

## تشخیص بیماری‌های شایع چشمی در تصاویر شبکه حای آب مروارید با استفاده از شبکه یادگیری عمیق

مازیار زمانی<sup>۱</sup>، رضا حسن زاده پاک رضائی<sup>۲</sup>

### چکیده

یکی از راه‌های تشخیص بیماری‌های چشمی، بررسی تصاویر سطح داخلی شبکه چشم توسط متخصص است. اما در بیماران مبتلا به بیماری آب مروارید، به دلیل محوشدگی تصاویر سطح داخلی شبکه، تشخیص سایر بیماری‌ها بسیار دشوار می‌باشد. هدف از این مقاله ارائه روشی مبتنی بر یادگیری عمیق جهت افزایش دقت تشخیص بیماری‌های شایع چشمی در حضور آب مروارید و سایر ضایعات شبکه چشم می‌باشد. در روش پیشنهادی، جهت رفع مشکل همپوشانی متقابل بین بیماری‌ها که منجر به تشخیص غیر صحیح بیماری می‌شود، از تکنیک وزن دهی در آموزش مدل به منظور افزایش قابلیت تشخیص شبکه یادگیری عمیق استفاده می‌گردد. همچنین به دلیل محدودیت در تعداد تصاویر حای آب مروارید شامل سایر بیماری‌های چشمی، برای آموزش شبکه یادگیری عمیق، انواع مدل‌های تخریب تصاویر سطح داخلی شبکه چشم جهت شبیه سازی تصاویر آب مروارید و بعضی ضایعات شبکه چشم به صورت مصنوعی تولید و در فرآیند آموزش شبکه استفاده می‌شوند. نتایج حاصل از ارزیابی بر روی پایگاه‌های مرجع تصاویر سطح داخلی شبکه چشم نشان می‌دهد که الگوریتم پیشنهادی توانسته است برای بیماری‌های تباهی لکه زرد، نزدیک بینی، بافت عروق کوروئیدی، آب سیاه، نئوواسکولاریزاسیون قرنیه و شبکه رنجوری دیابتی در شرایط وجود آب مروارید به ترتیب به مقدار صحت ۸۰، ۸۲، ۷۹، ۸۱، ۸۰ و ۶۵ دست یابد.

### کلید واژه‌ها

بیماری چشمی، تصاویر سطح داخلی شبکه، آب مروارید، طبقه بندی، یادگیری عمیق

تکنیک‌های متعددی، از جمله آنها توموگرافی نوری (OCT)، برای تجزیه و تحلیل تصاویر شبکه چشم وجود دارند. اما امروزه به دلیل دسترسی بالا، هزینه کم و غیرتهاجمی بودن، از عکس برداری سطح داخلی شبکه (FP<sup>۲</sup>) برای تشخیص بیماری‌های چشمی استفاده می‌شود [۲].

یکی از بیماری‌های شایع چشمی، آب مروارید (CA<sup>۳</sup>) است که در اثر عواملی چون افزایش سن، ناهنجاری‌های ایمنی و اختلال مادرزادی ایجاد می‌شود که چشم پزشکان برای تشخیص آن از تصاویر سطح داخلی شبکه (RF<sup>۴</sup>) استفاده می‌کنند. در حین معاینه

### ۱- مقدمه

تشخیص زودهنگام بیماری‌های شبکه چشم و ارائه درمان موثر، می‌تواند منجر به جلوگیری از پیشرفت بیماری‌های چشمی و افزایش احتمال نابینایی افراد گردد. چشم پزشکان برای تشخیص وجود یا عدم وجود بیماری‌های چشمی از تصاویر شبکه چشم استفاده می‌کنند [۱].

مقاله در شهریورماه ۱۴۰۲ دریافت گردید در آذرماه بازنگری و سپس در دی‌ماه پذیرفته شد.

<sup>۱</sup> دانشجوی کارشناسی ارشد گروه مهندسی برق دانشگاه گیلان

رایانامه: [maziar.zamani1991@gmail.com](mailto:maziar.zamani1991@gmail.com)

<sup>۲</sup> گروه مهندسی برق دانشگاه گیلان

رایانامه: [hasanzadehpak@guilan.ac.com](mailto:hasanzadehpak@guilan.ac.com)

<sup>۱</sup>Optical Coherence Tomography (OCT)

<sup>۲</sup>Fundus Photography (FP)

<sup>۳</sup>Cataract (CA)

<sup>۴</sup>Retinal Fundus (RF)

بیماری‌های چشمی از طریق تصاویر شبکیه‌استفاده گردید، که با بهینه سازی مدل‌در فاز پیش بینی، در مقایسه با شبکه‌های عصبی بازگشتی نتایج بهتری را به دست آورد. در این مدل برای بیماری‌های چند برجسی عمده تا به تغییر لایه خروجی مورد استفاده برای طبقه بندی چندگانه یا تقویت توانایی استخراج ویژگی‌های تصاویر پرداخته می‌شود در حالی که پیچیدگی ناشی از وجود همبستگی مابین چندین برجسب نادیده گرفته شده است.

در [۱۶] تشخیص بیماری تباهی لکه زرد با استفاده از شبکه VGG-16 انجام شده است. در این پژوهش تصاویر RF با استفاده از تکنیک‌های تغییر اندازه و برش پردازش می‌شوند. در مرحله بعد، شبکه VGG-16 با تصاویر پردازش شده آموزش داده می‌شود. سپس شبکه با بهینه‌سازی ابرپارامترها مورد ارزیابی قرار می‌گیرد.

در [۱۷] یک رویکرد ترکیبی مبتنی بر استفاده از روش‌های پردازش تصویر و یک مدل CNN برای تشخیص DR از طریق تصاویر RF ارائه شد. در این روش، ابتدا، اندازه تصاویر شبکیه یکسان سازی شده و از طریق تکنیک یکنواخت سازی هیستوگرام، کیفیت تصاویر بهبود می‌یابد. سپس تصاویر پیش پردازش شده به عنوان ورودی به یک مدل چند لایه CNN داده می‌شوند. در انتها ویژگی‌های استخراج شده به یک طبقه‌بند داده می‌شوند تا تصاویر RF را به کلاس‌های خفیف، متوسط و شدید DR تقسیم می‌کند.

از آنجا که سایر تحقیقات از جمله [۱۵-۱۲] به تشخیص بیماری‌های چشمی آنهم در شرایط عدم وجود CA می‌پردازند، لذا هدف اصلی مقاله حاضر تشخیص برخی بیماری‌های شایع چشمی در تصاویری است که بیمار در آن از CA هم رنج می‌برد. همچنین ماهیت پیچیده ضایعات شبکیه و همپوشانی بیماری‌ها جهت تشخیص بیماری‌های چشمی که در مطالعات پیشین نادیده گرفته شده است نیز در نظر گرفته می‌شوند. در این مقاله، علاوه بر لحاظ نمودن تصاویر واقعی موجود، با ایجاد تصاویر مصنوعی حاوی CA و برخی ضایعات شبکیه، اقدام به دسته بندی دقیق تر برخی بیماری‌های شایع با استفاده از شبکه عصبی ResNet-50 می‌گردد.

