$\text{گشتاور مرکزی مرتبه ششم} = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N \left[\frac{p(i,j) - \mu}{\sigma} \right]^6 \quad (6)$$

۳.۲ شبکه عصبی مصنوعی

شبکه‌های عصبی را می‌توان به منظور آموزش طبقه‌بندی الگو آموزش داد [۱۴]. ساده‌ترین شبکه عصبی مورد استفاده برای طبقه‌بندی الگو، شبکه عصبی ای است که یک لایه ورودی و یک لایه خروجی دارد. برای انجام طبقه‌بندی از هر دوی شبکه‌های عصبی پیشخور^۳ (رو به جلو) و شبکه‌های عصبی پیش‌خورد انتشار به عقب^۴ استفاده می‌شود. همچنین برای هر شبکه مورد استفاده، پارامترهای حساسیت، تشخیص و دقت جهت بررسی



شکل (۴): خروجی نهایی روش قطعه‌بندی.

۲.۲ پارامترهای آماری

پارامترهای آماری از منطقه‌ی مورد نظر در تصاویر CT استخراج می‌شوند که یک بخش قطعه‌بندی شده است که شامل دو ریه است. پارامترهای مورد نظر عبارتند از: میانگین، انحراف معیار، چولگی و کشیدگی [۱۳]. در این مقاله، گشتاورهای^۱ مرتبه بالاتر مانند گشتاور مرکزی مرتبه پنجم و گشتاور مرکزی مرتبه ششم نیز مورد توجه قرار گرفته‌اند.

۱.۲.۲ میانگین

میانگین مقادیر بیکسل‌های تعریف شده در پنجره که با μ نشان داده می‌شود، مقدار تصویر را در خوشه‌ی مرکزی تخمین می‌زند.

$$\mu = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N p(i,j) \quad (1)$$

که $p(i,j)$ مقدار شدت روشنایی بیکسل را در نقطه‌ی (i,j) نشان می‌دهد. اندازه‌ی تصویر نیز با $M \times N$ محاسبه می‌شود.

۲.۲.۲ انحراف معیار

انحراف معیار که با σ نشان داده می‌شود، میانگین مربعات انحراف مقدار شدت روشنایی $p(i,j)$ را از مقدار میانگین μ محاسبه می‌کند.

$$\sigma = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (p(i,j) - \mu)^2} \quad (2)$$

³ Feed Forward Neural Network

⁴ Feed Forward Back Propagation Neural Network

¹ Moments

² Peakness

کارآمدی آن حائز اهمیت می‌باشند که مورد محاسبه قرار می‌گیرند.

۱.۳.۲ حساسیت

این پارامتر، درصد مثبت‌های واقعی^۱ که به درستی تشخیص داده شده‌اند را محاسبه می‌کند. این درصد از برش‌های قطعه‌بندی شده شامل توده‌های سرطانی هستند که به درستی به عنوان ناحیه سرطانی طبقه‌بندی شده‌اند.

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (7)$$

که در آن:

- مثبت صحیح^۲ (TP): برش‌های قطعه‌بندی شده که شامل توده‌های سرطانی هستند و به عنوان ناحیه سرطانی طبقه‌بندی شده‌اند.

- منفی کاذب^۳ (FN): برش‌های قطعه‌بندی شده که شامل توده‌های سرطانی هستند اما به عنوان نواحی غیر سرطانی طبقه‌بندی شده‌اند.

۲.۳.۲ تشخیص

این پارامتر، درصد منفی‌هایی که به درستی تشخیص داده شده‌اند را محاسبه می‌کند. به عبارت دیگر درصد برش‌های قطعه‌بندی شده که شامل توده‌های سرطانی نیستند و به عنوان ناحیه غیر سرطانی نیز طبقه‌بندی شده‌اند را محاسبه می‌کند.

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (8)$$

که در آن:

- مثبت کاذب^۴ (FP): برش‌های قطعه‌بندی شده که شامل توده‌های سرطانی نیستند اما به عنوان ناحیه سرطانی طبقه‌بندی شده‌اند.

