

Received: 2021/8/26

Accepted: 2021/11/20

How to cite:

Mirabedini Sh, Kangavari M. Effect of deep generative adversarial networks models in determining the degree of diabetic retinopathy. EBNESINA 2022;24(1):36-45.

DOI: 10.22034/24.1.36

Original Article

Effect of deep generative adversarial networks models in determining the degree of diabetic retinopathy

Shirin Mirabedini¹✉, Mohammadreza Kangavari²

Abstract

Background and aims: Early detection of diabetic retinopathy in the military forces can prevent their performance reduction or avoid the occurrence of operational errors. So an automated and optimal method to diagnose the degree of disease from retinal images is valuable in the prevention of acute phases. The purpose of this article is to present a new method in determining of proliferation based on the deep generative adversarial networks models (GANs).

Methods: In this study, which was conducted in 2018-2019, a new method was used to classify 35,126 medical images on the data set available from the Kaggle site related to a hospital in the UK. To create a balance between levels, first with the help of a deep GAN, the number of small classes was increased, then using a designed classifier, the degree of disease was determined in different ways.

Results: Using the designed GAN, an accuracy of about 87% was obtained for classification, which was about 7% more than the best similar works. In addition, with the distribution of the model, the efficiency of automation also showed an improvement of 60%.

Conclusion: By solving the problem of imbalance between different levels of retinopathy, by producing new images using the designed GAN and distributing the mentioned operations, while increasing the performance, optimal accuracy has been obtained. Therefore, this new strategy can be used to automate the diagnosis of diabetic retinopathy.

Keywords: Diabetic Retinopathy, Neural Network Models, Deep Learning, Military

1. Instructor, Department of Computer Engineering, Payame Noor University, Tehran, Iran

2 Associate professor, Department of Computer Engineering, Iran University of Science and Technology, Tehran, Iran.

✉ Corresponding Author:

Shirin Mirabedini

Address: Department of Computer Engineering, Payame Noor University, Tehran, Iran. PO Box 19395-4697

Tel: +98 (21) 23320000

E-mail: Sh.Mirabedini@pnu.ac.ir

مقاله تحقیقی

تأثیر به کارگیری مدل‌های رقابتی مولد عمیق در تعیین درجه رتینوپاتی دیابتی

شیرین میرعبدینی^۱، محمدرضا کنگاوری^۲

چکیده

زمینه و اهداف: تشخیص زودهنگام رتینوپاتی دیابتی در نیروهای نظامی می‌تواند موجب جلوگیری از کاهش عملکرد این نیروها و یا ممانعت از بروز خطاهاي عملیاتی شود. به کارگیری یک روش خودکار و بهینه جهت تشخیص درجه بیماری از روی تصاویر شبکیه، در پیشگیری از حاد شدن بیماری کمک کننده است. هدف این مقاله ارائه روشی نو در تعیین پرولیفراتیو، مبتنی بر تجزیه و تحلیل داده‌ها از طریق تکنیک‌های یادگیری عمیق در هوش مصنوعی است.

روش بررسی: در این مطالعه که در سال ۱۳۹۷-۱۴۰۰ انجام شد از روشی نوین در رده‌بندی ۳۵,۱۲۶ تصویر پزشکی بر روی مجموعه داده‌های قابل دسترس از سایت کاگل مربوط به بیمارستانی در کشور انگلستان، استفاده شد. برای ایجاد توازن بین سطوح، ابتدا با کمک مدل رقابتی مولد عمیق، تعداد کلاس‌های کم تعداد را افزایش داد، سپس با استفاده از یک رده‌بند طراحی شده، تعیین درجه رتینوپاتی دیابتی، به طرق مختلف، انجام گرفت.

یافته‌ها: با استفاده از مدل مولد عمیق طراحی شده، دقت رده‌بندی حدود ۸۷٪ به دست آمد که نسبت به برترین کارهای مشابه، حدود ۷٪ بهبود داشت. ضمناً با توزیع مدل، کارایی خودکارسازی نیز به میزان ۶۰٪ بهبود نشان داد.

نتیجه‌گیری: با رفع مشکل عدم توازن سطوح مختلف رتینوپاتی، از طریق تولید تصاویر جدید با استفاده از مدل مولد عمیق طراحی شده و توزیع عملیات مذکور، ضمن افزایش کارایی، دقت بهینه نیز حاصل شده است. لذا از این راهکار نوین می‌توان جهت خودکارسازی تشخیص درجه رتینوپاتی بهره برد.

کلمات کلیدی: رتینوپاتی دیابتی، مدل‌های شبکه عصبی، یادگیری عمیق، نظامیان

(سال بیست و چهارم، شماره اول، بهار ۱۴۰۱، مسلسل ۷۸)

