



Segmentation and Classification of Diabetic Retinopathy from Iris Images Using an Optimized Particle Swarm Algorithm and Deep U-Net Neural Network

Fatemeh Sadeghi*

M.Sc. Student, Department of Engineering
(Biomedical Engineering), Kazerun Branch,
Islamic Azad University, Kazerun, Iran

Omid Mahdiyar

Assistant Professor, Department of Engineering
(Biomedical Engineering), Kazerun Branch,
Islamic Azad University, Kazerun, Iran

Mahdi Taghizadeh

Assistant Professor, Department of Engineering
(Biomedical Engineering), Kazerun Branch,
Islamic Azad University, Kazerun, Iran

Abstract

Diabetes is a highly prevalent disease throughout the world. It is considered the most common cause of blindness among people under the age of 50. Many researchers have confirmed that 90% of diabetic patients can be saved from this disease through early diagnosis. The image dataset considered in this study is MESSIDOR, and the simulation was carried out in the MATLAB environment in four stages. In the first stage, preprocessing is performed with the aim of removing possible noise and standardizing the input dataset. Then, segmentation is carried out. Next, an optimized particle swarm algorithm is used for dimensionality reduction, feature selection, and feature extraction. In this phase, skewness and kurtosis are also employed to achieve better and more optimal feature selection and extraction. The velocity and inertia weight operators in the optimized particle swarm algorithm are considered important factors in identifying the best features. Finally, in order to cluster retinopathy cases, the deep U-Net neural network algorithm is used, which is capable of creating two clusters: diseased and non-diseased. The diseased category itself is further divided into five conditions: Exudate, Microaneurysm, Bleeding, Keratoconjunctivitis, and Keratomalacia. The obtained results indicate that the accuracy of the proposed method is better than that of other methods. The achieved accuracy is 98.24%.

Keywords: segmentation, classification, neural networks, optimized particle swarm algorithm, diabetic retinopathy

Received: 07/June/2026

Accepted: 20/June/2026

eISSN: 3115-7610

ISSN: 3115-7572

* Corresponding Author: f.sadeghi8999@gmail.com

بخش‌بندی و طبقه‌بندی بیماری رتینوپاتی دیابتی از تصاویر عنبیه چشم با استفاده از الگوریتم اژدهام ذرات بهینه و شبکه عصبی عمیق U-Net

فاطمه صادقی*

گروه مهندسی (مهندسی پزشکی)، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

امید مهدی یار

گروه مهندسی (مهندسی پزشکی)، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

مهدی تقی‌زاده

گروه مهندسی (مهندسی پزشکی)، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

چکیده

دیابت بیماری بسیار شایع در سراسر جهان است. این بیماری به‌عنوان رایج‌ترین علت نابینایی برای افرادی که سن آن‌ها کمتر از ۵۰ سال بوده، متداول است. بسیاری از محققان تصدیق کردند که ۹۰٪ از بیماران دیابتی می‌توانند از طریق تشخیص زودرس از این بیماری نجات پیدا کنند. مجموعه داده تصویری مد نظر این تحقیق نیز MESSIDOR است و شبیه‌سازی در محیط MATLAB انجام گرفته و دارای چهار مرحله است. در مرحله نخست، پیش‌پردازش صورت می‌گیرد که با هدف حذف نویز احتمالاتی و استانداردسازی مجموعه داده ورودی است. سپس عملیات تقطیع انجام می‌گیرد. در ادامه از الگوریتم اژدهام ذرات بهینه با هدف کاهش ابعاد، انتخاب و استخراج ویژگی استفاده می‌شود. در این فاز، چولگی و کشیدگی نیز به‌منظور انتخاب و استخراج بهتر و بهینه‌تر ویژگی‌ها وارد عمل می‌شوند. عملگرهای سرعت و اینرسی وزن در الگوریتم اژدهام ذرات بهینه به‌عنوان مسئله‌ای مهم در تشخیص بهترین ویژگی‌ها مد نظر واقع می‌گردد. در انتها به‌منظور خوشه‌بندی رتینوپاتی از الگوریتم شبکه عصبی عمیق U-Net استفاده می‌شود که توانایی ایجاد دو خوشه شامل بیماری و عدم بیماری را دارد. بخش دارای بیماری، خود به ۵ بیماری تقسیم می‌شود: بیماری‌های Microaneurism، Exudate، Keratomalacia و Keratoconjunctivits، Bleeding. نتایج به‌دست آمده نشان می‌دهد که دقت روش ارائه شده نسبت به سایر روش‌ها، دارای عملکرد بهتری است. میزان دقت ۹۸/۲۴٪ است.