در ادامه مقاله، در بخش ۲ به مدل سازی عیوب CA و همچنین تخریب تصاویر RF پرداخته می‌شود. در بخش ۳ پایگاه داده و بیماری‌های چشمی شایع معرفی می‌گردند. در بخش ۴ روش پیشنهادی توضیح داده می‌شود. نتایج روش پیشنهادی در بخش ۵ ارائه شده و نهایتاً در بخش ۶ نتیجه گیری ارائه می‌گردد.

## ۲- شبیه سازی تصاویر شبکیه دارای عیوب

یک مطالعه غربالگری روی ۵۵۷۵ بیمار نشان می‌دهد که ۱۲٪ از تصاویر RF از کیفیت کافی برای تجزیه و تحلیل توسط چشم پزشکان برخوردار نیستند [۱۸]. تخریب تصاویر RF عموماً ناشی از عوامل بیماری‌زا یا عوامل خارجی مانند تجهیزات تصویربرداری و شرایط محیطی بد می‌باشد. نمونه‌های رایج عوامل با کیفیت پایین در تصاویر CA، نور ناهموار و ضایعات شبکیه می‌باشند که نه تنها

تصاویر RF در بیماران مبتلا به CA با دستگاه چشم بین (OPH<sup>۵</sup>)، نور هنگام عبور از عدسی، ضعیف و پراکنده شده و تصاویر RF تخریب می‌گردد. در نتیجه، مشاهده ساختارهای تشریحی شبکیه برای تشخیص سایر بیماری‌ها به سختی مقدور است [۳].

در سال‌های اخیر الگوریتم‌های مبتنی بر پردازش تصویر برای تشخیص و طبقه بندی بیماری‌های چشمی فاقد CA توسعه یافته‌اند [۴]. در [۵]، با تجزیه و تحلیل ساختارهای عروقی در تصاویر RF، و با استفاده از عملگرهای مورفولوژیک (MGH<sup>۶</sup>) به تشخیص بیماری‌های چشمی پرداخته می‌شود. در [۶] برای تشخیص بیماری شبکیه رنجوری دیابتی (DR<sup>۷</sup>)، نواحی کاندیدی میکروآنوریسم (MIC<sup>۸</sup>) با استفاده از عملگرهای مورفولوژیک تعیین و با استفاده از تجزیه و تحلیل مولفه اساسی (PCA<sup>۹</sup>)، اقدام به استخراج ویژگی‌هایی جهت تشخیص میکروآنوریسم‌های واقعی گردید. با این حال، به علت پایین بودن کیفیت تصاویر RF حاوی CA، تشخیص بیماری‌های شبکیه چشم چه بصورت پردازش تصاویر حاصله و چه بصورت مشاهده پزشک متخصص با خطای بسیار زیاد همراه می‌باشد [۷].

اخیراً یادگیری عمیق به فناوری اصلی برای حل مشکلات بینایی کامپیوتری مانند بهبود تصاویر، تقسیم بندی و طبقه بندی، به ویژه در تصاویر پزشکی تبدیل شده است. بسیاری از محققان، شبکه‌های یادگیری عمیق پیچشی را برای طبقه بندی بیماری‌های چشمی ارائه کرده‌اند [۸-۱۱].

در [۱۲]، از شبکه VGG-19 به دلیل ساختار ساده و انعطاف پذیری بالا در شناسایی اشیاء، برای شناسایی خودکار ۱۰ نوع بیماری شبکیه از طریق تصاویر RF، استفاده گردید. به دلیل فقدان پایگاه داده بزرگ، مقدار صحت برای هر ۱۰ کلاس حداکثر ۳۰٪ بود. در صورت محدود شدن کلاس بیماری‌های شبکیه به ۳ عدد، مقدار صحت به ۷۳٪ خواهد رسید. این یافته نشان می‌دهد با افزایش تعداد انواع بیماری، فرآیند طبقه بندی دشوار می‌شود.

در [۱۳] و [۱۴] حجم عظیمی از تصاویر RF برجسب گذاری شده استفاده شدند و شبکه‌های RCNN<sup>۱۰</sup> به دلیل دقت بالا، قابلیت تشخیص چند شیء و قابلیت تطبیق با اندازه‌ها و شکل‌ها برای تشخیص بیماری‌های شبکیه مورد استفاده قرار گرفتند. این مطالعات کمتر بر روی ماهیت پیچیده ضایعات شبکیه تمرکز می‌کنند و به دلیل عدم توجه به تداخل عروق خونی با دیگر ساختارهای چشم، نتایج مناسبی را به همراه نداشتند.

در [۱۵] از شبکه DKCNet<sup>۱۱</sup> به دلیل قابلیت بالا در تفکیک و تمایز بین اجزا و ویژگی‌های مختلف تصویر برای تشخیص

<sup>5</sup>Ophthalmoscope (OPH)

<sup>6</sup>Morphology (MGH)

<sup>7</sup>Diabetic Retinopathy (DR)

<sup>8</sup>Microaneurysm (MIC)

<sup>9</sup>Principal Component Analysis (PCA)

<sup>10</sup>Region-Based Convolutional Neural Network (RCNN)


<sup>11</sup>Discriminative Kernel Convolution Network (DKCNet)

کیفیت تصاویر RF و تشخیص‌های بعدی اثر می‌گذارد. به منظور شبیه‌سازی تصاویر RF حاوی CA خفیف از تخریب RF ناشی از تصویربرداری ناواضح از اشیاء نامطلوب استفاده می‌گردد. این تخریب به صورت زیر مدل می‌شود:

$$s = I + \sum_{k=1}^K G_k(\eta_k/4, \sigma_k) \cdot o_k \quad (3)$$

در این معادله،  $z$ ، تصویر حاصل از شبیه‌سازی با مصنوعات شبکیه و پارامتر  $o_k$ ، مقدار تراکم نور است که برای کنترل مقادیر روشنایی مورد استفاده قرار می‌گیرد.  $K$ ، تعداد اشیاء نامطلوب و تابع  $G_k$ ، یک فیلتر گوسی جهت مدل‌سازی شرایط تصویربرداری ناواضح از یک شی نامطلوب است.

مدل‌های تخریب ارائه شده را می‌توان به طور مستقل مورد استفاده قرار داد یا به طور تصادفی برای تخریب‌های پیچیده‌تر ترکیب کرد. در شکل (۱)، نتایج حاصل از شبیه‌سازی CA با انواع مدل‌های تخریب نشان داده شده است.



شکل (۱): (الف) یک نمونه تصویر سطح داخلی شبکیه نرمال (ب) تصویر شبیه‌سازی شده با اختلال در انتقال نور (ج) تصویر شبیه‌سازی شده با اختلال در انتقال نور، تاری تصویر و مصنوعات شبکیه

### ۳- پایگاه داده و بیماری‌های چشمی شایع

#### ۱-۳- پایگاه‌های داده

**پایگاه داده Odir**: شامل ۷۰۰۰ نمونه RF با ابعاد  $2304 \times 1728$  پیکسل است. تصاویر بر حسب شش نوع بیماری طبقه‌بندی شده‌اند. هر تصویر تنها حاوی یک بیماری و تک برجستگی می‌باشد. این مجموعه داده از مراکز درمانی کشور چین و توسط دوربین‌های مختلف اخذ و گردآوری شده است [۲۰].