- منفی صحیح^۵ (TN): برش‌های قطعه‌بندی شده که شامل توده‌های سرطانی نیستند و به عنوان نواحی غیر سرطانی طبقه‌بندی شده‌اند.

۳.۳.۲ دقت

دقت یک معیار آماری است که تعیین می‌کند چگونه یک دسته‌بندی، یک وضعیت را به درستی شناسایی کرده یا نادیده می‌گیرد. دقت نشان‌دهنده‌ی نسبت نتایج واقعی (مثبت صحیح و منفی صحیح) در کل نتایج است.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

۴.۲ معماری شبکه عصبی

در این پژوهش، هدف طراحی یک شبکه عصبی پیچیده برای تشخیص زودهنگام سرطان ریه است. این معماری شامل چندین لایه ورودی، پنهان و خروجی است که هر کدام برای بهبود دقت و کاهش خطاها تنظیم شده‌اند.

تعداد نورون‌های ورودی بر اساس ویژگی‌های استخراج شده از داده‌های CT تعیین می‌شود. اگر از ویژگی‌های آماری مانند میانگین، انحراف معیار، چولگی، کشیدگی، و گشتاورهای مرتبه پنجم و ششم استفاده کنیم، تعداد نورون‌های ورودی برابر با تعداد این ویژگی‌ها است. بنابراین، در پژوهش حاضر، تعداد نورون‌های ورودی، ۶ نورون در نظر گرفته شده است.

تعداد نورون‌های خروجی به نوع مسئله‌ی طبقه‌بندی یا پیش‌بینی بستگی دارد. در مسئله‌ی تشخیص سرطان ریه، هدف طبقه‌بندی تصاویر به دو دسته‌ی "سرطانی" و "غیرسرطانی" است. بنابراین، تعداد نورون‌های خروجی برابر با ۲ خواهد بود. در صورتی که بخواهیم دسته‌بندی دقیق‌تری مانند طبقه‌بندی انواع

⁴ False Positive

⁵ True Negative

¹ Actual positives

² True Positive

³ False Negative

و در مسائل طبقه‌بندی چندکلاسه از تابع Softmax استفاده می‌شود:

$$f(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (13)$$

۵.۲. انواع توابع آموزشی مورد استفاده برای طبقه‌بندی

شبکه عصبی انتشار به عقب، با سیزده الگوریتم تابع آموزشی، آموزش داده شده است [۱۵]. در این جا توابع آموزشی مورد استفاده، عبارتند از:

- کاهش گرادیان انتشار به عقب (traingd)
- کاهش گرادیان با نرخ یادگیری متغیر (traingda)
- کاهش گرادیان با گشتاور (traingdm)
- کاهش گرادیان با نرخ یادگیری متغیر و گشتاور (traingdx)
- انتشار به عقب بازگشتی (trainrp)
- الگوریتم‌های گرادیان مزدوج^۲ (traincgf, traincgp, traincgb, traincsg)
- گوسی نیوتن BFGS (trainbfg)
- الگوریتم متقاطع یک مرحله‌ای (trainoss)
- الگوریتم لونبرگ-مارکارد (trainlm)
- تنظیم خودکار (trainbr)

۶.۲. توابع آموزشی پیشنهادی

۱.۶.۲. تابع آموزشی اول

مقدار گشتاور و نرخ یادگیری بر روی دقت طبقه‌بندی و میانگین مربعات خطای شبکه عصبی تأثیرگذار هستند. در این جا یک تابع آموزشی جدید که شامل عامل گشتاور و نرخ یادگیری است، ارائه شده است. در تابع آموزشی اول، هر متغیر براساس کاهش گرادیان طبق گشتاور، به صورت زیر تنظیم می‌شود:

تومورها (خوش‌خیم، بدخیم) را انجام دهیم، تعداد نورون‌های خروجی به تعداد این دسته‌ها بستگی خواهد داشت.