تاریخ پذیرش: ۱۴۰۰/۸/۲۹

فصلنامه علمی پژوهشی ابن‌سینا / اداره بهداشت، امداد و درمان نهاد

تاریخ دریافت: ۱۴۰۰/۶/۴

۱. مری، دانشگاه پیام نور، گروه کامپیوتر، تهران، ایران

۲. دانشیار، دانشگاه علم و صنعت ایران، گروه مهندسی کامپیوتر، تهران، ایران

مؤلف مسئول: شیرین میرعبدینی^۱

آدرس: دانشگاه پیام نور، گروه کامپیوتر، تهران، ایران

صندوق پستی ۱۹۳۹۵-۴۶۹۷

تلفن: +۹۸ (۲۱) ۲۳۳۲۰۰۰۰

E-mail: Sh.Mirabedini@pnu.ac.ir

مقدمه

متفاوت کامپیوتری به کار گرفته شده است [۲-۲۳]. در کلیه موارد، روش‌های تجزیه و تحلیل تصاویر به طور کلی به غربالگری رتینوپاتی دیابتی، تصویربرداری شبکیه و به کارگیری مدل‌های عمیق قابل تقسیم است. در روش غربالگری رتینوپاتی دیابتی، سامانه‌ای طراحی می‌گردد که تصاویر اصلی شبکیه را دریافت کرده، در خروجی تصویری ارائه می‌دهد که مکان ضایعات را مشخص می‌نماید، سپس تشخیص درجه بیماری، بر اساس پیکسل‌های تصویر صورت می‌پذیرد [۱۲]. در روش تصویربرداری از شبکیه، تشخیص درجه رتینوپاتی دیابتی با استفاده از تکنیک‌های پردازش تصویر و سپس اعمال نگاشت با الگوریتم‌های معین بر اساس ویژگی‌های نواحی مختلف انجام می‌شود [۲۴]. در این دو روش استخراج ویژگی‌های شبکیه با استفاده از تکنیک‌های پردازش تصویر، نیاز به حضور فرد متخصص دارد؛ اما با استفاده از مدل‌های عمیق، دگرگونی اساسی در خودکارسازی استخراج ویژگی و تعیین درجه رتینوپاتی دیابتی بدون نیاز به فرد متخصص قابل انجام شده است. در این مقاله برای این حل مسئله با تأکید بر استفاده از مدل‌های عمیق، از طریق تولید نمونه‌های جدید با مدل‌های رقابتی مولد توزیعی و سپس رده‌بندی، با استفاده از مدل‌های عمیق راهکاری نو ارائه می‌گردد.

لازم به ذکر است در تمامی تحقیقات انجام گرفته با توجه به این که مجموعه داده تصاویر رتینوپاتی دیابتی نامتوازن بوده یعنی غالباً تعداد تصاویر مربوط به افراد بدون ضایعه، به مراتب از تعداد تصاویر افراد دارای ضایعه بیشتر است، این موضوع مشکلات مهمی را در زمان آموزش مدل‌های عمیق ایجاد می‌نماید. مدیریت داده‌های نامتوازن در این راستا چالشی چندین ساله در حوزه هوش مصنوعی است که تا کنون برای رفع این چالش سه روش کلی ارائه شده است: رویکردهایی در سطح داده^۱، رویکردهایی در سطح الگوریتم^۲ و چارچوب

دیابت، نوعی بیماری شایع در جهان است که منجر به تغییرات رگ‌های خونی در کل بدن، خصوصاً عروق موجود در چشم و در نتیجه بیماری رتینوپاتی دیابتی می‌گردد. این بیماری بر ارگانهای مختلف از قبیل چشم، سیستم عصبی، قلب و سایر اعضای بدن تأثیر منفی دارد. رتینوپاتی دیابتی عارضه‌ای است که به دلیل تغییرات ایجاد شده در عروق خونی شبکیه رخ می‌دهد که در سطح پرولیفراتیو، آسیب دیدن عروق خونی شبکیه، نشت خون، رشد شاخه‌های عروقی شکننده و کلافه مانند و تخریب شبکیه را در پی دارد و آسیب دیدن شبکیه، سبب تار شدن تصاویر ارسالی به مغز می‌گردد. رتینوپاتی دیابتی یکی از علل اصلی کاهش دید در گروه نظامیان بوده و افراد با دیابت درمان نشده چندین برابر بیشتر در معرض ابتلاء به نایابی قرار دارند [۱] کاهش دید می‌تواند بهره‌وری نیروی رزمی را کاهش داده و موجب افزایش درصد خطاها در مأموریت‌های مهم شود. ازانجاكه سلامت نیروهای نظامی به عنوان یک گروه جمعیتی همواره مورد توجه بوده است و این گروه، به خاطر نوع مأموریت و فعالیت‌هایشان استرس‌ها و ناراحتی‌های روانی و جسمانی مختلفی را متحمل می‌شوند، برای حفظ و ارتقای کارایی آنان بررسی دوره‌ای وضعیت سلامت روانی و جسمانی از اهمیت خاصی برخوردار است. لذا معاینات دوره‌ای به منظور جلوگیری از پیشرفت این بیماری و بروز نایابی نیز، ضروری است. همچنین در بدو استخدام نیروهای نظامی تشخیص صحیح میزان کاهش دید و علل آن از اهمیت ویژه‌ای برخوردار است. از این رو طراحی روشی خودکار برای درجه‌بندی و تشخیص رتینوپاتی دیابتی پرولیفراتیو در این حوزه بسیار راهگشا است. از طرفی مجموعه تصاویر شبکیه چشم شامل حداکثر پنج کلاس (سالم و رتینوپاتی دیابتی نوع ۱ الی ۴) با چالش عدم توازن رویروست؛ به این معنی که تعداد تصاویر سالم به مراتب از تعداد تصاویر دیابتی بیشتر است و این موضوع، آموزش مدل و رده‌بندی تصاویر را دچار اختلال می‌نماید. در دهه اخیر برای حل این مسئله بر روی تصاویر شبکیه چشم، الگوریتم‌های

1. Data level approaches

2. Algorithm level approaches

مینیماکس یک قانون تصمیم‌گیری است که در نظریه بازی و آمار برای مینیمم کردن احتمال شکست و ضرر در بدترین حالت که بیشترین احتمال ضرر را دارد از آن استفاده می‌شود. این قانون برای این کاربرد در قالب رابطه زیر قابل‌نمایش است:

$$\min_{\mathbf{G}} \max_{\mathbf{D}} f(\mathbf{D}, \mathbf{G}) = E_{x \sim p_{data}(x)} \log D(x) + E_{z \sim p_z(z)} \log(1 - D(G(z)))$$

در این تحقیق برای تشخیص درجه بیماری رتینوپاتی دیابتی، جهت رویارویی با چالش داده‌های نامتوازن از روش بیش‌نمونه‌برداری مبتنی بر مدل‌های رقابتی مولد استفاده شد. مجموعه داده‌های به کار گرفته شده در این تحقیق، ۳۵۱۲۶ تصویر شبکه چشم بیماران بیمارستانی در انگلیس و قابل دسترس از سایت کاگل^۸ شامل پنج کلاس است که کلاس کلاس افراد سالم بسیار پر تعداد در حدود ۷۳٪ کل داده‌هاست و کلاس‌های با درجه رتینوپاتی دیابتی نوع ۱ تا ۴ درصد پایینی از کل داده‌ها را شامل می‌شوند. چنان که در جدول ۱ مشخص است تعداد تصاویر پرولیفراتیو حدود ۲٪ کل داده‌هاست.