**پایگاه داده RfMid**: این پایگاه داده شامل ۳۲۰۰ تصویر RF در ابعاد  $2592 \times 1944$  پیکسل می‌باشد، هر کدام از این تصاویر ممکن است شامل یک یا چند بیماری برای یک چشم باشند. تنها پایگاه داده در دسترس عموم است که طیف وسیعی از بیماری‌های چشمی را تشکیل می‌دهد. غربالگری تصاویر RF این پایگاه داده به دو دسته سالم و غیر سالم تقسیم می‌شود. تعداد تصاویر RF حاوی CA این پایگاه داده ۵۲۳ می‌باشد [۲۱]. در جدول (۱)، تعداد و انواع تصاویر RF دو پایگاه داده ODIR و RfMid شرح داده شده است. همچنین شکل (۲)، نشان‌دهنده روند انتخاب بیماری‌های شایع در پایگاه‌های داده مرجع می‌باشد.

از تشخیص قابل اعتماد توسط چشم پزشکان جلوگیری می‌کنند بلکه بر عملکرد سیستم‌های تحلیل خودکار تصویر نیز تاثیر می‌گذارند. در [۱۹] سه مدل تخریب برای شبیه‌سازی تصاویر RF ارائه شده است. در این مقاله از این مدل‌های تخریب ارائه شده به منظور ایجاد تصاویر RF حاوی اختلال ناشی از انتقال نور، تاری تصویر ناشی از CA و ضایعات شبکیه استفاده می‌شوند.

#### ۱-۲- اختلال در انتقال نور

از آنجایی که دوربین‌های سطح داخلی شبکیه با نور دهی خودکار برنامه‌ریزی شده‌اند، نور سرگردان و ناپایدار محیط بر دوربین یا به طور دقیق‌تر منبع نور تاثیر می‌گذارد و در طول فرآیند تصویربرداری منجر به نوردهی کمتر از حد یا بیشتر از حد می‌شود. برای شبیه‌سازی تصاویر RF حاوی CA شدید، از مدل تخریب تصاویر RF ناشی از اختلال در انتقال نور سیستم تصویربرداری استفاده می‌شود. این مدل بصورت معادله (۱) نشان داده شده است:

$$x = clip(\alpha(I \cdot G_2(\eta_2, \sigma_2) + I) + \beta; s) \quad (1)$$

که در آن،  $x$ ، تصویر حاصل از شبیه‌سازی با اختلال در انتقال نور،  $I$ ، تصویر اصلی و پارامترهای  $\eta_2$ ،  $\sigma_2$  و  $\beta$ ، به ترتیب ضرایب تمایز، روشنایی و اشباع می‌باشند. تابع  $clip(\cdot; s)$ ، تابع محدود کننده فرآیند اشباع، که برای مدل‌سازی تخریب‌های سراسری (GD<sup>12</sup>) استفاده می‌شود. تابع  $G_2$  برای هموارسازی روشنایی و پارامتر  $\alpha$  به عنوان یک بایاس روشنایی تعریف می‌گردد.

#### ۲-۲- تاری تصویر و اثر CA

تنظیم اشتباه فاصله کانونی سیستم نوری دستگاه چشم‌بین حین معاینه شبکیه چشم بیماران می‌تواند باعث ایجاد فاصله نامطلوب بین سطح تصویر و لنز شده و منجر به تاری تصویر حاصله گردد. با توجه به شباهت این اثر با عیب ناشی از بیماری CA، در این مقاله همچنین به منظور شبیه‌سازی تصاویر RF حاوی CA با درجات مختلف نیز از این مدل استفاده می‌گردد. این مدل تخریب تصاویر RF بصورت معادله (۲) بیان می‌گردد:


$$y = I \cdot G_B(\eta_B, \sigma_B) + n \quad (2)$$

که در آن،  $y$ ، تصویر حاصل از شبیه‌سازی با تاری تصویر، تابع  $G_B$ ، فیلتر گوسی برای مدل‌سازی تخریب تصویر و  $n$ ، نویز موجود در سیستم تصویربرداری می‌باشد. پارامتر  $\eta_B$ ، مقدار انحراف استاندارد تابع گوسی را مشخص کرده، و پارامتر  $\sigma_B$  برای کنترل مقدار تاری تصویر مورد استفاده قرار می‌گیرد.

#### ۳-۲- مصنوعات شبکیه


اگر تصویربرداری در شرایط نامناسب صورت بگیرد، گرد و غبار و ذرات چسبیده به لنز می‌توانند تصاویر تاری ایجاد کنند که بر

<sup>12</sup>Global Degradation (GD)



شکل (۳): نمونه‌هایی از تصاویر RF موجود در پایگاه داده RFMid دارای بیماری‌های شایع چشمی (الف) شبکه رنجوری دیابتی (ب) تباهی لکه زرد (ج) نزدیک بینی چشمی، (د) آب سیاه، (ه) بافت عروق کورویئیدی (و) نتوواسکولاریزاسون قرنیه.

اما در بیماران مبتلا به CA به دلیل محوشدگی تصاویر RF، تشخیص بیماری‌ها بسیار زیاد همراه می‌باشد شکل (۴)، تصاویر RF حاوی CA با شدت‌های مختلف را نشان می‌دهد.



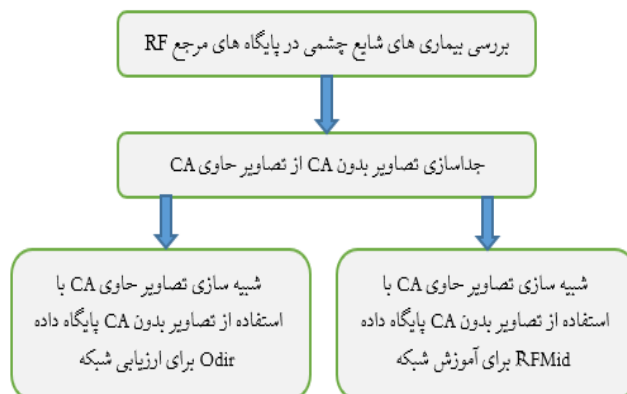
شکل (۴): نمونه‌هایی از تصاویر RF موجود در پایگاه RFMid دارای بیماری‌های شایع چشمی حاوی CA، (الف) شبکه رنجوری دیابتی دارای CA شدید (ب) تباهی لکه زرد دارای CA شدید (ج) نزدیک بینی دارای CA متوسط (د) آب سیاه دارای CA شدید (ه) بافت عروق کورویئیدی دارای CA متوسط (و) نتوواسکولاریزاسون قرنیه دارای CA شدید.

