

تشخیص بیماری‌های ماکولای چشم از روی تصاویر OCT

رضا مختاری^{۱*}، مریم محمدی^۲ و محدثه رمضانی^۳

^۱دانشکده علوم ریاضی، دانشگاه صنعتی اصفهان، اصفهان ۸۴۱۵۶۸۳۱۱۱، ایران، mokhtari@iut.ac.ir

^۲دانشکده علوم ریاضی، دانشگاه صنعتی اصفهان، اصفهان ۸۴۱۵۶۸۳۱۱۱، ایران، mohammadi.maryam@math.iut.ac.ir

^۳دانشکده علوم ریاضی، دانشگاه صنعتی اصفهان، اصفهان ۸۴۱۵۶۸۳۱۱۱، ایران، mohadeseh.ramezani@alumni.iut.ac.ir

*سرپرست تیم

چکیده - در این پروژه قصد داریم به تشخیص بیماری ماکولای چشم از روی تصاویر توموگرافی انسجام نوری (OCT) بر اساس یادگیری انتقالی بپردازیم. از این رو، پس از انجام پیش‌پردازش‌های لازم روی تصاویر و بررسی شبکه‌های عصبی پیچشی موجود، توسیعی از مدل ResNet-50 را همراه با توابع فعال‌ساز جدید پیشنهاد می‌دهیم. شبکه پیشنهادی همراه با تکنیک‌های مختلفی جهت جلوگیری از بیش‌برازش مدل و حل مشکل انفجار گرادیان، یک خط لوله (Pipeline) جدید تشکیل می‌دهد. سپس به کمک این خط لوله به طبقه‌بندی تصاویر OCT می‌پردازیم. روش پیشنهادی قادر است تصاویر مربوط به افراد سالم را از داده‌های مربوط به بیماران مبتلا به ماکولای چشم با دقت بسیار خوبی تشخیص دهد. همچنین تشخیص تصاویر بیماری ماکولای چشم دیابتی از نوع غیردیابتی نیز به کمک این مدل با دقت خوبی قابل انجام است.

کلید واژه- توموگرافی انسجام نوری، طبقه‌بندی، مدل Resnet توسعه یافته، یادگیری انتقالی

۱- مقدمه

یادگیری انتقالی در شبکه‌های عمیق، یک ابزار تشخیص برای غربال‌گری بیماران مبتلا به بیماری‌های شبکه‌ای ارائه دادند. در [3]، با توجه به بزرگ بودن شبکه‌های پیچشی، یک شبکه عصبی پیچشی Lightweight مبتنی بر یادگیری انتقالی برای طبقه‌بندی رتینوپاتی دیابتی (Diabetic Retinopathy) و ورم ماکولای دیابتی (Diabetic Macular Edema) توسعه داده شد که از شبکه ShuffleNet-V2 به عنوان نمونه اولیه شبکه پیشنهادی استفاده شده است. به تازگی، یک مدل یادگیری انتقالی چندگانه با استفاده از شبکه‌های AlexNet2، InceptionV3، ResNet-50 و DenseNet-121 برای پیش‌بینی بیماری‌های چشم پیشنهاد شده است [4]. در این پروژه قصد داریم با طراحی یک Pipeline مبتنی بر یادگیری انتقالی، به تشخیص بیماری ماکولای چشم از روی تصاویر OCT بپردازیم. این Pipeline شامل سه بخش اصلی پیش‌پردازش داده‌ها، مدل‌سازی و همچنین پیاده‌سازی است که در ادامه به تشریح آن می‌پردازیم.

۲- پیش‌پردازش داده‌ها

ابتدا پردازش‌های زیر روی تصاویر اولیه انجام شده است:

۱) **نرمال کردن داده‌های ورودی:** برای نشان دادن اهمیت نرمال کردن داده‌های ورودی، ابتدا یک شبکه عصبی تک‌لایه با دو ورودی را بررسی کردیم به طوری که مقدار ورودی اول در بازه (0,1) و مقدار ورودی دوم در بازه (0,0.001) در نظر گرفته شدند. چون شبکه وظیفه یادگیری نحوه ترکیب این ورودی‌ها را از طریق یک سری ترکیبات خطی و توابع فعال‌ساز غیرخطی برعهده دارد، پارامترهای مرتبط با هر ورودی نیز در مقیاس‌های مختلف وجود خواهند داشت. این امر می‌تواند اثر برخی پارامترها را روی گرادیان تابع زیان افزایش دهد که این خود جهت‌گیری شبکه نسبت به آن پارامترها را به همراه دارد. از طرفی به

