Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
Volume 13, Number 2, Summer 2024, pp. 13-24
Received: 08/23/2023, Revised: 10/20/2024, Accepted: 11/02/2024

Diagnosis and Classification of The Degree of Malignancy of Prostate Cancer in Pathological Images Using Ensemble Deep Learning

Hamed Fazlollahi Aghamalek[1], Naser Mehrshad[2] and Sajad Mohamadzadeh[3*]
1-Department of Electrical and Computer Engineering, University of Birjand, Birjand, Iran.
2-Department of Electrical and Computer Engineering, University of Birjand, Birjand, Iran.
3*-Department of Electrical and Computer Engineering, University of Birjand, Birjand, Iran.
[1]hamed.fazlollahi@birjand.ac.ir, [2]nmehrshad@birjand.ac.ir, and [3*]s.mohamadzadeh@birjand.ac.ir

Corresponding author address: Sajad Mohamadzadeh, Department of Electrical and Computer Engineering, University of Birjand, Birjand, Iran. Postal Code: 9717434765.

Abstract- Prostate cancer is considered as one of the most common diseases of men worldwide after lung cancer in this century. Diagnosis and classification of medical images is a very challenging task. Timely diagnosis and prevention of this disease helps significantly in the treatment process and preventing its progression to other tissues. In order to determine the degree of the disease, the tissues are sampled and the type of degree is determined by examining the pathology structure. The most common method used to diagnose prostate cancer is microscopic observation of stained biopsies by a pathologist and Gleason grading of pathology image. In the most recent classification, the prostate tissue is divided into five grades, where grade one is the most benign condition and grade five indicates the worst condition of the disease. In this article, a new method has been introduced that combines the output of the classifications of three models of deep learning. The Transfer Learning method trained on a set of images (ImageNet) has been used. To evaluate the trained networks, test samples are applied to the networks. By using two rules of the combination of classifiers, such as majority voting and averaging, the test image will be assigned to a class. In order to evaluate the proposed method, this method has been applied to the database of the International Society of Urological Pathology (ISUP). The proposed method in this research is based on ensemble deep learning, which provides detection accuracy about 97.2% and 97.33% in prostate cancer according, respectively, for two rules of combining voting and averaging. Compared to other conventional methods for grading prostate cancer pathology images, it has increased the accuracy of more than 4% in diagnosis and classification.

Keywords- Ensemble deep learning, combination of classifiers, prostate cancer, pathology images, Transfer Learning.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
جلد ۱۳، شماره ۲، تابستان ۱۴۰۳، صفحه ۱۳-۲۴
دریافت: ۱۴۰۲/۰۶/۰۱، بازنگری: ۱۴۰۳/۰۷/۲۹، پذیرش: ۱۴۰۳/۰۸/۱۲

تشخیص و طبقه‌بندی درجه بدخیمی سرطان پروستات در تصاویر پاتولوژی بااستفاده از ترکیب شبکه‌های عصبی عمیق

حامد فضل‌اللهی آقاملک [۱]، ناصر مهرشاد [۲]، سجاد محمدزاده *[۳]
۱- دانشکده مهندسی برق و کامپیوتر، دانشگاه بیرجند، ایران.
۲- استاد دانشگاه بیرجند، دانشکده مهندسی برق و کامپیوتر، بیرجند، ایران.
*۳- دانشیار دانشگاه بیرجند، دانشکده مهندسی برق و کامپیوتر، بیرجند، ایران.
[1]hamed.fazlollahi@birjand.ac.ir, [2]nmehrshad@birjand.ac.ir, and [3*]s.mohamadzadeh@birjand.ac.ir

* نشانی نویسنده مسئول: سجاد محمدزاده، خراسان جنوبی، بیرجند، شوکت آباد، دانشگاه بیرجند، دانشکده مهندسی برق و کامپیوتر. کدپستی:۹۷۱۷۴۳۴۷۶۵

چکیده- سرطان پروستات، یکی از شایع‌ترین بیماری‌های مردان در سراسر جهان بعد از سرطان ریه در قرن حاضر است. تشخیص و طبقه‌بندی تصاویر پزشکی یک کار بسیار چالش برانگیز است. تشخیص و پیشگیری به‌موقع این بیماری، به‌روند درمان و جلوگیری از پیشرفت آن به سایر بافت‌ها، کمک چشمگیری می‌کند. به‌منظور تعیین درجه‌ی بیماری، از بافت، نمونه‌برداری می‌شود و با بررسی ساختار پاتولوژی، درجه بدخیمی تعیین می‌شود. رایج ترین روش مورد استفاده در تشخیص سرطان پروستات، مشاهده میکروسکوپی بیوپسی‌های رنگ‌آمیزی شده توسط یک پاتولوژیست و درجه‌بندی گلیسون از تصاویر پاتولوژی است. در جدیدترین دسته‌بندی، بافت پروستات به پنج درجه تقسیم‌بندی می‌شود که درجه‌ی یک، خوش‌خیم‌ترین حالت و درجه‌ی پنج، نشان‌دهنده‌ی وخیم‌ترین حالت بیماری است. در این مقاله یک روش جدید معرفی شده است که خروجی طبقه‌بندهای سه مدل از یادگیری عمیق با هم ترکیب و ادغام می‌شوند، از روش یادگیری انتقالی که بر روی مجموعه از تصاویر (ImageNet) آموزش داده شده، استفاده شده است. برای ارزیابی شبکه‌های آموزش داده شده، نمونه‌های تست به شبکه‌ها اعمال می‌شود و با استفاده از دو قانون ترکیب طبقه بندها از قبیل رای‌گیری اکثریت و میانگین‌گیری، تصویر تست به یک کلاس نسبت داده خواهد شد. به‌منظور ارزیابی روش پیشنهادی، این روش روی پایگاه داده‌ی جامعه‌ی بین‌المللی آسیب‌شناسی اورولوژی(ISUP)، اعمال شده است. روش پیشنهادی در این تحقیق بر پایه یادگیری گروهی عمیق است، که با توجه به دو قاعده ترکیب، رای‌گیری و میانگین‌گیری، دقت تشخیص بترتیب ۹۷/۲ ٪ و ۹۷/۳۳ ٪ در سرطان پروستات را فراهم می‌آورد که نسبت به سایر روش‌های مرسوم برای درجه‌بندی تصاویر پاتولوژی سرطان پروستات باعث افزایش دقت بیش از ۴ درصد در تشخیص و طبقه‌بندی گردیده است.

واژه‌های کلیدی: یادگیری گروهی عمیق، ترکیب طبقه بندها، سرطان پروستات، تصاویر پاتولوژی، یادگیری انتقالی.

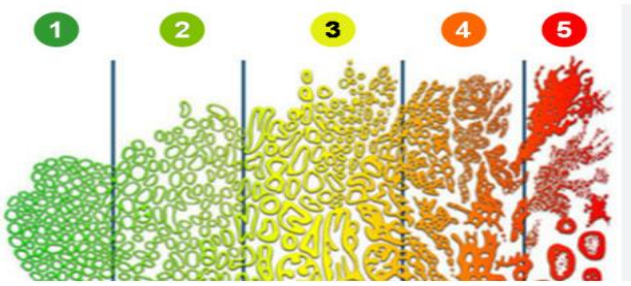
۱- مقدمه

آخرین آمارهای جهانی بیان‌گر این حقیقت است که شایع‌ترین بیماری در میان مردان، سرطان ریه (۱۴٪/۵) و پس از آن سرطان پروستات (۱۳٪/۵) است [۱]. پروستات[۱] یکی از غده‌های مهم دستگاه تناسلی مردان است که در زیر مثانه و مقابل روده‌ی بزرگ قرار داشته و نقش مهمی در تولید مثل ایفا می‌کند. اندازه این غده از سن پنجاه سالگی به بعد بزرگ‌تر شده و مشکلاتی را برای مردان