کلیدواژه‌ها: بخش‌بندی، طبقه‌بندی، شبکه‌های عصبی، الگوریتم اژدهام ذرات بهینه، رتینوپاتی دیابتی

مقدمه

افزایش شیوع چاقی، سبک زندگی کم‌تحرک شهری و نیز پیر شدن جمعیت، از عوامل اصلی رشد سریع دیابت در جهان و به‌ویژه در کشورهای در حال توسعه مانند ایران هستند؛ به‌گونه‌ای که امروزه بیش از ۲۰۰ میلیون نفر در جهان و حدود ۳ میلیون نفر در ایران به این بیماری مبتلا هستند. دیابت به‌دلیل اختلال در ترشح یا عملکرد انسولین [۱]، موجب افزایش غلظت قندخون و آسیب به مویرگ‌های ظریف بدن می‌شود که ازجمله پیامدهای آن، رتینوپاتی دیابتی است - یکی از مهم‌ترین علل نابینایی در بزرگسالان. این عارضه در دو نوع تکثیری^۱ و غیر تکثیری^۲ بروز یافته و با کنترل دقیق قند و فشارخون می‌توان پیشرفت آن را مهار کرد [۲].

تحقیقات متعددی در حوزه تشخیص خودکار رتینوپاتی دیابتی با استفاده از پردازش تصویر و یادگیری ماشین انجام شده است. روش‌های اولیه شامل استخراج ویژگی چندمقیاسی [۳] و فیلترهای ترکیبی هسین و گابور برای آشکارسازی رگ‌های خونی [۴] بودند. در ادامه، الگوریتم‌های با ناظر مانند شبکه عصبی مصنوعی با بردار ویژگی هفت‌بعدی [۵] و روش‌های بهینه‌سازی نظیر کلونی مورچگان [۶]، دقت استخراج عروق را بهبود بخشیدند. همچنین، تبدیلات موجک چندگانه [۷] و ماشین بردار پشتیبان [۸]، در تحلیل بافتی و طبقه‌بندی تصاویر شبکه‌ای به کار گرفته شدند.

در مطالعات جدیدتر، از الگوریتم K-means برای شناسایی میکروآنوریسم‌ها [۹] و از شبکه‌های عصبی کانولوشنی (CNN) به‌منظور استخراج ویژگی‌های عمیق در مجموعه داده‌های DR1 و MESSIDOR استفاده شده است [۱۰-۱۲]. این پژوهش‌ها، دقتی بین ۸۶ تا ۹۸ درصد در طبقه‌بندی درجات بیماری گزارش کرده‌اند.

در سال‌های اخیر، با پیشرفت یادگیری عمیق، رویکردهای انتقال یادگیری^۳ مبتنی بر معماری‌های AlexNet، GoogLeNet و ResNet50 به‌منظور تشخیص خودکار رتینوپاتی دیابتی از تصاویر شبکه‌ای، به‌ویژه در سیستم‌های تصویربرداری مبتنی بر تلفن هوشمند، توسعه یافته‌اند [۱۳]. مدل پیشنهادی آن مطالعه با استفاده از شبکه ResNet50، به دقت ۹۸/۶٪، حساسیت ۹۸/۲٪ و ویژگی ۹۹/۱٪ دست‌یافته است.

در ادامه، پژوهش‌های [۱۴، ۱۵] با به‌کارگیری یادگیری عمیق هم‌افزا^۴ و شبکه‌های سبک CNN، کارایی بالایی در طبقه‌بندی چندمرحله‌ای رتینوپاتی نشان داده‌اند. افزون بر این، مطالعه‌ی [۱۶] با استفاده از توموگرافی انسجام نوری (OCT) و شبکه عمیق OCTD-Net، امکان تشخیص زودهنگام رتینوپاتی در مراحل اولیه (درجات ۰ و ۱) را با دقت ۹۲٪ و ویژگی ۹۵٪ فراهم کرده است.

در مجموع، مرور پژوهش‌ها نشان می‌دهد تحول از روش‌های کلاسیک مبتنی بر فیلتر و ویژگی‌های هندسی به سمت مدل‌های عمیق و انتقال یادگیری، موجب جهش چشمگیری در دقت و قابلیت اطمینان سیستم‌های تشخیص خودکار رتینوپاتی دیابتی شده است. این پیشرفت‌ها مسیر توسعه‌ی سامانه‌های غربالگری قابل حمل و مقرون‌به‌صرفه را برای کاربردهای بالینی آینده هموار ساخته‌اند.