جدول (۲): تعداد تصاویر RF حاوی CA در پایگاه داده RFMid

بیماری‌ها	تعداد تصاویر آموزش	تعداد تصاویر ارزیابی
DR	۲۳	۴
ARMD	۵	۲
MYA	۱۲	۲
GL	۵۰	۱۴
TSLN	۵۱	۹
NE	۸	۱
NI <sup>20</sup>	۲۲	۶

جدول (۱): شرح جدولی تصاویر RF پایگاه داده Odir و RFMid

تعداد تصاویر	پایگاه داده Odir	پایگاه داده RFMid
کل	۷۰۰۰	۳۲۰۰
انواع بیماری چشمی	۶	۴۵
دارای CA	۴۰۲	۵۲۳
فاقد CA	۶۵۹۸	۲۶۷۷
فاقد CA برای آموزش شبکه	۰	۲۶۷۷
فاقد CA برای ارزیابی شبکه	۲۹۷۵	۰



شکل (۲): روندنمای انتخاب بیماری‌های شایع چشمی در پایگاه داده Odir و RFMid

## ۲-۳- انتخاب بیماری‌های شایع در تصاویر حاوی CA

با توجه به محدود بودن تعداد تصاویر RF بعضی از بیماری‌ها، بخصوص در شرایط وجود CA، در پایگاه‌های داده و ایجاد عدم تناسب بسیار زیاد بین دسته‌ها، فقط بیماری‌هایی به عنوان دسته‌های طبقه بندی انتخاب شدند که شایع‌تر هستند. بنابراین، دسته‌های شبکه رنجوری دیابتی (DR<sup>13</sup>)، تباهی لکه زرد (ARMD<sup>14</sup>)، آب سیاه (GL<sup>15</sup>)، نزدیک بینی چشمی (MYA<sup>16</sup>)، بافت عروق کورویئیدی (TSLN<sup>17</sup>) و نتوواسکولاریزاسیون قرنیه (NE<sup>18</sup>) انتخاب شدند. دیسک بینایی (OD<sup>19</sup>) و رگ‌های خونی مهم‌ترین مشخصه بیماری‌های شایع چشمی در تصاویر RF می‌باشد. در شکل (۳)، نمونه‌هایی از ۶ بیماری شایع چشمی پایگاه داده RFMid نشان داده شده است.

<sup>13</sup>Diabetic Retinopathy (DR)

<sup>14</sup>Age-Related Macular Degeneration (ARMD)

<sup>15</sup>Glaucoma (GL)

<sup>16</sup>Myopia (MYA)

<sup>17</sup>Tesselation (TSLN)

<sup>18</sup>Neovascularization (NE)

<sup>19</sup>Optic Disk (OD)

<sup>20</sup>Not Included

از شبکه ResNet-50 به دلیل مزیت رفع مشکل عمیق شدن شبکه به واسطه داشتن اتصالات اضافی در معماری خود، به عنوان استخراج کننده ویژگی و طبقه بند در تصاویر RF حاوی CA استفاده می شود [۲۲]. بنابراین تصاویر چند برجسی پیش پردازش شده، در مرحله استخراج ویژگی به شبکه ResNet-50 اعمال می-شوند تا طبقه بندی بیماری های چشمی صورت گیرد. معماری شبکه ResNet-50 در شکل (۵) ارائه شده است. همچنین در شکل (۶)، جزئیات کامل دو بخش پیش پردازش و استخراج ویژگی ارائه شده در سیستم پیشنهادی، نشان داده شده است. به دلیل هم پوشانی بیماری ها، در بخش ۳-۴، از تکنیک وزن دهی، در جهت افزایش قابلیت تشخیص شبکه یادگیری عمیق پیشنهادی استفاده می شود. همچنین در بخش ۴-۴، برای رفع معضل کمبود تصاویر حاوی CA و در نتیجه بهبود نتایج حاصله، از مدل های تخریب RF ارائه شده در بخش ۲ در جهت شبیه سازی تصاویر حاوی CA و برخی شایعات شبکه استفاده می گردد.

#### ۱-۴- پیش پردازش

##### الف) تغییر اندازه تصاویر

تصاویر RF پایگاه داده RFMid و Odir دارای وضوح بالا و همچنین حاشیه های سیاه رنگ بدون استفاده می باشند. لذا با توجه به محدودیت در سخت افزار و با هدف کاهش بار محاسباتی و افزایش سرعت یادگیری، نیازمند است تا کاهش ابعاد و حذف نواحی بدون استفاده در داده ها انجام شود.

##### ب) افزایش تعداد تصاویر

مطابق جدول (۲)، تعداد تصاویر RF، بخصوص تصاویر حاوی CA، برای آموزش و طبقه بندی شبکه یادگیری عمیق محدود می-باشند، بنابراین یک گام مهم، افزایش تعداد تصاویر RF می باشد. در این مقاله از تکنیک های انعکاس، چرخش و مدل های تخریب تصاویر برای افزایش تعداد تصاویر استفاده شده است. تصاویر تولید شده جهت آموزش و طبقه بندی به شبکه یادگیری عمیق اعمال می شوند.

#### ۲-۴- استخراج ویژگی و طبقه بندی چند برجسی

معماری شبکه ResNet-50 شامل ۵۰ لایه می باشد که ویژگی های تصاویر ورودی به شبکه را به خوبی استخراج کرده و طبقه بندی می کند. این شبکه، جهت حل مشکل عمیق شدن شبکه، متشکل از چندین اتصال اضافی ( $RC^{11}$ ) است که روی هم قرار گرفته اند و ساختار اصلی معماری را تشکیل می دهند. بخش اتصالات اضافی دو گزینه دارد که یا می تواند یک سری عملیات را روی ورودی اعمال کند یا اعمال آن عملیات را نادیده بگیرد. در معماری شبکه ResNet-50 هر بلوک کانولوشنی و هر بلوک همانی، شامل سه لایه

جدول (۲)، تعداد RF حاوی CA در پایگاه داده RFMid را نشان می دهد. که در آن NI بیانگر تعداد تصاویر RF فاقد ۶ بیماری شایع انتخابی می باشد. تعداد کم تصاویر RF حاوی CA در فرآیند آموزش شبکه، منجر به کم برآزش شدن مدل می گردد. لذا، به منظور جلوگیری از کم برآزش شدن مدل، از ۲۶۷۷ تصویر بدون CA پایگاه داده RFMid برای شبیه سازی تصاویر CA در جهت آموزش شبکه استفاده می شود. نتایج شبیه سازی تصاویر حاوی CA برای آموزش شبکه یادگیری عمیق در جدول (۳) ارائه گردیده است. در ارزیابی شبکه، برای رفع معضل کمبود داده حاوی CA، از تصاویر RF پایگاه داده Odir استفاده می گردد. با توجه به تک برجسی بودن این داده ها، ابتدا پس از بررسی تمام تصاویر این پایگاه داده توسط متخصصین جهت برجسب زنی سایر بیماری ها، تعداد ۲۹۷۵ تصویر انتخاب و با استفاده از انواع مدل های تخریب تصاویر چشم، تصاویر RF حاوی CA به صورت مصنوعی ایجاد می گردند. جدول (۴)، بیانگر تعداد تصاویر RF شبیه سازی شده حاوی CA برای ارزیابی شبکه یادگیری عمیق می باشد.