جدول ۱- اطلاعات مجموعه داده‌های رتینوپاتی دیابتی کاگل

کلاس	تعداد تصاویر	درصد	نام
.	۲۵۸۱۰	% ۷۳/۴۸	سالم
۱	۲۴۴۳	% ۶/۹۶	رتینوپاتی دیابتی نوع ۱
۲	۵۲۹۲	% ۱۵/۰۷	رتینوپاتی دیابتی نوع ۲
۳	۸۷۳	% ۲/۴۸	رتینوپاتی دیابتی نوع ۳
۴	۷۰۸	% ۲/۰۱	رتینوپاتی دیابتی نوع ۴ (پرولیفراتیو)

مشکل موجود در کار با مجموعه داده‌های نامتوازن، در مرحله آموزش شبکه عمیق است؛ با توجه به عدم توازن داده‌ها در دوره‌ای مختلف تجزیه و تحلیل با تکنیک یادگیری عمیق، به کلاس‌های کم تعداد، هیچ نمونه‌ای تعلق نمی‌گیرد و این موضوع آموزش مدل را دچار اختلال می‌کند؛ لذا ابتدا با استفاده از مدل رقابتی مولد طراحی شده (GAN)^۹ تعداد نمونه‌های کلاس‌های کم تعداد، افزایش و سپس عمل تشخیص درجه رتینوپاتی دیابتی، با آموزش مدل عمیق پیچشی (CNN)^{۱۰} صورت می‌گیرد. در انجام آزمایشات مذکور از سخت‌افزار

یادگیری حساس به هزینه^۱ که مابین رویکرد الگوریتمی و داده‌ای قرار دارد [۲۵]. روش‌های سطح داده به دو صورت زیرنمونه‌برداری^۲ از کلاس اکثیریت، بیش‌نمونه‌برداری^۳ از کلاس اقلیت، یا ترکیبی از هر دو روش انجام می‌شود [۲۶]. لازم به ذکر است در رابطه با مدل‌های عمیق، محققان راهکار بیش‌نمونه‌برداری را نسبت به دیگر روش‌ها، بهینه‌تر و موفق‌تر معرفی کرده‌اند [۲۷]. در این تحقیق جهت حل چالش داده‌های نامتوازن از بیش نمونه‌برداری مبتنی بر شبکه‌های مولد عمیق، استفاده شده است. به این ترتیب که ابتدا تصاویر کلاس‌های کم تعداد، توسط مدل مولد طراحی شده، به تعداد تصاویر کلاس افراد بدون عارضه افزایش داده شد که این عملیات به صورت معمولی و همچنین توزیع شده مورد آزمایش قرار گرفت. سپس جهت تشخیص درجه بیماری، با آموزش مدل عمیق روی تصاویر اصلی و تصاویر تولیدشده و تجزیه و تحلیل داده‌ها، عمل رده‌بندی صورت پذیرفت. از مدل به دست آمده می‌توان در تشخیص درجه رتینوپاتی دیابتی نیروهای نظامی نیز بهره جست و این گامی زمینه‌ساز برای پیشگیری و کنترل بیماری‌های مزمن بهویژه در نظامیان محسوب می‌شود.

روش بردسی

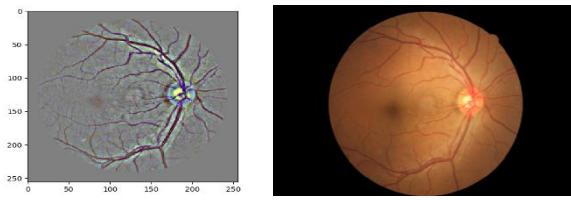
در این پژوهش جهت تجزیه و تحلیل داده‌ها، از مدل‌های رقابتی مولد عمیق استفاده شده است. این مدل‌ها از دو بخش اصلی مولد^۴ و متمایزگر^۵ تشکیل شده است که هر یک به صورت شبکه‌های عمیق غالباً از نوع پیچشی^۶ طراحی می‌گردد [۲۸-۳۰]. زیرشبکه مولد جهت ایجاد تصاویر جدید غیرواقعی و زیرشبکه متمایزگر، مسئول تمایز تصاویر ساختگی از تصاویر واقعی است. این شبکه مشابه بازی مینیماکس^۷ است که دو زیرشبکه مولد و متمایزگر، شرکت‌کنندگان اصلی آن هستند.

1. Cost-sensitive learning framework
2. Resampling_Undersampling
3. Resampling_Oversampling
4. Generator
5. Discriminator
6. Convolutional Neural Network
7. minimax

8. <https://www.kaggle.com/c/diabetic-retinopathy-detection/data>

9. generative adversarial network

10. Convolutional Neural Networks



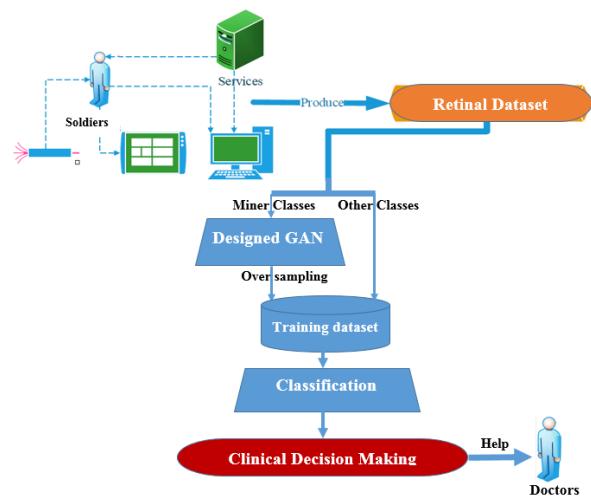
در مرحله دوم تصاویر اصلی مجموعه داده‌ها به همراه تصاویر جدید تولید شده به عنوان ورودی به مدل عمیق پیچشی طراحی شده‌ای جهت آموزش مدل، ارائه و در نهایت تجزیه و تحلیل داده‌ها و عمل رده‌بندی تصاویر انجام گرفت.

ملاحظات اخلاقی

در این پژوهش، با رعایت کلیه جوانب اخلاقی، از مجموعه داده رتینوپاتی دیابتی مربوط به بیمارستانی در کشور انگلیس استفاده شده است که اطلاعات آن به صورت آزاد، در اینترنت قابل دسترس است.