۱. PDR

۲. NPDR

۳. transfer learning

۴. synergic deep learning

روش تحقیق

در این پژوهش، فرایند پردازش تصاویر رتینوپاتی دیابتی با ورود داده‌های خام به مرحله پیش‌پردازش آغاز می‌شود. در این فاز، ابتدا حذف نویز با استفاده از فیلترهای مناسب (مانند فیلتر میانه یا گاوسی) انجام می‌گیرد تا اثرات نویز تصادفی کاهش یابد. سپس نرمال‌سازی شدت پیکسل‌ها اعمال می‌شود تا دامنه مقادیر پیکسل در محدوده استاندارد قرار گیرد. هم‌ترازسازی هیستوگرام با هدف افزایش کنتراست و بهبود توزیع شدت نور اجرا می‌گردد. فیلتر بالاگذر برای تقویت لبه‌ها و جزئیات ساختاری عروقی به کار گرفته می‌شود و در نهایت، تصحیح چرخش با استفاده از روش‌های مبتنی بر تبدیل هاف یا تحلیل مؤلفه‌های اصلی (PCA) انجام می‌شود تا تصاویر به جهت استاندارد هم‌راستا شوند.

پس از آماده‌سازی، تصاویر وارد مرحله تقطیع تصویر می‌شوند. در این مرحله، با بهره‌گیری از الگوریتم‌های پیشرفته تقسیم‌بندی (مانند آستانه‌گذاری تطبیقی، رشد ناحیه یا روش‌های مبتنی بر گراف)، نواحی معنادار مانند عروق خونی، میکروآنوریسم‌ها، آگزوداها و خون‌ریزی‌ها از زمینه جدا می‌گردند. هدف، ایجاد ماسک‌های دقیق برای هر ساختار پاتولوژیک است.

در مرحله بعد، استخراج ویژگی با الگوریتم بهینه‌سازی ازدحام ذرات (PSO) صورت می‌گیرد. این الگوریتم به‌صورت هم‌زمان سه عملیات کلیدی را انجام می‌دهد: کاهش بُعد داده‌ها با استفاده از تحلیل کواریانس و استخراج بردارهای ویژه، انتخاب بهینه ویژگی‌ها از میان مجموعه ویژگی‌های محلی و جهانی (مانند LBP، GLCM، چولگی، کشیدگی)، بهینه‌سازی جست‌وجوی فضای ویژگی با مکانیزم PSO و وزن‌دهی اینرسی. این مرحله منجر به تولید مجموعه‌ای فشرده، کم‌بُعد و با ارزش تفکیکی بالا از ویژگی‌ها می‌شود که برای طبقه‌بندی دقیق مناسب است.

در فاز نهایی، خوشه‌بندی و تقسیم‌بندی معنایی با معماری U-Net انجام می‌شود. این شبکه عمیق کانولوشنی شامل دو بخش اصلی است:

مسیر انقباضی^۱: با لایه‌های کانولوشن 3×3 و پولینگ ماکزیمم، ابعاد فضایی کاهش و ویژگی‌های سطح بالا استخراج می‌شود.

مسیر انبساطی^۲: با عملیات نمونه‌برداری بالا^۳ و اتصالات پرشی^۴، اطلاعات مکانی با وضوح بالا از لایه‌های اولیه به لایه‌های عمیق منتقل شده و دقت محلی‌سازی حفظ می‌گردد.

U-Net بدون لایه کاملاً متصل و تنها با لایه‌های کانولوشنی و فعال‌سازی ReLU، خروجی نهایی را به‌صورت نقشه تقسیم‌بندی پیکسل‌به‌پیکسل تولید می‌کند. خروجی نهایی سیستم مجموعه‌ای از تصاویر تقطیع‌شده، خوشه‌بندی‌شده و طبقه‌بندی‌شده با دقت بالا که امکان تشخیص خودکار و کمی‌سازی شدت رتینوپاتی دیابتی را فراهم می‌آورد. این فلوچارت، چارچوبی یکپارچه و قابل تکرار برای سیستم‌های هوشمند تشخیص پزشکی مبتنی بر یادگیری عمیق ارائه می‌دهد.

شکل ۱ فرایند کلی برای پردازش و تحلیل تصاویر رتینوپاتی دیابتی را نشان می‌دهد. در این روش، ابتدا تصاویر تحت پیش‌پردازش قرار می‌گیرند که شامل حذف نویز، نرمال‌سازی، معادل‌سازی هیستوگرام، فیلترینگ با گذر بالا و


۱. encoder

۲. decoder


۳. upsampling

۴. skip connections


تصحیح چرخش است. سپس، مرحله‌ای از تقسیم‌بندی تصویر انجام می‌شود که در آن ویژگی‌های مرتبط با تصویر از طریق الگوریتم بهینه‌سازی ازدحامی ذرات (PSO) استخراج می‌گردد. در ادامه، ویژگی‌های استخراج‌شده برای خوشه‌بندی تصاویر با استفاده از معماری U-Net شامل عملیات کانولوشن 3×3 ، لایه‌های تجمیع و اتصالات پرش استفاده می‌شود. در نهایت، تصاویر طبقه‌بندی‌شده و تقسیم‌بندی‌شده به‌عنوان خروجی به‌دست می‌آیند (شکل ۲ و ۳).



