



Development of an Engineering System for Diabetic Retinopathy Detection by Integrating Machine Learning and Biocompatible Materials in Retinal Imaging

Mohammadjavad
Hosseinpoor*

Department of Computer Engineering, Es.C.,
Islamic Azad University, Estahban, Iran

Abstract

Diabetic Retinopathy (DR) stands as a prevalent complication of diabetes and a leading cause of preventable blindness globally. Early and accurate detection of DR is crucial for halting its progression and preserving vision. While traditional diagnostic methods offer reasonable accuracy, they are often hampered by challenges such as being time-consuming, expensive, and reliant on the limited expertise of specialists. Consequently, the development of automated and intelligent diagnostic systems, leveraging novel engineering technologies, has become imperative. This research focuses on the development of an integrated engineering system that merges machine learning with cutting-edge principles in biocompatible materials and advanced retinal imaging techniques. The primary objective is to enhance the accuracy and speed of DR detection and severity classification using retinal fundus images. For this study, we have utilized the APTOS 2019 dataset, which comprises diverse images across five severity grades of the disease. Image preprocessing steps, including normalization and dimension standardization, have been performed, considering the characteristics of materials and sensors employed in imaging devices (although specific material details are not elaborated in this initial abstract, the overall approach leans in this direction). For precise feature extraction and classification, an advanced Convolutional Neural Network (CNN) architecture, specifically EfficientNet-B4, known for its transfer learning capabilities and high-level feature extraction prowess, has been employed. The final layers of the network have been optimized for the multi-class classification task of DR grading. A key innovation in this research lies in the synergistic integration of material engineering concepts (even at a conceptual level related to imaging quality) with deep learning models to elevate system performance. Preliminary results demonstrate promising performance in detecting and differentiating various DR severity levels, underscoring the potential of this engineered system as an effective tool in clinical decision support systems. This approach signifies a significant step towards offering novel and more accessible solutions for eye health.

Keywords: Diabetic Retinopathy, machine learning, biomedical engineering, retinal imaging, EfficientNet-B4, image preprocessing, smart healthcare

Received: 25/March/2026

Accepted: 08/May/2026

eISSN: 3115-7610

ISSN: 3115-7572

* Corresponding Author: mj.hosseinpoor@iau.ac.ir

توسعه سامانه مهندسی تشخیص رتینوپاتی دیابتی با ترکیب یادگیری ماشین و مواد زیست‌سازگار در تصویربرداری شبکه

استادیار، گروه مهندسی کامپیوتر، واحد استهبان، دانشگاه آزاد اسلامی، استهبان، ایران

محمدجواد حسین‌پور *

چکیده

سیستم‌های رتینوپاتی دیابتی (DR) یکی از عوارض شایع دیابت و عامل اصلی نابینایی قابل پیشگیری در سطح جهانی است. تشخیص زودهنگام و دقیق این بیماری به منظور جلوگیری از پیشرفت آن و حفظ بینایی حیاتی است. روش‌های تشخیصی سنتی، علی‌رغم دقت، با چالش‌هایی نظیر زمان‌بر بودن، هزینه بالا و وابستگی به تخصص محدود پزشکان روبه‌رو هستند. لذا، توسعه سامانه‌های خودکار و هوشمند تشخیص، با بهره‌گیری از فناوری‌های نوین مهندسی، امری ضروری است. این پژوهش به توسعه یک سامانه مهندسی یکپارچه می‌پردازد که یادگیری ماشین را با اصول نوین در حوزه مواد زیست‌سازگار و تکنیک‌های پیشرفته تصویربرداری شبکه ترکیب می‌کند. هدف اصلی، ارتقای دقت و سرعت در تشخیص و طبقه‌بندی شدت رتینوپاتی دیابتی با استفاده از تصاویر فوندوس شبکه است. در این مطالعه، ما از مجموعه داده APTOS 2019، که شامل تصاویر متنوعی از سطوح پنج‌گانه شدت بیماری است، بهره برده‌ایم. مراحل پیش‌پردازش تصویر شامل نرمال‌سازی و یکسان‌سازی ابعاد، با در نظر گرفتن ویژگی‌های مواد و سنسورهای به کاررفته در دستگاه‌های تصویربرداری (اگرچه در این چکیده اولیه جزئیات مواد ذکر نشده، اما رویکرد کلی به این سمت است)، انجام شده است. برای استخراج ویژگی‌های دقیق و انجام طبقه‌بندی، از معماری پیشرفته شبکه عصبی کانولوشنی EfficientNet-B4، که قابلیت یادگیری انتقالی و استخراج ویژگی‌های سطح بالا را دارد، استفاده شده است. لایه‌های نهایی شبکه برای وظیفه طبقه‌بندی چندکلاسه (پنج‌گرایه DR) بهینه‌سازی شده‌اند. جنبه نوآوری این پژوهش در تلفیق رویکردهای مهندسی مواد (حتی در سطح مفاهیم مرتبط با کیفیت تصویربرداری) با مدل‌های یادگیری عمیق برای بهبود عملکرد سیستم تشخیص است. نتایج اولیه نشان‌دهنده عملکرد امیدوارکننده‌ای در تشخیص و تفکیک سطوح مختلف رتینوپاتی دیابتی است، که بر پتانسیل این سامانه مهندسی به عنوان ابزاری کارآمد در سیستم‌های پشتیبان تصمیم‌گیری بالینی تأکید دارد. این رویکرد می‌تواند گامی مهم در جهت ارائه راهکارهای نوین و قابل دسترس‌تر برای سلامت چشم باشد.

کلیدواژه‌ها: رتینوپاتی دیابتی، یادگیری ماشین، مهندسی پزشکی، تصویربرداری شبکه، شبکه عصبی کانولوشنی، EfficientNet-B4، پیش‌پردازش تصاویر، سلامت هوشمند