##### جدول (۳): شبیه سازی تصاویر حاوی CA برای آموزش شبکه یادگیری عمیق با استفاده از پایگاه داده RFMid

بیماری ها	تعداد تصاویر
DR	۶۰۵
ARMMD	۱۶۲
MYA	۱۵۳
GL	۳۸۱
TSLN	۲۴۴
NE	۲۲۱
NI	۹۱۱

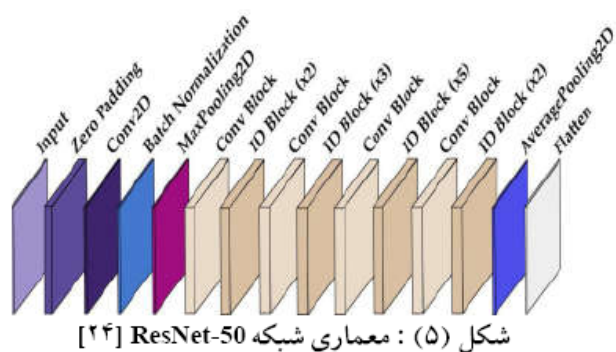
##### جدول (۴): شبیه سازی تصاویر RF حاوی CA برای ارزیابی شبکه یادگیری عمیق با استفاده از پایگاه داده Odir

بیماری ها	تعداد تصاویر
DR	۱۱۲۸
ARMMD	۱۶۴
MYA	۱۷۴
GL	۲۱۵
TSLN	۲۱۲
NE	۱۰۳
NI	۹۷۹

#### ۴- روش پیشنهادی

ساختار روش پیشنهادی دارای دو مرحله و شامل پیش پردازش و استخراج ویژگی می باشد که به ترتیب در بخش های ۴-۱ و ۴-۲ ارائه می گردند. هدف مرحله پیش پردازش یکسان سازی اندازه تصاویر و اعمال برخی فرآیندهای تبدیل همچون انعکاس و چرخش جهت افزایش داده است. پس از بررسی انواع الگوریتم های یادگیری عمیق به منظور طبقه بندی بیماری های چشمی فاقد CA،

<sup>11</sup>Residual Connection (RC)



### ۳-۴- استفاده از تکنیک وزن دهی معکوس فراوانی (IFW<sup>۲۳</sup>) مبتنی بر شبکه ResNet-50

تکنیک وزن دهی یکی از مولفه‌های مهم در آموزش مدل‌های یادگیری عمیق با داده‌های نامتعادل می‌باشد. این تکنیک در داده‌های نامتعادل، در راستای مقابله با کاهش دقت و عملکرد مدل‌های یادگیری عمیق در پیش‌بینی دسته‌ها با تعداد نمونه‌های کمتر مورد استفاده قرار می‌گیرد و با اختصاص وزن‌های مختلف به لایه‌ها یا استفاده قرار می‌گیرد و با اختصاص وزن‌های مختلف به لایه‌ها یا استفاده قرار می‌گیرد، به مدل کمک می‌کند که در فرآیند آموزش داده‌ها بهتر عمل کند. در پایگاه داده RFMid تعداد تصاویر در دسته‌های مختلف متفاوت است. لذا، به منظور جلوگیری از سوگیری در آموزش شبکه، از تکنیک وزن دهی معکوس فراوانی به دلیل دارا بودن بهترین نتیجه در مقایسه با سایر تکنیک‌های وزن دهی استفاده می‌شود [۲۵]. در این تکنیک هر چه تعداد تصاویر یک دسته کمتر باشد وزن بیشتری به آن اختصاص داده می‌شود تا اثر کم بودن تعداد آن جبران شود و شبکه با سوگیری (BS<sup>۲۴</sup>) نسبت به دسته‌های با تعداد بیشتر داده به اشتباه آموزش نبیند. شبکه ResNet-50 مبتنی بر تکنیک IFW تحت عنوان WR-50<sup>۲۵</sup> نام‌گذاری شده است. WR-50 برای رفع دو معضل عدم تمرکز بر روی ماهیت پیچیده ضایعات شبکه چشم و نادیده گرفتن پیچیدگی ناشی از همبستگی بین چندین بیماری که در مطالعات پیشین با استفاده از شبکه ResNet-50 لحاظ نشده‌اند، ارائه می‌گردد [۲۶].

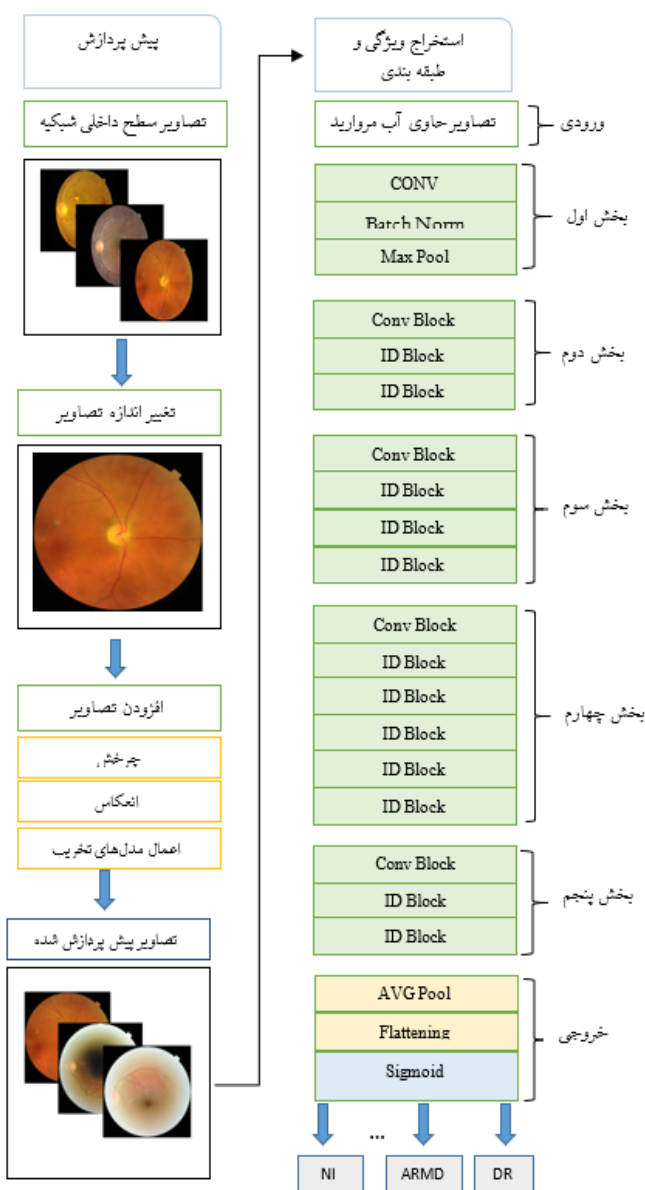
### ۴-۴- تولید تصاویر مصنوعی CA جهت آموزش و ارزیابی شبکه مبتنی بر شبکه ResNet-50

مطابق جدول (۲)، پایگاه داده RFMid با محدودیت تصاویر حاوی CA رو به رو است. با استفاده از تصاویر RF بدون CA پایگاه داده RFMid، تصاویر RF منتخب پایگاه داده Odir و به کمک انواع مدل‌های تخریب تصاویر شبکه چشم ارائه شده در بخش ۲، تصاویر RF حاوی CA به صورت مصنوعی تولید می‌گردد. با توجه به اینکه پایگاه داده Odir دارای مشکلاتی همچون تصاویر نامطلوب و طبقه بندی نامناسب می‌باشد، لذا تعدادی از تصاویر این پایگاه

کانولوشن می‌باشند [۲۳]. جزئیات شبکه استخراج ویژگی ResNet-50 در جدول (۵) ارائه شده است.