در سال‌های اخیر بیماری‌های مربوط به شبکه چشم انسان به سرعت در حال رشد هستند. از طرفی، در بیشتر بیماران دیابتی بیماری‌های شبکه تا مراحل پیشرفته بی‌علامت هستند که این موضوع سبب کاهش کیفیت زندگی بیماران و افزایش هزینه‌های نظام سلامت می‌شود. بنابراین، به ابزارهایی برای تشخیص زودهنگام بیماری‌های شبکه نیاز است که بررسی دقیق‌تری را در مقایسه با چشم غیرمسلح انجام دهند. یکی از این ابزارها توموگرافی انسجام نوری یا OCT است که در سال ۱۹۹۱ توسط هانگ (Haung) معرفی شد و امروزه به عنوان یک روش تصویربرداری نوری نوین سریع و غیرتهاجمی در اپتیک به کار می‌رود. به عبارتی، OCT با اندازه‌گیری پژواک نور پس‌پراکنده، تصویربرداری مقطعی و با وضوح بالا از ریزساختارهای داخلی در بافت‌ها انجام می‌دهد [1]. بنابراین، در اندام‌هایی مانند چشم انسان که تشخیص بافت میکروسکوپی با استفاده از نمونه‌برداری یا بیوپسی در دسترس نیست، استفاده از این ابزار برای تشخیص بیماری‌های مرتبط با شبکه می‌تواند بسیار مفید باشد. پزشک متخصص با استفاده از تصاویر OCT می‌تواند با بررسی مقاطع توموگرافیک از لایه‌های مختلف شبکه، بیماری را تشخیص دهد. با این حال، بررسی حجم وسیعی از تصاویر بسیار زمان‌بر و پیچیده است و ممکن است همراه با خطا باشد. از این رو، به روش‌هایی نیاز است که به پزشک متخصص در افزایش دقت تشخیص کمک کنند. در سال‌های اخیر، روش‌های مبتنی بر هوش مصنوعی به عنوان ابزارهای کمک‌کننده به پزشکان در تشخیص بیماری‌های ماکولای چشم نقش قابل‌توجهی ایفا کرده‌اند. تاکنون، مطالعات فراوانی برای تشخیص و طبقه‌بندی بیماری‌های ماکولای چشم با استفاده از روش‌های یادگیری عمیق انجام شده است. در سال ۲۰۱۸، کرمانی و همکاران [2] با بهره‌گیری از رویکرد


استفاده کرده‌اند [5]. شبکه‌های VGG, ResNet و MobileNet از جمله شبکه‌های پیچشی هستند که به طور گسترده برای طبقه‌بندی تصاویر پزشکی مانند طبقه‌بندی نمونه‌های پنومونی (ذات‌الریه) از روی تصاویر اشعه ایکس قفسه سینه [6]، تشخیص تومور پروستات [7]، تشخیص بیماری آلزایمر و طبقه‌بندی ضایعات پستان [8] به کار می‌روند.

یکی از چالش‌هایی که بیشتر مواقع در یادگیری عمیق با آن مواجه هستیم، کمبود داده‌های کافی برای آموزش شبکه است. هنگامی که داده‌های کافی برای آموزش شبکه در دسترس نباشد، یادگیری انتقالی به عنوان راه حل مناسب انتخاب می‌شود. یادگیری انتقالی روشی است که از دانش یک مدل آموزش‌دیده برای داده‌های دیگر استفاده می‌کند. در حقیقت، یادگیری انتقالی با بهره‌گیری از اطلاعات حوزه مبدأ و وظایف یادگیری به دنبال تقویت یادگیری در حوزه هدف است [11]. اگر از یک شبکه پیچشی با پارامترها (وزن‌های) از پیش آموزش‌دیده استفاده کنیم، دیگر نیازی به در نظر گرفتن تصادفی وزن‌های اولیه شبکه نداریم زیرا مدل‌های از پیش آموزش‌دیده بر روی داده‌های بزرگی همچون ImageNet آموزش دیده‌اند که این موضوع می‌تواند به بهبود عملکرد شبکه کمک کند.

