

## با رویکرد تطبیقی آموزش شبکه های OCT طبقه بندی تصاویر یادگیری عمیق

علی قادریان<sup>۱</sup>، مرتضی چوبین (نویسنده مسئول)<sup>۲</sup>،\*، حامد آقا پناه رودسری<sup>۳</sup>

<sup>۱</sup> دانشگاه ملایر، ملایر ali\_ghaderian1994@yahoo.com

<sup>۲</sup> دانشگاه ملایر، ملایر m.chobin@malayeru.ac.ir

<sup>۳</sup> دانشگاه علوم پزشکی اصفهان، اصفهان h.aghapanah@amt.mui.ac.ir

### چکیده

در حال حاضر حداقل ۲٫۲ میلیارد نفر در سراسر جهان دارای اختلال بینایی هستند که حداقل ۱ میلیارد نفر از آنها دارای اختلال بینایی هستند که می‌توانست از آن جلوگیری شود یا هنوز درمان نشده است. جهان از نظر مراقبت های چشمی با چالش های قابل توجهی از جمله نابرابری در پوشش و کیفیت خدمات پیشگیری، درمان و توانبخشی مواجه است. کمبود ارائه دهندگان خدمات مراقبت از چشم آموزش دیده؛ و ادغام ضعیف خدمات مراقبت از چشم در سیستم های بهداشتی، از جمله. در چشم پزشکی، غربالگری زودرس فوندوس یک راه اقتصادی و موثر برای پیشگیری از نابینایی ناشی از بیماری های چشمی است. از نظر بالینی، به دلیل کمبود منابع پزشکی، تشخیص دستی زمان بر است و ممکن است شرایط را به تاخیر بیندازد. با توسعه یادگیری عمیق، برخی از تحقیقات در مورد بیماری های چشمی به نتایج خوبی دست یافته اند، اما بیشتر آنها تنها بر اساس یک بیماری هستند. تشخیص زودهنگام چشم یک راه مقرون به صرفه و موثر برای پیشگیری از نابینایی ناشی از دیابت، گلوکوم، آب مروارید و بسیاری از بیماری های دیگر است. تشخیص سریع و خودکار در کاهش فعالیت چشم پزشک و جلوگیری از اختلال بینایی در بیماران مهم و ضروری است. بینایی کامپیوتری و یادگیری عمیق می تواند به طور خودکار بیماری های چشمی را پس از ارائه تصاویر پزشکی فوندوس با کیفیت بالا تشخیص دهد. در این مقاله آزمایش ها و روش های مختلفی را امتحان می کنیم تا با کمک شبکه های عصبی پیچشی با استفاده از کتابخانه TensorFlow مدلی برپایه این مدلها بسازیم. معماری پیشنهادی ما مدلی هیبرید می باشد بر پایه معماری های VGG16 , ResNet50 , MobileNetV3Small می باشد. مدل ما ۴ کلاس را با نرخ های ۹۶٫۰۲٪ و ۹۲٪ به ترتیب برای دقت (Accuracy)، حساسیت (Sensitivity) شناسایی کرد.

### واژه های کلیدی

یادگیری عمیق، تصاویر OCT، ترکیب شبکه ها.

# دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12<sup>th</sup> National Congress of  
the New Technologies in Sustainable Development of Iran

senaconf.ir

دیابت شیرین که به طور گسترده به عنوان دیابت شناخته می شود، بیماری است که در آن فرد به دلیل ترشح ناکافی انسولین، پاسخ نامناسب سلول های بدن به انسولین یا هر دو، سطح قند خون بیش از حد دارد. دیابت یک عارضه مهم سلامتی در سراسر جهان است و بیشتر به دلیل سبک زندگی کم تحرک، اضافه وزن، پیری و عادات غذایی نامناسب است. با افزایش میانگین طول عمر، شیوع دیابت به طور تصاعدی در حال افزایش است. با ۱۱۶ میلیون نفر مبتلا به دیابت، چین بیشترین تعداد مبتلایان به دیابت را در جهان دارد. پس از چین، هند (۷۷ میلیون نفر) و ایالات متحده (۳۱ میلیون نفر) و در ایران (۵،۵ میلیون نفر) بر اساس بنیاد بین المللی دیابت (IDF، ۲۰۱۹) قرار دارند. بیانیه IDF ۲۰۲۰ پیش بینی می کند که در سراسر جهان، تا سال ۲۰۴۵، تقریباً ۷۰۰ میلیون نفر به دیابت مبتلا خواهند شد [۱]. چندین عارضه پزشکی دیگر به دلیل دیابت ایجاد می شود، از جمله بیماری قلبی عروقی، بیماری چشم دیابتی، آسیب عصبی و نارسایی کلیه.