انتخاب تعداد لایه‌های مخفی و تعداد نورون‌ها در هر لایه بستگی به پیچیدگی مسئله و حجم داده‌ها دارد. برای شبکه‌های عصبی ساده، معمولاً یک یا دو لایه مخفی کافی است. اما در مسائل پیچیده‌تر مانند تشخیص سرطان، معمولاً از شبکه‌های عمیق‌تر با چندین لایه مخفی استفاده می‌شود. برای تعیین تعداد لایه‌های پنهان، از روش‌های تجربی و تحلیل پیچیدگی داده‌ها استفاده می‌شود. با توجه به پیچیدگی داده‌ها و نیاز به استخراج ویژگی‌های عمیق‌تر، از سه لایه پنهان استفاده شده است. این انتخاب بر اساس فرمول‌های تجربی و نیاز به افزایش دقت مدل صورت گرفته است. تعداد نورون‌ها در هر لایه را می‌توان به صورت زیر تعیین نمود:

$$O + \frac{1}{3}I = H \quad (10)$$

که در آن، H تعداد نورون‌های لایه مخفی، I تعداد نورون‌های ورودی و O تعداد نورون‌های خروجی است.

بنابراین، در هر لایه مخفی ۶ نورون خواهیم داشت. همچنین برای هر لایه مخفی، از توابع فعال‌سازی مانند ReLU، Sigmoid یا Tanh استفاده می‌شود. برای لایه‌های مخفی، ReLU به دلیل عملکرد بهتر در شبکه‌های عمیق معمولاً ترجیح داده می‌شود. فرمول تابع ReLU به صورت زیر است:

$$f(x) = \max(0, x) \quad (11)$$

که در آن x ورودی هر نورون است. این تابع به دلیل جلوگیری از مشکل ناپدید شدن گرادیان^۱ در شبکه‌های عمیق استفاده می‌شود. برای لایه‌های خروجی، در مسائل طبقه‌بندی دودویی از تابع Sigmoid استفاده می‌شود:


$$f(x) = \frac{1}{1+e^{-x}} \quad (12)$$

² Conjugate

¹ Vanishing gradient

نتایج به دست آمده پس از اعمال الگوریتم‌های معرفی شده، نشان می‌دهد که پارامتر چولگی حداکثر دقت طبقه‌بندی را ایجاد می‌کند. همچنین در ارتباط با پارامتر گشتاور، حتی با در نظر گرفتن گشتاورهای مرتبه‌های بالاتر نیز هیچ پیشرفت قابل توجهی در دقت طبقه‌بندی ایجاد نمی‌شود. در مقایسه با شبکه‌های عصبی پیشخور، دقت دسته‌بندی در شبکه‌های عصبی پیشخور انتشار به عقب بیشتر است. در شکل ۵، دقت دسته‌بندی شبکه‌های پیشخور و انتشار به عقب، نشان داده شده است.

برای شبکه انتشار به عقب، تمام سیزده تابع آموزشی با گشتاورهای مختلف و نرخ‌های یادگیری متفاوت، آموزش داده شده‌اند. گشتاورها و نرخ‌های یادگیری از ۰/۱ تا ۰/۹ متفاوت هستند. با ثابت نگه داشتن یکی از این پارامترها و تغییر دادن سایر آن‌ها، مجدداً عملکرد شبکه مورد مطالعه قرار گرفته است. بهترین دقت طبقه‌بندی و کمترین میانگین مربعات خطا برای توابع آموزشی مختلف با گشتاورهای مختلف و نرخ‌های یادگیری متفاوت در جدول ۱ نشان داده شده است.



شکل (۵): دقت طبقه‌بندی شبکه‌های پیش‌خور و شبکه انتشار برگشتی.

در جدول ۱ نشان داده می‌شود که تابع آموزشی Traingdx به بالاترین دقت طبقه‌بندی یعنی ۹۱/۱۱٪ دست یافته است. برای مقایسه این تابع آموزشی با تابع آموزشی پیشنهادی اول، پارامترهای تشخیص، حساسیت و دقت مورد ارزیابی قرار گرفتند. این نتایج برای تابع آموزشی Traingdx و تابع آموزشی پیشنهادی اول، با گشتاور ۰/۳ و نرخ یادگیری ۰/۷ در شکل ۶ نشان داده شده است.

$$dX = mc \times dXprev \quad (14)$$

که "dXprev" نشان دهنده تغییرات قبلی انجام شده بر روی وزن یا بایاس است. "mc" ثابت گشتاور است. "lr" نرخ یادگیری و "dperf" مشتق عملکرد با توجه به وزن و مقادیر بایاس X است. با استفاده از تابع آموزشی اول، دقت طبقه‌بندی افزایش می‌یابد.