مقدمه

بیماری‌های رتینوپاتی دیابتی^۱ یکی از عوارض شایع و مهم دیابت به‌شمار می‌رود که در اثر تغییرات پاتولوژیک عروق شبکه‌ای ایجاد شده و در صورت عدم تشخیص و مداخله به‌موقع، می‌تواند به کاهش بینایی و حتی نابینایی منجر شود [۱]. از آنجا که سیر بیماری معمولاً تدریجی است، تشخیص زودهنگام و غربالگری نظام‌مند بیماران نقش تعیین‌کننده‌ای در پیشگیری از پیشرفت و کاهش عوارض دارد [۲]. با این حال، تحقق غربالگری گسترده در عمل، به دلیل محدودیت‌های منابع و نیاز به ارزیابی دقیق تصاویر شبکه‌ای، با چالش‌های جدی روبه‌رو است. در روش‌های سنتی، تشخیص و ارزیابی رتینوپاتی دیابتی عمدتاً بر پایه بررسی دستی تصاویر فوندوس توسط متخصصان چشم انجام می‌شود [۳]. هرچند این رویکرد می‌تواند در مراکز تخصصی مؤثر باشد، اما وابستگی شدید به نیروی انسانی ماهر، زمان‌بر بودن فرایند غربالگری و همچنین تأثیرپذیری نتیجه از کیفیت تصاویر و شرایط نوردهی، محدودیت‌هایی را ایجاد می‌کند. افزون بر این، اختلاف در قضاوت بین متخصصان مختلف می‌تواند به کاهش یکنواختی تصمیم‌گیری در سطوح مختلف بالینی منجر شود. از سوی دیگر، در بسیاری از مناطق - به‌ویژه مناطق محروم یا کم‌برخوردار - دسترسی به متخصصان چشم محدود است و همین موضوع، ضرورت استفاده از راهکارهای خودکار و کمکی برای تشخیص دقیق‌تر و سریع‌تر را برجسته می‌سازد [۴]. در سال‌های اخیر، پیشرفت‌های قابل توجهی در حوزه یادگیری ماشین و به‌ویژه یادگیری عمیق، امکان تحلیل خودکار تصاویر پزشکی را با دقتی نزدیک به ارزیابی متخصصان فراهم کرده است. الگوریتم‌های مبتنی بر یادگیری ماشین با تحلیل حجم بالایی از داده‌های تصویری، قادرند ویژگی‌های پیچیده و الگوهای مرتبط با وجود و شدت رتینوپاتی دیابتی را استخراج کرده و آن‌ها را برای طبقه‌بندی بیماری به کار گیرند [۵]. این قابلیت، به‌ویژه در سناریوهای عملی که نیاز به سرعت پردازش و کاهش وابستگی به ارزیابی دستی دارند، می‌تواند ارزش افزوده جدی ایجاد کند. همچنین، سامانه‌های خودکار مبتنی بر یادگیری ماشین می‌توانند با افزایش سرعت ارزیابی و بهبود دسترسی به خدمات تشخیصی، اثر قابل توجهی بر پوشش غربالگری در مناطق با دسترسی محدود به متخصصان داشته باشند [۶]. در امتداد همین مسیر پژوهشی، مطالعات متعددی تلاش کرده‌اند عملکرد سامانه‌های تشخیص DR را بهبود دهند و محدودیت‌های عملی را کاهش دهند [۷]. بخشی از این تحقیقات بر توسعه مدل‌های سبک و کارآمد (از دید مصرف محاسباتی و پردازشی) تمرکز کرده‌اند تا استقرار آن‌ها در محیط‌های کلینیکی با منابع محدود امکان‌پذیرتر شود [۸]. [۹]. در دسته‌ای دیگر، استفاده از یادگیری انتقالی با به کارگیری شبکه‌های عصبی کانولوشنی و مدل‌های از پیش آموزش دیده^۲ مورد توجه قرار گرفته است؛ رویکردی که می‌تواند با کاهش نیاز به داده‌های حجیم، دقت طبقه‌بندی را افزایش دهد [۱۰-۱۲]. همچنین، برخی مطالعات ترکیب شبکه‌های کانولوشنی با تقسیم‌بندی ناحیه‌ای شبکه^۳ را به عنوان راهی برای دقیق‌تر کردن شناسایی بخش‌های آسیب‌دیده بررسی کرده‌اند [۱۳-۱۵]. در کنار این‌ها، مطالعاتی مبتنی بر استخراج ویژگی و پیش‌پردازش تصاویر با استفاده از مدل‌های از پیش آموزش دیده انجام شده که هدف آن‌ها بهبود دقت طبقه‌بندی شدت بیماری است [۱۶، ۱۷]. با وجود این پیشرفت‌ها، همچنان چالش‌های مهمی باقی مانده است. از یک سو، عدم توازن داده‌ها^۴ می‌تواند عملکرد مدل‌ها را تحت تأثیر قرار دهد، از سوی دیگر، برخی رویکردها نیازمند داده‌های گسترده‌تر و متنوع‌تر برای دستیابی به تعمیم بهتر هستند [۱۸، ۱۹]. همچنین، یکی از مسائل کلیدی در کاربرد بالینی، افزایش تفسیرپذیری مدل‌ها است؛ یعنی ارائه شواهدی روشن از اینکه مدل چگونه به تصمیم رسیده است. در کنار این موارد، رعایت حریم خصوصی بیماران نیز در طراحی سامانه‌های عملی اهمیت بالایی دارد و برای

1. Diabetic retinopathy (DR)

2. fine-tuning

3. retinal segmentation

4. data imbalance

آن راهکارهایی نظیر یادگیری فدرال مطرح شده است [۲۰]. علاوه بر چالش‌های مذکور، محدودیت منابع محاسباتی در محیط‌های واقعی نیز همچنان محرکی برای توسعه مدل‌های سبک‌تر و کارآمدتر محسوب می‌شود. براین اساس، شکاف تحقیقاتی را می‌توان در چند محور اصلی خلاصه کرد: نیاز به سامانه‌های تشخیص خودکار که هم‌زمان با دقت بالا، سرعت و کارایی عملیاتی و قابلیت استقرار در شرایط محدود همراه باشند؛ همچنین نیاز به کاهش وابستگی به ارزیابی دستی و محدودسازی خطاهای ناشی از Observer Variability و کیفیت نامناسب تصاویر، ازسوی دیگر، بهبود عملکرد مدل‌ها در شرایط چالش‌زا مانند عدم توازن داده‌ها، حرکت به سمت تفسیرپذیری بیشتر و رعایت ملاحظات حفظ حریم خصوصی نیز بخشی از شکاف‌های پابرجا در ادبیات پژوهشی است.

در این پژوهش، روش پیشنهادی بر مبنای توسعه یک سامانه مهندسی تشخیص رتینوپاتی دیابتی با بهره‌گیری از یادگیری ماشین/یادگیری عمیق شکل گرفته است. ایده اصلی آن است که با اتکا به قابلیت‌های تحلیل خودکار تصاویر شبکه، فرایند غربالگری و ارزیابی شدت بیماری را سریع‌تر، کم‌هزینه‌تر و کم‌وابسته‌تر به نیروی انسانی متخصص نماید؛ به‌طوری که بتواند در عمل، از محدودیت‌های روش‌های سنتی (زمان‌بر بودن، هزینه‌بر بودن، اختلاف نظر انسانی و وابستگی به کیفیت داده ورودی) عبور کند. افزون بر این، با توجه به چالش‌های گزارش شده در ادبیات (مانند عدم توازن داده‌ها و نیاز به توسعه سامانه‌های مناسب برای محیط‌های با منابع محدود)، چارچوب ارائه شده تلاش می‌کند قابلیت استقرار و کارایی سامانه را افزایش دهد و در نهایت، به حل شکاف موجود میان «پتانسیل روش‌های یادگیری عمیق» و «کاربردپذیری واقعی در فرایندهای بالینی و غربالگری» کمک کند.

روش

پژوهش حاضر از نوع کاربردی بوده و در سال ۱۴۰۳ انجام شده است. فرایند انجام این پژوهش در قالب چارچوبی نظام‌مند و چندمرحله‌ای طراحی شد که هدف آن توسعه سامانه مهندسی تشخیص رتینوپاتی دیابتی با رویکرد ترکیبی یادگیری ماشین و مواد زیست سازگار در تصویربرداری شبکه است. در این بخش، رویکردی نوین برای تشخیص و درجه‌بندی شدت رتینوپاتی دیابتی ارائه می‌شود که بر پایه ادغام هم‌افزای تصویربرداری پیشرفته شبکه با الگوریتم‌های یادگیری ماشین مقاوم، بنا شده است. هدف اصلی، توسعه سامانه‌ای است که نه تنها دقت بالایی در تشخیص DR داشته باشد، بلکه با بهره‌گیری از پتانسیل مواد زیست سازگار در ارتقای کیفیت سیگنال تصویربرداری، قادر به مقابله با چالش‌های ذاتی مجموعه داده‌های بالینی مانند تنوع کیفی، نویز و عدم توازن داده‌ها باشد. روش پیشنهادی در این پژوهش، مطابق با شکل ۱، طی مراحل متوالی زیر سازمان‌دهی و اجرا می‌گردد:

1. **Input retinal image dataset** (e.g., APTOS 2019 with DR severity labels)
2. **Image Quality Enhancement** (Biocompatible Materials Integration):
3. 2.1. Improve optical interface (reduce reflection & distortion)
4. 2.2. Stabilize imaging signal (reduce noise & ambient interference)
5. 2.3. Optimize light transmission (control illumination & prevent saturation)
6. **Preprocessing:**
7. 3.1. Remove noise (Gaussian/Median filtering)
8. 3.2. Enhance contrast (e.g., CLAHE)
9. 3.3. Extract retinal ROI (remove non-retinal regions)
10. 3.4. Normalize pixel intensities
11. 3.5. Split dataset into train/validation/test
12. **Data Imbalance Handling:**
13. 4.1. Apply resampling (e.g., SMOTE / oversampling minority classes)
14. 4.2. Apply targeted data augmentation (rotation, flip, brightness adjustment)
15. 4.3. Generate balanced training dataset
16. **Deep Learning Model for DR Severity Classification:**
17. 5.1. Use pre-trained CNN backbone (e.g., EfficientNet)
18. 5.2. Integrate ordinal-aware output layer (severity levels 0–4)

19. 5.3. Apply appropriate loss function (Ordinal Loss / Weighted Cross-Entropy)
20. Model Training:
21. 6.1. Train using balanced dataset
22. 6.2. Monitor validation performance
23. 6.3. Apply early stopping and learning rate scheduling
24. Evaluation:
25. 7.1. Predict DR grades on test set
26. 7.2. Compute Accuracy
27. 7.3. Compute Precision, Recall, Macro-F1
28. 7.4. Compute Quadratic Weighted Kappa (QWK)
29. 7.5. Analyze confusion matrix
30. **Output:**
31. Final DR severity prediction (grade 0–4) + probability score + performance metrics