ایجاد می‌کند. نگران‌کننده‌ترین بیماری پروستات، سرطان پروستات است، که در واقع به‌معنی شکل‌گیری سلول‌های سرطانی در بافت پروستات می‌باشد [۲]. از آن‌جا که این تغییر شکل سلول‌های پروستات، به‌آرامی صورت می‌گیرد، این احتمال وجود دارد تا چندین سال قبل از بدخیمی شدید، علائم خاصی از آن مشاهده نشود. تشخیص دیرهنگام، می‌تواند منجربه بدخیمی و همچنین گسترش و هجوم سلول‌های سرطانی به‌سایر بافت‌ها، از جمله مثانه و روده‌ی بزرگ گردد. بنابراین، در بررسی و درمان سرطان پروستات، تشخیص به‌موقع مرحله و یا درجه‌ی بافت سرطانی، از اهمیت ویژه‌ای برخوردار است [۳]. به‌منظور تشخیص سرطان پروستات، ابتدا فاکتور آنتی‌ژن اختصاصی پروستات[۲] (PSA) در خون، مورد بررسی و آزمایش قرار می‌گیرد. بالا بودن این فاکتور از یک مقدار مشخص، نشان دهنده‌ی احتمال وقوع سرطان پروستات می‌باشد. لازم به‌ذکر است که عوامل دیگری ممکن است باعث افزایش این فاکتور شوند، لذا به‌منظور تشخیص قطعی و نهایی، از روش‌های دیگری مانند تصویربرداری رنگی و بافت‌برداری استفاده می‌شود. از میان این روش‌ها، بافت‌برداری از پروستات و بررسی آن زیر میکروسکوپ از اهمیت ویژه‌ای برخوردار است، زیرا با بررسی و طبقه‌بندی بافت پروستات، شدت و میزان شیوع این بیماری را می‌توان مشخص نمود. از این‌رو در سالهای اخیر، از روش طبقه‌بندی گلیسون، که عددی بین ۱ تا ۵ را به بافت پروستات نسبت می‌دهد، به منظور تشخیص شدت و احتمال پخش شدن بیماری استفاده می‌شود. بیشترین عدد در این روش عدد ۵ که نشان دهنده‌ی وخیم‌ترین وضع بیماری و احتمال بالای سرایت آن به سایر اندام‌ها می‌باشد [۴]. سیستم درجه‌بندی گلیسون یکی از مطمئن‌ترین روش‌ها برای ارزیابی تهاجمی‌بودن سرطان پروستات است که در سال ۱۹۶۷ توسعه یافت و در سال ۲۰۱۴ به‌روز شد. این نوع طبقه‌بندی بافت پروستات، که از حدود نیم قرن پیش مورد استفاده بوده، دستخوش تغییراتی نیز شده است. اگر چه تغییرات اولیه توسط خود دکتر گلیسون صورت گرفته بود، اما با پیشرفت روش‌های بافت‌برداری، لزوم تغییر و بهبود روش گلیسون، به منظور افزایش کارایی این روش، به شدت احساس می‌شد. از این‌رو، جامعه‌ی بین‌المللی آسیب‌شناسی اورولوژی[۳] (ISUP) در سال ۲۰۰۵، نسخه‌ی بهبودیافته‌ی این روش را ارائه کرد و سپس در سال ۲۰۱۴، آن را بهبود بخشید. در نسخه‌ی بهبودیافته، تصمیم گرفته شد تا در تصویر هر بافت، درجه‌ی گلیسون[۴] مربوط به دو ساختاری که بیشترین فضا را اشغال کرده‌اند، با هم جمع شده و درجه‌ی نهایی به صورت عددی بین ۶ تا ۱۰ نمایش داده شود [۵]. به عنوان مثال، اگر در بافت پاتولوژی پروستات، بخش اعظمی از سطح بافت، ساختاری مشابه درجه‌ی ۵ گلیسون داشته و پس از آن، بیشترین سطح مربوط به ساختار درجه‌ی ۳ گلیسون باشد، درجه‌ی نهایی به صورت عدد ۸ بیان خواهد شد. یکی دیگر از تغییراتی که در درجه‌بندی جدید لحاظ شد، ناشی از آن بود که پژوهشگران به این نتیجه رسیده بودند که درجه‌ی گلیسون ۱ و ۲ نباید به عنوان خطر تشخیص داده شود، از این‌رو در نسخه‌ی جدید، عدد ۶ به عنوان کمترین درجه با احتمال خطر، در نظر گرفته شد، که از ترکیب دو سطح با درجه‌ی گلیسون ۳ به دست می‌آید. پس از این تغییرات، درجه‌ی نهایی با نام درجه‌ی ISUP شناخته می‌شود. بنابراین، درجه‌بندی نهاییISUP از جمع درجات گلیسون (GS) بدست می‌آید که در جدول ۱ نمایش داده شده است [۶]. شکل ۱، شمای بافت‌های پروستات در درجه‌بندی گلیسون را نمایش می‌دهد [۷].

جدول ۱: نمایش پارامتر مهم در تشخیص درجه بدخیمی سرطان پروستات

درجه تهاجمی یا بدخیمی	مجموع امتیاز گلیسون	امتیازگلیسون	مقدار درجه
کم خطر	۶	۳+۳	درجه ۱
خطر متوسط اما نزدیک به کم خطر	۷	۳+۴	درجه ۲
خطر متوسط اما نزدیک به پر خطر	۷	۴+۳	درجه ۳
پرخطر	۸	۴+۴, ۳+۵, ۵+۳	درجه۴
خیلی پرخطر	۹-۱۰	۴+۵, ۵+۴, ۵+۵	درجه ۵



شکل ۱: شمای بافت های پروستات در درجه‌بندی گلیسون[۷].

در پژوهشی، سزاوار و همکاران در سال ۲۰۱۹ با استفاده از ترکیب و ادغام ویژگی‌های عمیق و ویژگی‌های آماری بافت تصاویر پاتولوژی مدلی را معرفی کردند که با ترکیب استخراج ویژگی‌های بافتی و آماری تصاویر، به‌همراه ویژگی‌هایی که شبکه عصبی پیچشی از تصویر ارائه می‌دهد دقت طبقه‌بندی را به ۹۴/۴۷ درصد بهبود دادند [۵]. در تحقیقی مشابه دیگر، رووچانین و همکاران در سال ۲۰۲۲ با عنوان کاربرد هوش مصنوعی در تشخیص و درمان سرطان پروستات روشی را معرفی کردند که در این مقاله یک شبکه عصبی مصنوعی پیش‌خور ارائه شده است که قادر به تمایز بین بافت سرطانی و غیرسرطانی پروستات با دقت ۹۲/۷۷ درصد می‌باشد [۸].

در پژوهشی دیگر، هانگ و همکاران در سال ۲۰۲۲ با عنوان ادغام ویژگی‌های غیرعمیق و یادگیری عمیق در یک مدل شبکه عصبی پیچشی برای تشخیص و طبقه‌بندی دو کلاسه سرطان و غیرسرطان پروستات در تصاویر آسیب‌شناسی انجام‌شده است که با ترکیب و ادغام هفت ویژگی آماری و غیرعمیق با یک ویژگی یادگیری عمیق با استفاده از مدل ResNet انجام شده است. که در این مدل، سیستم توانست با دقت ۹۵/۴۵ درصد یک مسئله دو کلاسه را حل کند [۹]. در سال ۲۰۲۱، پژوهشی با عنوان تشخیص و درجه‌بندی سرطان پروستات در نمونه‌های رادیکال پروستاتکتومی از طریق تکنیک‌های یادگیری عمیق انجام شده است که در نتیجه، دقت در طبقه‌بندی ۹۱/۲ درصد حاصل شد. در این تحقیق از مدل شبکه عصبی پیچشی Inception v3 استفاده شده است [۱۰].

بهبود نتایج و عملکرد شبکه‌های عصبی عمیق این را به وضوح نشان می‌دهد که برای طبقه‌بندی(تصاویر پزشکی و غیرپزشکی)، از الگوریتم‌های یادگیری عمیق باید استفاده شود. معماری‌های یادگیری عمیق با موفقیت در طیف گسترده‌ای از کاربردها از طبقه‌بندی تصویر ویدئو گرفته تا مراقبت‌های بهداشتی بکار گرفته شده‌اند. موفقیت این مدل‌ها، به‌نمایش بهتر ویژگی‌ها از طریق معماری‌های پردازش چند لایه نسبت داده می‌شود. مدل‌های یادگیری عمیق عمدتاً برای مسائل طبقه‌بندی، رگرسیون و خوشه‌بندی استفاده شده‌اند [۱۱]. یادگیری گروهی رویکردی برای افزایش دقت کلی یک سیستم طبقه‌بندی با استفاده از طبقه‌بندی‌کننده‌های متعدد است. ترکیب یادگیری یا یادگیری گروهی به این معنی است که چندین مدل فردی را برای بدست آوردن عملکرد بهتر سیستم، ترکیب می‌شوند. در حال حاضر، معماری‌های یادگیری عمیق در مقایسه با مدل‌های کم‌عمق یا سنتی، عملکرد بهتری از خود نشان می‌دهند. مدل‌های یادگیری گروهی عمیق، مزایای هر دو مدل یادگیری عمیق و همچنین یادگیری گروهی را با هم ترکیب می‌کند و دارا می‌باشد. به طوری‌که مدل نهایی، عملکرد تعمیم بهتری دارد [۱۱].

هدف از این مقاله افزایش کارایی پیش‌بینی سرطان پروستات با ایجاد ترکیب طبقه‌بندها در شبکه‌های عصبی عمیق است. برای دستیابی به این هدف، سه شبکه عصبی عمیق کارآمد (VGG16-VGG19-RESNET) را مورد تحقیق و پژوهش قرار دادیم. با توجه به بررسی‌ها و مطالعات انجام شده این سه ساختار دارای مزایایی مانند یادگیری بهتر ویژگی‌های سطح بالا و مقاومت بهتر در برابر تغییرات مکانی هستند. این سه ساختار با پایگاه داده ImageNet داده شده‌اند.خروجی هر شبکه عصبی عمیق را با استفاده از قاعده رای‌گیری حداکثری و قاعده میانگین‌گیری، با هم ترکیب و ادغام نموده‌ایم. این دو قاعده باعث می‌شوند که نتیجه طبقه‌بندی به صورت چشمگیر بهتر از نتیجه طبقه بندی هر یک از شبکه‌های عصبی عمیق به‌صورت جداگانه باشد. نتیجه این روش پیشنهاد شده، بیان‌گر بهبود تشخیص درجه‌بندی سرطان پروستات به کلاس مربوطه را به وضوح نشان می‌دهد. مهم‌ترین نوآوری‌های این مقاله به شرح زیر می‌باشد:

الف) ارایه یک مدل برای ترکیب شبکه‌های عصبی عمیق

ب) استفاده از دو قاعده ترکیب طبقه بندها در خروجی شبکه‌های عصبی عمیق

ج) افزایش دقت و صحت طبقه‌بندی در شناسایی درجه بدخیمی سرطان پروستات.