یافته‌ها

رویکرد یادگیری ماشین^۳ از تعداد زیادی مؤلفه تشکیل شده است که این مؤلفه‌ها در حین روند آموزش، مقادیر متغیری به خود می‌گیرند تا با رسیدن به نقطه تعادل به بهترین مقدار برستند. برخی از مؤلفه‌ها قبل از آغاز روند آموزش مدل، تنظیم می‌شوند، به این مؤلفه‌ها، ابر مؤلفه گفته می‌شود. قانون و قاعده‌ای برای تنظیم ابر مؤلفه‌ها وجود ندارد؛ بنابراین راه حل موجود، به کارگیری مقادیر مختلف و بررسی تأثیر آن در نتیجه روند آموزش است. این ابر مؤلفه‌ها در زمان آموزش و دقت خروجی بسیار تأثیرگذار هستند. ابر مؤلفه‌هایی که مستقیم بر روی زمان آموزش تأثیرگذار هستند عبارتند از تعداد دوره^۴ و اندازه دسته^۵. تعداد دوره تعداد دفعاتی است که عملیات آموزش شبکه، روی تمامی داده‌های آموزش انجام می‌شود. اندازه دسته نیز مشخص کننده تعداد دفعاتی است که در هر دوره، خطای شبکه محاسبه شده و مؤلفه‌ها به روزرسانی می‌شوند.



^۱ GPU و زبان برنامه‌نویسی پایتون و ابزار کراس و TensorFlow^۲ استفاده شده است. راه حل پیشنهادی این مسئله در قالب تصویر ۱ نمایش داده شده است. مطابق این تصویر از آنجا که مجموعه داده‌های شبکه در شرایط متفاوت تهیه شده‌اند و تصاویر فوندوس از لحاظ نور و دیگر شرایط با یکدیگر متفاوت هستند؛ بنابراین ابتدا تا حد امکان، تصاویر یکپارچه شدند تا تأثیر منفی روی اجرای عملیات نگذارند. لذا در مرحله اول روی مجموعه داده‌ها، نرم‌السازی و پیش‌پردازش‌های لازم صورت پذیرفت و در انجام آزمایشات نیز برای نرم‌السازی تصاویر از کتابخانه OpenCV استفاده شد. با این عمل علاوه بر این که تصاویر یکپارچه گشته و از وضوح کافی برخوردار شدند، حجم آنها نیز از حدود ۴۰ گیگابایت به حدود ۲/۲ گیگابایت کاهش یافت. نمونه‌ای از تصویر شبکه قبل و بعد از عمل پیش‌پردازش در تصویر ۲ مشخص شده است.

بعد از پیش‌پردازش کل مجموعه داده‌ها، جهت بیش‌نمونه‌برداری داده‌های کم تعداد، با آموزش دهی به شبکه رقابتی مولد عمیق طراحی شده، تصاویری از کلاس‌های کم تعداد به تعداد کلاس صفر تولید شد. این عملیات در حالت معمولی با یک پردازنده گرافیکی و همچنین در حالت توزیعی با چندین واحد پردازنده گرافیکی مورد آزمایش قرار گرفت.

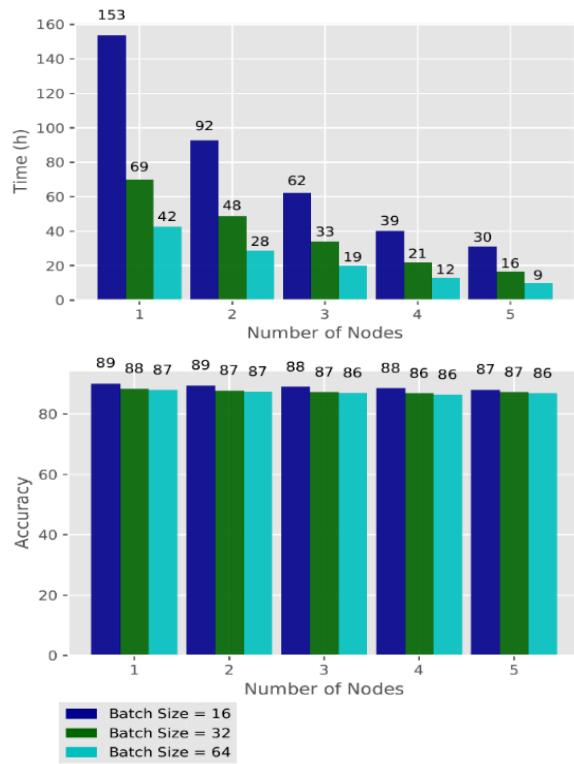
3. Machine learning

4. epoch

5 batch size

1. graphics processing unit

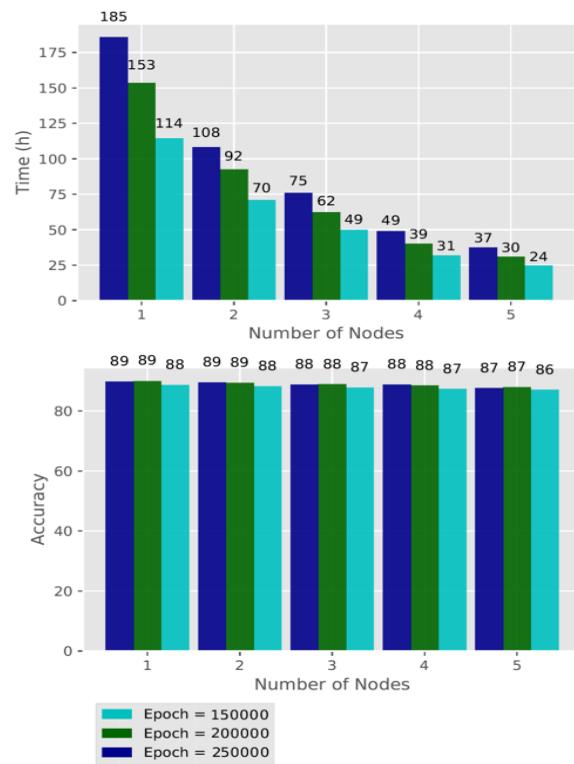
2. TensorFlow



نمودار ۲- تغییرات زمان آموزش مدل مولد و دقت رده‌بندی به ازای مقادیر مختلف اندازه دسته روی مجموعه داده رتینوپاتی دیابتی به دست آمده است این در حالی است که شرکت‌کنندگان برتر مسابقه برگزار شده توسط کاگل دقت حدود ۸۰٪ به دست آورده‌اند، لذا با روش پیشنهادی این تحقیق دقت در حدود ۷٪ بهبود داشته است.