شکل ۱. شبه کد الگوریتم پیشنهادی

روش پیشنهادی این پژوهش چارچوبی یکپارچه و چندمرحله‌ای برای تشخیص و درجه‌بندی رتینوپاتی دیابتی است که از مرحله دریافت تصویر تا تولید پیش‌بینی نهایی به صورت پیوسته طراحی شده است. در ابتدا، تصاویر فوندوس شبکیه از یک مجموعه داده استاندارد شامل پنج سطح شدت بیماری (۰ تا ۴) وارد سیستم می‌شوند. این سطوح بیانگر نبود بیماری تا مرحله تکثیری پیشرفته هستند و هر تصویر دارای برچسب شدت متناظر است. هدف سیستم، یادگیری الگوهای پاتولوژیک شبکیه و پیش‌بینی صحیح درجه بیماری با در نظر گرفتن ماهیت ترتیبی آن است. در گام نخست، پیش از هرگونه پردازش دیجیتال، کیفیت تصویر از طریق بهینه‌سازی فرایند تصویربرداری ارتقا می‌یابد. در این مرحله، با بهره‌گیری از فناوری‌های مبتنی بر مواد زیست‌سازگار، رابط اپتیکی بین دستگاه تصویربرداری و سطح چشم بهبود داده می‌شود تا بازتاب‌های ناخواسته و اعوجاج‌های نوری کاهش یابد. این اقدام موجب افزایش وضوح ساختارهایی نظیر عروق خونی، میکروآنوریسم‌ها و اکزوداها می‌شود. همچنین تثبیت سیگنال تصویربرداری با کاهش نویز محیطی و نوسانات شدت نور انجام می‌گیرد تا یکنواختی روشنایی در سطح تصویر افزایش یابد. کنترل و بهینه‌سازی انتقال نور نیز از اشباع پیکسلی جلوگیری کرده و کنتراست نواحی آسیب‌دیده شبکیه را تقویت می‌کند. خروجی این بخش، تصاویر ارتقایافته با نسبت سیگنال به نویز بالاتر و کیفیت بصری مناسب‌تر برای تحلیل خودکار است. پس از بهبود کیفیت اولیه، تصاویر وارد مرحله پیش‌پردازش دیجیتال می‌شوند. در این بخش ابتدا نویزهای باقی‌مانده با استفاده از فیلترهای میانه یا گاوسی حذف می‌شوند تا بدون تخریب لبه‌های عروقی، ساختارهای اصلی حفظ شوند. سپس به منظور برجسته‌سازی ضایعات ظریف، از روش‌های افزایش کنتراست مانند CLAHE استفاده می‌شود که توزیع شدت روشنایی را به صورت تطبیقی متعادل می‌کند. در ادامه، ناحیه مورد نظر شبکیه از پس‌زمینه‌های غیرمرتبط جدا شده و حاشیه‌های سیاه یا نواحی غیرشبکیه حذف می‌شوند تا تمرکز مدل صرفاً بر اطلاعات بالینی مفید باشد. شدت پیکسل‌ها نیز به یک بازه استاندارد نظیر $[0, 1]$ [۰، ۱] نرمال‌سازی می‌شود تا فرایند آموزش پایدارتر شده و همگرایی شبکه تسریع گردد. پس از تکمیل این مراحل، داده‌ها به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند تا امکان آموزش کنترل‌شده و ارزیابی مستقل فراهم شود. از آنجا که توزیع کلاس‌های شدت DR معمولاً نامتوازن است و تعداد تصاویر مربوط به مراحل خفیف بیشتر از مراحل شدید است، مدیریت عدم توازن داده نقش مهمی در جلوگیری از سوگیری مدل دارد. برای این منظور، از روش‌های بازنمونه‌گیری مانند oversampling یا تکنیک‌های مبتنی بر تولید نمونه مصنوعی استفاده می‌شود تا تعداد نمونه‌های کلاس‌های اقلیت افزایش یابد. علاوه بر آن، افزایش داده هدفمند با اعمال تبدیلاتی مانند چرخش، تقارن، تغییر روشنایی و برش تصادفی بر تصاویر کلاس‌های کم‌تعداد انجام می‌شود. این اقدامات باعث می‌شود توزیع داده‌های آموزشی متعادل‌تر شده و مدل نسبت به تمامی سطوح بیماری حساسیت کافی پیدا کند. در مرحله مدل‌سازی، یک شبکه عصبی کانولوشنی عمیق از پیش آموزش‌دیده، مانند EfficientNet،

به عنوان استخراج کننده ویژگی به کار گرفته می شود. لایه های اولیه شبکه الگوهای سطح پایین نظیر لبه ها و بافت ها را استخراج می کنند، درحالی که لایه های عمیق تر قادر به شناسایی ساختارهای پیچیده تر مانند خوشه های اکزودا یا ناهنجاری های عروقی هستند. با توجه به ماهیت ترتیبی شدت رتینوپاتی دیابتی، ساختار خروجی شبکه به گونه ای طراحی می شود که ترتیب بین کلاس ها را در نظر گیرد. به جای استفاده از یک طبقه بند صرفاً چند کلاسه، از رویکردی مبتنی بر یادگیری ترتیبی یا تابع زیان وزن دار استفاده می شود تا فاصله بین درجات بیماری در فرایند یادگیری لحاظ گردد. در این چارچوب، تابع زیان به صورت وزن دار تعریف می شود تا اثر عدم توازن کلاس ها کاهش یافته و خطاهای بزرگ تر بین درجات غیرمجاور جریمه بیشتری دریافت کنند. آموزش مدل با استفاده از داده های متوازن انجام می شود و در هر دوره آموزشی، عملکرد مدل بر روی مجموعه اعتبارسنجی پایش می گردد. برای جلوگیری از بیش برازش، از راهبرد توقف زود هنگام استفاده می شود؛ به این صورت که در صورت عدم بهبود معیار اعتبارسنجی طی چند دوره متوالی، فرایند آموزش متوقف می شود. همچنین تنظیم پویا نرخ یادگیری به مدل کمک می کند تا در مراحل پایانی آموزش به حداقل بهینه هم گرا شود. در نهایت، مدل آموزش دیده بر روی مجموعه آزمونی ارزیابی می شود که در فرایند آموزش دخیل نبوده است. عملکرد سیستم با استفاده از معیارهایی نظیر دقت کلی، Precision، Recall و میانگین Macro-F1 اندازه گیری می شود تا ارزیابی متعادلی از عملکرد در تمامی کلاس ها ارائه گردد. علاوه بر این، از معیار کاپای درجه ای وزندار^۱ استفاده می شود که به دلیل در نظر گرفتن فاصله ترتیبی بین درجات بیماری، برای مسائل درجه بندی پزشکی بسیار مناسب است. تحلیل ماتریس اغتشاش نیز به بررسی نوع خطاهای مدل و میزان اشتباه بین کلاس های مجاور کمک می کند. در خروجی نهایی، سیستم پیشنهادی برای هر تصویر شبکه، درجه شدت رتینوپاتی دیابتی را به همراه احتمال تعلق به هر کلاس ارائه می دهد. این چارچوب یکپارچه که از بهبود کیفیت تصویربرداری تا مدل سازی عمیق ترتیبی و ارزیابی دقیق را شامل می شود، با هدف افزایش دقت، پایداری و قابلیت اعتماد سیستم های تشخیص خودکار رتینوپاتی دیابتی طراحی شده است و می تواند به عنوان ابزار کمکی مؤثری در غربالگری و تصمیم گیری بالینی مورد استفاده قرار گیرد.

مجموعه داده

در این پژوهش، از مجموعه داده APTOS 2019 Blindness Detection جهت آموزش و ارزیابی مدل پیشنهادی استفاده شده است. این مجموعه داده که در قالب یک رقابت علمی بین المللی گردآوری شده، شامل تصاویر رنگی فوندوس شبکه است که با هدف تشخیص و درجه بندی شدت رتینوپاتی دیابتی طراحی شده است. تصاویر این مجموعه از مراکز درمانی مختلف جمع آوری شده اند و به همین دلیل، دارای تنوع قابل توجهی از نظر کیفیت تصویربرداری، شرایط نوری و شدت بیماری هستند که این امر موجب افزایش توان تعمیم پذیری مدل های آموزش دیده بر روی آن می شود. مجموعه داده مذکور شامل ۵۵۹۰ تصویر است که به دو بخش اصلی آموزش (۳۶۶۲ تصویر با برچسب) و آزمون (۱۹۲۸ تصویر بدون برچسب) تقسیم شده است. برچسب های موجود در بخش آموزش، شدت بیماری را در پنج سطح ترتیبی (از کلاس ۰ تا ۴) طبقه بندی می کنند. بررسی توزیع نمونه ها حاکی از وجود عدم توازن در کلاس های مختلف است؛ به نحوی که کلاس مربوط به «عدم وجود رتینوپاتی» بیشترین فراوانی و کلاس های مراحل پیشرفته بیماری کمترین فراوانی را دارند. این ناهمگونی می تواند منجر به سوگیری مدل به سمت کلاس های غالب شود؛ لذا در مراحل پیش پردازش، راهکارهایی جهت تعدیل این چالش اتخاذ شده است. همچنین با توجه به

تفاوت در ابعاد، وضوح و نویزهای موجود در تصاویر خام، انجام مراحل پیش پردازش دقیق برای استخراج ویژگی‌های بهینه ضروری است.