ساختار ادامه مقاله به شرح زیر است:

در بخش ۲، موادها و روش‌ها معرفی شده است. در بخش ۳، یادگیری گروهی به صورت کامل بیان شده و پس از آن، در بخش ۴، روش پیشنهادی به صورت کامل توضیح داده شده است. نتایج آزمایش‌ها و نتیجه‌گیری نیز به ترتیب در بخش‌های ۵ و ۶ شرح داده می‌شوند.

۲- موادها و روش‌ها

دراین پژوهش، ابتدا تکنیک‌های یادگیری عمیق، به عنوان یکی از جدیدترین و نوین‌ترین ابزارهای پردازش داده و بینایی ماشین، مورد بررسی قرار گرفته شده و از میان شاخه‌های آن، مدل‌های شبکه عصبی پیچشی VGG۱۶، ResNet-۵۰ و VGG۱۹ انتخاب و بررسی شده است. بدین‌ترتیب، در روش پیشنهادی، ویژگی‌های عمیق سطح بالا از تصاویر پاتولوژی، به‌وسیله‌ی سه مدل شبکه‌ی عصبی پیچشی متفاوت مذکور استخراج شده، نهایتا به‌منظور افزایش دقت در طبقه‌بندی، با روش‌های میانگین‌گیری و رای‌گیری حداکثری در طبقه خروجی، ترکیب طبقه‌بندها صورت می‌گیرد.

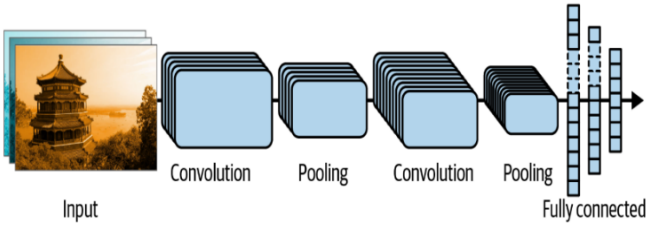
۲-۱- یادگیری عمیق

یادگیری عمیق[5]، یکی از زیرشاخه‌های یادگیری ماشین است که هدف آن، یاد گرفتن چکیده‌ی سطح بالا از داده‌ها با استفاده از معماری‌های سلسله‌مراتبی است که یک رویکرد در حال گسترش به‌شمار می‌رود و به‌طور گسترده در حوزه‌ی هوش مصنوعی(پردازش زبان طبیعی و بینایی ماشین) مورد استفاده قرار گرفته است. پس از اینکه الگوریتم شبکه‌ی عصبی عمیق AlexNet، در سال ۲۰۱۲ در چالش طبقه‌بندی تصاویر، موفق به کسب رتبه‌ی اول گردید، توجه محققان به سرعت به سمت الگوریتم‌های عمیق، متمرکز شد تا جایی‌که امروزه این الگوریتم‌ها در بسیاری از زمینه‌ها مورد

استفاده قرار گرفته است و عملکرد موفقی داشته‌اند. پژوهش‌های حوزه‌ی یادگیری عمیق به طور کلی به چهار دسته‌ی ماشین‌های بولتزمن محدود[۶]، کدینگ تنک[۷] ، خودرمزگذارها[۸] و شبکه‌های عصبی پیچشی [۹] تقسیم می‌شوند [۵]. اگرچه هر کدام از این روش‌ها در زمینه‌ی خاصی عملکرد موفقی داشته و دارای مزایایی هستند، اما با توجه به‌دلایل زیر، در این مقاله از شبکه‌های عصبی پیچشی استفاده می‌شود. روش‌های ماشین بولتزمن محدود، نیازمند محاسبات سنگینی بوده و در نتیجه بسیار زمان‌بر هستند. از سوی دیگر، خودرمزگزارها، در مقابل تغییراتی از قبیل چرخش تصویر، مقاوم نیستند. در کدینگ پراکنده نیز امکان آموزش ویژگی وجود ندارد. از طرفی، شبکه‌های عصبی پیچشی ، به‌طور خاص برای داده‌های ورودی دوبعدی(مانند تصویر) طراحی شده‌اند. از این‌رو در مبحث پردازش تصویر، به خصوص در استخراج ویژگی‌های عمیق از تصویر، استفاده از شبکه‌های عصبی پیچشی عمیق بسیار کارآمد است [۵].

۲-۲- شبکه عصبی پیچشی

شبکه‌های عصبی پیچشی (CNNs) شبکه‌های چند لایه‌ای هستند که از لایه‌های پیچشی همپوشانی برای استخراج ویژگی و لایه‌های نمونه‌برداری پایین برای پردازش ویژگی تشکیل شده‌اند. شکل ۲ ساختار یک شبکه عصبی پیچشی معمولی را نشان می‌دهد.



شکل ۲: معماری شبکه عصبی پیچشی [۱۲].

شبکه‌های عصبی پیچشی می‌توانند به‌طور خودکار ویژگی‌ها را از تصاویر استخراج کنند، بنابراین به یک موضوع داغ تحقیقاتی تبدیل شده‌اند. CNNها مدل‌های مبتنی بر پرسپترون هستند. مزیت آن‌ها این است که می‌توانند مستقیماً تصاویر اصلی را دریافت کنند تا از پیش پردازش بیش از حد تصویر، جلوگیری کنند [۱۲]. شبکه‌های عصبی پیچشی (CNNs)، می‌توانند پیچیدگی مدل‌ها را کاهش دهند، با استفاده کامل از اطلاعات محلی و سراسری تصویر، آن‌ها قادر به ترجمه، چرخش و مقیاس‌بندی قوی هستند. شبکه‌های عصبی پیچشی کلاسیک که در این تحقیق مورد استفاده قرارگرفته است عبارتند از: شبکه عصبی باقیمانده[۱۰] ResNet-۵۰، VGG۱۶ و VGG۱۹.

۲-۳- یادگیری انتقالی

یادگیری انتقالی[۱۱]، یکی از مهم‌ترین تکنیک‌های یادگیری عمیق می‌باشد. در یادگیری عمیق نیاز است که مقدار زیادی داده جمع‌آوری و برچسب زنی شود. با وجود داده کافی و جامع، شبکه از ابتدا آموزش را شروع کرده و اوزان بهینه پیدا می‌شوند. اگر تعداد داده آموزشی کم باشد شبکه دچار بیش برازش[۱۲] خواهد شد. برای حل این مشکل و برای رسیدن به نتایج بالا و عملکرد خوب شبکه مجبور خواهیم بود که از یادگیری انتقالی استفاده نماییم. روش یادگیری انتقالی این اجازه را به ما می‌دهد که به عنوان نقطه شروع از پارامترهای بهینه شده یا اوزان شبکه که قبلا با استفاده از داده بسیار بزرگ آموزش دیده، استفاده کرد که در شروع سریع یادگیری و آموزش شبکه، بسیار موثر است [۱۳-۱۴].

۲-۴- شبکه عصبی باقیمانده (ResNet)

دقت یک شبکه عصبی از لحاظ نظری باید با اضافه‌شدن لایه‌های بیشتر بهبود یابد. اما در واقعیت، این فرضیه نادرست است. با افزایش عمق شبکه، دقت شبکه تمایل به اشباع شدن و سپس کاهش سریع پیدا می‌کند. این مشکل به‌عنوان تخریب شناخته می‌شود. علت مشکل تخریب بیش‌برازش نیست، بلکه ناشی از ناپدید شدن یا انفجار گرادیان‌ها در شبکه‌های عصبی عمیق است. در طول فاز پس‌انتشار، به دلیل ضربات مکرر، گرادیان‌ها در مسئله گرادیان ناپدیدشونده به‌طور بی‌نهایت کوچک می‌شوند، که منجر به به‌روزرسانی‌های ناچیز پارامترها می‌شود. این مشکل قبل از معرفی شبکه عصبی باقیمانده با استفاده از لایه‌های نرمال‌سازی و اولیه‌سازی نرمال‌شده حل شده بود.شبکه عصبی باقیمانده (به اختصار ResNet) یک طرح CNN با بلوک باقیمانده به عنوان بلوک اصلی سازنده است. برای کاهش مشکل تخریب، یک بلوک باقیمانده از اتصالات پرشی استفاده می‌کند که می‌تواند به عنوان اتصالاتی تعریف شود که از یک یا چند لایه عبور می‌کنند. حتی اگر ضریب اتصال منظم در مرحله آموزش به صفر همگرا شود، میانبر باقیمانده یکپارچگی شبکه را تضمین می‌کند[۱۵]. ما از مدل ResNet–۵۰، که در مجموعه داده ImageNet از قبل آموزش داده شده بود، به عنوان مدل اصلی خود استفاده نموده‌ایم. مدل از پیش‌آموزش دیده شده، شامل تعدادی لایه‌های استخراج ویژگی و یک لایه خروجی کاملا متصل[۱۳] است. هدف این تقسیم‌بندی، تسهیل تنظیم دقیق (fine-tuning) پارامترهای مدل در همه لایه‌ها به جز لایه خروجی است. استفاده از یک مدل از پیش آموزش دیده، امکان دستیابی به دقت بالاتر را فراهم می‌کند و در عین حال، با استفاده از حداقل مقدار داده، صرفه‌جویی در زمان را نیز به همراه دارد.