۲.۶.۲. تابع آموزشی دوم


در اینجا به منظور کاهش میانگین مربعات خطا، به اصلاح تابع آموزشی اول پرداخته می‌شود. در تابع آموزشی دوم، هر متغیر براساس کاهش گرادیان طبق گشتاور، به صورت زیر تنظیم می‌شود:

$$dX = 3/7 \times mc \times dXprev \quad (15)$$

که "dXprev" نشان دهنده تغییرات قبلی انجام شده بر روی وزن یا بایاس است. "mc" ثابت گشتاور است. "lr" نرخ یادگیری و "dperf" مشتق عملکرد با توجه به وزن و مقادیر بایاس X است. با استفاده از تابع آموزشی دوم، میانگین مربعات خطا، حداقل می‌شود.

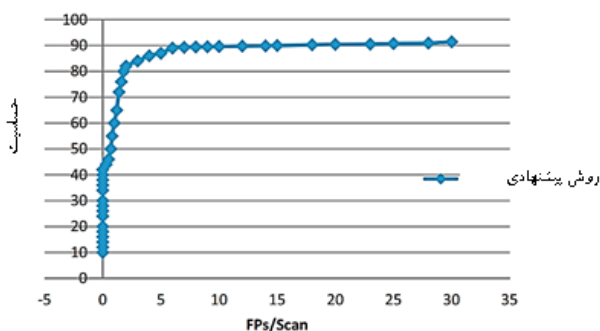
۳. نتایج

برای بررسی از تصویر قطعه‌بندی شده که شامل دو ریه است، پارامترهای آماری محاسبه شده و به‌عنوان ورودی به شبکه عصبی داده می‌شود. مجموعه‌ی آموزشی در نظر گرفته شده برای شبکه عصبی، شامل ۷۰٪ از کل تصاویر و مجموعه‌ی آزمایشی شامل ۳۰٪ از کل تصاویر است. لازم به ذکر است که تصاویر آموزشی و آزمایشی به بررسی از تصویر قطعه‌بندی شده که شامل دو ریه است اشاره دارند.




شکل (۷): دقت طبقه‌بندی و میانگین مربعات خطای توابع آموزشی Traindx، پیشنهادی اول و پیشنهادی دوم.

همچنین عملکرد و کارایی شبکه پیشنهادی با استفاده از FROC¹ تحلیل شده است که نتیجه آن در منحنی شکل ۸، قابل مشاهده است.



پارامتر حساسیت به این دلیل اندازه‌گیری شده است که درصد برش‌های قطعه‌بندی شده که شامل توده‌های سرطانی هستند و به‌عنوان ناحیه سرطانی نیز طبقه‌بندی شده‌اند را نشان می‌دهد. منحنی FROC نشان می‌دهد که در هر اسکن، با دو تشخیص مثبت کاذب (۲ FPs/scan) حساسیت برابر با ۸۲٪ است، همچنین با در نظر گرفتن ۱۵ تشخیص مثبت کاذب در هر اسکن (۱۵ FPs/scan) حساسیت به ۹۰٪ افزایش می‌یابد و با ۳۰ تشخیص مثبت کاذب در هر اسکن (۳۰ FPs/scan)، حساسیت به ۹۱٫۴٪ می‌رسد.

در این تحقیق، دقت تشخیص سرطان ریه با استفاده از شبکه‌های عصبی مصنوعی پیشنهادی به حدود ۹۴٪ رسیده است. این دقت بالاتر از نتایج گزارش شده در بسیاری از



شکل (۶): مقایسه تابع آموزشی Traindx در مقابل تابع آموزشی پیشنهادی اول.