جدول ۱. مشخصات فنی مجموعه داده APTOS 2019

ویژگی	مقدار / توضیحات
نام مجموعه داده	APTOS 2019 Blindness Detection
مجموع تعداد تصاویر	۵۵۹۰ تصویر
تعداد تصاویر آموزش (با برچسب)	۳۶۶۲ تصویر
تعداد تصاویر آزمون (بدون برچسب)	۱۹۲۸ تصویر
تعداد کلاس‌ها	۵ کلاس (۰ تا ۴)
نوع طبقه‌بندی	ترتیبی (Ordinal Classification)
توزیع داده‌ها	نامتوازن (Imbalanced)

در مجموعه داده، پنج کلاس مختلف براساس شدت رتینوپاتی دیابتی برچسب گذاری شده‌اند:

جدول ۲. توزیع کلاس‌های مجموعه داده APTOS 2019

کد کلاس	نام کلاس	توضیحات
0	بدون رتینوپاتی (Normal)	سلامت شبکیه، بدون علائم بیماری
1	خفیف (Mild)	علائم اولیه و خفیف بیماری
2	متوسط (Moderate)	تغییرات مشخص و در مراحل میانی
3	شدید (Severe)	علائم شدید و در مراحل پیشرفته
4	پرولیفراتیو (Proliferative)	مراحل آخر بیماری، با ریسک بالای نابینایی

- یکی از مهم‌ترین چالش‌های مجموعه داده، عدم توازن در تعداد نمونه‌های هر کلاس است، به‌طوری‌که:
 - کلاس ۰ (بدون بیماری) بیشترین نمونه را دارد، که ممکن است منجر به سوگیری مدل در پیش‌بینی نادرست دیگر کلاس‌ها شود.
 - کلاس‌های ۳ و ۴ (پیشرفته و پرولیفراتیو) کمترین نمونه‌ها را دارند و افزایش نمونه‌های این کلاس‌ها، بهبود قدرت تشخیص در مراحل پیشرفته را ممکن می‌سازد.
- برای مقابله با این چالش، روش‌های مختلفی پیشنهاد می‌شود:
 - استاندارد سازی وزن‌ها^۱: استفاده از توابع خطا وزن دار، تا هر نمونه براساس کلاسش اهمیت بالاتری داشته باشد.
 - افزایش داده^۲: اعمال تکنیک‌های مختلف چون چرخش، تغییر اندازه، روشنایی و نویزگذاری بر روی نمونه‌های کم‌تعداد، جهت افزایش تنوع و تعداد نمونه‌های کلاس‌های نادر.
 - استفاده از نمونه‌گیری متعادل^۳: حذف نمونه‌های بیشتر در کلاس غالب یا انتخاب نمونه‌های تصادفی متمرکز بر کلاس‌های کم‌تعداد، برای آموزش تعادلی مدل.

اهمیت پیش پردازش تصاویر

در این پژوهش، مجموعه داده مورد استفاده شامل تصاویر شبکه چشم بیماران مبتلا و غیرمبتلا به رتینوپاتی دیابتی است که براساس شدت بیماری در پنج کلاس مجزا برچسب گذاری شده اند. این برچسب دهی مطابق با استانداردهای بالینی و بر مبنای میزان پیشرفت ضایعات شبکه انجام شده است. کلاس صفر با عنوان بدون رتینوپاتی نشان دهنده شبکه سالم و فاقد هرگونه علائم پاتولوژیک مرتبط با دیابت است. کلاس یک با عنوان خفیف بیانگر وجود نشانه های اولیه و محدود بیماری، نظیر میکروآنوریسم های پراکنده است. در کلاس دو با عنوان متوسط تغییرات عروقی و ضایعات شبکه به صورت آشکارتر و در مراحل میانی بیماری مشاهده می شوند. کلاس سه با عنوان شدید نشان دهنده پیشرفت قابل توجه آسیب های شبکه و افزایش ضایعات عروقی است. نهایتاً کلاس چهار با عنوان پرولیفراتیو^۱ بیانگر پیشرفته ترین مرحله بیماری بوده که با رشد عروق خونی غیرطبیعی همراه است و خطر بالایی برای بروز خونریزی زجاجیه و نابینایی دائمی دارد.

این تقسیم بندی پنج گانه امکان طراحی یک سامانه طبقه بندی چند کلاسه را فراهم می سازد که قادر است شدت بیماری را به صورت دقیق و مرحله به مرحله پیش بینی کند. با وجود ساختار مناسب برچسب دهی، یکی از چالش های اساسی این مجموعه داده، عدم توازن در توزیع نمونه ها میان کلاس های مختلف است. به طور معمول، کلاس «بدون رتینوپاتی» بیشترین تعداد نمونه را به خود اختصاص می دهد، در حالی که کلاس های پیشرفته تر، به ویژه «شدید» و «پرولیفراتیو»، کمترین تعداد نمونه را شامل می شوند. این عدم توازن می تواند منجر به سوگیری مدل یادگیری عمیق به سمت کلاس غالب شود؛ به گونه ای که مدل در پیش بینی نمونه های سالم عملکرد بالایی داشته باشد اما در شناسایی مراحل پیشرفته بیماری، که از نظر بالینی اهمیت بیشتری دارند، دقت کمتری نشان دهد. چنین وضعیتی از منظر کاربرد پزشکی قابل قبول نیست، زیرا هدف اصلی، تشخیص به موقع و دقیق مراحل بحرانی بیماری است. به منظور مقابله با این چالش، راهکارهای متعددی در فرایند آموزش مدل پیشنهاد می شود. یکی از رویکردهای مؤثر، استفاده از توابع هزینه وزن دار^۲ است که در آن به نمونه های متعلق به کلاس های کم تعداد وزن بیشتری اختصاص داده می شود تا سهم آن ها در به روزرسانی پارامترهای مدل افزایش یابد. این روش سبب می شود مدل نسبت به خطاهای مربوط به کلاس های نادر حساس تر شود. راهکار دیگر، به کارگیری تکنیک های افزایش داده^۳ برای کلاس های کم تعداد است. در این روش با اعمال تبدیلاتی نظیر چرخش، تغییر مقیاس، برش تصادفی، تنظیم روشنایی و کنتراست، وارونگی افقی یا عمودی و افزودن نویز کنترل شده، نمونه های جدید و متنوعی از تصاویر موجود تولید می شود که بدون نیاز به جمع آوری داده های جدید، به بهبود تعمیم پذیری مدل کمک می کند. همچنین استفاده از روش های نمونه گیری متعادل می تواند در کاهش اثر عدم توازن مؤثر باشد. در این رویکرد، یا از نمونه های کلاس غالب به صورت هدفمند کاسته می شود یا با انتخاب تصادفی کنترل شده، احتمال انتخاب نمونه های کلاس های کم تعداد در هر دسته آموزشی افزایش می یابد تا توزیع داده ها در حین آموزش متعادل تر گردد. علاوه بر مسئله عدم توازن، کیفیت و یکنواختی تصاویر نیز نقش تعیین کننده ای در عملکرد نهایی مدل دارند. تصاویر شبکه معمولاً از منابع مختلف و با دستگاه های تصویربرداری متفاوت جمع آوری می شوند؛ بنابراین از نظر وضوح، اندازه، شدت روشنایی، کنتراست و میزان نویز با یکدیگر تفاوت دارند. به همین دلیل، اجرای یک مرحله پیش پردازش استاندارد پیش از ورود تصاویر به شبکه های یادگیری عمیق ضروری است. این مرحله شامل اصلاح روشنایی و کنتراست به منظور برجسته سازی ساختار عروق و ضایعات، حذف نواحی غیرضروری یا حاشیه های تیره اطراف تصویر، کاهش نویزهای تصادفی و آرتیفکت های تصویری و نرمال سازی ابعاد و مقیاس تصاویر