در اینجا ابتدا به توضیح مختصری از شبکه باقیمانده (Network Residual) می‌پردازیم و سپس شبکه پیشنهادی خود را معرفی خواهیم کرد. شبکه باقیمانده که به اختصار شبکه ResNet نامیده می‌شود، در سال ۲۰۱۵ توسط Kaiming و همکاران معرفی شد [9]. این شبکه با دارا بودن بلوک باقیمانده (Residual Block) و Skip Connection، مشکلاتی مربوط به دقت کم شبکه‌های عمیق را حل می‌کند و به دقت بالاتری منجر می‌شود. در این پروژه، با بررسی نتایج شبکه‌های بسیار زیادی مانند ResNet-18، ResNet-50، VGG-16، MobileNet-V2 و MobileNet-V3-Large، ویرایش تغییر یافته‌ای از شبکه ResNet-50 را برای کار روی تصاویر توموگرافی انسجم نوری پیشنهاد می‌دهیم.

ساختار شبکه ResNet-50 کلاسیک:


شبکه ResNet-50 شامل شش ماژول Conv1، Conv2_x، Conv3_x، Conv4_x، Conv5_x و لایه تمام متصل است. Conv5_x و Conv4_x به ترتیب دارای ۳، ۴ و ۶ بلوک باقیمانده هستند. شکل ۱ ساختار کلی این شبکه را نشان می‌دهد.



شکل ۲: ساختار شبکه ResNet50 کلاسیک

دلیل تفاوت مقادیر در دو ورودی اولیه، یک ورودی به نرخ یادگیری بزرگتر و دیگری به نرخ یادگیری کوچکتری نیاز دارد. از این رو انتخاب یک نرخ یادگیری برای آموزش شبکه، به پرس‌های بیشتر در نمودار و افزایش تعداد تکرارهای لازم برای رسیدن به هدف منجر خواهد شد. بنابراین، با نرمال‌سازی تمام ورودی‌ها در مقیاس استاندارد، به شبکه اجازه می‌دهیم تا با سرعت بیشتری پارامترهای بهینه را برای هر ورودی آموزش ببیند و حرکت ما به سمت نقطه بهینه هموارتر خواهد شد.

۲) متعادل‌سازی داده‌ها: از مسائل پرکاربرد در زمینه یادگیری ماشین به ویژه یادگیری عمیق، می‌توان به طبقه‌بندی اشاره کرد. طبقه‌بندی یک روش یادگیری با نظارت است که در آن، مدل سعی می‌کند برچسب‌های صحیح داده‌های ورودی را پیش‌بینی کند. در مسائل طبقه‌بندی، تعداد داده‌های یکی از کلاس‌های هدف اغلب بسیار کمتر از سایر کلاس‌ها است. به این نوع از داده‌ها، نامتعادل گفته می‌شود. در مطالعات تشخیص پزشکی، طبقه‌بندی نامتعادل یک چالش رایج است. با توجه به داده‌های مربوط به تصاویر توموگرافی انسجم نوری، تعداد افراد سالم بیشتر از افراد مبتلا به ورم ماکولای دیابتی (DME) و بیماران غیردیابتی با اختلالات نئوواسکولاریزیشن کروئیدال (CNV)، تخریب ماکولای وابسته به سن (AMD) و سوراخ ماکولا (MH) است.



شکل ۱: توزیع نامتعادل داده‌ها

برای رفع مشکل نامتعادل بودن داده‌ها، می‌توان به دو تکنیک Oversampling و Undersampling اشاره کرد. با توجه به تعداد کم داده‌های اولیه، در اینجا از روش Oversampling استفاده می‌کنیم. در این روش با ایجاد نمونه از دسته با داده کمتر، توازن دسته‌ها برقرار خواهد شد.

۲-۱- مدل پیشنهادی

شبکه‌های عصبی پیچشی دسته‌ای از روش‌های یادگیری عمیق هستند که از بنیانی حیوانات الهام گرفته شده‌اند. این شبکه‌ها با هدف یادگیری خودکار از طریق پس‌انتشار، از بلوک‌های متعددی مانند لایه‌های پیچشی، لایه‌های ادغام و لایه‌های تمام متصل طراحی شده‌اند. در زمینه تشخیص تصاویر پزشکی، شبکه‌های پیچشی به عنوان یک ابزار قدرتمند مورد توجه بسیاری قرار گرفته‌اند و امروزه محققان از آن‌ها در تشخیص بسیاری از بیماری‌ها از جمله تشخیص انواع تومورها، تشخیص ضایعات پوستی، تشخیص تصاویر توموگرافی انسجم نوری، تشخیص انواع سرطان‌ها و ناهنجاری‌های مربوط به قلب و قفسه سینه