جدول (۵): جزئیات شبکه ResNet-50

بخش	لایه‌ها
ورودی	داده ورودی
اول	یک لایه کانولوشن دو بعدی با اندازه ۷*۷ و گام ۲*۲، Batch Normalization، Max Pooling با اندازه ۳*۳ و اندازه گام ۲*۲
دوم	یک بلوک کانولوشنی، دو بلوک همانی (ID <sup>۲۲</sup> )
سوم	یک بلوک کانولوشنی، سه بلوک همانی
چهارم	یک بلوک کانولوشنی، پنج بلوک همانی
پنجم	یک بلوک کانولوشنی، دو بلوک همانی
خروجی	Average Pooling با اندازه ۲*۲، یک لایه Flatten



<sup>23</sup>Inverse Frequency Weighting (IFW)

<sup>24</sup>Bias (BS)

<sup>25</sup>Weighted ResNet-50 (WR-50)

<sup>22</sup>Identity Block (ID)

جدول (۶): ارزیابی شبکه های مختلف برای طبقه بندی بیماری های چشمی بدون CA در پایگاه داده Odir

شبکه	NI	NE	TSLN	GL	MYA	ARMD	DR
VGG-16	۰,۴۷	-	-	۰,۵۴	۰,۹۰	۰,۸۸	۰,۸۵
MobileNet V2	۰,۶۲	-	-	۰,۸۰	۰,۹۵	۰,۸۸	۰,۷۳
EfficientNet	۰,۵۳	-	-	۰,۷۰	۰,۹۲	۰,۸۰	۰,۷۸
Yolo V7	۰,۵۵	-	-	۰,۶۵	۰,۶۷	۰,۷۴	۰,۶۸
ResNet-50	۰,۷۳	-	-	۰,۹۳	۰,۹۸	۰,۹۳	۰,۷۴

جدول (۷): ارزیابی شبکه های مختلف برای طبقه بندی بیماری های چشمی بدون CA در پایگاه داده RFMid

شبکه	NI	NE	TSLN	GL	MYA	ARMD	DR
VGG-16	۰,۳۸	-	-	۰,۵۰	۰,۸۲	۰,۸۱	۰,۸۰
MobileNet V2	۰,۵۵	-	-	۰,۶۶	۰,۸۳	۰,۸۰	۰,۶۷
EfficientNet	۰,۴۹	-	-	۰,۶۶	۰,۸۳	۰,۷۱	۰,۷۰
Yolo V7	۰,۵۰	-	-	۰,۶۱	۰,۵۶	۰,۶۵	۰,۶۰
ResNet-50	۰,۶۹	-	-	۰,۸۳	۰,۸۶	۰,۸۵	۰,۶۰

جدول (۷)، نشان دهنده عملکرد مناسب شبکه ResNet-50 نسبت به سایر شبکه های یادگیری عمیق، در طبقه بندی بیماری های Odir و MYA در پایگاه داده RFMid است. همچنین شبکه VGG-16 در طبقه بندی بیماری DR عملکرد بالاتری نسبت به سایر شبکه ها دارد. کاهش صحت دسته های طبقه بندی پایگاه داده RFMid نسبت به پایگاه داده Odir به دلیل نامتعادل بودن تصاویر RF پایگاه داده RFMid می باشد با توجه به مقایسه نتایج جداول (۶) و (۷)، شبکه ResNet-50 و شبکه VGG-16 دارای بهترین نتایج نسبت به سایر شبکه ها بوده و لذا در ادامه از این دو شبکه یادگیری عمیق برای مقایسه طبقه بندی بیماری های شایع پایگاه داده RFMid در تصاویر RF حاوی CA و بدون CA استفاده می گردد.

## ۵-۲- طبقه بندی بیماری های شایع چشمی بدون CA در پایگاه داده RFMid

تشخیص طبقه بندی تصاویر RF فاقد CA در پایگاه داده RFMid با محدودیت هایی همچون نامتعادل بودن تعداد تصاویر در دسته های مختلف و همچنین همپوشانی بیماری ها رو به رو است. لذا، همانطور که در بخش ۴-۳ اشاره گردید، جهت رفع این مشکل، شبکه اصلاح شده WR-50 که بر پایه شبکه ResNet-50 و مبتنی تکنیک وزن دهی است، پیشنهاد شده است. با مقایسه جداول (۷) و (۸) مشاهده می شود که با افزایش تعداد دسته های طبقه بندی بیماری ها از ۵ به ۷، نتایج حاصل از صحت تشخیص بیماری ها توسط شبکه های VGG-16 و ResNet-50، به دلیل مشکلات فوق الذکر، کاهش پیدا کرده است. مطابق جدول (۸)، شبکه WR-50 در تشخیص و طبقه بندی بیماری های شایع چشمی بدون CA

داده جهت شبیه سازی تصاویر با کیفیت پایین برای ارزیابی شبکه و از پایگاه داده RFMid برای آموزش شبکه یادگیری عمیق استفاده می گردد. تولید مصنوعی تصاویر RF حاوی CA به همراه تکنیک IFW مبتنی بر شبکه ResNet-50 تحت عنوان MWR-50 نامگذاری شده است.

## ۵- روش ارزیابی کلی

برای ارزیابی عملکرد روش پیشنهادی از معیارهای صحت، دقت (PR<sup>۲۷</sup>) و F1-score استفاده شده است. این معیارها به صورت معادلات (۴)، (۵) و (۶) تعریف می شوند.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

$$F1 - score = \frac{2TP}{2TP + FN + FP} \quad (6)$$

که در آن TP<sup>۲۸</sup> تعداد تشخیص صحیح بیماری مورد نظر و TN<sup>۲۹</sup> تعداد تشخیص صحیح سایر بیماری ها است. همچنین FP<sup>۳۰</sup> تعداد تشخیص نادرست بیماری مورد نظر و FN<sup>۳۱</sup> تعداد تشخیص نادرست سایر بیماری ها می باشد

## ۵-۱- مقایسه شبکه های مختلف برای طبقه بندی تصاویر RF بدون CA در پایگاه داده RFMid و Odir

در ارزیابی های انجام شده، روش پیشنهادی ResNet 50 با شبکه [۲۷Yolo V7] و همچنین شبکه های بکار رفته در تشخیص بیماری های چشمی مانند [۲۸VGG-16]، [۲۹MobileNet V2]، [۳۰EfficientNet] مورد مقایسه قرار گرفته است. با توجه به اینکه در مراجع [۲۷-۲۹]، صرفاً به طبقه بندی ۵ کلاس، شامل ۴ بیماری شایع چشمی MYA، ARMD، GL و DR آنهم در شرایط عدم وجود CA و NI به عنوان کلاس فاقد ۴ بیماری شایع چشمی، پرداخته شده است، لذا جهت مقایسه با سایر مقالات در جداول (۶) و (۷)، مقایسه نتایج صرفاً با فرض این ۵ کلاس در پایگاه های داده Odir و RFMid انجام می گردد. جدول (۶) نشان می دهد که شبکه ResNet-50 در طبقه بندی بیماری های ARMD، MYA، Odir و NI نسبت به سایر شبکه های یادگیری عمیق عملکرد بهتری را دارا می باشد، اما شبکه VGG-16 عملکرد بهتری را در تشخیص بیماری DR دارا است.