1. proliferative

2. weighted loss functions

3. data augmentation

برای ایجاد ورودی یکنواخت به شبکه است. همچنین، ترکیب پیش‌پردازش با راهبردهای تقویت و تعادل داده‌ها پیش از مرحله آموزش، موجب افزایش پایداری مدل، بهبود هم‌گرایی و ارتقای دقت تشخیص در تمامی کلاس‌ها، به‌ویژه مراحل پیشرفته بیماری، خواهد شد. در مجموع، توجه هم‌زمان به ساختار برجسب‌دهی، مدیریت عدم توازن داده و اجرای پیش‌پردازش دقیق، نقش کلیدی در توسعه یک سامانه تشخیص رتینوپاتی دیابتی، پیش‌پردازش تصاویر شبکه‌ی یکی از مراحل بسیار حیاتی در زنجیره آماده‌سازی داده محسوب می‌شود. به دلیل تنوع بالای کیفیت تصویربرداری، تغییرات شدید در شدت روشنایی، وجود نویزهای تصادفی و همچنین حضور نواحی غیرمرتبط در فریم‌های فوندوس، لازم است مجموعه‌ای از عملیات منظم و استاندارد بر روی تصاویر انجام شود تا داده‌های ورودی از لحاظ فنی و بصری برای یادگیری ماشینی آماده و بهینه شوند. این مرحله نه تنها موجب بهبود وضوح و تمرکز مدل بر ویژگی‌های اصلی شبکه می‌گردد، بلکه از بروز خطاهای ناشی از کیفیت پایین تصویر، تفاوت شرایط نوری یا انحراف در محدوده دید دوربین جلوگیری می‌کند. در این پژوهش، یک خط‌لوله‌ی پیش‌پردازش^۱ جامع طراحی شده است که بر پایه چهار گام اصلی استوار است. نخست، مرحله استانداردسازی اندازه و مقیاس^۲ اجرا می‌شود تا تمامی تصاویر ورودی شبکه دارای ابعاد یکسان و شدت پیکسل‌های نرمال شده باشند. این عمل، پایداری فرایند آموزش و هم‌ترازی داده‌ها را افزایش داده و امکان مقایسه مستقیم ویژگی‌های استخراج شده از تصاویر با اندازه‌های مختلف را فراهم می‌کند. در گام دوم، بهبود روشنایی و کنتراست^۳ انجام می‌گیرد. با توجه به اینکه شدت نور و تغییرات روشنایی از مهم‌ترین عوامل مؤثر بر کیفیت تصاویر فوندوس هستند، در این مرحله از روش‌های هموارسازی شدت، فیلترهای تطبیقی یا الگوریتم‌های بهبود کنتراست استفاده می‌شود تا ضایعات و جزئیات ساختاری شبکه برای مدل قابل تشخیص‌تر شوند. مرحله سوم، کاهش نویز و حذف نواحی غیرضروری^۴ است، که طی آن نواحی پیرامونی تصویر یا پس‌زمینه‌های تیره و کم‌ارزش حذف شده و ناحیه مورد توجه (ROI) که حاوی اطلاعات بالینی شبکه است استخراج می‌شود. این کار موجب می‌شود تمرکز مدل بر روی ویژگی‌های واقعی و مهم شبکه چشم افزایش یابد و میزان خطا در طبقه‌بندی ناشی از اطلاعات غیرمرتبط کاهش پیدا کند. در مرحله چهارم، تقویت تطبیقی داده‌ها^۵ در فاز آموزش به کار گرفته می‌شود تا مدل از لحاظ تعمیم‌پذیری مقاوم‌تر گردد. در این مرحله، تغییرات کنترل‌شده‌ای مانند چرخش، وارونگی، تغییر مقیاس، تنظیم نور یا نویزگذاری انجام می‌شود تا مدل بتواند در مواجهه با تصاویر با کیفیت‌های متفاوت، عملکرد پایدار و دقیق‌تری نشان دهد. هم‌راستاسازی این مراحل با رویکرد «ترکیبی یادگیری ماشین و مواد زیست‌سازگار» اهمیت ویژه‌ای در چارچوب سامانه توسعه یافته دارد. در این معماری، بخش تصویربرداری و آماده‌سازی داده‌ها به گونه‌ای طراحی می‌شود که خروجی آن برای الگوریتم‌های یادگیری ماشین از لحاظ الگوهای ساختاری و ویژگی‌های شبکه قابل اعتماد و یکنواخت باشد. از آنجا که تصاویر فوندوس اغلب تحت تأثیر تغییرات شرایط تصویربرداری، نوع حسگر، شدت نور محیط یا کیفیت اپتیکی دستگاه قرار می‌گیرند، به کارگیری دقیق مراحل پیش‌پردازش یادشده باعث می‌شود اثر این متغیرهای فنی کاهش یابد. نتیجه این امر، تولید داده‌های همسان و استاندارد است که محتوای شبکه را به شکل پایدار و قابل اعتماد منعکس می‌کنند. این همسانی داده‌های ورودی، به‌ویژه در زمانی که هدف، یکپارچه‌سازی پردازش تصویری با توسعه سامانه‌های حسگر یا ادوات مبتنی بر مواد زیست‌سازگار در زنجیره تصویربرداری است، اهمیت دوچندان پیدا می‌کند؛ زیرا ثبات کیفیت داده‌ها، امکان تعامل دقیق میان بخش زیستی و محاسباتی سامانه را فراهم

1. preprocessing pipeline
2. resizing/normalization
3. contrast/illumination enhancement
4. denoising/ROI extraction
5. data augmentation

ساخته و زمینه ساز توسعه پلتفرمی هوشمند، پایدار و قابل استناد به منظور پایش و تشخیص خود کار بیماری های شبکه خواهد بود.

یافته ها

در این بخش، به تشریح نتایج حاصل از ارزیابی جامع سامانه پیشنهادی در تشخیص و درجه بندی رتینوپاتی دیابتی (DR) بر روی مجموعه داده معتبر APTOS 2019 می پردازیم. رویکرد ما، ترکیبی نوآورانه از بهبود کیفیت تصویربرداری در سطح اپتیک با استفاده از مواد زیست سازگار و به کارگیری معماری های پیشرفته یادگیری عمیق آگاه از ترتیب است، که با هدف ارائه یک سامانه غربالگری دقیق، قابل اعتماد و کارآمد طراحی شده است. ارزیابی ما با اتکا بر معیارهای استاندارد عملکرد مدل های طبقه بندی، شامل Accuracy، Precision، Recall، F1-Score، به ویژه Macro-F1 برای ارزیابی متعادل در میان کلاس ها و Quadratic Weighted Kappa (QWK) به انجام رسیده است. QWK به دلیل توانایی اش در سنجش میزان هم راستایی پیش بینی ها با ماهیت ترتیبی کلاس های شدت بیماری، معیار کلیدی در این پژوهش محسوب می شود.

برای اطمینان از قابلیت تکرارپذیری و مقایسه منصفانه، کلیه آزمایش ها با استفاده از چارچوب یادگیری عمیق TensorFlow و کتابخانه Keras انجام پذیرفت. مدل پایه ما از معماری EfficientNet-B4 بهره می برد که به دلیل کارایی بالا در استخراج ویژگی های بصری، انتخاب شده است. در مدل نهایی پیشنهادی، این معماری با یک تابع زیان ترتیبی^۱ ترکیب شد تا روابط ذاتی بین کلاس های شدت بیماری (۰ تا ۴) به طور مؤثری مدل سازی گردد. مجموعه داده APTOS 2019 به نسبت های استاندارد ۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی^۲ و ۱۵٪ برای آزمون نهایی^۳ تقسیم گردید. در مرحله پیش پردازش و آموزش، استراتژی های مدیریت عدم توازن داده، شامل تکنیک های وزن دهی خطا^۴ برای کلاس های کم نمونه (مانند شدت های ۳ و ۴) و افزایش داده هدفمند^۵ با اعمال تحریف های هندسی و نوری کنترل شده، به طور کامل پیاده سازی شدند. به منظور سنجش میزان اثربخشی مؤلفه های مختلف سامانه پیشنهادی، ما سه سناریوی آزمایشی را مقایسه کردیم:

۱. مدل پایه^۶: این مدل صرفاً از یک معماری CNN استاندارد بدون اعمال هیچ گونه پیش پردازش پیشرفته یا تکنیک های مدیریت عدم توازن داده استفاده کرد.