پس از انتخاب تعداد دوره، اندازه دسته مورد بررسی قرار گرفت. از میان اعداد درون بازه مذکور هر چه عدد انتخابی بزرگ‌تر باشد، تعیین‌پذیری مدل کاهش می‌یابد و به حافظه بیشتری هم نیاز است. طبق بررسی‌های انجام شده از میان اعداد درون بازه مذکور، اندازه ۱۶، ۳۲ و ۶۴ بهترین انتخاب‌ها بوده و ۳۲ را به عنوان پیش‌فرض معرفی نموده‌اند [۳۱؛ ۳۲]؛ اما نمی‌توان با قطعیت این عدد را به عنوان اندازه دسته انتخاب نمود. بنابراین لازم است ارزیابی روی هر سه اندازه انجام شود تا بهترین اندازه دسته برای مدل پیشنهادی انتخاب شود.

طبق نمودار ۲ مدل پیشنهادی برای مجموعه داده رتینوپاتی دیابتی کاگل روی سایز دسته معادل ۱۶، ۳۲ و ۶۴ مورد ارزیابی و بررسی قرار داده شد تا بهترین تعداد دسته معین شود. با وجود زمان طولانی‌تر آموزش به ازای تعداد دسته ۱۶، اندازه ۱۶ برای مدل پیشنهادی انتخاب گردید چرا که دقت بالاتری در



نمودار ۱- تغییرات دقت رده‌بندی و زمان آموزش مدل به ازای مقادیر مختلف تعداد نod و اندازه دسته روی مجموعه داده رتینوپاتی دیابتی مشاهدات نشان می‌دهد که با افزایش تعداد دوره، به مراتب زمان آموزش نیز افزایش می‌یابد. اما لزوماً از نظر دقت رده‌بندی بهبودی حاصل نمی‌شود؛ چراکه افزایش تعداد دوره، شبکه را دچار بیش‌برازش^۱ می‌نماید. در انجام این آزمایشات برای انتخاب تعداد دوره، برای رسیدن به بهترین تعداد دوره، از ۱۰۰,۰۰۰ دوره آغاز و با گام ۵۰,۰۰۰ تعداد دوره افزایش داده شد. پس از رسیدن به دقت مطلوب اندازه گام را کاهش داده و نقاط پیرامون نقطه مطلوب مورد بررسی قرار گرفت تا بهترین انتخاب حاصل شود. در نمودار تصویر ۳ زمان و دقت به ازای بهترین تعداد دوره و تعداد دوره‌های قبل و بعد از آن نمایش داده شده است. طبق نتایج حاصل شده، از تعداد دوره ۲۰۰,۰۰۰ مدل به ثبات می‌رسد؛ بنابراین دوره ۲۰۰,۰۰۰ برای مدل مولد طراحی شده برگزیده شد.

همچنان که در نمودار ۱ مشاهده می‌شود زمان آموزش در مرحله بیش نمونه‌برداری مبتنی بر مدل رقابتی مولد، از ۱۸۵ ساعت به ۲۴ ساعت تقلیل یافت. همچنین دقت رده‌بندی ۸۷٪

1 Overfitting

Nvidia GTX 1080 Ti در حالت غیر توزیعی به مدت شش روز زمان می‌برد که با اعمال عملیات توزیع زمان آموزش، کاهش چشم‌گیر ۶۰٪ نشان داد.

لازم به ذکر است طی دو دهه اخیر برای حل مسئله رتینوپاتی دیابتی تحقیقاتی از جهت مختلف و بر روی مجموعه داده‌های مختلف از جمله داده‌های خصوصی مراکز درمانی یا داده‌های در دسترس روی وب و با الگوریتم‌های گوناگون صورت گرفته است. برخی از این روش‌ها در جدول ۲ نمایش داده شده است.

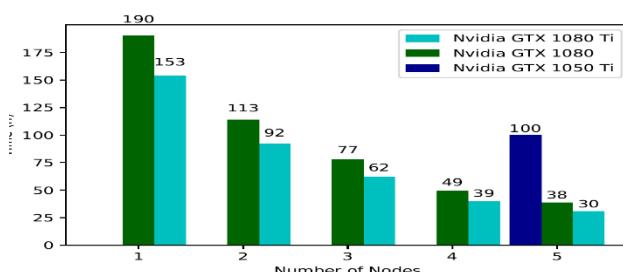
در این روش‌ها از تکنیک‌های پردازش تصویر، غربالگری، تصویربرداری و مدل‌های عمیق، جهت تعیین عارضه و رده‌بندی استفاده شده است؛ اما در کلیه روش‌ها مشکل داده‌های نامتوازن موجب اختلال در امر تشخیص می‌شود. روش پیشنهادی علاوه بر تمرکز روی افزایش کارایی رده‌بندی و بهبود زمان آموزش مدل‌های رقابتی مولد عمیق که در بخش‌های قبلی به آن اشاره شد، دقت رده‌بندی را نیز نسبت به روش‌های مشابه، افزایش داده است. لازم به ذکر است رده‌بندی تصاویر مذکور در سال ۲۰۱۵ که توسط کاگل ارائه شد، نفرات برتر این مسابقه در بین ۶۰ تیم شرکت‌کننده به دقت حدود ۸۰٪ دست یافتند [۳۴، ۳۳]. از میان روش‌های رده‌بندی انجام شده روی این مجموعه داده، دو مقاله علمی، نزدیک و مشابه روش پیشنهادی این مقاله هستند. پرت^۱ و همکاران [۲۱] در سال ۲۰۱۶ و کومار^۲ و همکاران [۳۵] در سال ۲۰۱۹ با تکنیک‌های یادگیری عمیق، روی همین مجموعه داده‌ها رده‌بندی انجام دادند که در جدول ۳، مقایسه این روش‌ها و درنهایت دقت رده‌بندی‌ها در هر روش نمایش داده شده است. چنانکه در جدول ۳ مشاهده می‌شود، درروش پیشنهادی، علاوه بر بهبود کارایی تشخیص درجه رتینوپاتی دیابتی، دقت رده‌بندی نیز ۷٪ نسبت به روش‌های قبلی افزایش نشان می‌دهد.