۲-۵- شبکه عصبی VGG۱۶

شبکه VGG16 یک معماری شبکه عصبی پیچشی است که توسط Visual Geometry Group در دانشگاه آکسفورد برای مسابقه ImageNet توسعه داده شده است. این معماری از تصاویر ورودی با وضوح ۲۲۴×۲۲۴ پیکسل پشتیبانی می‌کند. فیلترهای مورد استفاده ۳×۳ هستند و از تکنیک padding برای حفظ وضوح نتایج میانی بهره می‌برد، تا ابعاد تصویر پس از اعمال فیلترها تغییر نکند و همان وضوح اولیه را حفظ کند. عبارت "حفظ وضوح نتایج میانی" به معنای حفظ ابعاد نقشه‌های ویژگی در طول مسیر پردازش است، به طوری که بعد از هر لایه پیچشی ابعاد نقشه ویژگی به میزان زیادی کاهش پیدا نکند و اطلاعات مکانی تصویر حفظ شود. به عبارت دیگر، تکنیک padding به این منظور به کار می‌رود که با افزودن حاشیه‌ای از پیکسل‌های صفر به اطراف تصویر، ابعاد تصویر پس از هر لایه‌ی پیچشی ثابت بماند و اطلاعات مکانی تصویر از دست نرود [۱۵].

۲-۶- شبکه عصبی VGG۱۹

شبکه VGG۱۹ گونه ای از مدل VGG است که به طور خلاصه از ۱۹ لایه (۱۶ لایه پیچشی ، ۳ لایه کاملا متصل، ۵ لایه MaxPool و ۱ لایه SoftMax) تشکیل شده است. در این تحقیق از مدل VGG۱۹ که روی مجموعه داده ImageNet از قبل آموزش داده شده است، استفاده شده است [۱۲].

۳- یادگیری گروهی

در یادگیری گروهی[۱۴]، چندین شبکه پایه آموزش می‌بینند و خروجی‌های این شبکه‌های پایه را با استفاده از قوانینی، ترکیب و ادغام می‌شوند. قاعده‌ای که برای ترکیب خروجی‌ها استفاده می‌شود، عملکرد مؤثر یک گروه را تعیین می‌کند. رویکردهای مختلفی برای ترکیب خروجی‌های مدل‌های یادگیری بکار گرفته می‌شوند که در این مقاله از دو روش استفاده شده است که عبارتند از:

۳-۱- روش میانگین‌گیری بدون وزن

میانگین‌گیری بدون وزن[۱۵] از خروجی شبکه‌های پایه در یک مدل ترکیبی، بیشترین رویکردی است که برای تلفیق یا ادغام تصمیمات خروجی دنبال می‌شود. در اینجا، نتایج شبکه‌های عصبی متفاوت را برای به‌دست آوردن پیش‌بینی نهایی مدل مجموعه، میانگین‌گیری می‌شوند. معماری‌های یادگیری عمیق دارای واریانس بالا و بایاس کم هستند. بنابراین میانگین‌گیری ساده از شبکه‌های عمیق عملکرد تعمیم را به دلیل کاهش واریانس بین مدل‌ها بهبود می‌بخشد. میانگین‌گیری یا بر روی خروجی‌های شبکه‌های پایه به طور مستقیم یا بر اساس احتمالات پیش‌بینی شده کلاس‌ها از طریق تابع Softmax انجام می‌شود [۱۱]:

$$P_i^j = softmax^j(O_i) = \frac{O_i^j}{\sum_{k=1}^{k} exp\,(O_k^j)} \qquad (۱)$$

جاییکه P_i^j نتیجه احتمالی واحد i ام در شبکه یادگیری پایه j ام است. O_i^j خروجی واحد i ام از شبکه یادگیری پایه j ام است و k تعداد کلاس‌ها است. میانگین‌گیری بدون وزن، انتخاب معقولی است زمانی‌که عملکرد و کارآیی شبکه‌های یادگیری پایه قابل مقایسه باشند. زمانی‌که شبکه‌های یادگیری عمیق متفاوت وجود داشته باشد باید این شبکه به‌تنهایی از یک کارایی و عملکرد خوبی برخوردار باشند تا بتوانند در ترکیب نتیجه بهتری حاصل شود به‌عبارتی نمی‌توانیم از شبکه‌های یادگیری عمیق ضعیف انتظار خروجی بهتر در یادگیری گروهی داشته باشیم [۱۷-۱۶].

۳-۲- روش رای‌گیری حداکثری

مانند میانگین‌گیری بدون وزن، روش رای‌گیری حداکثری[۱۶]، خروجی‌های شبکه‌های یادگیری عمیق پایه که هر یک ازآن‌ها نمونه‌های آزمایشی را به یک کلاس اختصاص می‌دهند با هم به رای‌گیری گذاشته می‌شوند. به‌جای در نظر گرفتن میانگین احتمالات، رای اکثریت، کلاس خروجی هر یک از شبکه‌های یادگیری عمیق را شمارش می‌کند و برچسب‌های نهایی را به عنوان برچسب با اکثریت آرا پیش‌بینی می‌کند. یا به‌عبارتی در این روش، اظهارنظر هر طبقه‌بند در مورد کلاس الگوی ورودی، به عنوان یک رأی محسوب می‌شود و تصمیم‌گیری نهایی بر اساس آرای اخذ شده از طبقه‌بندهای مختلف صورت می‌گیرد. الگوی ورودی به کلاسی تعلق خواهد گرفت که بیشترین رأی را بیاورد. اگر طبقه‌بندها مستقل از یکدیگر بوده و نرخ طبقه‌بندی صحیح آنها، مستقل از تعداد کلاس‌ها بیش از پنجاه‌درصد باشد، با افزایش تعداد طبقه‌بندها، روش رأی‌گیری باعث افزایش دقت طبقه‌بندی می‌شود [۲۰-۱۸].

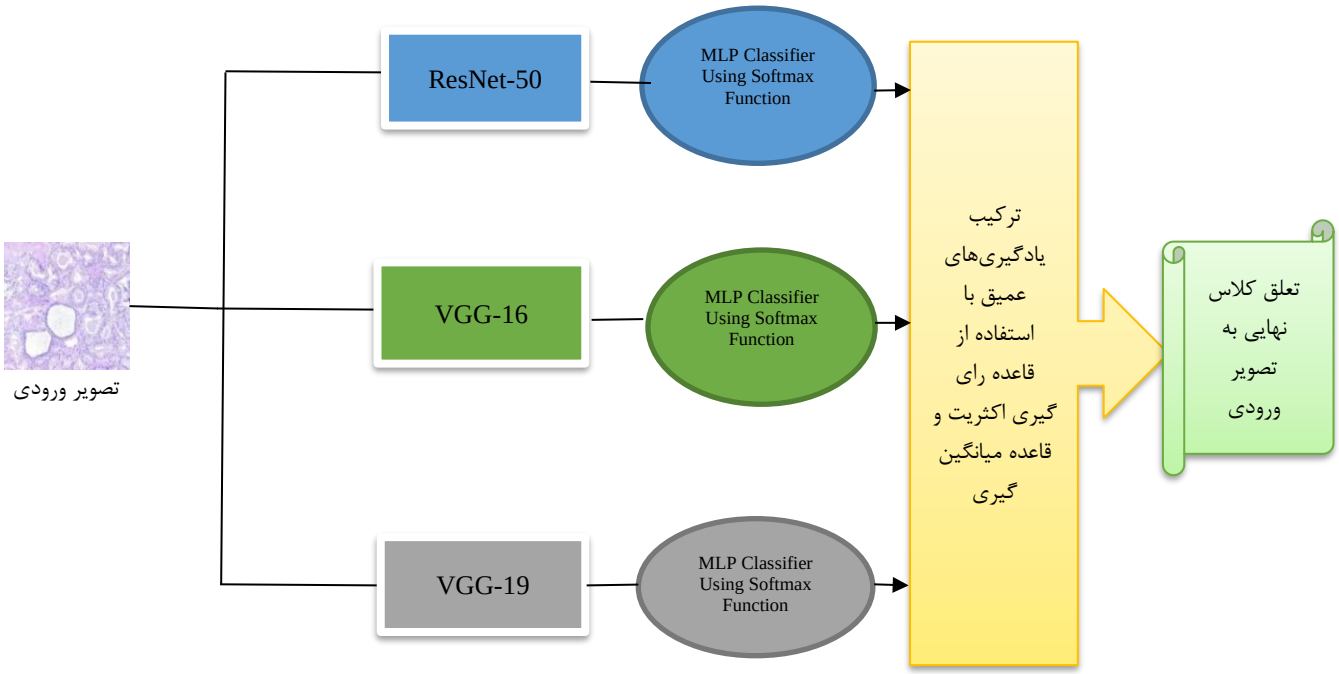
۴- روش پیشنهادی

در این پژوهش، مطالعات بر روی تصاویر پاتولوژی پروستات انجام شده است. برای تشخیص درجه بدخیمی سرطان پروستات از یادگیری گروهی عمیق به کمک فریمورک تنسورفلو و بهره‌گیری از کتابخانه کراس استفاده شده است. در این بخش، الگوریتم پیشنهادی، شرح داده خواهد شد. یکی از مشکلات استفاده از شبکه‌های عمیق این است که به دلیل زیاد بودن پارامترهای قابل