<sup>26</sup>Weighted ResNet-50 with Modified images (MWR-50)

<sup>27</sup>Precision

<sup>28</sup>True Positive

<sup>29</sup>True Negative

<sup>30</sup>False Positive

<sup>31</sup>False Negative

تر بیماری‌های شایع چشمی و حتی در حضور تصاویر RF با کیفیت پایین و حاوی CA به نتایج مطلوبی دست یافت.

در پایگاه داده RFMid در مقایسه با شبکه‌های VGG-16 و ResNet-50 در تمامی دسته‌ها، دارای عملکرد بهتری می‌باشد.

### ۳-۵- طبقه بندی بیماری‌های شایع چشمی حاوی

#### CA در پایگاه داده RFMid

طبقه بندی تصاویر RF حاوی CA پایگاه داده RFMid با چالش‌هایی همچون، همپوشانی بیماری‌ها و محدودیت تصاویر حاوی CA روبه رو می‌باشد. برای رفع این چالش‌ها از تکنیک وزن دهی و همچنین شبیه سازی تصاویر با کیفیت پایین و دارای اختلالات شبکه استفاده می‌شود. مطابق جدول (۹)، مقادیر صحت، دقت و F1-score حاصل از طبقه بندی بیماری‌های شایع چشمی در تصاویر RF حاوی CA توسط شبکه WR-50 به دلیل استفاده از تکنیک وزن دهی نسبت به شبکه ResNet-50 افزایش پیدا کرده است. در شبکه MWR-50، با استفاده از تصاویر RF بدون CA پایگاه داده RFMid و به کمک انواع مدل‌های تخریب RF ارائه شده در بخش ۲، تصاویر CA به صورت مصنوعی جهت آموزش شبکه تولید شده است، که این امر باعث افزایش صحت و دقت دسته های طبقه بندی نسبت به شبکه های ResNet-50 و WR-50 می‌گردد.

جدول (۸): طبقه بندی بیماری‌های شایع چشمی بدون CA در پایگاه داده RFMid

شبکه	NI	NE	TSLN	GL	MYA	ARMD	DR
VGG-16	۰,۴۳	۰,۷۹	۰,۷۵	۰,۵۰	۰,۷۶	۰,۸۰	۰,۸۱
ResNet-50	۰,۶۶	۰,۸۳	۰,۸۰	۰,۸۳	۰,۸۵	۰,۸۳	۰,۶۷
WR-50	۰,۸۳	۰,۹۰	۰,۹۸	۰,۹۸	۰,۹۸	۰,۹۷	۰,۸۸

### ۶- نتیجه گیری

تشخیص بیماری‌های چشمی توسط افراد متخصص در بیماران مبتلا به CA بسیار دشوار می‌باشد. در این مقاله از پایگاه‌های داده RFMid، Odir و شبکه ResNet-50 برای تشخیص بیماری‌های شایع چشمی در تصاویر RF حاوی CA استفاده شد. با توجه به ماهیت پیچیده ضایعات شبکه در تصاویر RF چند برجستگی پایگاه داده RFMid، چالش همپوشانی بیماری‌ها برطرف می‌گردد. از آنجایی که در پایگاه‌های داده، تعداد تصاویر در کلاس‌های مختلف متفاوت است از تکنیک وزن دهی استفاده می‌شود. همچنین به دلیل محدودیت در تعداد تصاویر حاوی CA و سایر اختلالات چشمی، با کمک انواع مدل‌های تخریب تصاویر RF، تصاویر حاوی CA به صورت مصنوعی ایجاد می‌گردد. پس از اعمال اصلاحات برای بهبود عملکرد مدل پیشنهادی، از پارامتر صحت برای ارزیابی الگوریتم پیشنهادی استفاده می‌گردد. نتایج حاصله نشان دهنده این است که روش پیشنهادی در تشخیص طیف متنوع

جدول (۹): طبقه بندی بیماری‌های شایع چشمی در تصاویر RF حاوی CA در پایگاه داده RFMid

شبکه	بیماری	Accuracy	Precision	F1-score
ResNet-50	DR	۰,۵۰	۰,۴۸	۰,۴۲
	ARMD	۰,۴۸	۰,۴۱	۰,۰۶
	MYA	۰,۵۵	۰,۳۵	۰,۰۸
	GL	۰,۵۳	۰,۳۸	۰,۰۹
	TSLN	۰,۵۳	۰,۳۸	۰,۰۹
	NE	۰,۵۶	۰,۴۳	۰,۰۷
	NI	۰,۴۹	۰,۷۴	۰,۴۷
WR-50	DR	۰,۵۸	۰,۵۶	۰,۵۰
	ARMD	۰,۷۱	۰,۵۱	۰,۱۶
	MYA	۰,۶۶	۰,۴۰	۰,۱۲
	GL	۰,۷۰	۰,۶۲	۰,۲۹
	TSLN	۰,۷۱	۰,۴۶	۰,۱۸
	NE	۰,۷۰	۰,۵۰	۰,۱۱
	NI	۰,۵۴	۰,۷۷	۰,۵۲
MWR-50	DR	۰,۶۱	۰,۷۲	۰,۶۱
	ARMD	۰,۸۰	۰,۸۹	۰,۳۳
	MYA	۰,۸۲	۰,۹۱	۰,۳۵
	GL	۰,۸۱	۰,۹۴	۰,۳۷
	TSLN	۰,۷۹	۰,۸۷	۰,۳۶
	NE	۰,۸۰	۰,۸۷	۰,۲۲
	NI	۰,۶۱	۰,۸۰	۰,۵۷

در کارهای آینده، استفاده از شبکه‌های مولد تخصصی (GAN<sup>۳۲</sup>) به دلیل مزایایی چون تولید تصاویر با وضوح بالا و تولید تصاویر واقع‌گرا، جهت تولید تصاویر مصنوعی حاوی CA با حفظ مشخصه بیماری‌ها و ضایعات شبکه در تصاویر RF قابل ارزیابی می‌باشد.

همچنین در صورت افزایش داده‌ها، امکان لحاظ نمودن طیف وسیع تری از بیماری‌های چشمی شامل سایر بیماری‌های کمتر شایع نیز در توسعه روش پیشنهادی برای شناسایی تعداد بیشتری از بیماری‌های چشمی قابل بررسی می‌باشد. بهینه سازی ابرپارامترها برای پیکربندی مناسب مدل پیشنهادی نیز می‌تواند در بهبود عملکرد روش پیشنهادی موثر باشد.