رده‌بندی ایجاد می‌نماید و از طرفی در سیستم‌های با ظرفیت حافظه کمتر نیز قابل اجرا است. مطابق نمودار ۳ و ۴ پس از تنظیم ابر مؤلفه‌ها دقت رده‌بندی در حالت تک پردازنده ۸۹٪ و در حالت چندپردازنده ۸۷٪ و کاهش ۶٪ زمان در حالت استفاده از روش توزیعی حاصل شده است.

بحث و نتیجه‌گیری

از اهداف مهم عملیات توزیع، افزایش کارایی مدل و کاهش زمان است. با توجه به نتایج به دست آمده با افزایش تعداد ماشین‌های درون خوشه، زمان آموزش به طرز چشم‌گیری کاهش می‌یابد. این عمل در سیستم‌های فیزیکی با پردازنده گرافیکی معمولی تأثیر بیشتری دارد زیرا عملیات آموزش بسیار کندتر از سیستم‌های فیزیکی قدرتمند است. از دیگر اهداف توزیع، امکان استفاده از سیستم‌های معمولی است که یا امکان اجرای عملیات روی آنها وجود ندارد و یا در صورت امکان‌پذیر بودن بسیار سنگین و زمان بر هستند. این میزان از تأثیرگذاری برای مدل‌های پیچیده نمایان‌تر است. نمودار ۳ نشان‌دهنده تأثیر توزیع مدل پیشنهادی بر روی مجموعه داده رتینوپاتی دیابتی کاگل در زمان آموزش روی سیستم‌های فیزیکی باقدرت متفاوت است.

طبق این نمودار امکان اجرای مدل ارائه شده برای مجموعه داده رتینوپاتی دیابتی به صورت غیر توزیعی به دلیل پیچیدگی بالای زیاد و حجم بالای داده‌ها در حالت غیر توزیعی روی Nvidia GTX 1050 Ti سیستم با پردازنده گرافیکی امکان‌پذیر نیست و برای اجرای توزیعی نیز به حداقل پنج ماشین باقدرت مشابه نیاز است. این مدل روی پردازنده قدرتمند



نمودار ۳- مقایسه زمان آموزش مدل مولد طراحی شده بر روی مجموعه داده رتینوپاتی دیابتی کاگل روی سیستم‌های متفاوت

1. Prat
2. Qummar

جدول ۲- نمونه هایی از الگوریتم های بکار گرفته شده در رتینوپاتی دیابتی

نوبتمند اول (سال)	تکنیک به کار گرفته شده	مجموعه داده ها	نوع تحقیق	دقت
اشرف (۲۰۱۴) [۱۸]	غربالگری ماشین بردار پشتیانی	مجموعه داده خصوصی	%۸۷ تعیین عارضه: غیرپرولیفراتیو	
رضاء (۲۰۱۱) [۱۷]	تصویربرداری	STARE	%۹۷ تعیین عارضه: غیرپرولیفراتیو	
سینکلاوانیجا (۲۰۰۵) [۷]	تصویربرداری	۳۳۶ تصویر شبکیه: ۲۲۱ کلاس سالم و ۱۱۵ کلاس غیرپرولیفراتیو %۸۳ رده بندی		
فیلیپ (۲۰۰۷) [۸]	تصویربرداری	۶۷۲۲ بیمار	%۶۷ رده بندی	
استبلریدیس (۲۰۰۷) [۱۱]	تصویربرداری	مجموعه داده شامل ۴۰ تصویر شبکیه	%۹۰ رده بندی	
پرت (۲۰۱۶) [۲۱]	مدل عمیق پیچشی	کاگل	%۷۵ رده بندی	
ونگ (۲۰۱۷) [۲۳]	مدل عمیق پیچشی	کاگل	- تعیین ویژگی و رده بندی تصاویر	
کومار (۲۰۱۹) [۳۵]	مدل عمیق پیچشی	کاگل	- رده بندی	
کولک (۲۰۱۷) [۱۰]	مدل عمیق پیچشی	کاگل	- تعیین میکروآنوریسم و عارضه های دیگر	
لام (۲۰۱۸) [۳۶]	مدل عمیق پیچشی	کاگل	%۷۴/۵ تعیین ویژگی	
روش پیشنهادی	بیش نمونه برداری مبتنی بر	کاگل	%۸۹ رده بندی	- مدل روابطی مولد پیچشی -
				مدل عمیق پیچشی

به سرعت رو به افزایش است و این تلاش ها به میزان بالایی به تشخیص درجه این بیماری به افراد مبتلا و متخصصین کمک کرده است. لازم به ذکر است از آنجا که تصاویر کلاس سالم، در غالب مجموعه تصاویر پزشکی بسیار پر تعدادتر از نمونه های دارای عارضه است، لذا این راهکار می تواند برای مجموعه داده های دیگر حوزه پزشکی، خصوصاً طب نظامی نیز به کار گرفته شود. از آنجا که سلامت کارکنان نظامی ارتباط مستقیم با توان دفاعی کشور دارد و ماهیت فعالیت های نظامی ایجاب می کند که این گروه، در زمان صلح و جنگ از آمادگی جسمانی و ترکیب بدنی مناسبی برخوردار باشد و با توجه به این که بیماری های مزمن، از جمله دیابت باعث افت کیفیت زندگی بیماران شده و نیز آمادگی جسمانی نظامیان، که از مهمترین ویژگی هایی است که سبب برتری ایشان در میدان نبرد می شود، را کاهش می دهد، توجه به پیشگیری از این بیماری ها با فراهم کردن زیرساخت های لازم برای استفاده از رویکردهای نوین تجزیه و تحلیل داده ها در حوزه هوش مصنوعی، امری راهگشا و ضروری است.