آموزش، به داده‌های ورودی زیادی نیاز دارند. بنابراین، در این پژوهش از تکنیک افزایش داده[17] به منظور افزایش تعداد تصاویر ورودی استفاده شده است. بدین‌صورت که از هر تصویر، چرخش‌ها و دوران‌های مختلفی ایجاد می‌شود تا داده‌ی کافی برای مرحله‌ی آموزش فراهم گردد. که نهایتا از هر کلاس یا درجه بدخیمی تعداد ۳۰۰ تصویر و برای پنج کلاس یا پنج درجه بدخیمی تعداد ۱۵۰۰ تصویر بدست آمده است. با تکمیل‌کردن و جمع‌آوری نهایی تصاویر یا داده‌های ورودی، با استفاده از سه شبکه عصبی پیچشی ResNet-۵۰، VGG۱۶و VGG۱۹ که بر روی پایگاه داده بزرگ ImageNet آموزش داده شده، بدون تغییردادن پارامترها، قسمت‌های استخراج ویژگی یا یادگیری ویژگی، ثابت نگه داشته می‌شوند تا بتوانیم وزن‌های بهینه این شبکه‌ها را که بر روی این پایگاه داده بزرگ آموزش داده شده را بدست آوریم و بر روی پایگاه داده ISUP مجددا آموزش دهیم. سپس لایه‌های طبقه‌بند چگال[18] مدل جدید خویش را به شبکه اضافه می‌کنیم. در شکل۳، روش پیشنهادی ارائه شده است. با در نظر گرفتن یک لایه چگال Flatten ، با ۵۱۲ نرون، خروجی لایه پیچشی که یک تنسور چند بعدی است به یک تنسور یک بعدی تبدیل می‌شود و قسمت کاملا متصل، شبکه ایجاد می‌شود. و در لایه چگال دوم، یک لایه چگال ۲۵۶ نرونی به خروجی لایه قبل، متصل می‌شوند. و نهایتا با یک لایه چگال با ۵ نرون که باید برابر با تعداد کلاس‌ها باشد ایجاد می‌گردد. شبکه عصبی عمیق از چند لایه برای درک بخش‌هایی از داده‌ها استفاده می‌کند، اما برای طبقه‌بندی داده‌ها باید مجموعه‌ای از احتمالات را برای تصمیم‌گیری نهایی داشته باشیم. تابع Softmax، یک تابع شناخته شده است که مقادیر احتمالات را در یک محدوده استاندارد بین ۰-۱ نرمالیزه می‌کند.

از تکنیک dropout به منظور جلوگیری از بیش‌برازش استفاده می‌شود. که بین لایه اول و دوم از dropout (0.3) بکار گرفته شده، که ۳۰ درصد از نرون‌ها حذف می‌شوند. بدین صورت که در هر مرحله از آموزش هر نورون با احتمال P-۱ از شبکه حذف می‌شود و یا با احتمال p نگه داشته می‌شود به‌طوری‌که در نهایت یک شبکه کاهش داده شده باقی بماند. یال‌های ورودی و خروجی به یک نود نیز حذف می‌شود تا بدین صورت تنها شبکه کاهش‌یافته برروی داده‌ها در آن مرحله قابل آموزش باشد. و درنهایت با استفاده از adam optimizer که برای محاسبه بسیاری از توابع بهینه‌ساز در تنسورفلو است بهینه‌سازی وزن‌ها انجام می‌گردد.

در قاعده رای‌گیری حداکثری، هر یک از سه شبکه‌های عصبی، الگوهای ورودی را به یک کلاس اختصاص می‌دهند. سپس با توجه به بیشترین رای به کلاس مربوطه توسط سه شبکه عصبی، الگوی ورودی به کلاس نهایی تعلق پیدا خواهد کرد. در قاعده میانگین‌گیری، در هریک از شبکه‌های عصبی، خروجی تابع softmax یک احتمالی از الگوی ورودی به پنج کلاس اختصاص



شکل ۳: روش پیشنهادی یادگیری گروهی عمیق برای تشخیص درجه بدخیمی سرطان پروستات

خواهد داد. که با میانگین‌گیری خروجی توابع softmax سه شبکه، هر کلاسی که مقدار آن با میانگین‌گیری، بیشترین مقدار را بدست بیاورد، الگوی ورودی به آن کلاس تعلق خواهد داشت. در بخش نتایج مشاهده خواهیم کرد که روش میانگین‌گیری از روش رای‌گیری عملکرد بهتری خواهد داشت. در جدول ۲ الگوریتم روش پیشنهادی آورده شده است.

۵- نتایج آزمایش‌ها و بحث

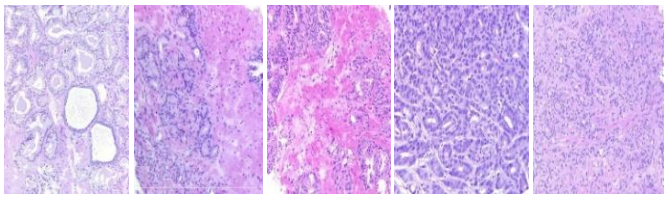
۵-۱- پایگاه داده ISUP

برای ارزیابی هر الگوریتم طبقه‌بندی، به یک پایگاه داده‌ی جامع نیاز است. یکی از مشکلات پژوهش در زمینه‌ی پزشکی و به خصوص بافت‌شناسی، کمبود پایگاه‌های داده با تعداد تصاویر زیاد است. از این‌رو، در بسیاری از پژوهش‌ها، محققان تصاویر مورد نیاز را شخصا جمع‌آوری می‌کنند. پژوهش‌های طبقه‌بندی بافت پروستات نیز از این قاعده مستثنی نیستند. لذا اکثر پژوهش‌های انجام‌شده در زمینه‌ی طبقه‌بندی و محاسبه‌ی درجه‌ی گلیسون، روی تصاویر جمع‌آوری شده از نمونه‌های محلی صورت گرفته است [۲۱-۲۴].

خوشبختانه اخیرا جامعه‌ی بین‌المللی آسیب‌شناسی اورولوژی(ISUP) تصاویری از نمونه‌های مختلفی از بافت پروستات را جمع‌آوری کرده، درجه‌ی آنها را زیر نظر متخصصان این حوزه تعیین کرده و در اختیار عموم قرار داده است. این پایگاه داده در حال‌حاضر یکی از جامع‌ترین پایگاه‌های داده‌ی تصاویر بافت پروستات به حساب آمده و در این پژوهش نیز، از این پایگاه داده برای آموزش و ارزیابی الگوریتم پیشنهادی استفاده شده است. پایگاه داده مورد استفاده برای سرطان پروستات شامل ۱۵۰۰ تصویر پاتولوژی به‌صورت رنگی می‌باشد که تمام تصاویر در شدت نور برابر، مورد تصویربرداری قرار گرفته‌اند [۲۵]. مجموعه تصاویر این پایگاه داده مورد پژوهش، شامل ۵ کلاس یا درجه می‌باشد که از درجه یک یا خوش‌خیم تا درجه ۵ یا بدخیم برچسب‌گذاری شده است. به‌عبارتی پنج کلاس و در هر کلاس ۳۰۰ تصویر و در مجموع ۱۵۰۰ تصویر در اختیار داریم. که ۱۲۰۰ نمونه آموزشی و ۳۰۰ نمونه آزمایشی است. ده درصد از کل نمونه آموزش یعنی ۱۲۰ نمونه به‌عنوان داده اعتبارسنجی استفاده شده است. همچنین، عملکرد مدل بر روی داده‌های اعتبارسنجی به صورت دوره‌ای ارزیابی می‌شود. اگر عملکرد مدل بر روی داده‌های اعتبارسنجی برای ۱۰ دوره متوالی بهبود نیابد، آموزش متوقف می‌شود. ابعاد این تصاویر ۱۰۲۴×۱۰۲۴ به‌صورت رنگی است. شکل ۴ نمونه‌ای از تصاویر موجود در پایگاه داده‌ی ISUP را نشان می‌دهد.

جدول ۲: الگوریتم یا شبه کد روش پیشنهادی

1: Inputs:
2: $I = \{I_1, I_2, ..., I_n\}$: Set of n images.
3: Training data
4: $X = [x_1, x_2, \ldots, x_m]$.
5: Training class labels
6: $Y = [y_1, y_2, \ldots, y_m]$.
7: Testing data
8: $Z = [z_1, z_2, \ldots, z_p]$.
9: Training process:
10: Training modelResNet-50 with X , Y data.
11: Training modelVGG-16 with X , Y data.
12: Training modelVGG-19 with X , Y data.
13: Testing process:
14: A = Predict(modelResNet-50, Z)
15: B = Predict(modelVGG-16, Z)
16: C = Predict(modelVGG-19, Z)
17: Output 1 : Majority Voting
A_1 = Arg. {max (A)};
B_1 = Arg. {max (B)};
C_1 = Arg. {max (C)};
18: D_1 = mode (A_1, B_1 ,C_1)
19: Output 2 : Unweighted Averaging
$E_1 = (A+B+C) / 3$;
20: E_2 = Arg. {Max (E_1)};
21: 18 and 20 will be compared with each other.