شکل ۱. فرایند پیش‌پردازش، استخراج ویژگی و خوشه‌بندی تصاویر رتینوپاتی دیابتی با استفاده از PSO و U-Net



شکل ۲. معماری کلی U-Net



شکل ۳. ساختار U-Net ارائه شده در این تحقیق

با ارائه این روش، عملیات خوشه‌بندی با الگوریتم شبکه عصبی عمیق نیز به‌صورتی بهینه انجام خواهد شد. لازم است تا روش پیشنهادی، شبیه‌سازی شود تا نتایج آن مشاهده گردد و با روش‌های پیشین مقایسه‌ای انجام گیرد.


یافته‌ها

شبیه‌سازی در محیط MATLAB انجام می‌شود. مجموعه‌داده‌های استفاده شده در این تحقیق، Messidor است که به نام داده‌های Messidor <http://www.adcis.net/en/Download-Third-Party/Messidor.html> است که نیاز است تا یک تصویر به‌عنوان ورودی مطرح است و دارای تصاویر شبکه چشم با کیفیت و رزولوشن بالایی است. نیاز است تا یک تصویر به‌عنوان ورودی وارد سیستم شود تا بتوان عملکرد رویکرد پیشنهادی را مشخص و تضمین کرد. تصویر ورودی که بر روی آن پردازش اولیه صورت می‌گیرد به‌صورت شکل ۴ است.




شکل ۴. تصویر ورودی

این تصویر، دارای رگ‌های خونی است که بعضی نواحی این رگ‌ها، همان‌طور که در تصویر نیز مشخص است، به سایر بخش‌های رگ متصل نیست و در واقع بن‌بست می‌شود. در این شرایط، گفته می‌شود که مسدودی رگ خونی وجود دارد و احتمال رشد و افزایش ناحیه رتینوپاتی را افزایش می‌دهد. حال تصویر وارد برنامه می‌شود و قرار است تا ناحیه رتینوپاتی دقیقاً مشخص گردد. در ابتدا بر روی تصویر نرمال‌سازی اولیه صورت می‌گیرد که به صورت دودویی تبدیل و سطح خاکستری در آن نمایان می‌شود، همین‌طور نويزهای اولیه با فیلتر میانه تا جای ممکن کاهش می‌یابد تا بتوان پردازش ساده‌تری را داشت. خروجی آن به صورت شکل ۵ است.




شکل ۵. تصویر نرمال و فیلترگذاری شده به صورت دودویی

در ادامه تقطیع اولیه و ساده‌ای بر روی تصویر ایجاد می‌شود که خروجی آن به صورت شکل ۶ است و در این خروجی، رگ‌ها تا جای ممکن مشخص شده‌اند.



شکل ۶. تقطیع اولیه

تقطیع اولیه بر پایه‌ی ویژگی‌های شدت روشنایی و لبه انجام شده است؛ به‌طوری که نواحی با شدت نور بالاتر، لبه‌های مشخص‌تری دارند و خطوط جداکننده رگ‌ها قابل مشاهده هستند (شکل ۶). این فرایند نشان می‌دهد برخی رگ‌ها به بن‌بست می‌رسند. سپس استخراج ویژگی‌های تصویری براساس نواحی رگ‌های خونی و با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات انجام می‌شود، که بخش اول و دوم آن در شکل‌های ۷ و ۸ نمایش داده شده‌اند.