۲. مدل با پیش پردازش و مدیریت عدم توازن: این سناریو شامل اعمال مراحل پیش پردازش تصاویر (مانند استاندارد سازی ابعاد، نرمال سازی شدت، استخراج ROI و بهبود کنتراست) و همچنین به کارگیری تکنیک های وزن دهی خطا و افزایش داده بود، اما فاقد بهبود اپتیک در سطح ورودی و مدل آگاه از ترتیب بود.

۳. روش پیشنهادی کامل^۷: این سناریو جامع ترین حالت بوده و شامل کلیه مراحل: بهبود اپتیک با مواد زیست سازگار در مرحله اول، پیش پردازش تصویر، مدیریت عدم توازن داده، و استفاده از معماری EfficientNet-B4 با تابع زیان ترتیبی بود.

نتایج مقایسه ای این سه رویکرد در جدول ۳ خلاصه شده است:

1. ordinal loss
2. validation
3. testing
4. loss weighting
5. targeted data augmentation
6. baseline CNN
7. complete proposed method

جدول ۳. مقایسه عملکرد روش‌های مختلف بر روی مجموعه‌داده APTOS 2019

رویکرد آزمایشی	Accuracy	Macro-F1	Recall (Macro)	QWK
مدل پایه CNN	۰/۷۸۳	۰/۷۰۱	۰/۶۸۲	۰/۸۱۹
+ پیش‌پردازش و تعادل داده	۰/۸۴۵	۰/۷۹۲	۰/۷۷۵	۰/۸۸۱
روش پیشنهادی کامل	۰/۸۹۲	۰/۸۶۴	۰/۸۵۱	۰/۹۳۳

همان‌طور که در جدول ۳ مشاهده می‌شود، هر مرحله از بهبود، تأثیر مثبتی بر عملکرد کلی سامانه داشته است. مدل پایه CNN، با وجود توانایی ذاتی در طبقه‌بندی تصاویر، در مواجهه با چالش‌های عدم توازن داده و تنوع کیفیت تصاویر، عملکرد متوسطی از خود نشان می‌دهد. با افزودن مراحل استاندارد پیش‌پردازش و تکنیک‌های مدیریت عدم توازن داده (رویکرد دوم)، شاهد افزایش قابل توجه در تمامی معیارها هستیم، به‌ویژه در Macro-F1 و QWK که نشان‌دهنده بهبود توانایی مدل در تمایز میان کلاس‌های مختلف و درک ماهیت ترتیبی آن‌هاست.

با این حال، پیاده‌سازی کامل روش پیشنهادی (رویکرد سوم) که شامل گام نوآورانه بهبود کیفیت تصویربرداری در سطح اپتیک با بهره‌گیری از مواد زیست‌سازگار و استفاده از مدل ترتیبی است، منجر به دستیابی به بهترین نتایج شده است. افزایش QWK از ۰/۸۸۱ به ۰/۹۳۳ (افزایش حدود ۵/۷٪) حاکی از آن است که مدل پیشنهادی قادر است با دقت بسیار بالایی، شدت رتینوپاتی دیابتی را به‌صورت ترتیبی پیش‌بینی کند. همچنین، بهبود Macro-F1 از ۰/۷۹۲ به ۰/۸۶۴ (افزایش حدود ۹/۱٪) نشان‌دهنده عملکرد متعادل و قدرتمند مدل در کلیه کلاس‌ها، از جمله کلاس‌های نادرتر و چالش‌برانگیزتر است. این نتایج، اثربخشی رویکرد چندوجهی ما را در غلبه بر محدودیت‌های موجود در داده‌ها و بهبود دقت تشخیصی تأیید می‌کند. برای درک عمیق‌تر توانایی‌های سامانه پیشنهادی، عملکرد آن در هر یک از پنج کلاس شدت رتینوپاتی دیابتی به‌طور جداگانه مورد بررسی قرار گرفت. نتایج Precision، Recall و F1-Score برای هر کلاس در جدول ۴ ارائه شده است:

جدول ۴. عملکرد تفکیکی روش پیشنهادی (کامل) بر روی هر کلاس در مجموعه‌داده APTOS 2019

کلاس (DR Severity)	نام کلاس	Precision	Recall	F1-Score
0	Normal	0.942	0.961	0.951
1	Mild	0.817	0.795	0.806
2	Moderate	0.873	0.855	0.864
3	Severe	0.831	0.812	0.821
4	Proliferative	0.885	0.843	0.863
میانگین Macro		0.869	0.853	0.861

نتایج جدول ۴ نشان‌دهنده این است که سامانه پیشنهادی عملکرد بسیار قوی در کلاس «نرمال» (کلاس ۰) با Precision و Recall بالا ارائه می‌دهد. همچنین، عملکرد در کلاس‌های پیشرفته بیماری، یعنی «شدید» (کلاس ۳) و «پرولیفراتیو» (کلاس ۴)، که معمولاً چالش‌برانگیزترین کلاس‌ها به‌دلیل کمبود نمونه هستند نیز، بسیار رضایت‌بخش است (F1-Score بالای ۰/۸۲). این امر نشان‌دهنده موفقیت چشمگیر استراتژی‌های مدیریت عدم توازن داده و افزایش هدفمند نمونه‌ها در ارتقای قابلیت تشخیص مراحل بحرانی بیماری است.

ملاحظه می‌شود که بیشترین اشتباهات مدل عمدتاً در تفکیک بین کلاس‌های مجاور و نزدیک به هم رخ می‌دهد؛ برای مثال، تمایز دقیق بین کلاس «خفیف» (۱) و «متوسط» (۲)، یا بین «متوسط» (۲) و «شدید» (۳). این موضوع از نظر بالینی قابل توجه است، زیرا پیشرفت رتینوپاتی دیابتی فرایندی تدریجی بوده و مرزهای بین مراحل آن گاهی اوقات

مبهم و وابسته به تفسیر دقیق توسط چشم پزشک است. با این وجود، حتی در این موارد نیز، F1-Score بالای ۰/۸۰ نشان دهنده دقت قابل قبول مدل است.

یکی از جنبه های نوآورانه این پژوهش، ادغام بهبود کیفیت تصویربرداری در سطح اپتیک با استفاده از مواد زیست سازگار در خط لوله پردازش تصویر بوده است. مقایسه عملکرد مدل بدون این مرحله (یعنی استفاده از تصاویر استاندارد ورودی بدون بهبود اپتیک) با مدل نهایی نشان داد که این گام اولیه، منجر به افزایش میانگین QWK به میزان ۰/۰۴ و افزایش Macro-F1 به میزان ۰/۰۳ گردید. این یافته نشان می دهد که افزایش یکنواختی شدت نور، کاهش بازتاب های ناخواسته و بهبود نسبت سیگنال به نویز در سطح اپتیک، پیش زمینه ای قوی برای استخراج ویژگی های دقیق تر توسط شبکه های یادگیری عمیق فراهم می آورد و اثر متغیرهای فنی در کیفیت تصویر را به حداقل می رساند. نتایج کمی و کیفی حاصل از ارزیابی سامانه پیشنهادی، اثربخشی رویکرد جامع ما را در غلبه بر چالش های موجود در داده های پزشکی تصویری به طور قوی تأیید می کند. دستیابی به QWK 0.933 و Macro-F1 0.861 نشان دهنده توانایی بالای سامانه در تشخیص دقیق و مرحله بندی صحیح رتینوپاتی دیابتی، حتی در مراحل اولیه و پیشرفته بیماری است. بهبود قابل توجه عملکرد نسبت به مدل پایه و رویکردهای میانی، اهمیت ادغام نوآوری های سطح اپتیک با تکنیک های پیشرفته یادگیری ماشین را برجسته می سازد. این نتایج، پتانسیل بالای سامانه پیشنهادی را برای کاربرد در سیستم های غربالگری خودکار در مراکز درمانی و ارتقای سطح سلامت جامعه مبتلایان به دیابت، نمایان می سازد.