شکل ۴: پنج نمونه از تصاویر موجود پایگاه داده‌ی ISUP از درجه ۱ تا درجه ۵ به ترتیب از چپ به راست.

۵-۲- معیارهای ارزیابی

یکی از ابزارهای ارزیابی سیستم‌های طبقه‌بند، ماتریس درهم‌ریختگی[19] می‌باشد. هر سطر و هر ستون از این ماتریس، مربوط به یک طبقه از داده‌ها است. در هر سطر، مشخص می‌شود که سیستم چه تعداد از داده‌های ورودی را به چه طبقه‌ای نسبت داده است. اگر سیستم، طبقه‌ی تمام داده‌ها را درست تخمین بزند، ماتریس درهم‌ریختگی قطری بوده و سایر عناصر غیر از قطر اصلی صفر خواهند بود. هر چه ماتریس به ماتریس قطری نزدیک‌تر باشد، سیستم عملکرد دقیق‌تری داشته است. لذا برای روش پیشنهادی، ماتریس درهم‌ریختگی محاسبه می‌شود تا عملکرد سیستم مورد

ارزیابی قرار گیرد [۲۷-۲۶].

عملکرد مدل‌ها در بحث طبقه بندی با استفاده از پارامترهایی ذیل، مورد سنجش و ارزیابی قرار می‌گیرد که از قبیل دقت، حساسیت، ویژگی، صحت، امتیاز F1 به شرح زیر است [۲۸].

دقت رایج‌ترین شاخص ارزیابی است. دقت، نسبت پیش‌بینی‌های صحیح بر تعداد کل پیش‌بینی‌ها است. هر چه درصد این پارامتر بالاتر باشد ، عملکرد طبقه بندی‌کننده بهتر است.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (۲)$$

پارامترهای سنجش از قبیل حساسیت و ویژگی به ترتیب توانایی طبقه‌بندی‌کننده در تشخیص مثال‌های مثبت و منفی را اندازه‌گیری می‌کنند. هر چه مقدار بزرگتر باشد، عملکرد تشخیص بالاتر است. پارامتر حساسیت بیان می‌کند از بین همه موارد مثبت واقعی، چند مورد را به عنوان مثبت پیش‌بینی کرده است و همچنین پارامتر ویژگی بیان می‌کند، از بین همه موارد منفی واقعی، چه تعداد را به عنوان منفی پیش‌بینی کرده است.

$$Sensitivity = Recall = \frac{TP}{TP + FN} \quad (۳)$$

$$Specificity = \frac{TN}{TN + FP} \quad (۴)$$

پارامتر دیگر صحت می‌باشد. که این پارامتر به ما نشان می‌دهد که از بین همه موارد مثبت پیش‌بینی شده، چند مورد واقعاً مثبت بودند. که به صورت زیر تعریف می‌شود:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (۵)$$

پارامتر مهم دیگری به نام (معیار F1) وجود دارد که برای ارزیابی عملکرد دسته‌بندها بسیار مورد استفاده قرار می‌گیرد و از ترکیب دو پارامتر حساسیت و صحت حاصل می‌شود. که به صورت زیر تعریف می‌شود:

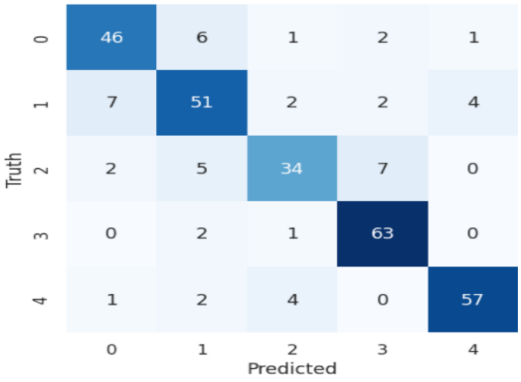
$$F1_{_Score} = \frac{2 * \text{Precision} * Recall}{\text{Precision} + Recall} \quad (۶)$$

- TP :نمونه عضو دسته مثبت باشد و عضو همین کلاس تشخیص داده شود(True Positive)
- FN :نمونه عضو کلاس مثبت باشد و عضو کلاس منفی تشخیص داده شود(False Negative)
- TN :نمونه عضو کلاس منفی باشد و عضو همین کلاس تشخیص داده شود(True Negative)
- FP : نمونه عضو کلاس منفی باشد و عضو کلاس مثبت تشخیص داده شود (False Positive).

۵-۳- نتایج

ابتدا به ترتیب عملکرد هر سه مدل شبکه‌های عصبی مورد ارزیابی قرار می‌گیرد و نهایتا عملکرد روش پیشنهادی، به وضوح نشان خواهد داد که یادگیری گروهی عمیق نتایج بسیار چشمگیری نسبت به یادگیری عمیق خواهند داشت.

ابتدا در شکل ۵، ماتریس درهم‌ریختگی شبکه عصبی باقیمانده ResNet-۵۰ مشاهده می‌شود. همان‌طور که مشخص می‌باشد اکثر طبقه‌بندی اشتباه در درجه‌های ۱ و ۲ که بافت‌های غیر سرطانی و تقریبا مشابه می‌باشند به اشتباه در کلاس یکدیگر پیش‌بینی شده است.



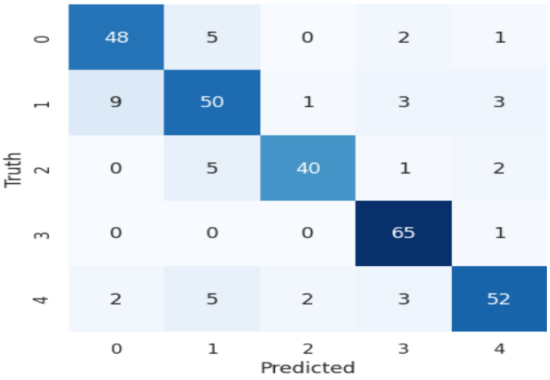
شکل ۵: ماتریس درهم ریختگی مدلResNet۵۰

در شکل ۶، نمودار پارامترهای خطا و دقت مدل، در مرحله آموزش و اعتبارسنجی را نشان می‌دهد.

در شکل ۷، ماتریس درهم‌ریختگی شبکه عصبی VGG۱۶ و در شکل ۸، پارامترهای خطا و دقت این مدل در مرحله آموزش و اعتبارسنجی، و نیز در شکل ۹، ماتریس درهم‌ریختگی شبکه عصبی VGG۱۹ و همچنین در شکل ۱۰، پارامترهای خطا و دقت این مدل در مرحله آموزش و اعتبارسنجی، مشاهده خواهد شد. در شکل‌های ۱۱ و ۱۲ بترتیب ماتریس درهم‌ریختگی روش پیشنهادی، ترکیب یادگیری عمیق با قاعده رای‌گیری و قاعده میانگین‌گیری نمایش داده شده است. که این ماتریس به وضوح بیانگر این است که دقت طبقه‌بند در روش پیشنهادی بهتر خواهد بود.



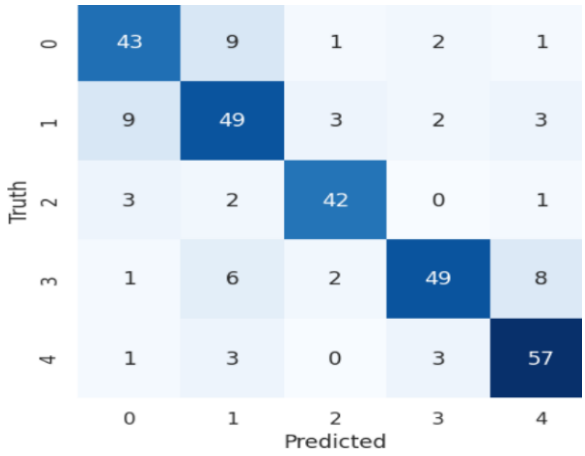
شکل ۶: نمودار loss و accuracy مدل ۵۰-ResNet در مرحله آموزش



شکل ۷: ماتریس درهم ریختگی مدل VGG۱۶



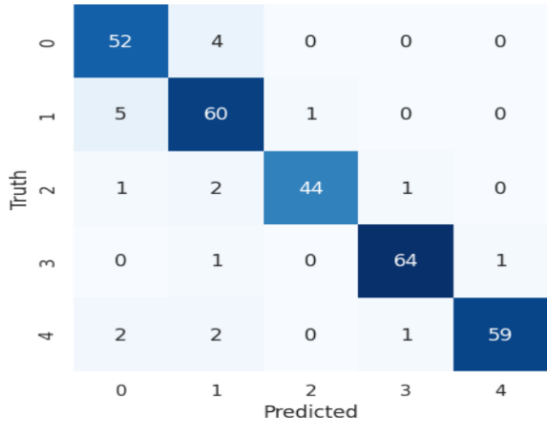
شکل ۸: نمودار loss و accuracy مدل VGG۱۶ در مرحله آموزش