شبکه ResNet پیشنهادی:

توابع فعال‌ساز بخش مهمی از شبکه‌های عمیق را تشکیل می‌دهند. این توابع وظیفه اضافه کردن غیرخطی بودن را به شبکه‌ها بر عهده دارند. در واقع توابع فعال‌ساز براساس ورودی‌هایی که دریافت می‌کنند، در مورد فعال کردن یک نورون تصمیم می‌گیرند. توابع فعال‌ساز مختلفی در مدل‌های یادگیری عمیق به کار برده می‌شوند. یکی از توابع فعال‌سازی که در بیشتر شبکه‌های پیچشی از جمله شبکه ResNet-50 به کار می‌رود، تابع فعال‌ساز Rectified Linear Unit (ReLU) است (شکل ۱). تابع ReLU از نظر محاسباتی کارآمد است و مشکل ناپدید شدن گرادیان که در برخی از توابع فعال‌ساز مانند Sigmoid و Hyperbolic Tangent رخ می‌دهد را ندارد. از این رو در بسیاری از شبکه‌ها مورد استفاده قرار می‌گیرد و بسیار محبوب است. با این حال، تابع ReLU از مشکل Dying ReLU رنج می‌برد. تابع Leaky ReLU توسعه‌یافته تابع فعال‌ساز ReLU است که به جای برگرداندن مقدار صفر برای ورودی‌های منفی، یک مقدار منفی کوچک برمی‌گرداند. این موضوع به رفع مشکل Dying ReLU کمک می‌کند. در حقیقت، تابع Leaky ReLU این امکان را فراهم می‌کند که تمام نورون‌های شبکه بتوانند به خروجی شبکه کمک کنند. در شبکه‌هایی با تعداد زیاد ورودی منفی، تابع فعال‌ساز Leaky ReLU نسبت به ReLU عملکرد بهتری از خود نشان می‌دهد. این تابع می‌تواند به کاهش مشکل بیش‌برازش نیز کمک کند زیرا به جای در نظر گرفتن یک پارامتر شیب ثابت، از یک پارامتر شیب قابل یادگیری استفاده می‌کند [10]. برای طراحی شبکه پیشنهادی، ابتدا در لایه‌های تمام متصل شبکه ResNet-50، تابع فعال‌ساز Leaky ReLU را جایگزین می‌کنیم که نتایج آن به مراتب نسبت به شبکه کلاسیک ResNet-50 بهتر است.

تابع Logsoftmax یک تابع فعال‌ساز مبتنی بر تابع Softmax است که به صورت

$$\text{Logsoftmax}(p_i) = \log \left(\frac{e^{p_i}}{\sum_j e^{p_j}} \right)$$

تعریف می‌شود. این تابع برای مقادیر لگاریتمی به کار می‌رود و به طور کارآمدی مشکل ناپایداری عددی تابع Softmax را حل می‌کند. به ویژه زمانی که احتمالات بسیار کوچک هستند، استفاده از این تابع می‌تواند پایداری عددی را بهبود بخشد و بهینه‌سازی بهتر در طول آموزش شبکه عصبی را فراهم کند. زمانی که در مسائل طبقه‌بندی از این تابع استفاده می‌شود، با جریمه کردن مدل برای کلاس‌هایی که به درستی پیش‌بینی نمی‌کنند، به آموزش بهتر مدل کمک می‌کند. از این رو این تابع را به عنوان لایه انتهایی شبکه پیشنهادی در نظر می‌گیریم.

۳- پیاده‌سازی

در مرحله پیاده‌سازی Pipeline طراحی‌شده، به بررسی دو مشکل بیش‌برازش و انفجار گرادیان می‌پردازیم. در شبکه‌های عصبی عمیق به ویژه شبکه‌های پیچشی عمیق، به دلایلی از جمله عمیق بودن شبکه‌ها (زیاد بودن تعداد لایه‌ها و پارامترها)، کوچک بودن اندازه داده‌های آموزش و داده‌های آموزشی حاوی نویز، با مشکل بیش‌برازش (Overfitting) مواجه خواهیم شد. زمانی که این مشکل اتفاق می‌افتد، مقدار هزینه آموزش بعد از طی کردن دوره‌هایی (Epoch)

هم‌چنان در حال کاهش است، در حالی که مقدار هزینه ارزیابی در حال بزرگ شدن است. در نتیجه شبکه روی داده آموزش عملکرد مناسبی دارد اما روی داده‌های آزمون (یا تست یعنی داده‌هایی که هنوز ندیده است) نمی‌تواند عملکرد خوبی داشته باشد. از این رو در این پروژه، راه‌کارهای زیر را برای رفع این مشکل به کار می‌گیریم تا مدل پیشنهادی ما بتواند به خوبی تعمیمی از داده‌های آموزشی به داده‌های آزمون را یاد بگیرد.