شکل ۷. نتیجه استخراج ویژگی مبتنی بر الگوریتم ازدحام ذرات بهینه



شکل ۸. نتیجه استخراج ویژگی با استفاده از ازدحام ذرات بهینه

در خروجی شکل‌های ۷ و ۸، رگ‌های خونی تا حد ممکن رشد یافته و نواحی آن‌ها تشخیص داده شده‌اند. ویژگی‌ها براساس چولگی و کشیدگی با الگوریتم ازدحام ذرات بهینه استخراج می‌شوند؛ جمعیت اولیه ذرات، نواحی رگ‌های بدون انتها را شناسایی و واضح‌تر می‌کند (شکل ۷). عملگرهای سرعت و اینرسی وزن معادل چولگی و کشیدگی عمل کرده و باعث بارزتر شدن ویژگی‌ها می‌شوند. ویژگی‌های محلی شامل شدت نور و لبه و ویژگی‌های آماری مرتبط با شناسایی نواحی دارای رتینوپاتی هستند. این فرایند برای تمامی تصاویر مجموعه داده MESSIDOR انجام شده و طبقه‌بندی با الگوریتم شبکه عصبی عمیق U-Net به صورت آماری اعمال شده است (شکل‌های ۹ و ۱۰).

```

Command Window
New to MATLAB? See resources for Getting Started.
case with ID : 89143601 True Positive (Have Retinopathy)
case with ID : 89143602 True Positive (Have Retinopathy)
case with ID : 8915 Exudate
case with ID : 891670 True Positive (Have Retinopathy)
case with ID : 891703 True Positive (Have Retinopathy)
case with ID : 891716 True Positive (Have Retinopathy)
case with ID : 891923 True Positive (Have Retinopathy)
case with ID : 891936 True Positive (Have Retinopathy)
case with ID : 892189 Microaneurysm
case with ID : 892214 True Positive (Have Retinopathy)
case with ID : 892399 True Positive (Have Retinopathy)
case with ID : 892438 True Negative (Have not Retinopathy)
case with ID : 892604 True Positive (Have Retinopathy)
case with ID : 89263202 True Negative (Have not Retinopathy)
case with ID : 892657 True Positive (Have Retinopathy)
case with ID : 89296 True Positive (Have Retinopathy)
case with ID : 893061 True Positive (Have Retinopathy)
case with ID : 89344 True Positive (Have Retinopathy)
fx case with ID : 89346 True Positive (Have Retinopathy)

```

شکل ۹. نمونه‌ای از بخش خوشه‌بندی با استفاده از الگوریتم شبکه عصبی عمیق U-Net به صورت تحلیل آماری

```

Command Window
New to MATLAB? See resources for Getting Started.
Case with ID : 8712064 True Positive (Have Retinopathy)
case with ID : 8712289 True Negative (Have not Retinopathy)
case with ID : 8712291 Exudate
case with ID : 87127 True Positive (Have Retinopathy)
case with ID : 8712729 True Negative (Have not Retinopathy)
case with ID : 8712766 True Negative (Have not Retinopathy)
case with ID : 8712853 Exudate
case with ID : 87139402 True Positive (Have Retinopathy)
case with ID : 87163 Microaneurysm
case with ID : 87164 True Negative (Have not Retinopathy)
case with ID : 871641 True Positive (Have Retinopathy)
case with ID : 871642 True Positive (Have Retinopathy)
case with ID : 872113 True Positive (Have Retinopathy)
case with ID : 872608 True Positive (Have Retinopathy)
case with ID : 87281702 True Negative (Have not Retinopathy)
case with ID : 873357 True Positive (Have Retinopathy)
case with ID : 873586 True Positive (Have Retinopathy)
case with ID : 873592 True Negative (Have not Retinopathy)
fx case with ID : 873593 True Negative (Have not Retinopathy)


```

شکل ۱۰. نمونه‌ای از بخش خوشه‌بندی با استفاده از الگوریتم شبکه عصبی عمیق U-Net به صورت تحلیل آماری

در تحلیل آماری بخش خوشه‌بندی، ویژگی‌های هر بیمار به طور دقیق مشخص می‌شود تا وضعیت رتینوپاتی آن‌ها تعیین گردد. برای این منظور، از خوشه‌بندی آموزش محور با روش K-Fold استفاده شده که ۶۵٪ داده‌ها برای آموزش و ۳۵٪ برای آزمون اختصاص یافته‌اند. همان‌طور که در شکل‌های ۱۰ و ۱۱ مشاهده می‌شود، هر تصویر به یک بیمار اختصاص یافته و خوشه‌بندی روی آن انجام شده است.


خوشه‌بندی مبتنی بر شبکه عصبی عمیق U-Net شامل دو خوشه اصلی است: عدم بیماری و دارای بیماری. خوشه دارای بیماری به پنج نوع رتینوپاتی تقسیم می‌شود: Bleeding، Microaneurism، Exudate، Keratomalacia و Keratoconjunctivitis. MATLAB نشان می‌دهد که بیمار با شناسه ۸۹۱۴۳۶۰۲ در شکل ۸ در مرحله اولیه بیماری قرار دارد، بیمار با شناسه ۸۹۱۵ دارای نوع Exudate و بیمار با شناسه ۸۷۱۶۳ در شکل ۹ دارای Microaneurism است، درحالی‌که بیمار با شناسه ۸۷۲۸۱۷۰۲ فاقد بیماری است.