بیماری چشم دیابتی (DED)، یکی از محصولات دیابت است که نادیده گرفته شده و درمان نشده است که می تواند باعث از دست دادن دائمی بینایی شود. مشاهده شده است که علت اصلی اختلال بینایی و نابینایی در طبقه کارگر DED است. DED از رتینوپاتی دیابتی (DR)، گلوکوم (GL) و آب مروارید (ca) تشکیل شده است [۲]–[۵]. علائم DED را می توان در قسمت های مختلف شبکیه چشم انسان مشاهده کرد. اینها شامل رشد نامنظم و پارگی عروق خونی، تخریب عدسی، شکستن عصب بینایی به دلیل فشار داخل چشم و تشکیل ترشحات سخت در نزدیکی ناحیه ماکولا است که باعث تورم در ماکولا می شود. با توجه به افزایش شیوع آن در سراسر جهان، DR به عنوان یک بیماری مزمن چشمی توسط سازمان بهداشت جهانی (WHO) در فهرست قرار گرفته است. مشاهده شده است که خطر DED با تنظیم قند خون، وجود فشار خون شریانی و طول مدت بیماری مرتبط است. دیابت نوع ۱ بیشترین خطر را دارد. پس از یک دهه دیابت نوع ۲، DED تقریباً ۸۰ درصد از مبتلایان را تحت تأثیر قرار می دهد [۶]. برخی از درمان های بسیار موثر DED توسعه یافته اند. اینها شامل کورتیکواستروئیدها، فتوکواگولاسیون لیزری و تزریق داخل زجاجیه ای عوامل ضد فاکتور رشد اندوتلیال عروقی (VEGF) است. با این حال، اثربخشی این رویکردها در جلوگیری از کاهش بینایی به تشخیص زودهنگام DED بستگی دارد. به ویژه، در مرحله مقدماتی، افراد هیچ علامتی را تجربه نمی کنند. به همین دلیل است که غربالگری برای DED در بیماران دیابتی در سراسر جهان بسیار توصیه می شود، همانطور که در دستورالعمل های بین المللی و منطقه ای نشان داده شده است [۷]. تشخیص این تغییرات تشریحی با عکاسی فوندوس دارای تعدادی چالش است. اول، گسترش مداوم اطلاعات پزشکی بیمار، مانند تصاویر فوندوس، چالش های مداومی را برای معاینه، تشخیص و درمان ایجاد می کند. استخراج دستی ویژگی ها از حجم زیادی از تصاویر فوندوس و تشخیص بعدی منجر به از دست دادن زمان بین تشخیص و درمان می شود. چشم پزشکان اغلب روزها طول می کشند تا تصاویر عادی را مطالعه کنند. چشم پزشکان نیز روزها برای بررسی تصاویر بیماری DED وقت می گذارند [۸]. یکی دیگر از نکات منفی آنالیز دستی تصویر شبکیه فوندوس و ارزیابی DED چشم پزشکان این است که ممکن است همیشه به نتایج دقیقی دست پیدا نکنند، زیرا حتی عالی ترین متخصص و چشم پزشک حرفه ای ممکن است تغییرات کوچک در آناتومی چشم را ردیابی نکنند. یک سیستم تشخیص خودکار DED که ضایعات DED را در زمان محاسباتی کمتر طبقه بندی و شناسایی می کند، درمان زودهنگام را ارائه می کند و از کاهش بینایی جلوگیری می کند. بنابراین، تکنیک های تشخیص خودکار DED برای رفع این مشکل ضروری است. دوم، در چند دهه گذشته، تلاش هایی برای توسعه سیستم های تجزیه و تحلیل DED مبتنی بر رایانه با استفاده از روش های پردازش تصویر و رویکردهای یادگیری ماشین انجام شده است [۹–۱۱]. شبکه های عصبی پیچشی CNN به طور گسترده برای تشخیص DED تجزیه و تحلیل شده اند و بیشتر از روش های تشخیص تصویر قبلی بهتر عمل می کنند. به طور کلی، یادگیری عمیق پتانسیل فوق العاده ای را در حوزه مراقبت های بهداشتی نشان داده است، که امکان شناسایی بیمارانی را که احتمالاً در آینده به بیماری مبتلا می شوند، می دهد. دقت آزمون طبقه بندی باینری (DED سالم و شدید) با استفاده از یادگیری عمیق بالاترین دقت را به دست آورده است. در حالی که طبقه بندی باینری DED سالم و خفیف (یعنی مرحله اولیه)، و همچنین طبقه بندی چند طبقه (خفیف، متوسط و شدید) از تصاویر فوندوس رنگی، هنوز یک چالش باز است [۱۲]، [۱۳].