تشکر و قدردانی

این مطالعه با کد IR.PNU.REC.1400.028 در کمیته اخلاق در پژوهش دانشگاه پیام نور مورد تصویب قرار گرفته است.

در روش پیشنهادی، رویکردی نوین برای رفع مشکل داده های نامتوافق با استفاده از بیش نمونه برداری مبتنی بر مدل های رقابتی مولد عمیق ارائه شد و همچنین به عنوان نقطه تمایز و نوآوری این پژوهش نسبت به تحقیقات قبلی، عملیات اجرایی در بیش نمونه برداری، روی چندین پردازنده نیز مورد آزمایش قرار گرفت که موجب کاهش بسیار زیاد زمان آموزش مدل، از ۱۸۵ ساعت به ۲۴ ساعت شد. همچنین دقت تشخیص با یک پردازنده حدود ۸۷٪ حاصل آمد که نسبت به موارد مشابه قبلی ۷٪ بهبود داشت.

همان گونه که بیان شد از سال ۱۹۹۶ در راستای تشخیص درجه رتینوپاتی دیابتی تلاش های زیادی صورت گرفته است، اما از سال ۲۰۱۴ پس از نتایج شگفت انگیزی که از آموزش مدل های عمیق در حوزه بینایی ماشین ارائه شد تلاش های زیادی نیز در راستای پردازش تصاویر پزشکی و از جمله تصاویر شبکیه چشم برای حل مسئله رتینوپاتی دیابتی صورت پذیرفت که به علت عملکرد بهینه این رویکرد، تمایل به بهبود حل مسائل و تشخیص های پزشکی از طریق مدل های عمیق

جدول ۳- مقایسه روش پیشنهادی با [۳۵] و [۲۱]

مطالعه	تعداد تصاویر / روش	نوع رده بند	کتابخانه / زبان پیاده سازی	دقت
پرت [۲۱]	%۷۵ کاگل	TQWT داده	CNN کراس/ایتون	۸۰,۰۰۰
کومار [۳۷]	%۸۰/۸ کاگل	TQWT داده	TL-CNN کراس/ایتون	۳۵,۱۲۶
روش پیشنهادی	%۸۷/۸ کاگل	TL-CNN	GAN کراس/ایتون	۳۵,۱۲۶

CNN: شبکه های عصبی پیچشی (Convolutional Neural Network)
GAN: شبکه های مولد رقابتی (Generative Adversarial Networks)
TL: یادگیری انتقال (Transfer Learning)

پژوهش و نگارش سهم مساوی داشته، با تأیید نهایی، مسئولیت
صحت و دقت مطالب مندرج در آن را می‌پذیرند.

منابع مالی

این پژوهش مورد حمایت معاونت پژوهشی دانشگاه پیام نور
انجام شده است

تعارض منافع

نویسنده‌گان اعلام می‌کنند که در این پژوهش هیچ‌گونه
تعارض منافع وجود ندارد.

سهم نویسنده‌گان

در مقاله حاضر، همه نویسنده‌گان در ارائه ایده، انجام

References

- Pollack S, Igo RP, Jensen RA, Christiansen M, Li X, Cheng C-Y, et al. Multiethnic genome-wide association study of diabetic retinopathy using liability threshold modeling of duration of diabetes and glycemic control. *Diabetes*. 2019;68(2):441-456. doi:[10.2337/db18-0567](https://doi.org/10.2337/db18-0567)
- Wang H, Hsu W, Goh KG, Lee ML. An effective approach to detect lesions in color retinal images. Paper presented at: Proceedings IEEE Conference on Computer Vision and Pattern Recognition. CVPR 2000 (Cat. No. PR00662)2000.
- Sinhanayothin C, Kongbunkiat V, Phoojaruenchanachai S, Singalavanija A. Automated screening system for diabetic retinopathy. Paper presented at: 3rd International Symposium on Image and Signal Processing and Analysis, 2003. ISPA 2003. Proceedings of the 2003.
- Fleming AD, Philip S, Goatman KA, Williams GJ, Olson JA, Sharp PF. Automated detection of exudates for diabetic retinopathy screening. *Physics in medicine & biology*. 2007;52(24). doi:[10.1088/0031-9155/52/24/012](https://doi.org/10.1088/0031-9155/52/24/012)
- Lee SC, Lee ET, Wang Y, Klein R, Kingsley RM, Warn A. Computer classification of nonproliferative diabetic retinopathy. *Archives of ophthalmology*. 2005;123(6):759-764. doi:[10.1001/archophth.123.6.759](https://doi.org/10.1001/archophth.123.6.759)
- Kahai P, Namuduri KR, Thompson H. A decision support framework for automated screening of diabetic retinopathy. *International journal of biomedical imaging*. 2006;2006:1-8. doi:[10.1155/IJBI/2006/45806](https://doi.org/10.1155/IJBI/2006/45806)
- Singalavanija A, Supokavej J, Bamroongsuk P, Sinhanayothin C, Phoojaruenchanachai S, Kongbunkiat V. Feasibility study on computer-aided screening for diabetic retinopathy. *Japanese journal of ophthalmology*. 2006;50(4):361-366. doi:[10.1007/s10384-005-0328-3](https://doi.org/10.1007/s10384-005-0328-3)
- Philip S, Fleming AD, Goatman KA, Fonseca S, Mcnamee P, Scotland GS, et al. The efficacy of automated “disease/no disease” grading for diabetic retinopathy in a systematic screening programme. *British journal of ophthalmology*. 2007;91(11):1512-1517. doi:[10.1136/bjo.2007.119453](https://doi.org/10.1136/bjo.2007.119453)
- Zhou W, Wu C, Chen D, Wang Z, Yi Y, Du W. Automatic microaneurysms detection based on multifeature fusion dictionary learning. *Computational and mathematical methods in medicine*. 2017;2017:1-11. doi:[10.1155/2017/2483137](https://doi.org/10.1155/2017/2483137)
- Quellec G, Charrière K, Boudi Y, Cochener B, Lamard M. Deep image mining for diabetic retinopathy screening. *Medical image analysis*. 2017;39:178-193. doi:[10.1016/j.media.2017.04.012](https://doi.org/10.1016/j.media.2017.04.012)
- Estabridis K, de Figueiredo RJ. Automatic detection and diagnosis of diabetic retinopathy. Paper presented at: 2007 IEEE International Conference on Image Processing2007.
- Li Q, Jin X-M, Gao Q-x, You J, Bhattacharya P. Screening diabetic retinopathy through color retinal images. In: Zhang D, ed. *Medical biometrics*. Berlin, Heidelberg: International Conference on Medical Biometrics. Springer; 2008:176-183. doi:[10.1007/978-3-540-77413-6_23](https://doi.org/10.1007/978-3-540-77413-6_23)
- Yun WL, Acharya UR, Venkatesh YV, Chee C, Min LC, Ng EYK. Identification of different stages of diabetic retinopathy using retinal optical images. *Information sciences*. 2008;178(1):106-121. doi:[10.1016/j.ins.2007.07.020](https://doi.org/10.1016/j.ins.2007.07.020)
- Nayak J, Acharya R, Bhat PS, Shetty N, Lim T-C. Automated diagnosis of glaucoma using digital fundus images. *Journal of medical systems*. 2009;33(5):337-346. doi:[10.1007/s10916-008-9195-z](https://doi.org/10.1007/s10916-008-9195-z)
- Acharya UR, Lim CM, Ng EYK, Chee C, Tamura T. Computer-based detection of diabetes retinopathy stages using digital fundus images. *Proceedings of the institution of mechanical engineers, part H: journal of engineering in medicine*. 2009;223(5):545-553. doi:[10.1243/09544119JEIM486](https://doi.org/10.1243/09544119JEIM486)
- Dupas B, Walter T, Erginay A, Ordóñez R, Deb-Joardar N, Gain P, et al. Evaluation of automated fundus photograph analysis algorithms for detecting microaneurysms, haemorrhages and exudates, and of a computer-assisted diagnostic system for grading diabetic retinopathy. *Diabetes & metabolism*. 2010;36(3):213-220. doi:[10.1016/j.diabet.2010.01.002](https://doi.org/10.1016/j.diabet.2010.01.002)
- Ahmed Wasif R, Eswaran C. A decision support system for automatic screening of non-proliferative diabetic retinopathy. *Journal of medical systems*. 2011;35(1):17-24. doi:[10.1007/s10916-009-9337-y](https://doi.org/10.1007/s10916-009-9337-y)
- Ashraf MN, Habib Z, Hussain M. Texture feature analysis of digital fundus images for early detection of diabetic retinopathy. Paper presented at: 2014 11th International Conference on Computer Graphics, Imaging and Visualization2014.
- Akram MU, Khalid S, Tariq A, Khan SA, Azam F. Detection and classification of retinal lesions for grading of diabetic retinopathy. *Computers in biology and medicine*. 2014;45:161-171. doi:[10.1016/j.combiomed.2013.11.014](https://doi.org/10.1016/j.combiomed.2013.11.014)
- Lunscher N, Chen ML, Jiang N, Zelek J. Automated screening for diabetic retinopathy using compact deep networks. *Journal of computational vision and imaging systems*. 2017;3(1):1-3.