جدول (۱): نتایج بررسی طبقه‌بندی با استفاده از ۱۳ الگوریتم آموزشی.

تابع آموزشی	گشتاور	نرخ یادگیری	دقت طبقه‌بندی	خطای میانگین مربعات
Traingd	۰/۴	۰/۶	۸۶/۷	۰/۱۲۴۲
Traingda	۰/۳	۰/۵	۸۸/۸۹	۰/۱۱۸
Traingdm	۰/۴	۰/۷	۸۸/۸۹	۰/۱۱۵
Traingdx	۰/۳	۰/۷	۹۱/۱۱	۰/۱۱۲
Traingdf	۰/۳	۰/۵	۷۵/۵۰	۰/۱۶۴
Traingdb	۰/۶	۰/۳	۷۳/۳۰	۰/۱۹۸
Traingdg	۰/۴	۰/۸	۷۵/۵۶	۰/۱۶۲
Trainlm	-	۰/۸	۸۲/۲۰	۰/۱۴۴
Trainoss	۰/۶	۰/۶	۷۳/۳۰	۰/۱۹۶
Trainrp	۰/۴	۰/۷	۸۰	۰/۱۵۴
Trainseg	۰/۶	۰/۳	۷۳/۳۰	۰/۱۹۷
Trainbfg	-	۰/۵	۸۰	۰/۱۵۶
Trainbr	۰/۴	۰/۶	۸۸/۸۶	۰/۱۱۵

دقت طبقه‌بندی و خطای میانگین مربعات برای تابع آموزشی Traingdx و تابع آموزشی پیشنهادی اول و دوم، با گشتاور ۰/۳ و نرخ یادگیری ۰/۷ در شکل ۷ نشان داده شده است.

¹ Free-response Receiver Operating Characteristic

پژوهش‌های مشابه است. برای مثال، در مطالعه عبدالله و همکاران، دقت تشخیص با استفاده از سیستم‌های CAD حدود ۹۰٪ بوده است. پژوهش حاضر با بهره‌گیری از الگوریتم‌های بهینه‌سازی و شبکه‌های عصبی پیشرفته، توانسته است دقت تشخیص را بهبود بخشد.

در مقایسه با تحقیق کارمالینگی و همکاران، که حساسیت تشخیص را ۸۰٪ گزارش کرده بودند، پژوهش حاضر با دستیابی به حساسیت ۹۳.۴٪ نشان‌دهنده پیشرفت قابل توجهی است. این افزایش حساسیت ناشی از تحلیل عمیق‌تر و دقیق‌تر ویژگی‌های پیچیده تصاویر CT است که با استفاده از مدل‌های جدید شبکه‌های عصبی امکان‌پذیر شده است.

همچنین، تحقیق الکادی و همکاران، که دقت ۸۳.۳٪ را برای دسته‌بندی سرطان ریه گزارش کرده بودند، نشان می‌دهد که پژوهش حاضر با دقت حدود ۹۴٪ توانسته است بهبود معناداری ایجاد کند. این تفاوت به دلیل استفاده از ویژگی‌های آماری پیشرفته و الگوریتم‌های بهینه یادگیری عمیق است که در این تحقیق به کار گرفته شده‌اند.

۴. نتیجه‌گیری

در این مقاله، یک روش قطعه‌بندی و طبقه‌بندی رایانه‌ای پیشنهاد شده است. برای انجام قطعه‌بندی و طبقه‌بندی تصاویر از عملگرهای مورفولوژیک بر روی شبکه‌های عصبی مختلف استفاده شده است. در این جا به عنوان ویژگی‌های مورد نیاز برای طبقه‌بندی از پارامترهای آماری استفاده شده است. همچنین به منظور دستیابی به بالاترین دقت طبقه‌بندی، پارامترهای آماری مختلفی همچون میانگین، انحراف معیار، کشیدگی، گشتاور مرکزی مرتبه‌ی پنجم، گشتاور مرکزی مرتبه‌ی ششم و چولگی، با یکدیگر مقایسه شده‌اند. با استفاده از پارامتر چولگی بین ۵ تا ۸ درصد در دقت طبقه‌بندی بهبود ایجاد می‌شود. در میان ۱۳ تابع آموزشی که از قبل موجود بودند، تابع آموزشی traingdx