تکنیک حذف تصادفی (Dropout): حذف تصادفی یک تکنیک منظم‌سازی برای مدل‌های شبکه عصبی است که با خاموش کردن برخی نورون‌ها در شبکه (به طبع آن حذف یال‌های متصل به آن‌ها) به ساده‌تر شدن شبکه کمک می‌کند. افزودن Dropout باعث می‌شود که وابستگی مدل به نورون‌های خاص در یک لایه از بین برود و همه نورون‌ها ویژگی‌های مفیدی را در طی زمان آموزش یاد بگیرند که به حل مشکل بیش‌برازش کمک می‌کند.

توقف زودهنگام (Early Stopping): در این تکنیک، در هر تکرار، مقدار تابع زیان روی داده‌های ارزیابی را با بهترین مقدار تابع زیان به دست آمده در طول فرایند آموزش مقایسه می‌کنیم و زمانی که روند نزولی تابع زیان حفظ نشود، تکرارها متوقف می‌شوند. توقف زودهنگام با متوقف کردن یادگیری شبکه در نقطه بهینه سعی می‌کند که خطا را روی داده‌های ارزیابی به حداقل برساند. **تکنیک منظم‌سازی L2:** در این تکنیک منظم‌سازی، با اضافه کردن یک مقدار جریمه به تابع هزینه، سعی می‌شود مقدار تابع هزینه کمینه شود و ساختار کلی تابع هزینه به صورت

$$j(w, b) = \frac{1}{m} \sum_{i=1}^m L(\hat{y}^{(i)}, y^{(i)}) + \frac{\lambda}{2m} \|w\|^2 + \frac{\lambda}{2m} b^2$$



تغییر می‌یابد. در حقیقت با استفاده از این تکنیک، وزن‌ها نسبت به حالت معمول بیشتر کاهش پیدا می‌کنند.

همچنین باید توجه داشت که انفجار گرادیان زمانی به وجود می‌آید که افزایش مقدار مشتق سبب ناپایدار شدن مدل شود. بنابراین، تغییرات تابع زیان رشد زیادی دارد. یکی از روش‌هایی که برای رفع این مشکل در نظر می‌گیریم، روش آستانه‌گذاری مقادیر گرادیان‌ها، قبل از انجام مرحله گرادیان کاهشی یا Gradient Clipping است. در این روش، مقادیر گرادیان خطا در برابر یک مقدار آستانه بررسی می‌شوند و در صورتی که گرادیان خطا از آستانه فراتر رود، مقدار گرادیان به این آستانه محدود می‌شود. در حقیقت در این روش، مشتق خطا در طول پس‌انتشار در شبکه تغییر کرده و از گرادیان‌های بریده شده برای به روزرسانی وزن‌ها استفاده می‌شود.

۴- نتایج

در این بخش نتایج حاصل از پیاده‌سازی مدل پیشنهادی گزارش می‌شود. با استفاده از روش K-fold cross validation ابتدا هایپرپارامترهای مورد نیاز برای آموزش شبکه را تنظیم خواهیم کرد و سپس بعد از مشخص شدن مقدار بهینه برای این هایپرپارامترها، روی کل داده‌ها شبکه را آموزش می‌دهیم. در شکل‌های 3 و 4 نتایج مربوط به فولد اول و پنجم (تابع زیان و دقت مدل پیشنهادی) روی داده‌های آموزش و ارزیابی را بررسی کردیم. با توجه به نتایج، میانگین دقت (مربوط به فولدها) روی داده ارزیابی 99/44% و روی داده آموزش 99/45% بوده است. نتایج نشان می‌دهد که تابع زیان روی داده‌های

ارزیاب به طور هموار کاهش می‌یابد. به عبارتی، رفتار نوسانی شایع دیده نمی‌شود.