### مراجع

- [1] A. Geevarghese, G. Wollstein, H. Ishikawa and S. Schuman, "Optical coherence tomography and glaucoma", Annual Review of Vision Science, vol. 7, pp. 693-726, 2021.
- [2] S. Phihilip, L. Cowie, and J. Olson, "The impact of the health technology board for Scotland's grading model on

<sup>32</sup>Generative Adversarial Networks (GAN)



- relatd macular degeneration", *Diagnostics*, vol. 10, no. 5, p. 261, 2020.
- [17] K. Hu, Z. Zhang and X. Nie, "Retinal vessel segmentation of color fundus images using multiscale convolutional neural network with an improved cross-entropy loss function", *Neurocomputing*, vol. 309, pp.179–191, 2018.
- [18] E. Ouda and A. Abdelaziz, "Multiple ocular disease diagnosis using fundus images based on Multi-label deep learning classification", *Compure Science and Engineering*, vol. 11, pp 1–27, 2022.
- [19] SH. Ziyi and F. Huazhu, "Modeling and Enhancing Low Quality Retinal Fundus Images", *IEEE Transactions on medical imaging* Vol.40, no.3, pp. 996–1006,2021.
- [20] Shangong Medical Technology, "Ocular Disease Intelligent Recognition", *Peking University International Competition*, 2019.
- [21] S. Pachade, P. Porwal and D. Thulkar "Retinal Fundus Multi disease Images Dataset", *IEEE Dataport* Vol.8, no.2, ,2021.
- [22] V. Mayya, D. Surra and U. Acharya, "An empirical study of preprocessing techniques with convolutional neural network for accuratedetection of chronic ocular diseases using fundus images", *IEEE Transactions on Image processing*. Vol. 53, no. 2, pp 1548–1566, 2023.
- [23] P. Dwivedi, "Understanding and Coding a ResNet in Keras", *Towards Data Science*, 2019.
- [24] S. Mukherjee, "The Annotated ResNet–50", *Towards Data Science*, 2022.
- [25] S. Arif, J. Holliday and P. Willett, "Inverse frequency weighting of fragments for similarity-based virtual screening", *Journal of Chemical Information and Modeling*, vol. 50, no. 8, pp.1340–1349, 2010.
- [26] Z. Zhao, D. Murphy and H. Gifford, "Analysis of an adaptive lead weighted ResNet for multiclass classification of 12-lead ECGs", *Physiological Measurement*, vol. 43, no. 3, p. 034001, 2022.
- [27] S. Rath, "YOLOv7 Object Detection Paper Explanation and Inference", *LearnOpenCv*,2022.
- [28] N. Gour and P. Khanna, "Multi-class multi-label ophthalmological disease detection using transfer learning based convolutional neural network", *Biomed Signal Process Control*, vol. 66, p. 102329, 2021.
- [29] N. Dipu, K. Salam and S. Shohan, "Ocular Disease Detection Using Advanced Neural Network Based classification Algorithms", *Asian Journal of convergence in technology*, vol. 7, no. 2, pp. 91–99, 2021.
- [30] J. Yang, L. Wang, Z. Huo, W. He and L. Huo, "Multi-label Classification of Fundus Images with EfficientNet", *IEEE Access*, vol. 8, pp. 212499–508, 2020.
- referrals to ophthalmologyservices", *British Journal of Ophthalmology*, vol. 89, no. 7, p. 891, 2005.
- [3] J. Cheng, Z. Li, Z. Gu and H. Fu, "Structure Preserving guided retinal image filtering and its application for optic disk analysis", *IEEE Transactions on medical imaging*, vol. 37, no. 11, pp. 2536–2546, 2018.
- [4] M. Abramoff, M. Garvin and M. Sonka, "Retinal Imaging and Image Analysis", *IEEE Reviews in Biomedical Engineering*, vol. 3, pp. 169–208, 2010.
- [5] G. Hassan and N. Bendary, "Retinal Blood Vessel Segmentation Approach Based on Mathematical Morphology", *Procedia Computer Science*, vol. 65, pp. 612–622, 2015.
- [6] J. Staal, M. D. Abramoff, M. Niemeijer, M. A. Viergever, and B. Van Ginneken, "Ridge-based vessel segmentation in color images of the retina", *IEEE Transactions on Medical Imaging*, vol. 23, no. 4, pp. 501–509, 2004.
- [7] M. Foracchia, E. Grisan, and A. Ruggeri, "Luminosity and contrast normalization in retinal images", *Medical Image Analysis*, vol. 9, no. 3, pp. 179–190, 2005.
- [8] P. Glaret subin and P. Mukhukannan, "Optimized Convolution neural network based multiple eye disease detection", *Physical and Engineering Sciences in Medicine*, vol. 146, p. 105648, 2022.
- [9] D. Helen and S. Gokila, "An eye disease detection system using convolutional neural network", *In 2023 2<sup>nd</sup> International Conference on Edge Computing and Applications*, pp. 839–842,2023.
- [10] N. Nurugan, S. Rajesh and K. Praveen, "Fundus image diseases classification using convolutional neural network", *The American Institute of Physics*, vol. 2519, no. 1, 2022.
- [11] J. I. Orlando, J. Breda, and A. Diaz, "Refuge Challenge: A unified framework for evaluating automated methods for glaucoma assessment from fundus photographs", *Medical Image Analysis*, vol. 59, p. 101570, 2020.
- [12] T. Nazir, A. Irtaza and A. Javad, "Retinal analysis for diabetes-based eye disease detection using deep learning", *Appllied Sciences*, vol. 10, no. 18, p.6185, 2020.
- [13] Z. Wang, K. Chen and L. Zhang "A RCNN based approach for microaneurysms detection in retinal fundus images", *In Health Information Science: 8<sup>th</sup> International Conference*, pp. 201–212,2019.
- [14] H. Almubarak, Y. Bazi and N. Alajlan, "Two-stage mask RCNN approach for detecting and segmentation the optic nerve head, optic disc and optic cup in fundus images", *Applied Sciences*, vol. 10, no. 11, p. 3833, 2020.
- [15] A. Bhati, N. Gour and P. Khanna, "Discriminative kernel convolution network for Multi-label ophthalmic disease detection on imbalanced fundus images dataset", *Computers in Biology and Medicine*, vol. 153, p.106519, 2023.
- [16] T. Heo, K. Kim and J. Min, "Development of a deep learning based artificial intelligence tool for differential diagnosis between dry and neovascular age-



مازیار زمانی مدرک کارشناسی خود را در رشته مهندسی برق گرایش الکترونیک در سال ۱۳۹۳ از دانشگاه آزاد اسلامی لاهیجان و مدرک کارشناسی ارشد خود را در رشته مهندسی برق گرایش سیستم‌های الکترونیک دیجیتال در سال ۱۴۰۲ از دانشگاه گیلان کسب نمود. علاقه‌مندی‌های علمی ایشان شامل پردازش سیگنال، پردازش تصویر، یادگیری ماشین، یادگیری عمیق و هوش مصنوعی می‌باشد.



رضا حسن‌زاده پاک‌رضائی مدرک کارشناسی را در رشته مهندسی برق گرایش الکترونیک در سال ۱۳۷۹ از دانشگاه گیلان و مدارک کارشناسی ارشد و دکتری خود را در رشته مهندسی برق گرایش الکترونیک دیجیتال به ترتیب در سال‌های ۱۳۸۱ و ۱۳۸۶ از دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران) کسب نمود. ایشان هم‌اکنون دانشیار گروه مهندسی برق دانشگاه گیلان و زمینه‌های پژوهشی مورد علاقه ایشان شامل پردازش سیگنال‌ها و تصاویر صنعتی و پزشکی، یادگیری ماشین و منطق فازی است.