به بالاترین دقت طبقه‌بندی برابر با ۹۱/۱۱٪ دست یافت. تابع آموزشی پیشنهادی اول به دقت طبقه‌بندی ۹۳/۳٪، تشخیص ۱۰۰٪ و حساسیت ۹۱/۴٪ دست یافت. تابع آموزشی پیشنهادی دوم به دقت طبقه‌بندی ۹۳/۳٪ و میانگین مربعات خطای ۰/۰۹۴۲ دست یافت. عملکرد سیستم CAD پیشنهادی، با ۲ FPS/scan دارای حساسیت ۸۲٪ است که این دقت با ۳۰ FPS/scan به ۹۱/۴٪ افزایش می‌یابد. حساسیت به‌عنوان درصد برش‌های قطعه‌بندی شده‌ای که شامل توده سرطانی هستند و به‌درستی به‌عنوان ناحیه سرطانی طبقه‌بندی شده‌اند، محاسبه می‌شود. طبقه‌بندی نادرست در تصاویری اتفاق می‌افتد که در آن‌ها توده‌های سرطانی در نزدیکی پرده‌ی ریه واقع شده‌اند.

نتایج این پژوهش نشان می‌دهد که استفاده از شبکه‌های عصبی مصنوعی می‌تواند به تشخیص زودهنگام سرطان ریه با دقت بالا کمک کند. با توجه به این‌که دقت شبکه‌های پیشنهادی در این مطالعه بیش از ۹۳٪ بوده است، می‌توان گفت که این روش در مقایسه با بسیاری از روش‌های موجود، عملکرد بهتری دارد. کاربردهای کلینیکی این سیستم تشخیصی شامل کاهش زمان مورد نیاز برای تشخیص اولیه، کاهش نیاز به انجام آزمایش‌های تهاجمی مانند بیوپسی، و ارائه ابزار کمکی برای پزشکان در تحلیل تصاویر CT است. این سیستم می‌تواند به عنوان یک ابزار مکمل در کنار رادیولوژیست‌ها استفاده شود تا دقت و سرعت تشخیص بهبود یابد و شانس زنده‌ماندن بیماران افزایش یابد.

در پژوهش حاضر، اگرچه استفاده از شبکه‌های عصبی مصنوعی توانسته است دقت بالایی در تشخیص سرطان ریه از تصاویر CT اسکن نشان دهد، اما چندین محدودیت وجود دارد. اولاً، تعداد داده‌های آموزشی مورد استفاده محدود بوده و تنها از تصاویر پایگاه داده‌ی LIDC شامل ۱۵۵ بیمار استفاده شده است. این محدودیت می‌تواند منجر به کاهش توانایی تعمیم‌پذیری مدل به داده‌های جدید شود. ثانیاً، در طبقه‌بندی نهایی، شبکه

حتی استفاده از روش‌های ترکیبی مانند شبکه‌های عصبی عمیق (Deep Learning) به همراه شبکه‌های کانولوشنی (CNN) می‌تواند دقت مدل را افزایش دهد. به علاوه، پیشنهاد می‌شود که مدل‌های پیشنهادی برای طبقه‌بندی انواع مختلف تومورهای ریوی (مانند خوش‌خیم و بدخیم) توسعه یابند تا سیستم قابلیت کاربرد گسترده‌تری در تشخیص کلینیکی داشته باشد.