شکل ۱۱ نتایج عوامل اصلی و ویژگی‌های تأثیرگذار در هر نوع بیماری را نمایش می‌دهد و نشان می‌دهد که مهم‌ترین عوامل قبل و بعد از خوشه‌بندی، چگونه تعیین شده‌اند.



شکل ۱۱. نتایج عامل‌های تأثیرگذار و بیماری‌هایی که ویژگی‌های آن بیشتر استخراج شده است.


در شکل ۱۱، به‌طور کامل واضح است که نمودار قرمز رنگ که همان Microaneurism است، دارای ویژگی‌های استخراج شده بیشتری نسبت به سایر عوامل و بیماری‌های تأثیرگذار در دیابت رتینوپاتی چشم است. اما بعد از خوشه‌بندی مبتنی بر شبکه عصبی عمیق U-Net، می‌بایست این عامل‌های تأثیرگذار را مشخص کرد که خروجی آن به‌صورت شکل ۱۲، است.



شکل ۱۲. نتایج عامل‌های تأثیرگذار و بیماری‌هایی که خوشه‌بندی شده‌اند.


نتایج در شکل ۱۲، حاکی از آن است که عوامل و ویژگی‌های بسیار وجود دارد که می‌تواند منجر به دیابت رتینوپاتی گردد. اما مهم‌ترین عوامل و تشخیص‌ها در خوشه‌بندی مربوط به حالت بیماری Exudate با نمودار آبی رنگ، سپس Microaneurism با نمودار قرمز رنگ، سپس Keratomalacia با نمودار سبز رنگ، در ادامه

Bleeding با نمودار نارنجی و سپس Keratoconjunctivitis با نمودار بنفش رنگ است. نمودارهای دیگر نیز برای سایر حالت در ویژگی‌های دیگر این بیماری است که مد نظر این تحقیق نیست، اما نتایج آن نشان داده شده است. معیار ناحیه زیر منحنی برای نمایش سطح تشخیص به صورت تابع زیر منحنی در شکل ۱۳، نمایش داده شده است.



شکل ۱۳. معیار ناحیه زیر منحنی برای نمایش سطح تشخیص به صورت تابع زیر منحنی

براساس شکل ۱۳، نشان داده شده است که بازه بزرگی از خوشه‌بندی در حالت کمینه و بیشینه‌سازی در تصاویر، طبقه‌بندی شده است و سایر بخش‌هایی که طبقه‌بندی نشده‌اند، احتمالاً به دلیل عدم استخراج ویژگی‌های صحیح بوده است. بنابراین، می‌توان نموداری برای نرخ تشخیص بیماری‌های تأثیرگذار در رتینوپاتی دیابتی ترسیم کرد که خروجی آن به صورت شکل ۱۴، است.



شکل ۱۴. برای نرخ تشخیص بیماری‌های تأثیرگذار در رتینوپاتی دیابتی

به‌وضوح می‌توان دید که نرخ تشخیص در Keratoconjunctivitis با نمودار سبز رنگ به‌شدت سخت بوده است. همین‌طور Exudate با نمودار صورتی و سپس Bleeding با نمودار قرمز در نهایت و ساده‌ترین تشخیص در Microaneurism با نمودار آبی بوده است که نتایج خوشه‌بندی نیز این را نشان می‌دهد. نتایج معیارهای ارزیابی در این تحقیق بر روی ۱۰۰ تصویر انجام گرفته است و خروجی‌های شکل ۷، الی ۱۳، بر روی آن‌ها انجام گرفته است و نتایج حاصل شده است. معیارهای ارزیابی آن‌ها نیز به‌صورت میانگین کامل در خروجی‌ها برای تمامی تصاویر با رویکرد پیشنهادی به‌صورت جدول ۱ است.


جدول ۱. نتایج معیارهای ارزیابی رویکرد پیشنهادی

۰/۳	میانگین مربعات خطا
۱۴/۷۷ dB	نسبت سیگنال به نویز (dB)
۳۳/۳۵ dB	اوج نسبت سیگنال به نویز (dB)
٪ ۹۸/۲۴	دقت (٪)
٪ ۸۴	حساسیت (٪)
٪ ۸۸/۹۶	نرخ ویژگی‌ها (٪)
٪ ۹۰	فراخوان (٪)

حال می‌توان مقایسه‌ای موردی با مقالات دیگری انجام داد که از مجموعه داده MESSIDOR استفاده کرده‌اند و در شرایط یکسان این کار انجام گرفته است، اما مسلماً روش‌ها و الگوریتم‌های تشخیص رتینوپاتی در آن‌ها متفاوت بوده است. جدول ۲ و شکل ۱۵، نتایج مقایسه رویکرد پیشنهادی با رویکردهای پیشین را نمایش می‌دهد.