## ۲. ادبیات موضوع

رتینوپاتی دیابتی (DR): منصور و همکاران [33] معماری AlexNet را برای طبقه‌بندی ۵ مرحله از DR اصلاح کردند.  $accuracy$  ۹۷,۹۳٪،  $specificity$  ۹۳٪ و  $sensitivity$  ۱۰۰٪ بر روی مجموعه داده Kaggle بدست آمد. X. Li و همکاران [34] از مدل‌های مختلف CNN از پیش آموزش دیده مانند AlexNet، GoogLeNet و VGGNet استفاده کرد. آنها به  $accuracy$  ۹۲,۰۱٪،  $specificity$  ۹۷,۱۱٪ و  $sensitivity$  ۸۶,۰۳٪ دست یافتند. آنها به ترتیب به  $accuracy$  ۹۵,۲۱٪،  $specificity$  ۹۷,۸۰٪ و  $sensitivity$  ۷۷,۷۹٪ دست یافتند. پردومو و همکاران [35] تصاویر DR نرمال و تصاویر اگزودا را با استفاده از معماری LeNet طبقه بندی کردند. با استفاده از مجموعه داده e-optha، نویسندگان به  $accuracy$  ۹۹,۶٪،  $specificity$  ۹۹,۶٪ و  $sensitivity$  ۹۹,۸٪ دست یافتند. تاکاهاشی و همکاران [36] یک GoogLeNet اصلاح شده برای تشخیص مراحل مختلف DR اعمال کرد. آنها GoogLeNet را با حذف پنج لایه دقت اصلاح کردند و اندازه دسته را به چهار کاهش دادند و به  $accuracy$  ۸۱٪ دست یافتند. وان و همکاران [37] از یک CNN نه لایه ای استفاده کردند که شامل پنج لایه پیچشی با ۳۲ فیلتر الهام گرفته از معماری OxfordNet بود. آنها با استفاده از مجموعه داده Messidor به  $specificity$  ۹۱,۴۰ درصد و  $sensitivity$  ۹۱,۹۰ درصد دست یافتند [38]. سائرس و همکاران [39] پنج مرحله مختلف DR را با دقت ۸۸,۴ درصد طبقه بندی کرد.  $accuracy$  در تصاویر نرمال ۹۶,۹٪ و  $accuracy$  در تصاویر DR خفیف و بدتر ۵۷,۹٪ بود.

Umapathy و همکاران [40] از تصاویر [41] STARE، HRE، MESSIDOR [38] و تصاویر به دست آمده از مجموعه داده‌های موسسه شبکیه چشم کارناتاکا استفاده کردند. نویسندگان دو روش را برای تشخیص خودکار پیشنهاد کردند، که شامل طبقه‌بندی کننده درخت‌های تصمیم و یادگیری انتقالی (TL) می‌باشد. آنها آخرین لایه معماری Inception-V3 را برای طبقه بندی تصاویر نرمال و DR دوباره آموزش دادند. آنها به  $accuracy$  ۸۸,۸٪ دست یافتند. نگوین و همکاران یک روش خودکار غربالگری DR با استفاده از مدل‌های DL مانند CNN، VGG-16 و VGG-19 ارائه کرد. این سیستم پنج دسته از محدوده DR 0-4 را طبقه بندی می‌کند که در آنها ۰ بدون DR و ۴ دارای DR است. آنها به ترتیب  $sensitivity$  ۸۰٪،  $specificity$  ۸۲٪ و  $accuracy$  ۸۲٪ را به دست آوردند.