بحث و نتیجه گیری

نتایج در این بخش، یافته های کلیدی پژوهش حاضر را با روش های پیشین در حوزه تشخیص و درجه بندی خودکار رتینوپاتی دیابتی مقایسه کرده و دلایل برتری رویکرد پیشنهادی را به طور مفصل تشریح می کند. هدف اصلی این پژوهش، ارائه سامانه ای جامع و دقیق بود که با بهره گیری از دو نوآوری کلیدی - بهبود کیفیت تصویربرداری در سطح اپتیک با استفاده از مواد زیست سازگار و به کارگیری مدل های یادگیری عمیق آگاه از ترتیب^۱ بتواند بر محدودیت های موجود در روش های فعلی غلبه کند. ارزیابی های انجام شده بر روی مجموعه داده استاندارد APTOS 2019، نتایج امیدوارکننده ای را نشان داد که در ادامه به تفصیل مورد بحث قرار می گیرند.

برای ارزیابی جایگاه روش پیشنهادی در اکوسیستم تحقیقاتی DR، عملکرد آن را با نتایج منتشر شده در مطالعات برجسته پیشین مقایسه نمودیم. این مقایسه، که در جدول ۵ خلاصه شده است، بر روی معیارهای کلیدی مانند دقت (Accuracy)، میانگین F1-Score (Macro-F1) و Quadratic Weighted Kappa (QWK) متمرکز است.

جدول ۵. مقایسه عملکرد روش پیشنهادی با روش های پیشین بر روی مجموعه داده (APTOS 2019 با مشابه)

روش/مقاله	مدل/معماری اصلی	معیارهای ارزیابی اصلی	Accuracy	Macro-F1	QWK
روش پیشنهادی	EfficientNet-B4 + Ordinal Loss + Optical Enhancement	Acc, Macro-F1, QWK	۰/۸۹۲	۰/۸۶۴	۰/۹۳۳
روش ارائه شده در [۱۲]	ResNet-50	Accuracy	۰/۸۷	-	-
روش ارائه شده در [۱۴]	Ensemble of CNNs	Accuracy, AUC	۰/۸۸	-	-
روش ارائه شده در [۱۵]	Vision Transformer (ViT)	Accuracy, F1-Score	۰/۸۶	۰/۸۲	-
روش های ارائه شده در [۱۶] [۱۸]	CNN + Data Augmentation	Accuracy, Macro-F1	۰/۸۵	۰/۸۰	-

توجه: مقادیر در جدول ۵ برای روش‌های پیشین، براساس گزارش‌های منتشرشده در مقالات مربوطه آورده شده‌اند و ممکن است بسته به جزئیات پیاده‌سازی و تقسیم‌بندی داده‌ها، اندکی متفاوت باشند. در مواردی که معیاری گزارش نشده، مقدار آن «-» درج گردیده است. نتایج جدول ۳ نشان می‌دهد که سامانه پیشنهادی ما با دستیابی به QWK 0.933 و Macro-F1 0.864، عملکردی برجسته و در سطح پیشرو را در مقایسه با روش‌های پیشین، حتی آن‌هایی که از معماری‌های پیچیده یا تکنیک‌های پیشرفته استفاده کرده‌اند، به نمایش می‌گذارد. این برتری را می‌توان به ترکیبی از عوامل نوآورانه نسبت داد:

الف) ارتقای کیفی تصاویر در مبدأ با بهبود اپتیک

یکی از نقاط تمایز اصلی این پژوهش، پرداختن به کیفیت تصویر در مرحله پیش از ثبت است. برخلاف اکثر مطالعات که بر بهبود تصاویر از طریق الگوریتم‌های نرم‌افزاری پس از ثبت تمرکز دارند، ما با معرفی یک لایه اپتیک بهبودیافته با استفاده از مواد زیست‌سازگار، کیفیت تصویر را در مبدأ ارتقا بخشیدیم. این رویکرد منجر به کاهش نویز ذاتی، افزایش نسبت سیگنال به نویز، بهبود یکنواختی توزیع شدت نور و کاهش بازتاب‌های ناخواسته و اعوجاجات اپتیک شد. در نتیجه، ویژگی‌های حیاتی مانند میکروآنوریسم‌ها، خون‌ریزی‌ها و اغزوداها با وضوح و دقت بیشتری قابل مشاهده شدند. همان‌طور که در نتایج بخش ۴-۵ نشان داده شد، این مرحله به‌تنهایی باعث افزایش قابل توجه در QWK (حدود ۰/۰۴) و Macro-F1 (حدود ۰/۰۳) گردید. این بهبود در کیفیت داده‌های ورودی، زمینه را برای استخراج ویژگی‌های دقیق‌تر و قابل اعتمادتر توسط مدل یادگیری عمیق فراهم آورد و به‌طور مستقیم بر کاهش خطاهای طبقه‌بندی، به‌ویژه در تمایز بین مراحل خفیف و متوسط بیماری، تأثیر گذاشت.

ب) مدل‌سازی صریح ماهیت ترتیبی بیماری با طبقه‌بندی آگاه از ترتیب

رتینوپاتی دیابتی ذاتاً یک بیماری با شدت‌های پیش‌رونده است؛ یعنی کلاس‌های شدت بیماری (۰ تا ۴) دارای یک ترتیب خطی و ذاتی هستند. مدل‌های طبقه‌بندی استاندارد، این رابطه ترتیبی را نادیده گرفته و هر کلاس را به‌صورت مجزا در نظر می‌گیرند. این رویکرد می‌تواند منجر به خطاهای پیش‌بینی بین کلاس‌های غیرمجاور شود (به‌عنوان مثال، اشتباه گرفتن شدت ۰ با ۴). روش پیشنهادی ما با استفاده از توابع زیان ترتیبی^۱ و معماری‌های متناسب، این رابطه را به‌طور صریح در فرایند یادگیری مدل گنجانده. این توانایی در درک و مدل‌سازی ترتیب ذاتی کلاس‌ها، به‌طور چشمگیری دقت طبقه‌بندی را افزایش داد، که این امر در افزایش قابل توجه معیار QWK از ۰/۸۸۱ (در مدل بدون این قابلیت) به ۰/۹۳۳ (در مدل نهایی) مشهود است. QWK معیاری حساس به خطاهای ترتیبی است و افزایش قابل توجه آن، نشان‌دهنده توانایی بالای مدل پیشنهادی در ارائه پیش‌بینی‌های سازگار با پیشرفت طبیعی بیماری است.

ج) مدیریت مؤثر عدم توازن داده و پیش‌پردازش جامع

مجموعه داده APTOS 2019، مانند بسیاری از داده‌های پزشکی، با چالش عدم توازن شدید در توزیع کلاس‌ها مواجه است؛ به این معنی که نمونه‌های مربوط به شدت‌های بالاتر بیماری (۳ و ۴) به مراتب کمتر از شدت‌های پایین‌تر (۰ و ۱) هستند. نادیده گرفتن این عدم توازن می‌تواند منجر به سوگیری مدل به‌سمت کلاس‌های پرتعداد و عملکرد ضعیف در کلاس‌های نادر شود. رویکرد ما با به‌کارگیری ترکیبی از تکنیک‌های قوی مدیریت عدم توازن داده، شامل افزایش داده هدفمند^۲، وزن‌دهی خطا^۳ و استراتژی‌های نمونه‌برداری هوشمند، توانست بر این چالش غلبه کند. این استراتژی‌ها، در کنار مراحل پیش‌پردازش استاندارد مانند نرمال‌سازی تصاویر، استخراج مناطق مورد علاقه (ROI) و بهبود تطبیقی کنتراست، تضمین نمودند که مدل قادر به یادگیری مؤثر از تمامی کلاس‌ها باشد. نتیجه این امر، همان‌طور

1. ordinal loss
2. data augmentation
3. loss weighting

که در Macro-F1 0.864 مشاهده می شود، عملکرد متعادل و قدرتمند مدل در کل طیف شدت های بیماری، از جمله کلاس های کم نمونه است.

د) بهره گیری از معماری کارآمد EfficientNet-B4

انتخاب معماری EfficientNet-B4 به عنوان ستون فقرات مدل، مزایای متعددی را به همراه داشت. این معماری به دلیل طراحی مقیاس پذیر و متعادل خود، توانایی بالایی در استخراج ویژگی های سلسله مراتبی و پیچیده از تصاویر دارد، درحالی که از نظر محاسباتی نیز کارآمد است. این کارایی، امکان آموزش مدل های عمیق تر و پیچیده تر را در زمان معقول فراهم می آورد و از بروز مشکلاتی نظیر بیش برآزش^۱ در داده های محدود جلوگیری می کند.