جدول ۲. نتایج مقایسه رویکرد پیشنهادی با رویکردهای پیشین [۱۷-۲۱]

مقاله مرجع	دقت (٪)	حساسیت (٪)	نرخ ویژگی‌ها (٪)
Siddalingaswamy P. C., and GopalakrishnaPrabhu K., 2010	٪ ۹۵/۴۱	٪ ۸۶/۴۷	٪ ۹۶
Joes Staal, et al., 2004	٪ ۹۴/۰۷	-	-
Diego Marín, et al., 2011	٪ ۹۵/۲۶	٪ ۶۹/۴۴	٪ ۹۸/۱۹
Akbar Shahzad, et al., 2018	٪ ۹۵/۱۰	٪ ۹۴	٪ ۹۵
Pranjali Kokare, 2017	٪ ۹۲	٪ ۸۶/۶۷	٪ ۸۳/۰۵
Xiaogang Li, et al., 2018	٪ ۹۲/۰۱	٪ ۸۶/۰۳	٪ ۹۷/۱۱
رویکرد پیشنهادی این تحقیق	٪ ۹۸/۲۴	٪ ۸۴	٪ ۸۸/۹۶



شکل ۱۵. نتایج مقایسه رویکرد پیشنهادی با رویکردهای پیشین

به این ترتیب، نشان داده شد رویکرد پیشنهادی، یک روش ترکیبی مبتنی بر فیلترگذاری اولیه برای بخش نرمال‌سازی و پیش‌پردازش است و همین‌طور مرحله تقطیع، در ادامه آن منجر به استخراج ویژگی با رویکرد الگوریتم ازدحام ذرات بهینه با ابعاد بالا با استفاده از چولگی و کشیدگی است. در ادامه و انتها نیز خوشه‌بندی با الگوریتم شبکه عصبی عمیق U-Net، توانایی بالایی در تشخیص بیماری رتینوپاتی دیابتی از مجموعه تصاویر MESSIDOR نسبت به تحقیقات مشابه را نشان می‌دهد.

نتیجه‌گیری

با توجه به افزایش روزافزون دیابت و عوارض ناشی از آن، شناسایی زودهنگام رتینوپاتی دیابتی اهمیت ویژه‌ای دارد، زیرا این بیماری می‌تواند به کاهش بینایی و حتی نابینایی منجر شود. علائم اولیه رتینوپاتی شامل هموری‌ها و میکروآنوریزم‌ها در شبکه چشم هستند و تشخیص به موقع آن‌ها می‌تواند از پیشرفت بیماری جلوگیری کند. پردازش تصویر و بینایی ماشین با بهره‌گیری از الگوریتم‌های یادگیری ماشین، امکان تشخیص خودکار و دقیق این بیماری را فراهم می‌آورند.

در این پژوهش، روش نوینی برای شناسایی و تشخیص رتینوپاتی دیابتی با استفاده از مجموعه داده تصویری MESSIDOR و شبیه‌سازی در MATLAB ارائه شده است. این روش شامل چهار مرحله اصلی است: پیش‌پردازش تصاویر به منظور حذف نویز و استانداردسازی اندازه، تقطیع نواحی مورد نظر، استخراج ویژگی با الگوریتم ازدحام ذرات بهینه (PSO) که شامل کاهش ابعاد، انتخاب ویژگی و بهینه‌سازی با استفاده از چولگی و کشیدگی و عملگرهای سرعت و اینرسی وزن است و در نهایت خوشه‌بندی با شبکه عصبی عمیق U-Net. در این خوشه‌بندی دو گروه اصلی «بیماری» و «عدم بیماری» ایجاد شده است و گروه بیماران به پنج نوع رتینوپاتی شامل

Keratomalacia و Keratoconjunctivitis، Bleeding، Microaneurism، Exudate و یک حالت اولیه ساده تقسیم شده است. نتایج به‌دست‌آمده نشان می‌دهند که روش ارائه‌شده با دقت ۹۸/۲۴٪ نسبت به سایر روش‌ها عملکرد بهتری دارد و قادر است رتینوپاتی دیابتی را به‌صورت خودکار و مؤثر شناسایی کند، که این امر امکان پیشگیری از آسیب‌های جدی بینایی و بهبود مدیریت بیماری را فراهم می‌آورد.