**گلوکوم (GI):** Ghamdi و همکاران [42] یک مدل نیمه نظارت شده CNN TL برای تشخیص خودکار GI ارائه کرد. آنها از پایگاه داده RIM-ONE [43] استفاده کردند و به  $accuracy$  ۹۲,۴٪،  $specificity$  ۹۳,۳٪ و  $sensitivity$  ۹۱,۷٪ دست یافتند. Cerentinia و همکاران [44] از معماری GoogLeNet برای تشخیص حضور GI استفاده کرد.

آنها از مجموعه داده‌های پایگاه‌های مختلف استفاده کردند و به دقت ۹۰ درصد از پایگاه داده با وضوح بالا (HRF)، ۹۴,۲ درصد دقت از [43] RIMONE(r1)، ۸۶,۲ درصد  $accuracy$  از [43] RIM-ONE (r2) دست یافتند. ۸۶,۴ درصد  $accuracy$  از [43] RIM-ONE(r3) و با ترکیب هر سه پایگاه داده  $accuracy$  به دست آمده ۸۷,۶ درصد بود. فی و همکاران [44] از شبکه VGG برای طبقه بندی میدان‌های بینایی گلوکوم و غیر گلوکوم بر اساس نتایج مطالعه میدان بینایی (VF)<sup>۲</sup> استفاده کردند و برای این آزمایش، نمونه های VF را به دست آوردند. از سه مرکز مختلف چشم پزشکی در کشور چین. آنها  $accuracy$  ۸۷,۶ درصد را به دست آوردند در حالی که  $specificity$  ۸۲,۶ درصد و  $sensitivity$  ۹۳,۲ درصد بود.

**آب مروارید (Ca):** در نهایت، تشخیص آب مروارید با استفاده از DL توسط Pratap و همکاران [45] انجام شد. نویسندگان داده‌ها را از منابع مختلفی مانند HRF، STARE [41]، DIARETDB0، MESSIDOR [50]، FIRE و غیره جمع‌آوری کرده‌اند. در مجموع ۸۰۰ تصویر (۲۰۰ - طبیعی، ۲۰۰ - خفیف، ۲۰۰ - متوسط، ۲۰۰ - شدید) جمع‌آوری کردند.  $accuracy$  به دست آمده ۹۲,۹۱٪ بود.

<sup>1</sup>. Transfer Learning

<sup>2</sup>. visual field

# دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12<sup>th</sup> National Congress of  
the New Technologies in Sustainable Development of Iran

senaconf.ir

مقایسه تحقیقات انجام شده در زمینه طبقه بندی تصاویر فوندوس چشم

DED	معماری	مدل	منبع	نتایج
DR	AlexNet	CNN	[46]	ACC = 97.93%, S E = 100%, S P = 93%
	VGGNet	CNN	[47]	SE =90.5%, SP =91.6%
	Inception-V3	CNN	[48]	SE =90.1%, SP =98.2%
	AlexNet, GoogLeNet, VGGNets	CNN	[34]	ACC = 92.01%, SE =86.03%,SP=97.11%
	GoogLeNet	CNN	[36]	ACC =81%, PABAK =74%
	Inception-V4	CNN	[39]	ACC =88.4%
	Inception-V3	CNN	[40]	ACC =88.8%
	VGG-16, VGG-19	CNN	[49]	ACC =82%, SE =80%, SP =82%
	ResNet50	CNN	[50]	ACC =96.3%
GI	VGG-16	CNN	[42]	ACC =92.4%, SE=91.7%, SP = 93.3%
	GoogLeNet	CNN	[44]	ACC = 90.0%, 94.2%, 86.2%, 86.4%, 87.3%
	VGG	CNN	[45]	ACC =87.6%, SE =82.6% ,SP =93.2%
Ca	AlexNet	CNN	[51]	ACC =92.91%

ACC = Accuracy, SE = Sensitivity, SP = Specificity

# دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12<sup>th</sup> National Congress of  
the New Technologies in Sustainable Development of Iran

senaconf.ir

## ۳. روش پیشنهادی

### ۳.۱. داده‌گان

دیتاست استفاده شده [Ocular Disease Intelligent Recognition \(ODIR\)](#) می‌باشد که از سایت Kaggle دریافت شده است که آن یک پایگاه داده چشم پزشکی ساختاریافته از ۵۰۰۰ بیمار با سن، عکس‌های فوندوس رنگی از چشم چپ و راست و کلمات کلیدی تشخیصی پزشکی از پزشکان است.