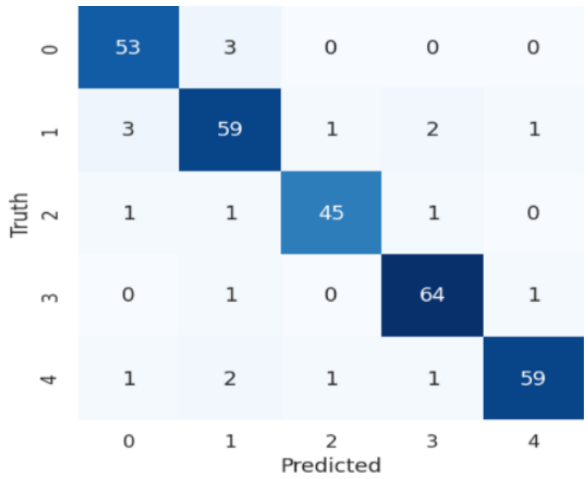
شکل ۹ : ماتریس درهم ریختگی مدل VGG۱۹



شکل ۱۰: نمودار loss و accuracy مدل VGG۱۹ در مرحله آموزش



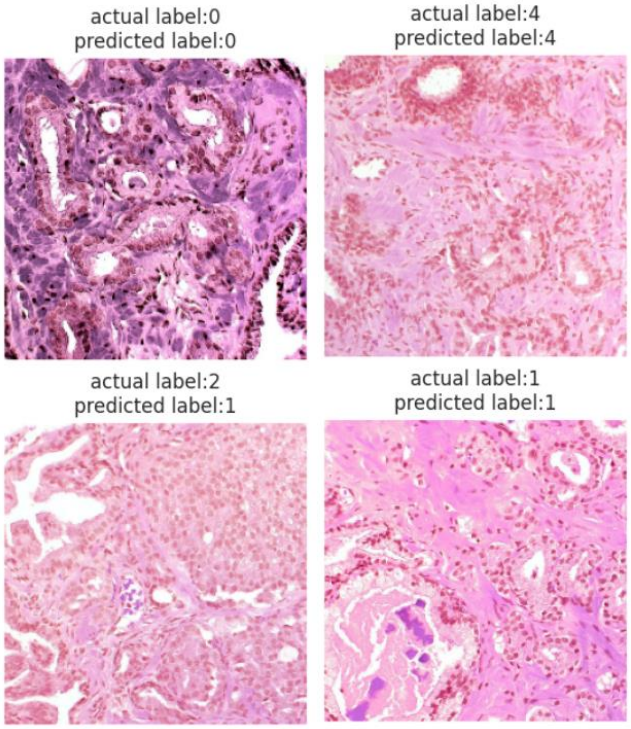
شکل ۱۱: ماتریس درهم ریختگی روش پیشنهادی، ترکیب یادگیری عمیق با قاعده رای‌گیری



شکل ۱۲: ماتریس درهم ریختگی روش پیشنهادی، ترکیب یادگیری عمیق با قاعده میانگین‌گیری

شکل ۱۳، تعدادی از نمونه‌های آزمایش که با برچسب واقعی یا درست و برچسبی که مدل به نمونه ورودی نسبت داده یا پیش بینی کرده، نشان داده شده است.

در جدول ۳، مقایسه معیارهای ارزیابی طبقه‌بندی روش‌های پیشنهادی با دیگر روش‌ها بیان شده است. همانطور که به وضوح مشخص می‌باشد روش‌های پیشنهادی دقت بالاتری نسبت به دیگر روش‌ها دارد.



شکل ۱۳: برخی از نمونه‌های آزمایش که مدل به درستی یا به‌اشتباه، به نمونه‌های تست برچسب زده است

جدول ۳: مقایسه انواع معیارهای ارزیابی دو مدل روش پیشنهادی با دیگر روش‌ها

مدل‌های متفاوت شبکه عصبی پیچشی	حساسیت Recall	ویژگی Specificity	صحت Precision	F1-Score	دقت Accuracy
ResNet-۵۰	٪ ۸۳/۶۷	٪۹۵/۹۲	٪ ۸۳/۶۷	٪ ۸۳/۶۷	٪۹۳/۴۷
VGG۱۶	٪۸۵	٪۹۶/۲۵	٪۸۵	٪۸۵	٪۹۴
VGG۱۹	٪۸۰	٪۹۵	٪۸۰	٪۸۰	٪۹۲
[5] Sezavar at el.(2019) روش ترکیب ویژگی عمیق با ویژگی‌های بافت و آماری	٪ ۸۶/۱۳	٪ ۹۶/۵۵	٪ ۸۶/۱۳	٪ ۸۶/۱۳	٪ ۹۴/۴۷
[8] Rovčanin at el.(2022) روش شبکه عصبی مصنوعی پیش‌خور	٪۹۵/۶۲	٪۷۰	٪۹۶/۲۲	٪۹۵/۹۱	٪۹۲/۷۷
[9] Huang at el.(2022) روش ترکیب ویژگی عمیق با هفت ویژگی آماری	٪۹۷/۲۷	٪۹۳/۶۴	–	–	٪۹۵/۴۵
[10] Melo at el.(2021) روش شبکه عصبی پیچشی inception_V3	–	–	–	–	٪۹۱/۲
روش پیشنهادی، ترکیب یادگیری عمیق با روش رای‌گیری حداکثری	**٪۹۳**	**٪ ۹۸/۲۵**	**٪۹۳**	**٪۹۳**	**٪۹۷/۲**
روش پیشنهادی، ترکیب یادگیری عمیق با روش میانگین‌گیری بدون وزن	**٪ ۹۳/۳۳**	**٪ ۹۸/۳۳**	**٪ ۹۳/۳۳**	**٪ ۹۳/۳۳**	**٪ ۹۷/۳۳**

۵-۴- بحث

نتایج بررسی‌ها و شبیه‌سازی‌ها نشان دادند که روش پیشنهادی نسبت به بقیه مراجع و روش‌ها، دقت و صحت بهتری دارد. روش پیشنهادی در مقایسه با مرجع ۵ که در آن از ترکیب در سطح ویژگی استفاده شده است، عملکرد بهتری دارد؛ زیرا در مرجع ۵ ، برای استخراج ویژگی از ویژگی‌های آماری و بافتی در کنار شبکه AlexNet استفاده شده است و طبقه بندی توسط طبقه‌بند بیزین انجام شده است در حالی که در روش پیشنهادی، هم استخراج ویژگی و هم طبقه‌بندی با ترکیب سه شبکه عمیق جدید انجام شده است. در مقایسه با مرجع ۸ که از شبکه عصبی پیش‌خور استفاده کرده است به وضوح مشخص است که عملکرد و نتیجه دقت و صحت، شبکه‌های عصبی عمیق بهتر از شبکه‌های عصبی پیش‌خور است. در مقایسه با مرجع ۹ که در آن از ترکیب ویژگی شبکه‌های عصبی عمیق و هفت ویژگی آماری (غیرعمیق) استفاده شده است، روش پیشنهادی کارایی بهتری دارد؛ زیرا استفاده از سه شبکه عصبی عمیق می‌تواند ویژگی‌های موثرتری را استخراج کند. همچنین در تصمیم گیری نیز ترکیب طبقه‌بندها کارایی بهتری دارد؛ زیرا استفاده از دو معیار میانگین‌گیری یا رای گیری سبب می‌شوند که بهترین تصمیم از بین نتایج سه شبکه استخراج شود. در مراجع۸ و ۹ معیارهای ارزیابی حساسیت و ویژگی و صحت بالاتر بوده به این علت می‌باشد که در تمامی این پژوهش‌ها مسئله دو کلاسه می‌باشد ولی در این پژوهش مسئله طبقه‌بندی پنج کلاسه می‌باشد. با این تفاسیر الگوریتم‌های پیشنهادی قادر بوده نرخ دقت طبقه‌بندی را نسبت به دیگر روش‌ها بهبود دهد. علاوه بر آن، در این تحقیق دو قاعده ترکیب میانگین گیری و رای گیری به طور مجزا بررسی شدند. نتایج نشان دادند که قاعده ترکیب میانگین‌گیری، کارایی بهتری نسبت به رای گیری دارد.

۶- نتیجه گیری

در این مقاله، روشی جدید با استفاده از ترکیب شبکه‌های عصبی عمیق برای افزایش دقت کلی یک سیستم طبقه‌بندی تصاویر پاتولوژی سرطان پروستات، ارائه شده است. به‌وضوح مشخص می‌باشد ترکیب طبقه‌بندها عملکرد کلی طبقه‌بندی را، بهبود می‌بخشند. در این پژوهش، قاعده رای اکثریت و قاعده میانگین‌گیری برای تصمیم گیری نهایی نمونه آزمایش به کلاس مربوطه، انجام شده است. نتایج که در جدول ۳ نشان داده شده است، بیانگر این موضوع می‌باشد که روش‌های پیشنهادی ضعف طبقه‌بندها را پوشش داده و با استفاده از قاعده شوراها می‌توان نرخ دقت را به صورت بسیار چشمگیری افزایش داد.