منابع

- Kayal D, Banerjee S. A new dynamic thresholding based technique for detection of hard exudates in digital retinal fundus image. In: Proc 1st Int Conf Signal Processing and Integrated Networks (SPIN); 2014. p. 141-4.
- Agurto C, Murray V, Barriga E. Multi-scale AM-FM methods for diabetic retinopathy lesion detection. IEEE Trans Med Imaging. 2010;29(2):502-12.
- Chang HW, Agam G, Stanchev P. A hybrid filtering approach to retinal vessel segmentation. 2007. p. 604-7.
- Siddalingaswamy PC, Gopalakrishna Prabhu K. Automatic detection of multiple oriented blood vessels in retinal images. J Biomed Sci Eng. 2010;3(1).
- Marín D, Aquino A, Gegúndez-Arias ME, Bravo JM. A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features. IEEE Trans Med Imaging. 2011;30(1):146-58.
- Asad AH, Azar AT, Hassanien AE. Ant colony based feature selection heuristics for retinal vessel segmentation. 2014.
- Marín D, Aquino A, Gegúndez-Arias ME, Bravo JM. A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features. IEEE Trans Med Imaging. 2011;30(1):146-58.
- Asad AH, Azar AT, El-Bendary N, Hassanien AE. Ant colony based feature selection heuristics for retinal vessel segmentation. In: Proc Federated Conf Comput Sci Inf Syst; 2014. p. 199-205.
- Staal J, Niemeijer M, Viergever MA, van Ginneken B. Ridge-based vessel segmentation in color images of the retina. IEEE Trans Med Imaging. 2004;23(4).
- ایمانی س، پوررضاح، بنایی ت. طراحی سیستم خودکار تشخیص رتینوپاتی دیابتی با قابلیت ارزیابی کیفیت تصاویر شبکه‌ای [پایان‌نامه کارشناسی ارشد]. مشهد: دانشگاه فردوسی مشهد، دانشکده مهندسی، گروه کامپیوتر؛ ۱۳۹۳.
- ناصری ا، پویان ع، کاویان ن. تحلیل تصاویر OCT شبکه‌ای به منظور تشخیص اتوماتیک رتینوپاتی دیابتی [پایان‌نامه کارشناسی ارشد]. شاهرود: دانشگاه صنعتی شاهرود، دانشکده مهندسی، گروه کامپیوتر-هوش مصنوعی؛ ۱۳۸۹.
- Javeria A, Sharif M, Mussarat Y, Hussam A, Fernandes SL. A method for the detection and classification of diabetic retinopathy using structural predictors of bright lesions. J Comput Sci. 2017.
- Campbell J, Peter R, Michael C, Lore E, Tian P, Ostmo S, et al. Diagnostic discrepancies in retinopathy of prematurity classification. Ophthalmology. 2016;123(8):1795-801.
- Chandran A, Nisha KK, Vineetha S. Computer aided approach for proliferative diabetic retinopathy detection in color retinal images. In: IEEE Int Conf Next Generation Intelligent Systems (ICNGIS); 2017.
- Manoj Kumar SB, Sheshadri HS. Classification and detection of diabetic retinopathy using K-means algorithm. In: IEEE Int Conf Electrical, Electronics, and Optimization Techniques (ICEEOT); 2016.
- Li X, Pang T, Xiong B. Convolutional neural networks based transfer learning for diabetic retinopathy fundus image classification. In: 10th Int Congr Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI); Shanghai, China; 2018.
- Kokare P. Wavelet based automatic exudates detection in diabetic retinopathy. In: Int Conf Wireless Communications, Signal Processing and Networking (WiSPNET); Chennai, India; 2018.
- Shahzad A, Usman M, Sharif M, Tariq A, Yasin UU. Arteriovenous ratio and papilledema based hybrid decision support system for detection and grading of hypertensive retinopathy. Comput Methods Programs Biomed. 2018.
- Hacisoftaoglu RE, Karakaya M, Sallam AB. Deep learning frameworks for diabetic retinopathy detection with smartphone-based retinal imaging systems. Pattern Recognit Lett. 2020;135:409-17.

20. Shankar K, Wahab Sait AR, Gupta D, Pandey HM. Automated detection and classification of fundus diabetic retinopathy images using synergic deep learning model. Pattern Recognit Lett. 2020;133:210-6.
21. Li X, Shen L, Shen M, Qiu Connor S. Deep learning based early stage diabetic retinopathy detection using optical coherence tomography. Neurocomputing. 2019;369:134-44.

استناد به این مقاله: صادقی، فاطمه، مهدی یار، امید، و تقی‌زاده، مهدی. (۱۴۰۵). بخش‌بندی و طبقه‌بندی بیماری رتینوپاتی دیابتی از تصاویر عنبیه چشم با استفاده از الگوریتم ازدحام ذرات بهینه و شبکه عصبی عمیق U-Net. فصلنامه پیشرفت‌های مهندسی در حوزه‌ی پزشکی و مواد، ۲(۱)، ۶۹-۸۳.



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