این مجموعه داده به معنای نمایش مجموعه اطلاعات «زندگی واقعی» بیماران است که توسط شرکت فناوری پزشکی Shanggong از بیمارستان‌ها/مراکز پزشکی مختلف در چین جمع‌آوری شده است. در این موسسات، تصاویر فوندوس توسط دوربین‌های مختلف موجود در بازار مانند کانن، زایس و کووا گرفته می‌شود که منجر به وضوح تصویر متفاوت می‌شود. این دیتاست در مجموع شامل ۸ کلاس می‌باشد که ما در این تحقیق از ۴ کلاس استفاده کرده‌ایم.


### ۳.۲. پیش پردازش

در این مرحله یک فایل CSV از تمام داده‌های تصویر به همراه برچسب آنها داریم. اکنون یک تابع برای تقسیم داده‌ها به دسته خاص نوشته ایم. بنابراین ما در حال تغییر اندازه داده‌های تصویر به اندازه‌های ۲۲۴\*۲۲۴ و افزودن تصاویر یک کلاس خاص به آن قاب مجموعه داده می‌باشیم. بنابراین ما هر چهار کلاس تصویر را در قاب داده ds اضافه کرده ایم. دسته‌های مورد استفاده عبارتند از: ۰: آب مروارید، ۱: گلوکوم، ۲: طبیعی و ۳: دیابت

### ۳.۳. معماری پیشنهادی

معماری که در این تحقیق مورد استفاده قرار گرفته است یک معماری هیبرید بر پایه سه معماری ResNet، MobileNetV3Small و VGG16 می‌باشد.

### ۳.۴. معماری پیشنهادی



### ۳.۵. نتایج

جدول ۱-۱- مقایسه معماری‌های پیاده‌سازی شده

Row	Model	Metrics			
		Recall(sensitivity)	F1-Score	Accuracy	Precision
1	ResNe50	0.86	0.87	0.9016	0.88
2	VGG16	0.82	0.84	0.8817	0.87
4	MobileNetV3Small	0.86	0.88	0.9016	0.90
5	مدل پیشنهادی	0.92	0.91	0.9602	0.91



# دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12<sup>th</sup> National Congress of  
the New Technologies in Sustainable Development of Iran

senacnf.ir

۴. نتیجه‌گیری

روشهای مختلفی برای شناسایی زودهنگام بیماری های چشم ارائه شده‌اند. شبکه‌های عصبی کانولوشن و یادگیری ماشینی ابزارهایی برای طبقه‌بندی هستند و می‌توانند به علم چشم پزشکی کمک کنند، به ویژه در رابطه با مشکل جهانی گلوکوم و رتینوپاتی دیابتی.

در این تحقیق معیارهای عددی را نشان می‌دهد که تقریباً کامل هستند (Accuracy, Recall, Specificity) Precision, and F1 score نزدیک به ۱ هستند).

مدل پیشنهادی ما در مقایسه با سایر مدل‌هایی که در جدول ۲-۲ معرفی و پیاده سازی گشت عملکرد مناسب تری داشته و در تمامی معیارهای اعتبار سنجی معرفی شده رشد قابل قبولی داشته و با دقت ۹۶.۰۲٪ از دیگر معماری‌ها دقتی بالاتر را کسب کرده است و همین امر کارآمدی معماری مورد نظر را اثبات می‌کند.