عصبی تنها دو حالت "سرطانی" و "غیرسرطانی" را مدنظر قرار داده است، در حالی که در کلینیک، تشخیص انواع مختلف تومورها (مانند خوش‌خیم و بدخیم) اهمیت بالایی دارد. برای بهبود این پژوهش، توصیه می‌شود که از مجموعه داده‌های بزرگ‌تر و متنوع‌تری استفاده شود تا مدل به خوبی با انواع مختلف داده‌های بیماران تطبیق یابد. همچنین، استفاده از ویژگی‌های پیچیده‌تر مانند ویژگی‌های بافتی، الگوهای محلی، و

۵. مراجع

- H. Sung, J. Ferlay, R. L. Siegel, M. Laversanne, I. Soerjomataram, A. Jemal, F. Bray. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA Cancer J. Clin.* 71 (3) (2021) 209-249.
- E. Augustus, K. Zwaenepoel, V. Siozopoulou, J. Raskin, S. Jordaens, G. Baggerman, L. Sorber, G. Roeyen, M. Peeters, P. Pauwels. Prognostic and predictive biomarkers in non-small cell lung cancer patients on immunotherapy—The role of liquid biopsy in unraveling the puzzle. *Cancers* 13 (7) (2021) 1675.
- M. P. Paing, K. Hamamoto, S. Tungjitkusolmun, C. Pintavirooj. Automatic detection and staging of lung tumors using locational features and double-staged classifications. *Appl. Sci.* 9(11) (2019) 2329.
- S. C. Lo, S. L. Lou, J. S. Lin, M. T. Freedman, M. V. Chien, S. K. Mun. Artificial convolution neural network techniques and applications for lung nodule detection. *IEEE Trans. Med. Imag.* 14 (4) (1995) 711-718.
- M. Uçar, E. Uçar. Computer-aided detection of lung nodules in chest X-rays using deep convolutional neural networks. *Sakarya Uni. J. Comput. Inform. Sci.* 2 (1) (2019) 1-8.
- A. A. Abdullah, S. M. Shaharum. Lung cancer cell classification method using artificial neural network. *Inform. Eng. Lett.* 2 (1) (2012) 49-59.
- N. Camarlinghi, I. Gori, A. Retico, R. Bellotti, P. Bosco, P. Cerello, G. Gargano, E. Lopez Torres, R. Megna, M. Peccarisi, M. E. Fantacci. Combination of computer-aided detection algorithms for automatic lung nodule identification. *Int. J. Comput. Assisted Radiology Surgery* 7 (2012) 455-464.
- O. S. Al-Kadi, D. Watson. Texture analysis of aggressive and nonaggressive lung tumor CE CT images. *IEEE Trans. Biomed. Eng.* 55 (7) (2008) 1822-1830.
- B. Van Ginneken, S. G. Armato III, B. de Hoop, S. van Amelsvoort-van de Vorst, T. Duindam, M. Niemeijer, K. Murphy, A. Schilham, A. Retico, M. E. Fantacci, N. Camarlinghi. Comparing and combining algorithms for computer-aided detection of pulmonary nodules in computed tomography scans: the ANODE09 study. *Med. Image Anal.* 14 (6) (2010) 707-722.
- R. Bellotti, F. De Carlo, G. Gargano, S. Tangaro, D. Cascio, E. Catanzariti, P. Cerello, S. C. Cheran, P. Delogu, I. De Mitri, C. Fulcheri. A CAD system for nodule detection in low-dose lung CTs based on region growing and a new active contour model. *Med. Phys.* 34 (12) (2007) 4901-4910.
- W. Wu, L. Gao, H. Duan, G. Huang, X. Ye, S. Nie. Segmentation of pulmonary nodules in CT images based on 3D - UNET combined with three - dimensional conditional random field optimization. *Med. Phys.* 47 (9) (2020) 4054-4063.
- R. C. Gonzalez, R. E. Wood, *Digital Image Processing*. 3ed ed., Pearson Prentice Hall, 2008.
- S. A. Patil, V. R. Udupi. Geometrical and texture features estimation of lung cancer and TB images using chest X-ray database. *Int. J. Biomed. Eng. Tech.* 6 (1) (2011) pp.58-75.
- R. Manickavasagam, S. Selvan, M. Selvan. CAD system for lung nodule detection using deep learning with CNN. *Med. Biological Eng. Comput.* 60 (1) (2022) 221-228.
- F. Paulin, A. Santhakumaran. Back propagation neural network by comparing hidden neurons: case study on breast cancer diagnosis. *Int. J. Comput. Appl.* 2 (4) (2010) 40-44.