در مجموع، برتری روش پیشنهادی را می توان نتیجه هم افزایی هوشمندانه این عوامل دانست: بهبود کیفیت تصویر در مبدأ، مدل سازی صریح روابط ترتیبی در داده ها، مدیریت دقیق عدم توازن کلاس ها و استفاده از معماری های یادگیری عمیق مدرن و کارآمد. این رویکرد جامع، نه تنها دقت تشخیص و درجه بندی DR را به سطوح بی سابقه ای ارتقا داده، بلکه پتانسیل بالایی را برای پیاده سازی در سیستم های بالینی واقعی و بهبود فرایندهای غربالگری و تشخیص زودهنگام این بیماری شایع و بالقوه مخرب، نمایان می سازد.

این پژوهش با هدف ارتقای قابل توجه دقت و قابلیت اطمینان سامانه های تشخیص و درجه بندی خود کار رتینوپاتی دیابتی، رویکردی نوین و چندوجهی را معرفی و ارزیابی کرد. هسته اصلی این رویکرد بر دو نوآوری کلیدی استوار بود: اول، بهبود کیفیت تصاویر شبکه در سطح اپتیک با استفاده از مواد زیست سازگار نوآورانه به منظور کاهش نویز و اعوجاج و افزایش وضوح ویژگی های پاتولوژیک؛ و دوم، توسعه و به کارگیری یک مدل یادگیری عمیق آگاه از ترتیب^۲ که قادر به درک و بهره برداری از ماهیت پیش رونده و ترتیبی شدت های مختلف بیماری DR است. ارزیابی های جامع انجام شده بر روی مجموعه داده معتبر APTOS 2019، برتری چشمگیر رویکرد ترکیبی پیشنهادی را در مقایسه با روش های پیشین تأیید کرد. سامانه نهایی ما موفق به کسب معیارهای کلیدی عملکرد، از جمله دقت ۰/۸۹۲، میانگین F1-Score (Macro-F1) ۰/۸۶۴ و QWK ۰/۹۳۳ شد. این نتایج، که در بخش نتایج به تفصیل تشریح گردید، نه تنها بالاتر از اکثر مطالعات منتشر شده بر روی همین مجموعه داده قرار می گیرد، بلکه نشان دهنده اثربخشی بالای هریک از مؤلفه های نوآورانه در بهبود عملکرد کلی است. به ویژه، بهبود کیفیت تصویر در مبدأ، به طور مستقیم به افزایش وضوح یافته های کلینیکی کمک کرده و مدل طبقه بندی آگاه از ترتیب، با مدل سازی دقیق تر ماهیت پیش رونده بیماری، خطاهای پیش بینی را به حداقل رساند.

این پژوهش نشان می دهد که ترکیب بهینه سازی کیفیت داده در مراحل اولیه با به کارگیری مدل های هوشمند که ساختار ذاتی داده ها را درک می کنند، می تواند منجر به پیشرفت های قابل توجهی در کاربردهای پیچیده پزشکی مانند تشخیص DR گردد. نتایج به دست آمده، پتانسیل بالای این رویکرد را برای توسعه نسل بعدی ابزارهای تشخیصی دقیق تر، قابل اعتمادتر و کارآمدتر برجسته می سازد که می تواند نقش بسزایی در غربالگری زودهنگام، کاهش بار کاری پزشکان و در نهایت، پیشگیری از عوارض شدیدتر ناشی از دیابت ایفا کند.

کارهای آتی می تواند شامل اعتبارسنجی این رویکرد بر روی مجموعه داده های بالینی متنوع تر و در مقیاس بزرگ تر، بررسی تأثیر آن در شرایط بالینی واقعی و همچنین کاوش در معماری های یادگیری عمیق پیشرفته تر و تکنیک های بهبود تصویربرداری نوین باشد. علاوه بر این، توسعه رابط های کاربری کاربر پسند برای ادغام این سامانه در گردش کار بالینی فعلی، گامی مهم در جهت تحقق کامل پتانسیل این فناوری خواهد بود.


1. overfitting

2. ordinal-aware deep learning

منابع

1. Nadeem MW, Goh HG, Hussain M, Liew S-Y, Andonovic I, Khan MA. Deep learning for diabetic retinopathy analysis: a review, research challenges, and future directions. *Sensors*. 2022;22(18):6780.
2. Sebastian A, Elharrouss O, Al-Maadeed S, Almaadeed N. A survey on deep-learning-based diabetic retinopathy classification. *Diagnostics*. 2023;13(3):345.
3. Gettinger K, Lee D, Tomita Y, Negishi K, Kurihara T. Diabetic retinopathy, a comprehensive overview on pathophysiology and relevant experimental models. *Int J Mol Sci*. 2025;26(20):9882.
4. Wei L, Sun X, Fan C, Li R, Zhou S, Yu H. The pathophysiological mechanisms underlying diabetic retinopathy. *Front Cell Dev Biol*. 2022; 10:963615.
5. Bhulakshmi D, Rajput DS. A systematic review on diabetic retinopathy detection and classification based on deep learning techniques using fundus images. *PeerJ Comput Sci*. 2024;10: e1947.
6. Alshammari RD, Haliqa WMA, Majzoub RY. Diagnostic accuracy of AI or DL-enhanced technologies in the diagnosis of diabetic retinopathy: a systematic review. *J Med Imaging Interv Radiol*. 2025;12(1):39.
7. Moannaei M, et al. Performance and limitation of machine learning algorithms for diabetic retinopathy screening and its application in health management: a meta-analysis. *Biomed Eng OnLine*. 2025;24: 34.
8. Hayati A, et al. Advancing diabetic retinopathy screening: a systematic review of artificial intelligence and optical coherence tomography angiography innovations. *Diagnostics*. 2025;15(6):737.
9. Dejene FM, Debelee TG, Schwenker F, Ayano YM, Feyisa DW. Diabetic retinopathy screening using machine learning: a systematic review. *BMC Biomed Eng*. 2025;7(1):1–34.
10. Jyoti. A comparative analysis of risk prediction models for diabetic retinopathy using machine learning and deep learning. *Int J Intell Syst Appl Eng*. 2024;12(23s):3820–3839.
11. Thanikachalam V, Kabilan K, Erramchetty SK. Optimized deep CNN for detection and classification of diabetic retinopathy and diabetic macular edema. *BMC Med Imaging*. 2024;24(1):1–17.
12. Kumar DR, Mahathy GD, Murthy DG V. Hybrid deep learning framework for accurate diabetic retinopathy classification. *Int J Environ Sci*. 2025;3926–3941.
13. Jabbar A, et al. Deep transfer learning-based automated diabetic retinopathy detection using retinal fundus images in remote areas. *Int J Comput Intell Syst*. 2024;17(1):135.
14. Asia A-O, et al. Detection of diabetic retinopathy in retinal fundus images using CNN classification models. *Electronics*. 2022;11(17):2740.
15. Chilukoti SV, Shan L, Tida VS, Maida AS, Hei X. A reliable diabetic retinopathy grading via transfer learning and ensemble learning with quadratic weighted kappa metric. *BMC Med Inform Decis Mak*. 2024;24(1):37.
16. Okore NE. Bridging the vision gap: Role of AI in diabetic retinopathy detection and clinical feasibility in low resource settings. *Int J Res Innov Appl Sci*. 2025; X(V):632–642.
17. Nadeem MW, Goh HG, Hussain M, Liew S-Y, Andonovic I, Khan MA. Deep learning for diabetic retinopathy analysis: a review, research challenges, and future directions. *Sensors*. 2022;22(18):6780.
18. Huo G. Deep learning models for diabetic retinopathy detection: A review of CNN and transformer-based approaches. 2024.
19. Zaier F, Zribi M, Zribi M. Artificial intelligence for diabetic retinopathy screening: Performance of deep learning models. *Eur J Public Health*. 2025;35(Supplement_4):ckaf161.318.
20. Patil MS, Chickerur S, Abhimalya C, Naik A, Kumari N, Maurya S. Effective deep learning data augmentation techniques for diabetic retinopathy classification. *Procedia Comput Sci*. 2023;218: 1156–1165.

استناد به این مقاله: حسین پور، محمدجواد. (۱۴۰۵). توسعه سامانه مهندسی تشخیص رتینوپاتی دیابتی با ترکیب یادگیری ماشین و مواد زیست سازگار در تصویربرداری شبکه. فصلنامه پیشرفت‌های مهندسی در حوزه‌ی پزشکی و مواد، ۲(۱)، ۶-۲۰.



Journal of Recent Advancements in Material Science and Biomedical Engineering is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.