## منابع و مراجع

- [1] N. G. Forouhi and N. J. Wareham, "Epidemiology of diabetes," *Medicine (Baltimore)*, vol. 47, no. 1, pp. 22–27, 2019.
- [2] R. R. A. Bourne *et al.*, "Prevalence and causes of vision loss in high-income countries and in Eastern and Central Europe in 2015: magnitude, temporal trends and projections," *Br. J. Ophthalmol.*, vol. 102, no. 5, pp. 575–585, 2018.
- [3] C.-Y. Cheng *et al.*, "Prevalence and causes of vision loss in East Asia in 2015: magnitude, temporal trends and projections," *Br. J. Ophthalmol.*, vol. 104, no. 5, pp. 616–622, 2020.
- [4] R. P. Finger, R. Fimmers, F. G. Holz, and H. P. N. Scholl, "Incidence of blindness and severe visual impairment in Germany: projections for 2030," *Invest. Ophthalmol. Vis. Sci.*, vol. 52, no. 7, pp. 4381–4389, 2011.
- [5] R. Kahloun *et al.*, "Prevalence and causes of vision loss in North Africa and Middle East in 2015: magnitude, temporal trends and projections," *Br. J. Ophthalmol.*, vol. 103, no. 7, pp. 863–870, 2019.
- [6] R. Lee, T. Y. Wong, and C. Sabanayagam, "Epidemiology of diabetic retinopathy, diabetic macular edema and related vision loss," *Eye Vis.*, vol. 2, no. 1, pp. 1–25, 2015.
- [7] T. Y. Wong *et al.*, "Guidelines on diabetic eye care: the international council of ophthalmology recommendations for screening, follow-up, referral, and treatment based on resource settings," *Ophthalmology*, vol. 125, no. 10, pp. 1608–1622, 2018.
- [8] N. Silberman, K. Ahrlich, R. Fergus, and L. Subramanian, "Case for automated detection of diabetic retinopathy," in *2010 AAAI spring symposium series*, 2010.
- [9] C. Y. Cheung, F. Tang, D. S. W. Ting, G. S. W. Tan, and T. Y. Wong, "Artificial intelligence in diabetic eye disease screening," *Asia-Pacific J. Ophthalmol.*, vol. 8, no. 2, pp. 158–164, 2019.
- [10] P. R. Vamsi and A. Chahuan, "Machine learning based hybrid model for fault detection in wireless sensors data," *EAI Endorsed Trans. Scalable Inf. Syst.*, vol. 7, no. 24, pp. e6–e6, 2020.
- [11] I. H. Sarker, M. F. Faruque, H. Alqahtani, and A. Kalim, "K-nearest neighbor learning based diabetes mellitus prediction and analysis for eHealth services," *EAI Endorsed Trans. Scalable Inf. Syst.*, vol. 7, no. 26, pp. e4–e4, 2020.
- [12] R. Poplin *et al.*, "Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning," *Nat. Biomed. Eng.*, vol. 2, no. 3, pp. 158–164, 2018.
- [13] C. Lam, D. Yi, M. Guo, and T. Lindsey, "Automated detection of diabetic retinopathy using deep learning," *AMIA summits Transl. Sci. Proc.*, vol. 2018, p. 147, 2018.
- [14] Y. Bengio, A. Courville, and P. Vincent, "Representation learning: A review and new perspectives," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 35, no. 8, pp. 1798–1828, 2013.
- [15] F. Wang and Y. Li, "Beyond physical connections: Tree models in human pose estimation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2013, pp. 596–603.
- [16] M. D. Zeiler and R. Fergus, "Visualizing and understanding convolutional networks," in *European conference on computer vision*, 2014, pp. 818–833.
- [17] D. C. Cireşan, U. Meier, J. Masci, L. M. Gambardella, and J. Schmidhuber, "High-performance neural networks for visual object classification," *arXiv Prepr. arXiv1102.0183*, 2011.
- [18] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [19] S. Gupta, R. Girshick, P. Arbeláez, and J. Malik, "Learning rich features from RGB-D images for object detection and segmentation," in *European conference on computer vision*, 2014, pp. 345–360.
- [20] D. Warde-Farley, I. J. Goodfellow, A. Courville, and Y. Bengio, "An empirical analysis of dropout in piecewise linear networks," *arXiv Prepr. arXiv1312.6197*, 2013.

# دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12<sup>th</sup> National Congress of  
the New Technologies in Sustainable Development of Iran