21. Pratt H, Coenen F, Broadbent DM, Harding SP, Zheng Y. Convolutional neural networks for diabetic retinopathy. Procedia computer science. 2016;90:200-205. doi:10.1016/j.procs.2016.07.014
22. Abràmoff MD, Lou Y, Erginay A, Clarida W, Amelon R, Folk JC, et al. Improved automated detection of diabetic retinopathy on a publicly available dataset through integration of deep learning. Investigative ophthalmology & visual science. 2016;57(13):5200-5206. doi:10.1167/iovs.16-19964
23. Wang Z, Yang J. Diabetic retinopathy detection via deep convolutional networks for discriminative localization and visual explanation. Paper presented at: Workshops at the thirty-second AAAI conference on artificial intelligence2018.
24. Abràmoff MD, Garvin MK, Sonka M. Retinal imaging and image analysis. IEEE reviews in biomedical engineering. 2010;3:169-208. doi:10.1109/RBME.2010.2084567
25. Ali A, Shamsuddin SM, Ralescu AL. Classification with class imbalance problem. International journal of advances in soft computing. 2013;5(3):1-30.
26. Sun Y, Wong AK, Kamel MS. Classification of imbalanced data: a review. International journal of pattern recognition and artificial intelligence. 2009;23(04):687-719. doi:10.1142/S0218001409007326
27. Buda M, Maki A, Mazurowski MA. A systematic study of the class imbalance problem in convolutional neural networks. Neural networks. 2018;106:249-259. doi:10.1016/j.neunet.2018.07.011
28. Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. Generative adversarial nets. Advances in neural information processing systems. 2014;27:1-9.
29. Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. 4th International Conference on Learning Representations; 2016; San Juan, Puerto Rico.
30. Dosovitskiy A, Tobias Springenberg J, Brox T. Learning to generate chairs with convolutional neural networks. Paper presented at: Proceedings of the IEEE conference on computer vision and pattern recognition2015.
31. Bengio Y. Practical recommendations for gradient-based training of deep architectures. In: Montavon G, Orr GB, Müller KR, eds. Neural networks: tricks of the trade: Springer; 2012:437-478. doi:10.1007/978-3-642-35289-8_26
32. Keskar NS, Mudigere D, Nocedal J, Smelyanskiy M, Tang PTP. On large-batch training for deep learning: Generalization gap and sharp minima. 5th International Conference on Learning Representations; 2016; Toulon, France.
33. Graham B. Kaggle diabetic retinopathy detection competition report. University of Warwick. 2015.
34. Antony M, Brgemann S. Kaggle Diabetic Retinopathy Detection Team o O solution. Competition Report Github. url: https://github.com/sveitser/kaggle_diabetic ...; 2015.
35. Qummar S, Khan FG, Shah S, Khan A, Shamshirband S, Rehman ZU, et al. A deep learning ensemble approach for diabetic retinopathy detection. IEEE Access. 2019;7:150530-150539. doi:10.1109/ACCESS.2019.2947484
36. Lam C, Yi D, Guo M, Lindsey T. Automated detection of diabetic retinopathy using deep learning. AMIA summits on translational science proceedings. 2018;2018:147-155.