شکل 3: تابع زیان و دقت مدل پیشنهادی (روی داده‌های آموزش و ارزیاب) مربوط به فولد اول

شکل 6: ماتریس درهم‌ریختگی


۵- نتیجه‌گیری

در این پروژه یک مدل به منظور تشخیص بیماری‌های ماکولای چشم از روی تصاویر OCT پیشنهاد شده است. این مدل مبتنی بر یادگیری انتقالی و توسیعی کارآمد از شبکه کلاسیک Resnet-50 است که قادر است افراد سالم، افراد با بیماری ماکولای چشم دیابتی و افراد با سایر بیماری‌های ماکولا را با دقت مطلوبی طبقه‌بندی کند. این ادعا بر اساس تجارب قبلی و آزمایشات بسیار متنوعی است که تیم تحقیقاتی در این مدت انجام داده است.



شکل 4: تابع زیان و دقت مدل پیشنهادی (روی داده‌های آموزش و ارزیاب) مربوط به فولد پنجم

همان‌طور که در شکل 5 مشاهده می‌شود مدل بالاترین میزان ارزیابی کمی را داشته است و به عبارتی این منحنی بیانگر عملکرد مطلوبی روی داده‌های ارزیاب است.



شکل 5: منحنی ROC

منابع

- [1] J. Fujimoto and W. Drexler, "Introduction to optical coherence tomography," In Optical coherence tomography: Technology and applications. Berlin, Heidelberg: Springer Berlin Heidelberg., pp. pp. 1-45, 2008.
- [2] D. Kermany, M. Goldbaum, W. Cai, C. Valentim, H. Liang, S. Baxter, A. McKeown, G. Yang, X. Wu, . F. Yan and J. Dong, "Identifying medical diagnoses and treatable diseases by image-based deep learning," *cell*, pp. pp.1122-1131, 2018.
- [3] Z. Lu, J. Miao, J. Dong, S. Zhu, X. Wang and J. Feng, "Automatic classification of retinal diseases with transfer learning-based lightweight convolutional neural network," *Biomedical Signal Processing and Control*, p. p.104365, 2023.
- [4] Y. Kumar and S. Gupta, "Deep transfer learning approaches to predict glaucoma, cataract, choroidal neovascularization, diabetic macular edema, drusen and healthy eyes: an experimental review," *Archives of Computational Methods in Engineering*, pp. 521-541, 2023.

یکی دیگر از معیارهای متداول ارزیابی مدل، بررسی ماتریس درهم‌ریختگی (Confusion Matrix) است. این ماتریس با بررسی مقادیر مثبت/منفی کاذب/واقعی میزان پیش‌بینی مدل روی طبقات مختلف را نشان می‌دهد. در شکل 6 نتایج مربوط به فولدها روی داده ارزیاب نشان داده شده است. با توجه به شکل 6، مدل پیشنهادی نه تنها به درستی بیماران مبتلا به ماکولای چشم غیردیابتی (برچسب ۲) را تشخیص می‌دهد بلکه در سایر حالات خطایی کمتر از ۱ درصد دارد.

- [8] L. Wang, . M. Zhang, G. He, . D. Shen and M. Meng, "Classification of Breast Lesions on DCE-MRI Data Using a Fine-Tuned MobileNet," *Diagnostics*, 2023.
- [9] K. He , R. Shaoqing , S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [10] A. Maas, A. Hannun and . A. Ng, "Rectifier nonlinearities improve neural network acoustic models," *In Proceedings of the 30th International Conference on Machine Learning, Atlanta, Georgia, USA*, 2013.
- [11] A. Bohi, V. H. C. de Albuquerque, P. N. Srinivasu and G. e. Marques, *Cognitive and Soft Computing Techniques for the Analysis of Healthcare Data*, Academic Press, 2022.
- [5] D. R. Sarvamangala and R. V. Kulkarni, "Convolutional neural networks in medical image understanding: a survey," *Evolutionary intelligence*, 2021.
- [6] S. Showkat and S. Qureshi, "Determining the efficacy of Transfer Learning-based ResNet models in Chest X-ray image classification for detecting Covid-19 pneumonia," *Chemometrics and Intelligent Laboratory Systems*, 2022.
- [7] L.-Y. Ye, X.-Y. Miao, W.-S. Cai and W.-J. Xu, "Medical image diagnosis of prostate tumor based on PSP-Net+VGG16 deep learning network," *Computer Methods and Programs in Biomedicine*, 2022.