senacnf.ir

- [21] C. Szegedy, A. Toshev, and D. Erhan, "Deep neural networks for object detection," *Adv. Neural Inf. Process. Syst.*, vol. 26, 2013.
- [22] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929–1958, 2014.
- [23] L.-C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "Semantic image segmentation with deep convolutional nets and fully connected crfs," *arXiv Prepr. arXiv1412.7062*, 2014.
- [24] K. Cho, T. Raiko, and A. T. Ihler, "Enhanced gradient and adaptive learning rate for training restricted Boltzmann machines," in *Proceedings of the 28th international conference on machine learning (ICML-11)*, 2011, pp. 105–112.
- [25] J. L. Chu and A. Krzyżak, "Analysis of feature maps selection in supervised learning using convolutional neural networks," in *Canadian Conference on Artificial Intelligence*, 2014, pp. 59–70.
- [26] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Commun. ACM*, vol. 60, no. 6, pp. 84–90, 2017.
- [27] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv Prepr. arXiv1409.1556*, 2014.
- [28] T. Mikolov, I. Sutskever, K. Chen, G. S. Corrado, and J. Dean, "Distributed representations of words and phrases and their compositionality," *Adv. Neural Inf. Process. Syst.*, vol. 26, 2013.
- [29] B. Hariharan, P. Arbeláez, R. Girshick, and J. Malik, "Simultaneous detection and segmentation," in *European conference on computer vision*, 2014, pp. 297–312.
- [30] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning," *Image Recognit.*, vol. 7, 2015.
- [31] L. Deng, "A tutorial survey of architectures, algorithms, and applications for deep learning," *APSIPA Trans. Signal Inf. Process.*, vol. 3, 2014.
- [32] L. Deng and D. Yu, "Deep learning: methods and applications," *Found. trends® signal Process.*, vol. 7, no. 3–4, pp. 197–387, 2014.
- [33] R. F. Mansour, "Deep-learning-based automatic computer-aided diagnosis system for diabetic retinopathy," *Biomed. Eng. Lett.*, vol. 8, no. 1, pp. 41–57, 2018.
- [34] X. Li, T. Pang, B. Xiong, W. Liu, P. Liang, and T. Wang, "Convolutional neural networks based transfer learning for diabetic retinopathy fundus image classification," in *2017 10th international congress on image and signal processing, biomedical engineering and informatics (CISP-BMEI)*, 2017, pp. 1–11.
- [35] O. Perdomo, J. Arevalo, and F. A. González, "Convolutional network to detect exudates in eye fundus images of diabetic subjects," in *12th International Symposium on Medical Information Processing and Analysis*, 2017, vol. 10160, pp. 235–240.
- [36] H. Takahashi, H. Tampo, Y. Arai, Y. Inoue, and H. Kawashima, "Applying artificial intelligence to disease staging: Deep learning for improved staging of diabetic retinopathy," *PLoS One*, vol. 12, no. 6, p. e0179790, 2017.
- [37] M. J. J. P. Van Grinsven, B. van Ginneken, C. B. Hoyng, T. Theelen, and C. I. Sánchez, "Fast convolutional neural network training using selective data sampling: Application to hemorrhage detection in color fundus images," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1273–1284, 2016.
- [38] E. Decencière *et al.*, "Feedback on a publicly distributed image database: the Messidor database," *Image Anal. Stereol.*, vol. 33, no. 3, pp. 231–234, 2014.
- [39] R. Sayres *et al.*, "Using a deep learning algorithm and integrated gradients explanation to assist grading for diabetic retinopathy," *Ophthalmology*, vol. 126, no. 4, pp. 552–564, 2019.
- [40] A. Umapathy, A. Sreenivasan, D. S. Nairy, S. Natarajan, and B. N. Rao, "Image processing, textural feature extraction and transfer learning based detection of diabetic retinopathy," in *Proceedings of the 2019 9th International Conference on Bioscience, Biochemistry and Bioinformatics*, 2019, pp. 17–21.
- [41] D. J. J. Farnell *et al.*, "Enhancement of blood vessels in digital fundus photographs via the application of multiscale line operators," *J. Franklin Inst.*, vol. 345, no. 7, pp. 748–765, 2008.
- [42] M. Al Ghamdi, M. Li, M. Abdel-Mottaleb, and M. Abou Shousha, "Semi-supervised transfer learning for convolutional neural networks for glaucoma detection," in *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 3812–3816.
- [43] F. Fumeró, S. Alayón, J. L. Sanchez, J. Sigut, and M. Gonzalez-Hernandez, "RIM-ONE: An open retinal image database for optic nerve evaluation," in *2011 24th international symposium on computer-based medical systems (CBMS)*, 2011, pp. 1–6.
- [44] A. V Gundlapalli, M.-C. Jaulent, and D. Zhao, *MEDINFO 2017: Precision Healthcare Through Informatics: Proceedings of the 16th World Congress on Medical and Health Informatics*, vol. 245. IOS Press, 2018.
- [45] F. Li *et al.*, "Automatic differentiation of Glaucoma visual field from non-glaucoma visual field using deep convolutional neural network," *BMC Med. Imaging*, vol. 18, no. 1, pp. 1–7, 2018.
- [46] M. D. Abràmoff *et al.*, "Improved automated detection of diabetic retinopathy on a publicly available dataset through integration of deep learning," *Invest. Ophthalmol. Vis. Sci.*, vol. 57, no. 13, pp. 5200–5206, 2016.
- [47] V. Gulshan *et al.*, "Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus

# دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12<sup>th</sup> National Congress of  
the New Technologies in Sustainable Development of Iran

senacnf.ir

- photographs,” *Jama*, vol. 316, no. 22, pp. 2402–2410, 2016.
- [48] D. S. W. Ting *et al.*, “Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes,” *Jama*, vol. 318, no. 22, pp. 2211–2223, 2017.
- [49] Q. H. Nguyen *et al.*, “Diabetic retinopathy detection using deep learning,” in *Proceedings of the 4th international conference on machine learning and soft computing*, 2020, pp. 103–107.
- [50] X. Li, X. Hu, L. Yu, L. Zhu, C.-W. Fu, and P.-A. Heng, “CANet: cross-disease attention network for joint diabetic retinopathy and diabetic macular edema grading,” *IEEE Trans. Med. Imaging*, vol. 39, no. 5, pp. 1483–1493, 2019.
- [51] T. Pratap and P. Kokil, “Computer-aided diagnosis of cataract using deep transfer learning,” *Biomed. Signal Process. Control*, vol. 53, p. 101533, 2019.
- [52] N. E. institute. F. A. D. E. D. <https://>, 2015. [Online; Last Nei.nih.gov/health/diabetic/retinopathy, and R. September-2015]., “No Title”.
- [53] S. Diamond, V. Sitzmann, F. Julca-Aguilar, S. Boyd, G. Wetzstein, and F. Heide, “Dirty pixels: Towards end-to-end image processing and perception,” *ACM Trans. Graph.*, vol. 40, no. 3, pp. 1–15, 2021.
- [54] S. A. Tabish, “Is diabetes becoming the biggest epidemic of the twenty-first century?,” *Int. J. Health Sci. (Qassim)*, vol. 1, no. 2, p. V, 2007.
- [55] H. Kolb, “Simple anatomy of the retina by helga kolb,” *Webvision Organ. Retin. Vis. Syst.*, 2011.
- [56] E. T. D. R. S. R. Group, “Grading diabetic retinopathy from stereoscopic color fundus photographs—an extension of the modified Airlie House classification: ETDRS report number 10,” *Ophthalmology*, vol. 98, no. 5, pp. 786–806, 1991.
- [57] R. Varma, P. P. Lee, I. Goldberg, and S. Kotak, “An assessment of the health and economic burdens of glaucoma,” *Am. J. Ophthalmol.*, vol. 152, no. 4, pp. 515–522, 2011.
- [58] A. Almazroa, R. Burman, K. Raahemifar, and V. Lakshminarayanan, “Optic disc and optic cup segmentation methodologies for glaucoma image detection: a survey,” *J. Ophthalmol.*, vol. 2015, 2015.
- [59] L. Zhang, J. Li, H. Han, B. Liu, J. Yang, and Q. Wang, “Automatic cataract detection and grading using deep convolutional neural network,” in *2017 IEEE 14th international conference on networking, sensing and control (ICNSC)*, 2017, pp. 60–65.
- [60] P. Vashist, S. Singh, N. Gupta, and R. Saxena, “Role of early screening for diabetic retinopathy in patients with diabetes mellitus: an overview,” *Indian J. community Med. Off. Publ. Indian Assoc. Prev. Soc. Med.*, vol. 36, no. 4, p. 247, 2011.
- [61] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [62] A. K. Krizhevsky, I. S. Sutskever, and G. E. Hinton, “ImageNet Classification Classification with Deep Convolutional Convolutional Neural Networks”.
- [63] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, “Improving neural networks by preventing co-adaptation of feature detectors,” *arXiv Prepr. arXiv1207.0580*, 2012.
- [64] O. Russakovsky *et al.*, “Imagenet large scale visual recognition challenge,” *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, 2015.
- [65] A. Howard *et al.*, “Searching for mobilenetv3,” in *Proceedings of the IEEE/CVF international conference on computer vision*, 2019, pp. 1314–1324.