مراجع

[1] S .Tyagi , N. Tyagi, A. Choudhury, G. Gupta, M. Maher Abdul Zahra and S. Ahmed Rahin, "Identification and Classification of Prostate Cancer Identification and Classification Based on Improved Convolution Neural Network" Hindawi BioMed Research International, 2022.

[2] M. Tsuneki, M. Abe and F. Kanavati, "A Deep Learning Model for Prostate Adenocarcinoma Classification in Needle Biopsy Whole-Slide Images Using Transfer Learning" MDPI Journal Diagnostics, vol. 12, no.3, pp. 768-779, 2022.

[3] J. M. Castillo T, M. Arif, W. J. Niessen, I. G. Schoots and J. F. Veenland, "Automated Classification of Significant Prostate Cancer on MRI: A Systematic Review on the Performance of Machine Learning Applications" MDPI Journal Cancers, vol. 3, no. 2, pp. 45-56, 2020.

[4] A. H. M. Linkon, Md. M. Labib, T. Hasan, M. Hossain and M. Jannat, "Deep learning in prostate cancer diagnosis and Gleason grading in histopathology images: An extensive study" Informatics in Medicine Unlocked Published by Elsevier Ltd, 2021.

[۵] امیر سزاوار، حسن فرسی، فریما فرسی " طبقه‌بندی و تشخیص درجه‌ی بدخیمی سرطان پروستات با استفاده از ترکیب ویژگی‌های عمیق و ویژگی‌های آماری بافت تصاویر پاتولوژی"، مجله مهندسی پزشکی زیستی، دوره ۱۲، شماره ۴، صفحه ۳۵۵-۳۴۱، زمستان ۱۳۹۷.

[6] P. Khosravi, M. Lysandrou, M. Eljalby, Q. Li, E. Kazemi, P. Zisimopoulos, A. Sigaras, M. Brendel, J. Barnes, C. Ricketts, D. Meleshko, A. Yat, T. D. McClure, B. D. Robinson, A. Sboner, O. Elemento, B.Chughtai, and I. Hajirasouliha, "A Deep Learning Approach to Diagnostic Classification of Prostate Cancer Using Pathology–Radiology Fusion" Journal of Magnetic Resonance Imaging published by Wiley Periodicals LLC, vol. 2, no. 3, pp: 462-471, 2021.

[۷] صابر فولادی، حسن فرسی، سجاد محمدزاده ، "استفاده از شبکه‌های عصبی یادگیری عمیق در تشخیص درجه بدخیمی سرطان پروستات و تشخیص سرطان سینه"، مجله دانشکده پزشکی دانشگاه علوم پزشکی مشهد، صفحه ۱۱۸۷-۱۱۷۸، سال ۶۱ و شماره ۵، آذر-دی۱۳۹۷.

[8] A. Rovčanin, S. Skopljak, S. Suleiman, A. Smajović, E. Bečić, F. Bečić, L. Spahić Bećirović and L. Gurbeta "Application of artificial intelligence in diagnosis and therapy of prostate cancer" IFAC PapersOnLine, , Vol. 55, no. 4, pp: 74-79, 2022.

[9] X. Huang, Z. Li, M. Zhang and S. Gao, "Fusing hand-crafted and deep-learning features in a convolutional neural network model to identify prostate cancer in pathology images" Frontiers in Oncology Journal, vol. 12, no. 3, pp: 212-225, 2022.

[10] P.A. S. Melo, C. L. N. Estivallet, M. Srougi, W.C.Nahas, K. R.M. Leite, "Detecting and grading prostate cancer in radical prostatectomy specimens through deep learning techniques" Clinics journal, Vol.76, pp: 1-5, 2021.

[11] M. A. Ganaiea, M. Hu, A.K. Malik, M. Tanveer and P.N. Suganthan "Ensemble deep learning: A review" Engineering Applications of Artificial Intelligence, vol. 115, no. 2, pp: 105-151, 2022.

[12] Aurélien Géron "Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow" THIRD EDITION, Published by O'Reilly Media, 2022.

[13] R. Fogarty, D. Goldgof , L. Hall, A. Lopez, J. Johnson, M. Gadara, R. Stoyanova, S. Punnen, A. Pollack, J. Pow-Sang and Y. Balagurunathan "Classifying Malignancy in Prostate Glandular Structures from Biopsy Scans with Deep Learning" MDPI Cancers Journal, vol. 15, no. 8, pp:1-19, 2023.

[14] D. KARIMI, H. DOU and A. GHOLIPOUR "Medical Image Segmentation Using Transformer Networks" IEEE Access Journal, vol. 10, no. 3, pp: 29322- 29332, 2022.

[15] Y. Djenouri, A. Belhadi, A, Yazidi, G. Srivastava and J. Chun-Wei Lin "Artificial intelligence of medical things for disease detection using ensemble deep learning and attention mechanism" Expert Systems Journal, vol. 45, no. 4, pp: 33-46, 2022.

[16] Zh. Tao, L. Huiling, Y. Zaoli, Q. Shi, H. Bingqiang and D. Yali "The ensemble deep learning model for novel COVID-19 on CT images" Applied Soft Computing Journal, vol. 98, no. 5, pp: 198-211, 2021.

[17] Z. H. Kilimci and S. Akyokus "Deep Learning- and Word Embedding-Based Heterogeneous Classifier Ensembles for Text Classification" Hindawi Complexity Journal, vol. 34, no. 3, pp. 35-46, 2018.

[18] D. MÜLLER, I. SOTO-REY and F. KRAMER "An Analysis on Ensemble Learning Optimized Medical Image Classification With Deep Convolutional Neural Networks" IEEE Access Journal, vol. 10, no. 2, pp: 66467- 66480, 2022.

[19] X. ZHANG, D. HE, Y. ZHENG, H. HUO, S. LI, R. CHAI and T. LIU "Deep Learning Based Analysis of Breast Cancer Using Advanced Ensemble Classifier and Linear Discriminant Analysis" IEEE Access Journal, Vol. 8, no. 2, pp: 120208- 120217, 2020.

[20] S.Yoo, I. Gujrathi, M. A. Haider and F. Khalvati "Prostate Cancer Detection using Deep Convolutional Neural Networks" nature research Scientific Reports Journal, vol. 9, no. 1, pp. 33-47, 2019.

[21] Y. Tolkach, T. Dohmgörgen , M. Toma and G. Kristiansen "High-accuracy prostate cancer pathology using deep learning" Nature Machine Intelligence Journal,vol. 14, no. 2, pp: 411-418, 2020.

[22] I. Bhattacharya, Y. S. Khandwala, S. Vesal, W. Shao, Q. Yang, S. J.C. Soerensen, R. E. Fan, P. Ghanouni, C. A. Kunder, J. D. Brooks, Y. Hu, M. Rusu and G. A. Sonn "A review of artificial intelligence in prostate cancer detection on imaging" SAGE Journals, Therapeutic Advances in Urology, vol. 14, no. 1, pp: 1–31, 2022.

[23] P. Ambrosini, E. Hollemans, Ch. F. Kweldam , G. J. L. H. van Leenders, S. Stallinga1 and F.Vos "Automated detection of cribriform growth patterns in prostate histology images" nature research Scientific Reports Journal, vol. 10, no. 1, pp: 41-52, 2020.

[24] P. A. de Souza Melo, C. L. N. Estivallet, M. Srougi, W. C. Nahas and K. R. Moreira Leite "Detecting and grading prostate cancer in radical prostatectomy specimens through deep learning techniques" Clinics Journal, vol. 76, no. 3, pp: 33-45, 2021.

[25] Site of International Society of Urological Pathology, Available: https://isupweb.org/isup/.

[۲۶] فاطمه محمودی، فرساد زمانی بروجنی"بازیابی تصاویر پزشکی ریه با استفاده از درهم سازی با ناظر، انتخاب ویژگی mRMR و شبکه‌های عصبی کانولوشنی عمیق"مجله علمی پژوهشی رایانش نرم و فناوری اطلاعات دانشگاه صنعتی نوشیروانی بابل،جلد۱۱، شماره۴، صفحه ۱۸-۱ زمستان۱۴۰۱.

[۲۷] رضا نصیری‌پور، حسن فرسی ، سجاد محمدزاده" شناسایی شی برجسته در پیش‌بینی تمرکز نگاه با استفاده از یادگیری عمیق" مجله علمی پژوهشی رایانش نرم و فناوری اطلاعات دانشگاه صنعتی نوشیروانی بابل، جلد۹، شماره۳، صفحه ۱۰۸-۹۳، پاییز ۱۳۹۹.

[28] D. Ahmed Alkurdi, M. Ilyas and A.Jamil "Cancer detection using deep learning techniques" Evolutionary Intelligence Springer Link, July2021.

پاورقی‌ها

[1] Prostatitis
[2] Prostate Specific Antigen
[3] International Society Urological Pathology
[4] Gleason
[5] Deep Learning
[6] Restricted Boltzmann Machines
[7] Sparse Coding
[8] Autoencoder
[9] Convolutional Neural Networks
[10] Residual Neural Networks
[11] Transfer Learning
[12] Overfitting
[13] Fully-Connected
[14] Ensemble Deep learning
[15] Unweighted Averaging
[16] Majority Voting
[17] Data Augmentation
[18] Dense Layer
[19] Confusion Matrix